

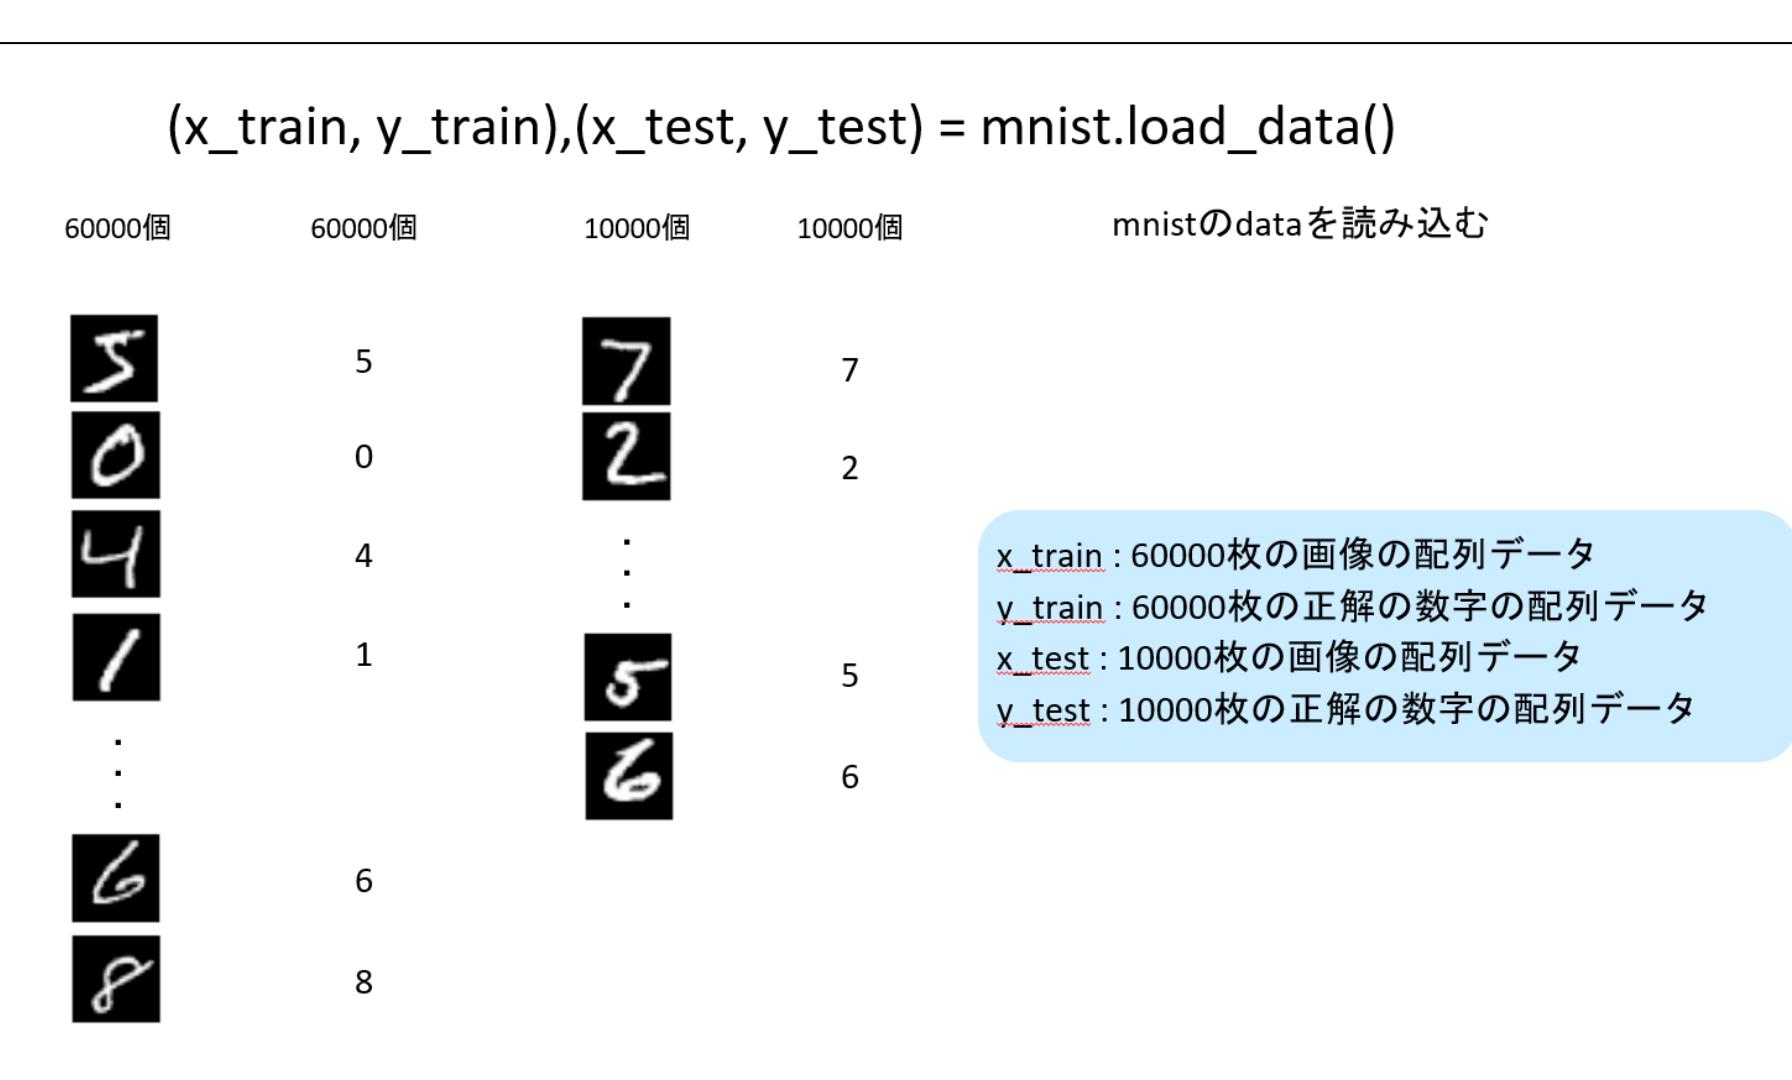
医療とAI・ビッグデータ応用

④MLP

統合教育機構
須藤毅顕

前回までの復習

データを読み込む



```
print(x_train.shape)  
print(y_train.shape)  
print(x_test.shape)  
print(y_test.shape)
```

```
(60000, 28, 28)  
(60000, )  
(10000, 28, 28)  
(10000, )
```

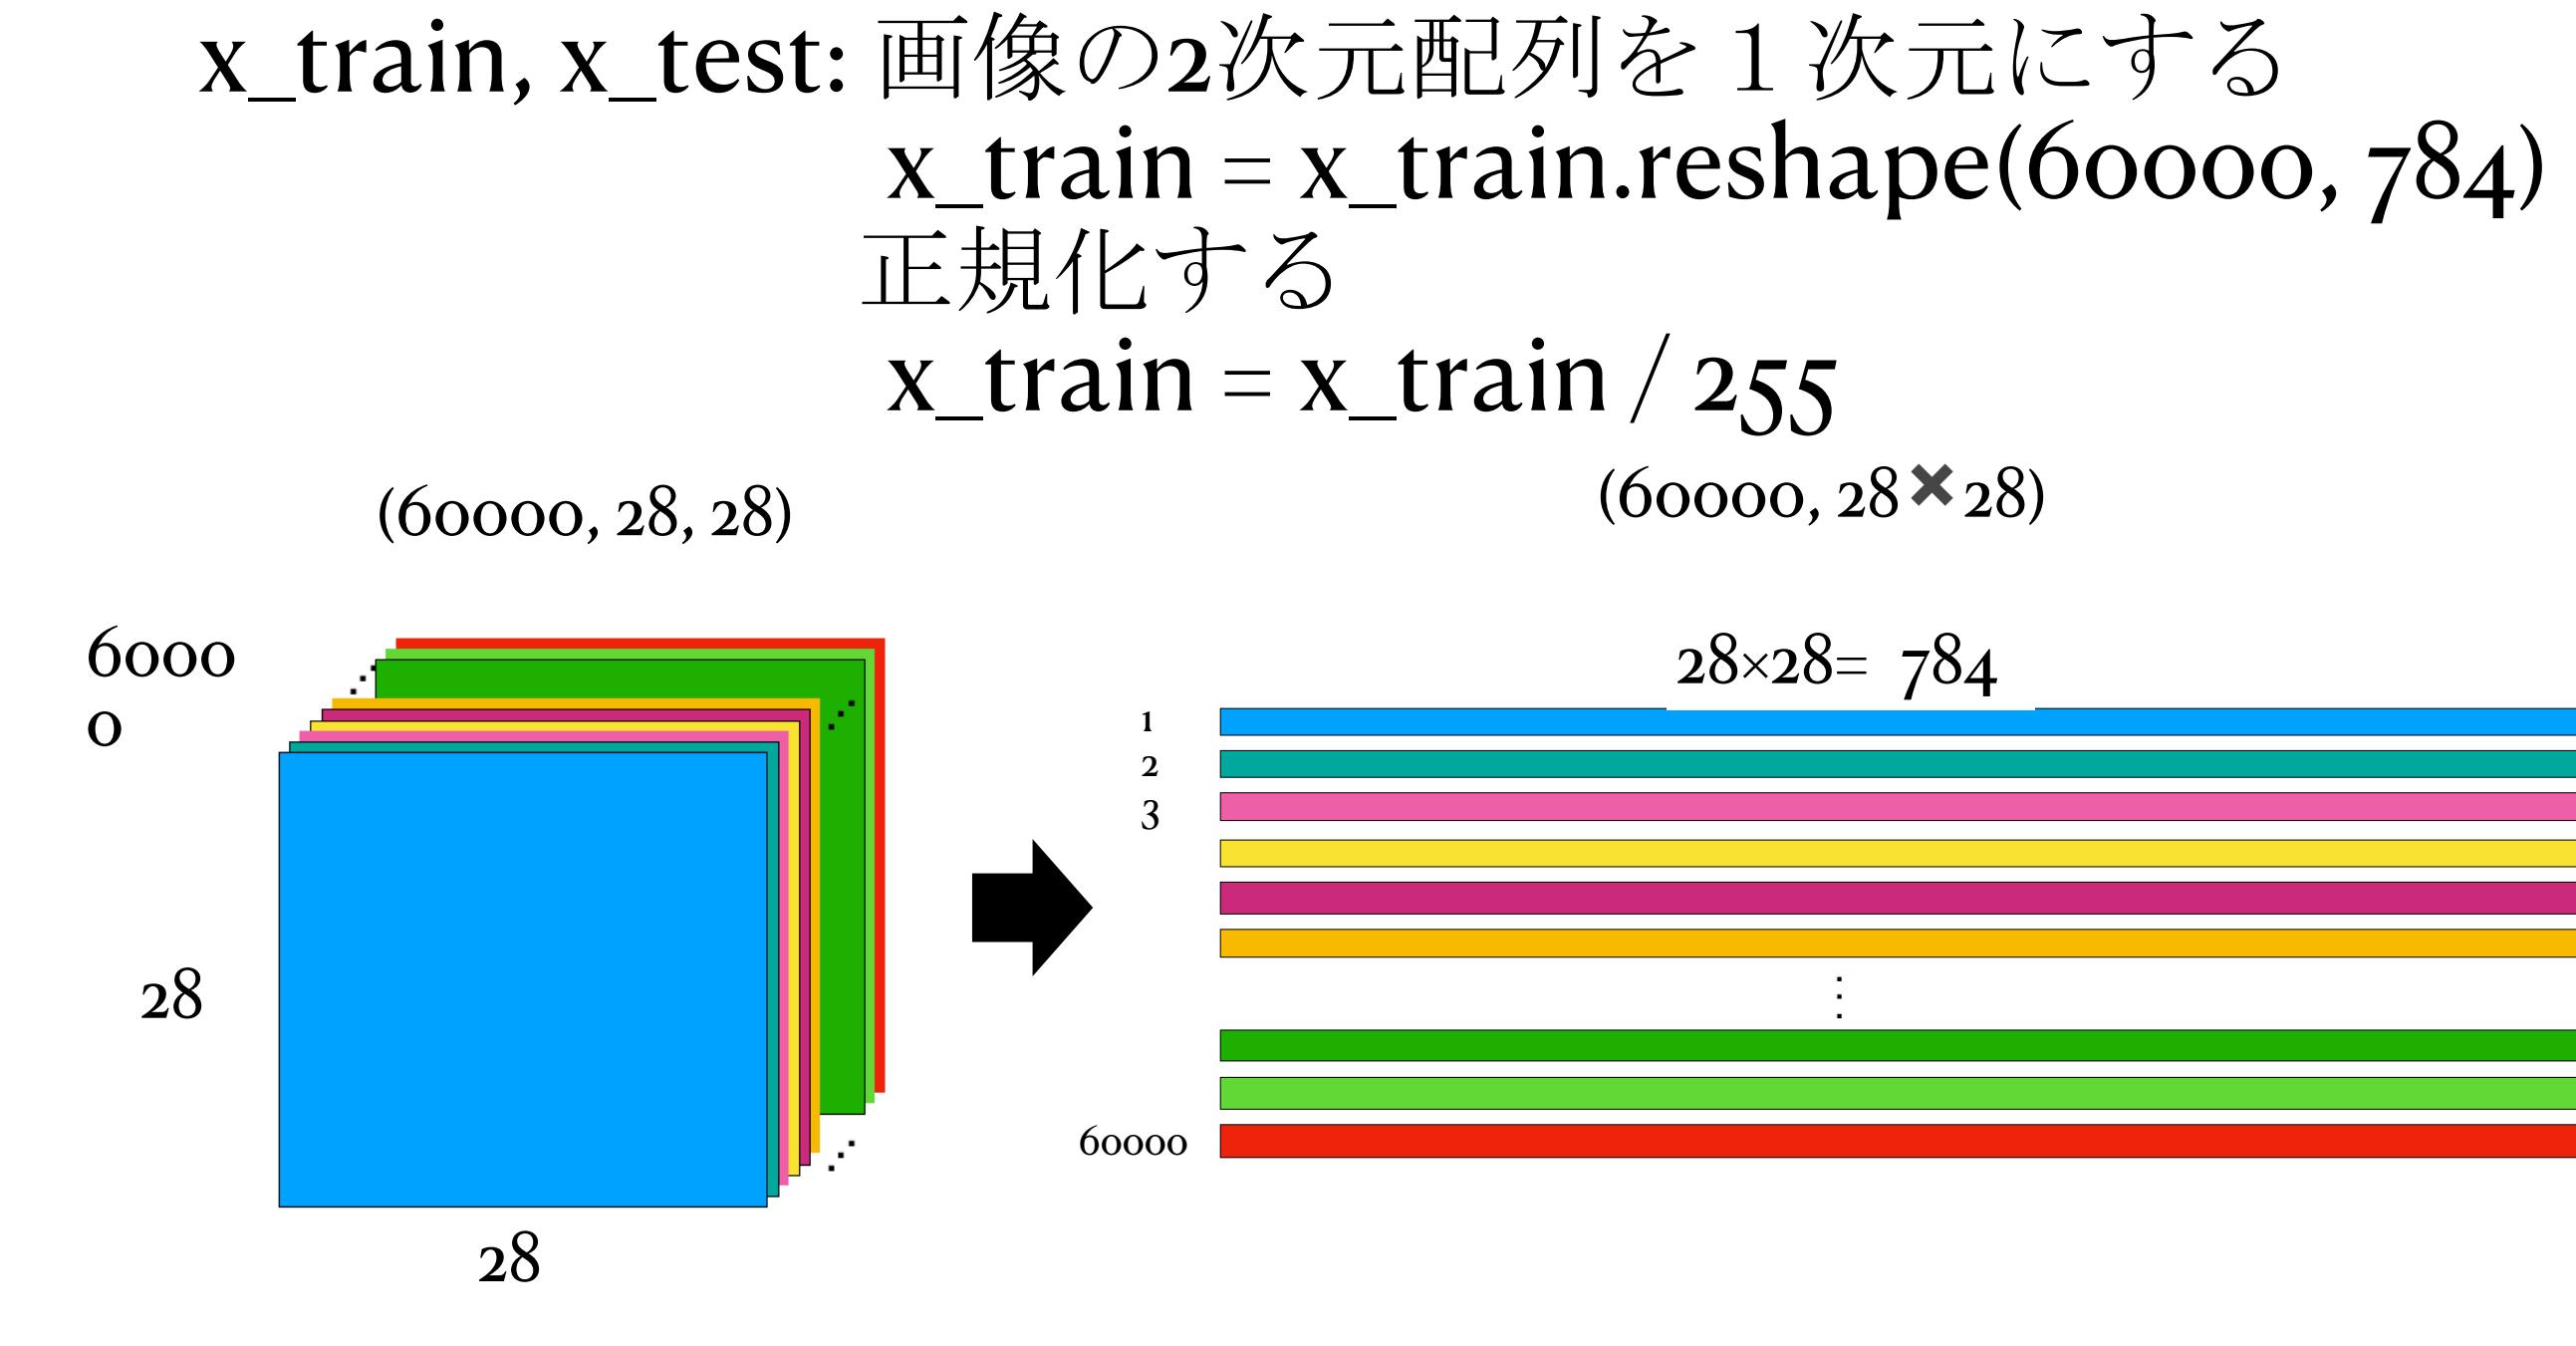
```
print(x_train.shape)  
print(x_test.shape)
```

(60000, 784)
(10000, 784)

```
print(y_train.shape)  
print(y_test.shape)
```

(60000, 10)
(10000, 10)

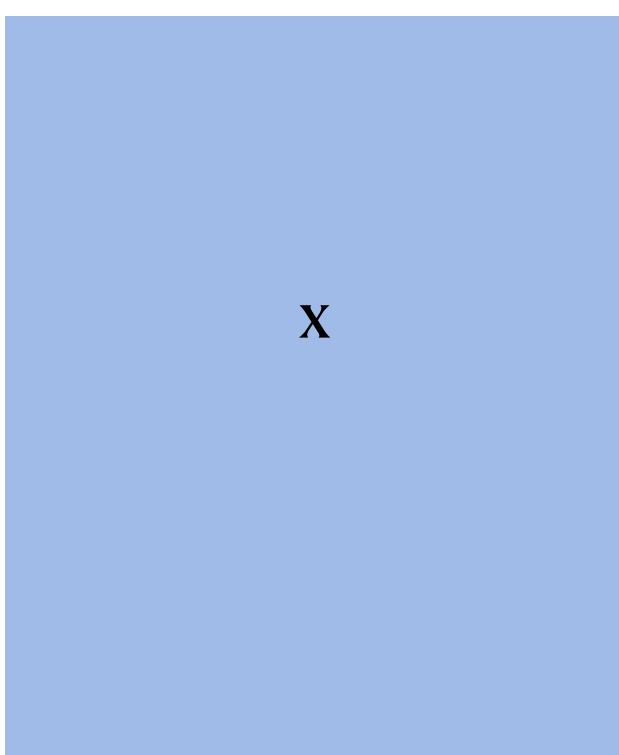
データを加工する



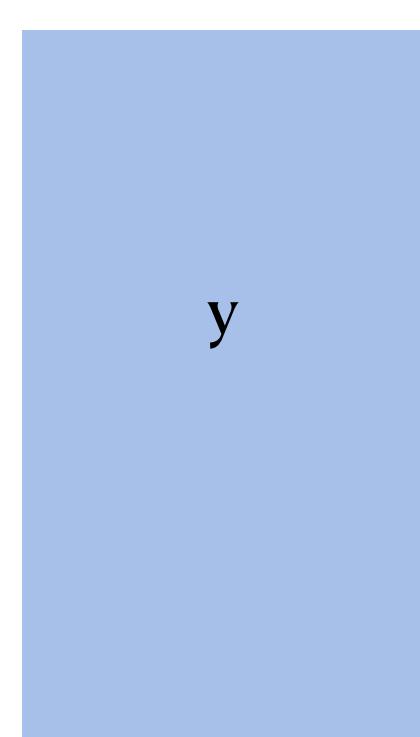
深層学習(教師あり機械学習)の復習

データを用意する

x(特徴量データ)



y(正解データ)

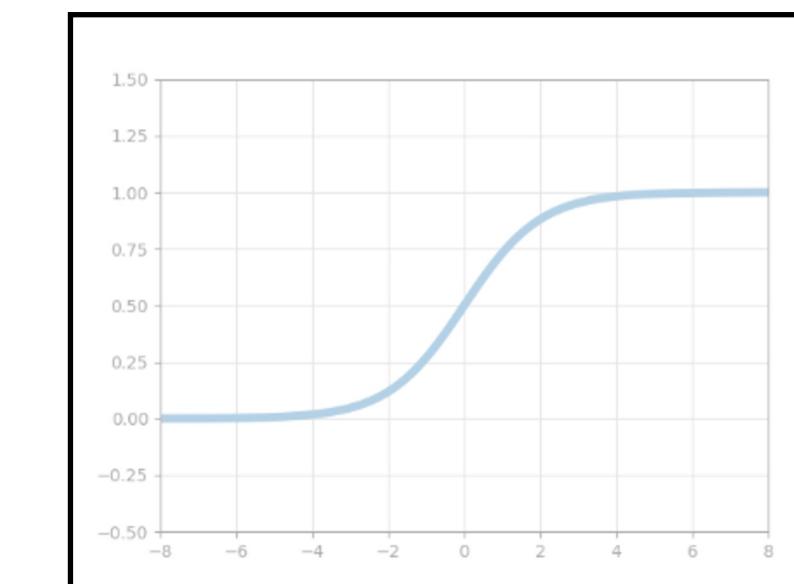


データを配列に整える

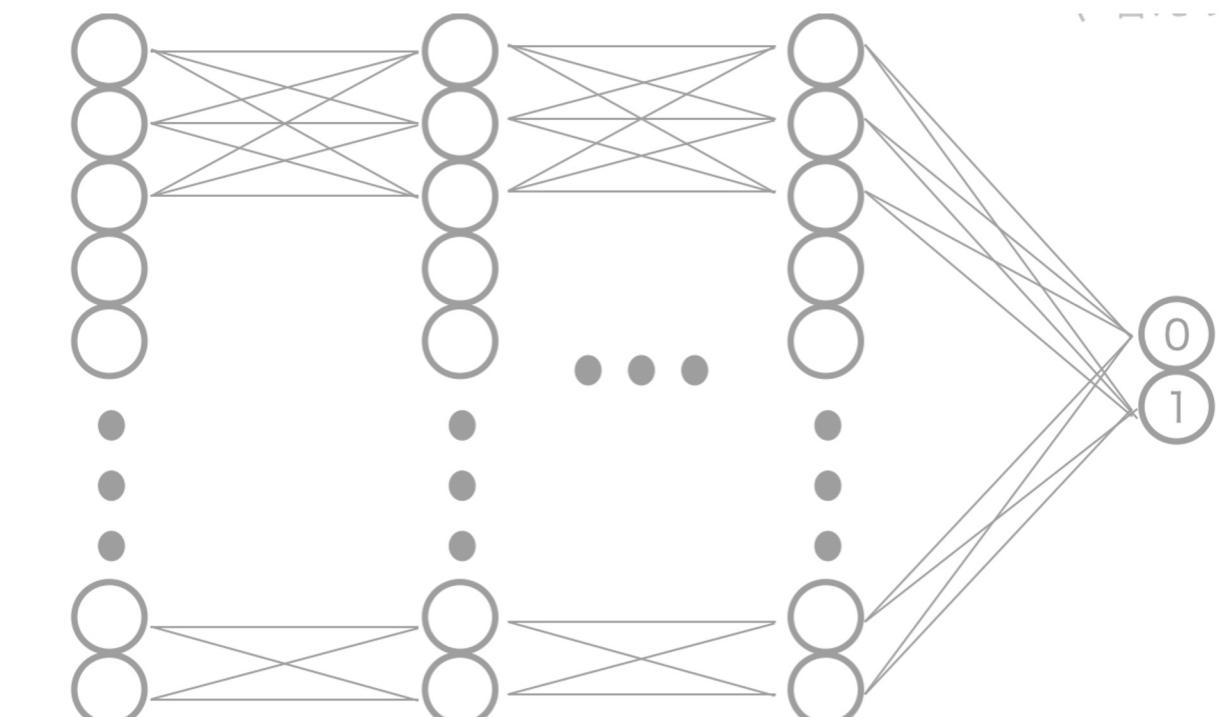


学習させる

ロジスティック回帰分析

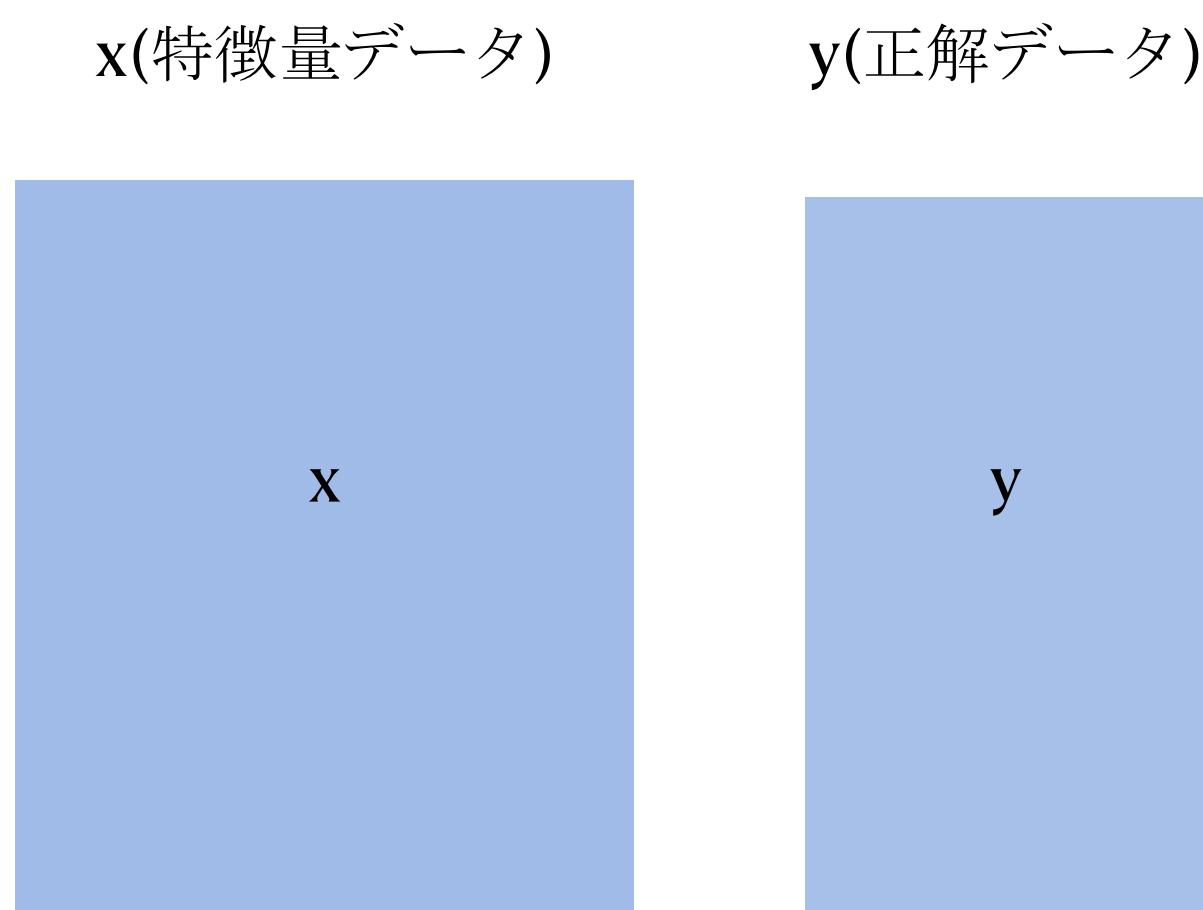


ニューラルネットワーク



深層学習(教師あり機械学習)の復習

データを用意する

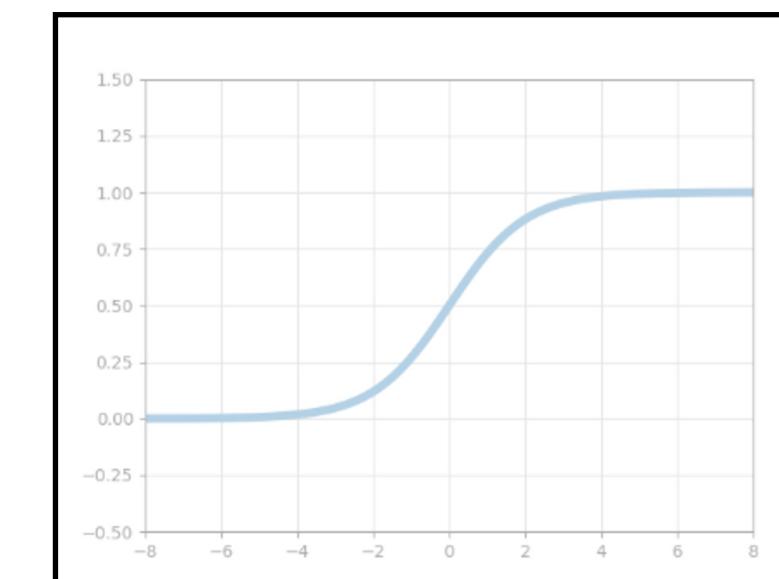


データを配列に整える

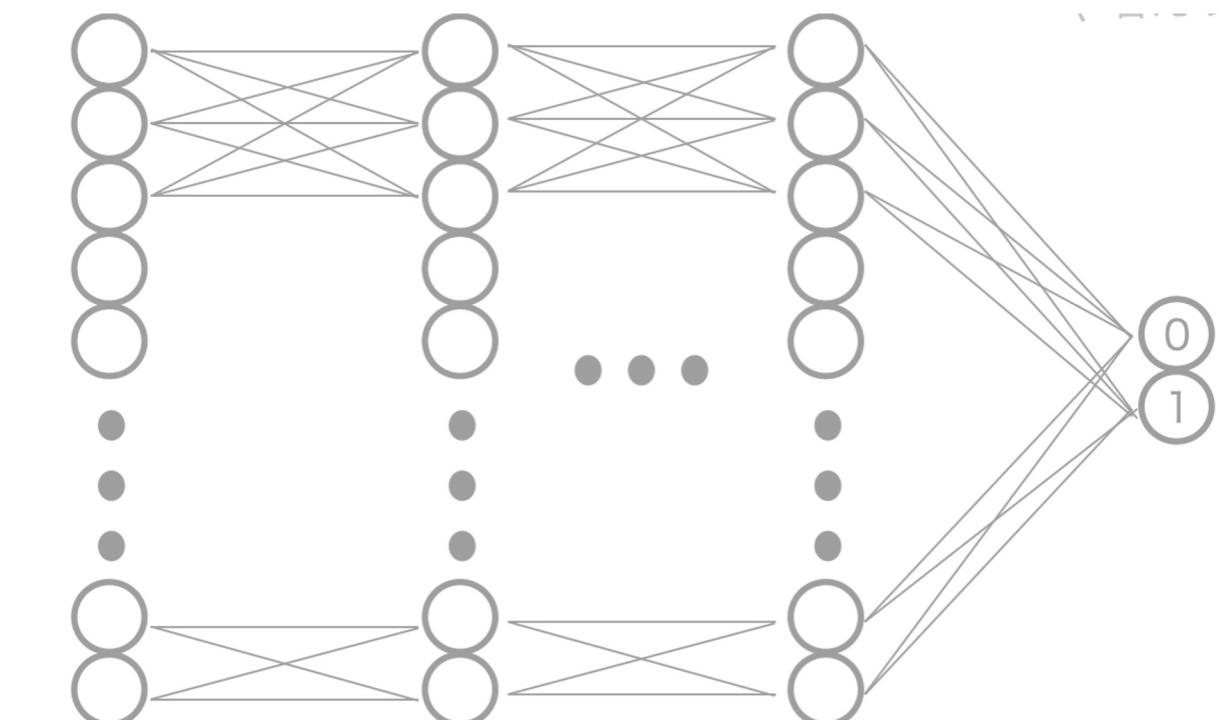


学習させる

ロジスティック回帰分析

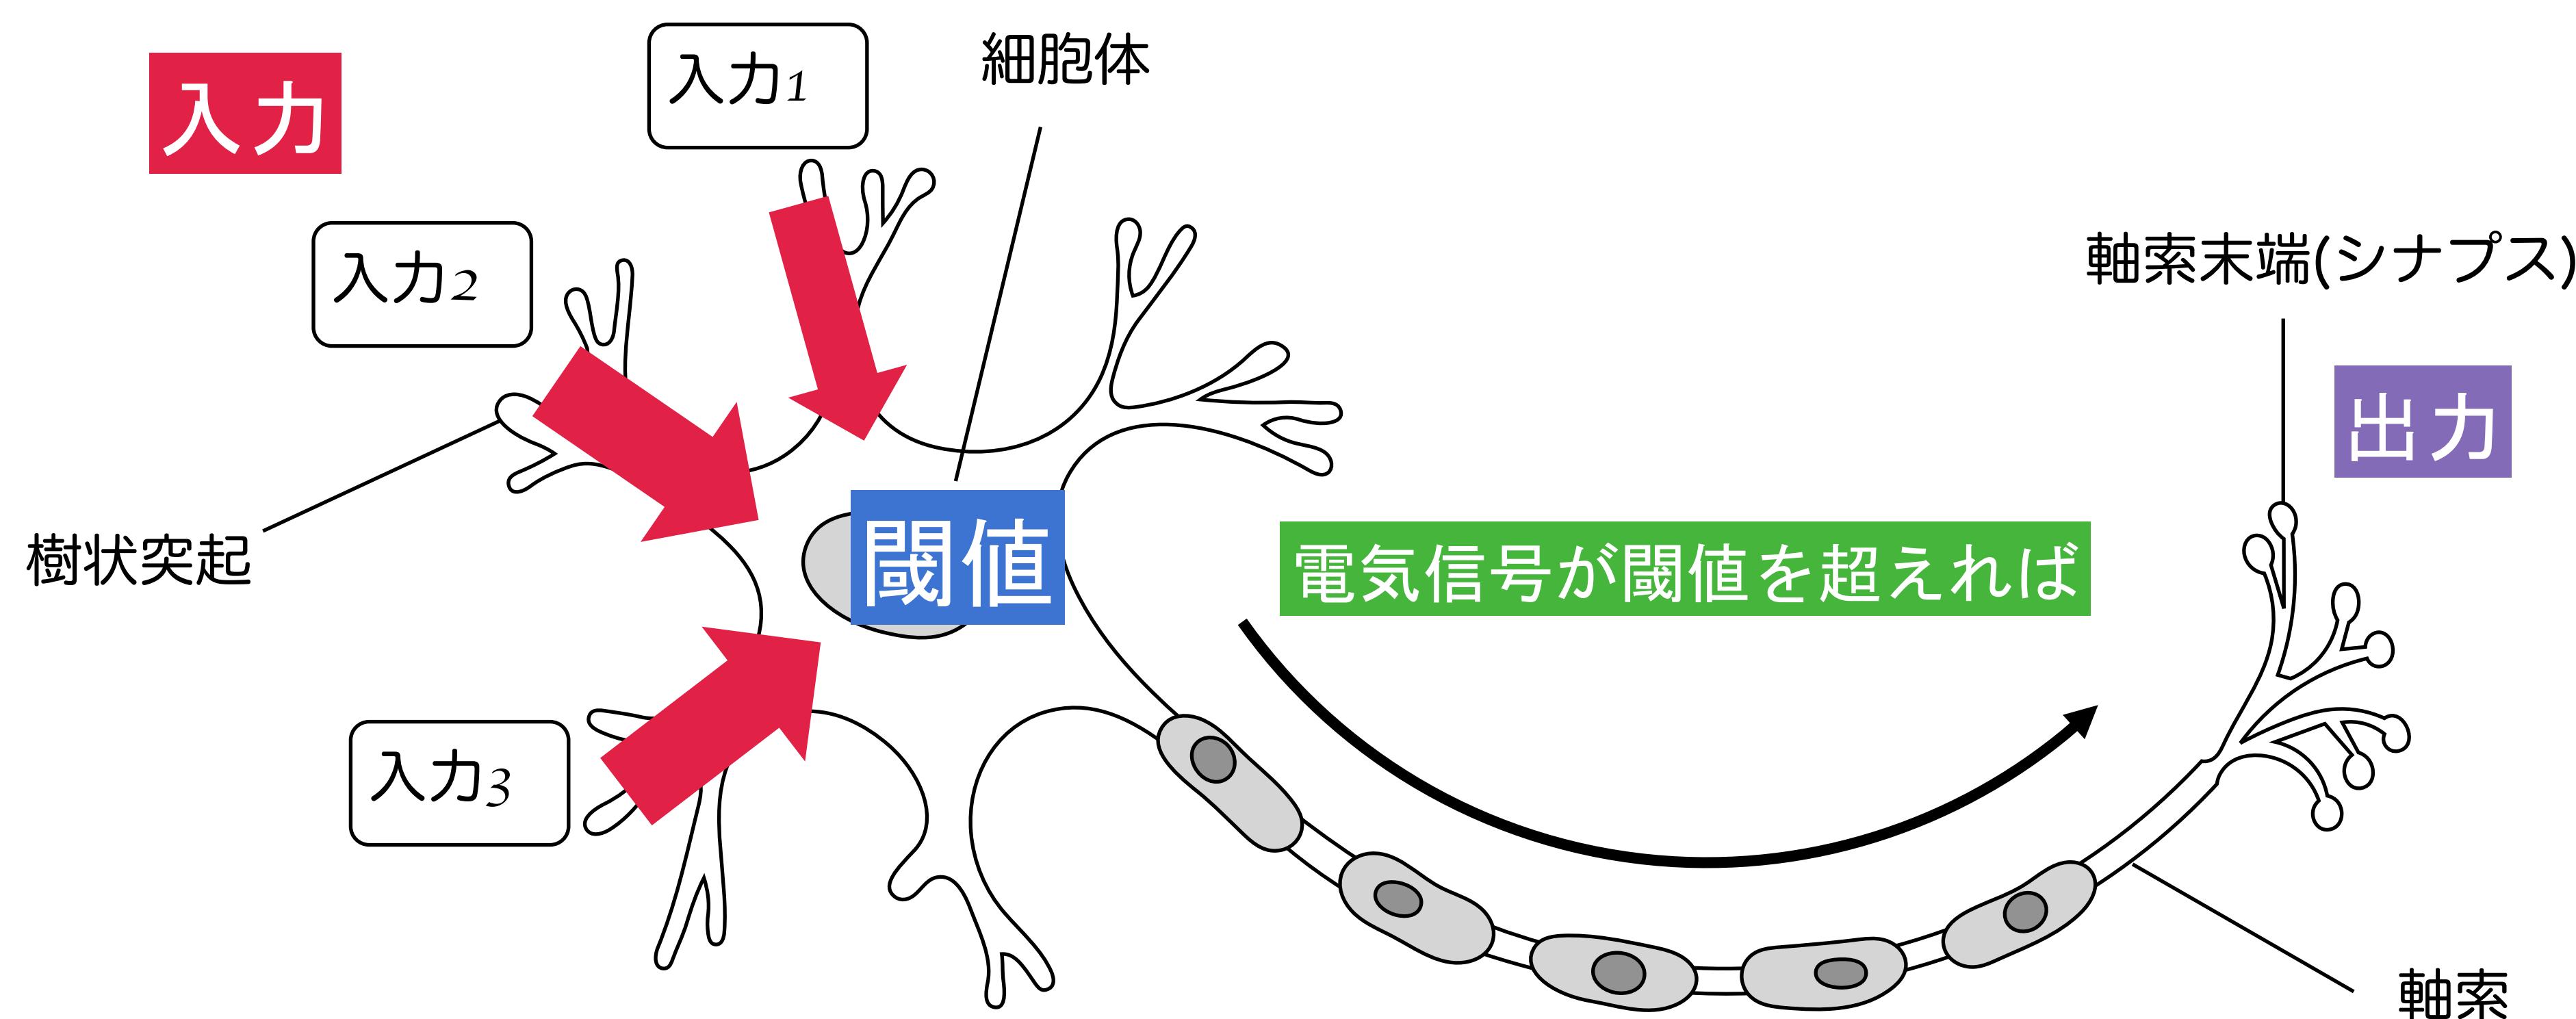


ニューラルネットワーク



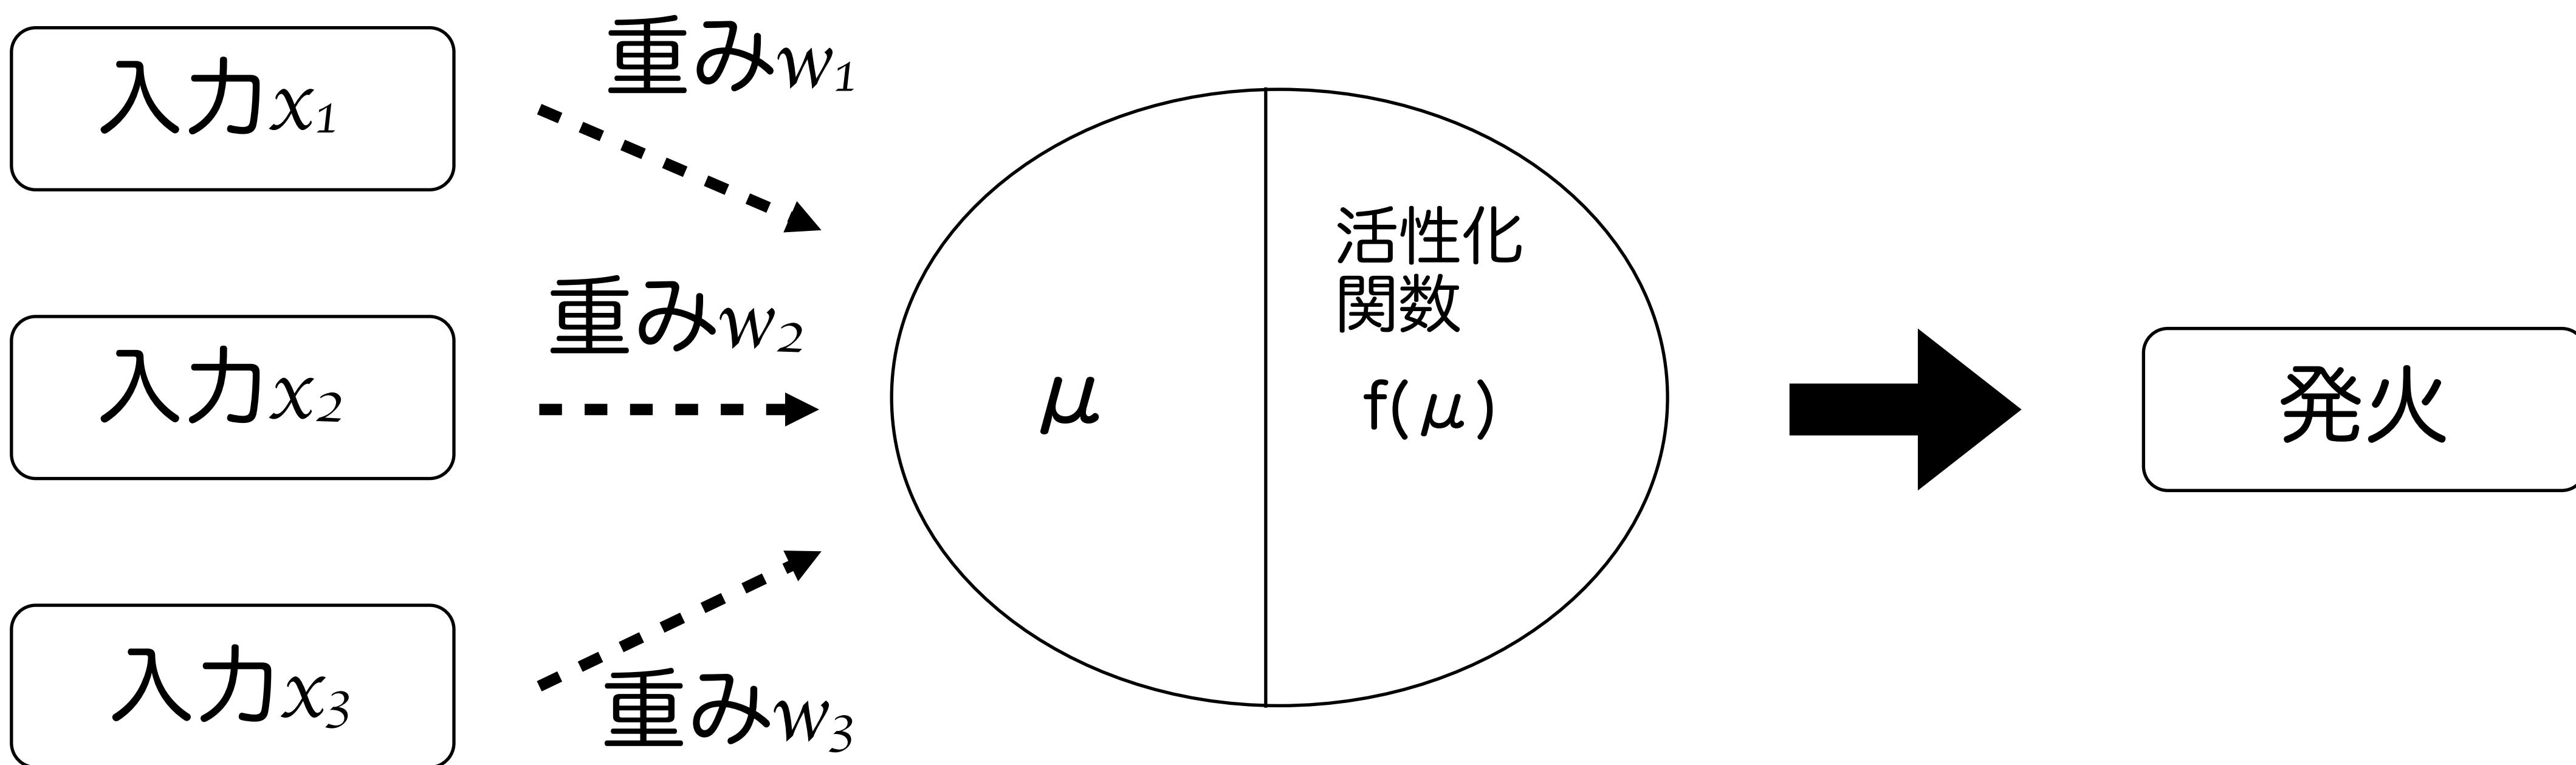
ニューロンとパーセプトロン

- ・ニューロンは、**樹状突起**、**細胞体**、**軸索**からなる
- ・ニューロンは、樹状突起から入力された電気信号が神経細胞内の電位を超えるかどうかの**閾値**を持っている
- ・閾値を超えるとニューロンは興奮状態となり、軸索末端から電気信号が出力される



ニューロンとパーセプトロン

単一の人工ニューロンはこのようなモデルで表すことができる。



ニューロンとパーセプトロン

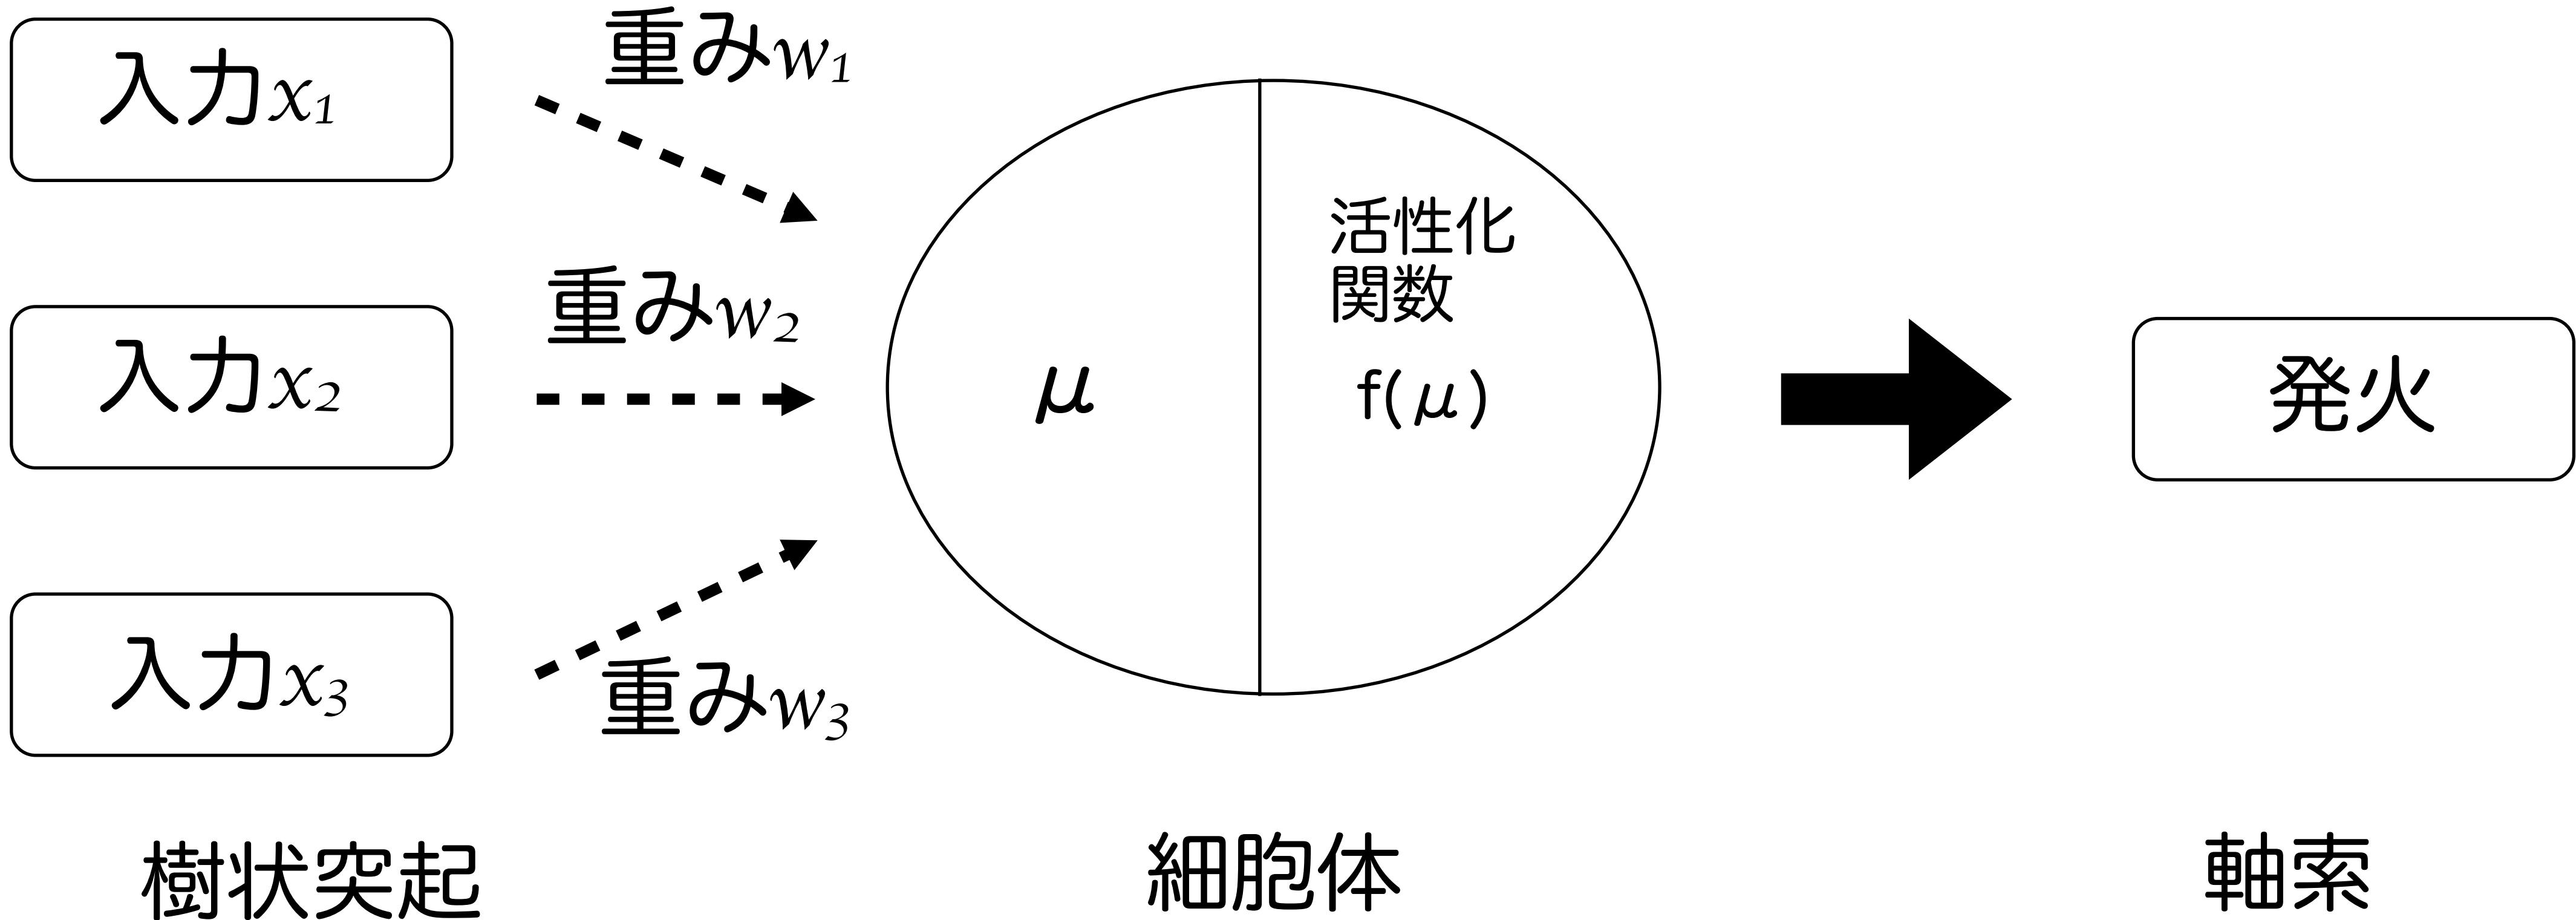
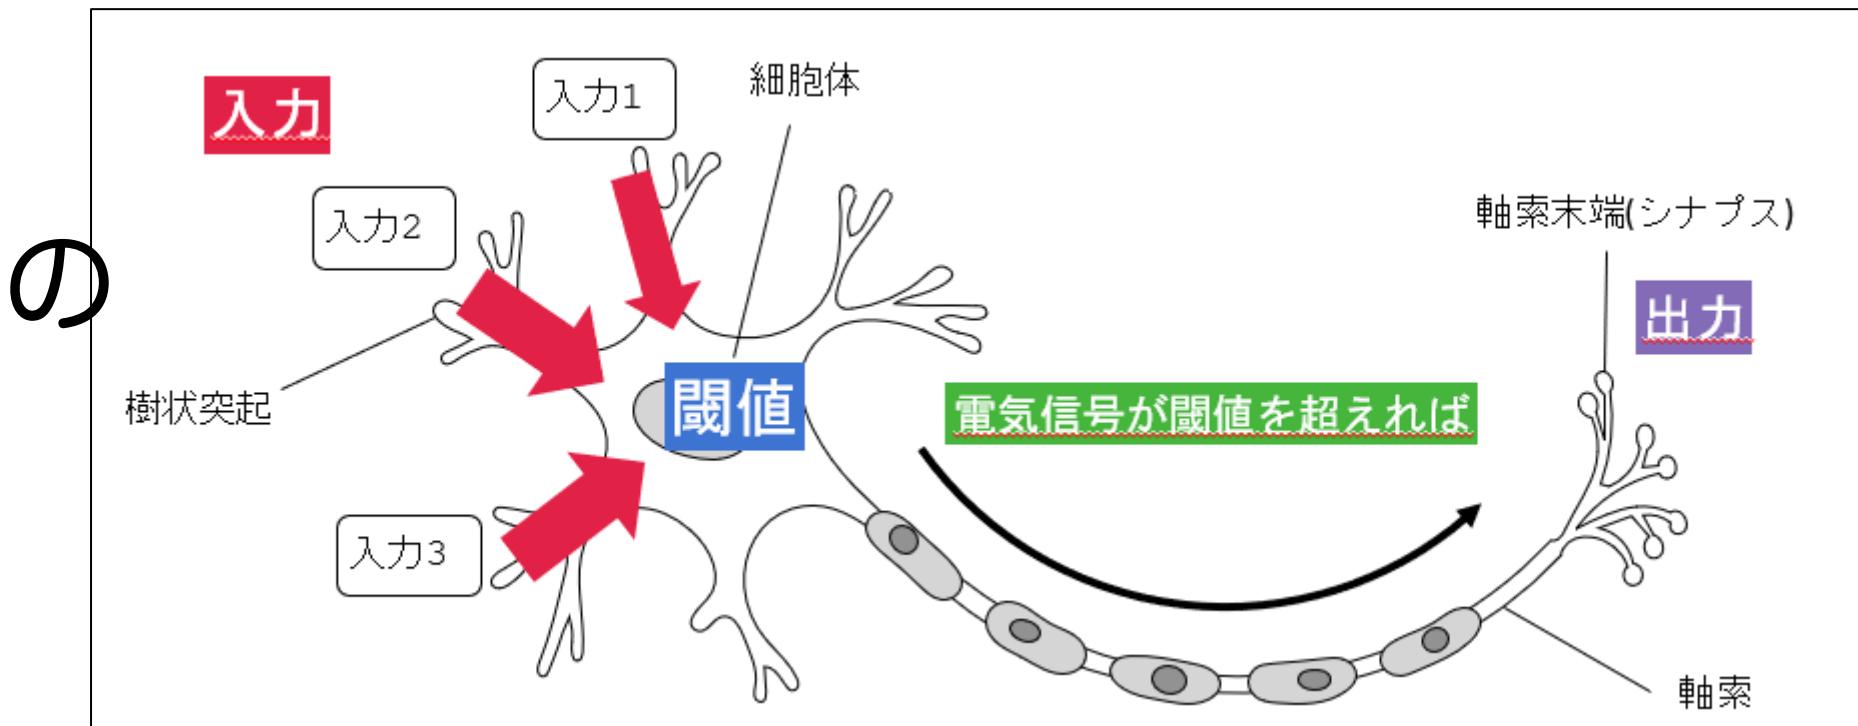
(イメージ)

$x_1 \sim x_3$: 入力. 各電気信号

$w_1 \sim w_3$: 重み. 細胞体までに受ける抵抗の様なものの

μ : 各電気信号が細胞体に集まった際の総和

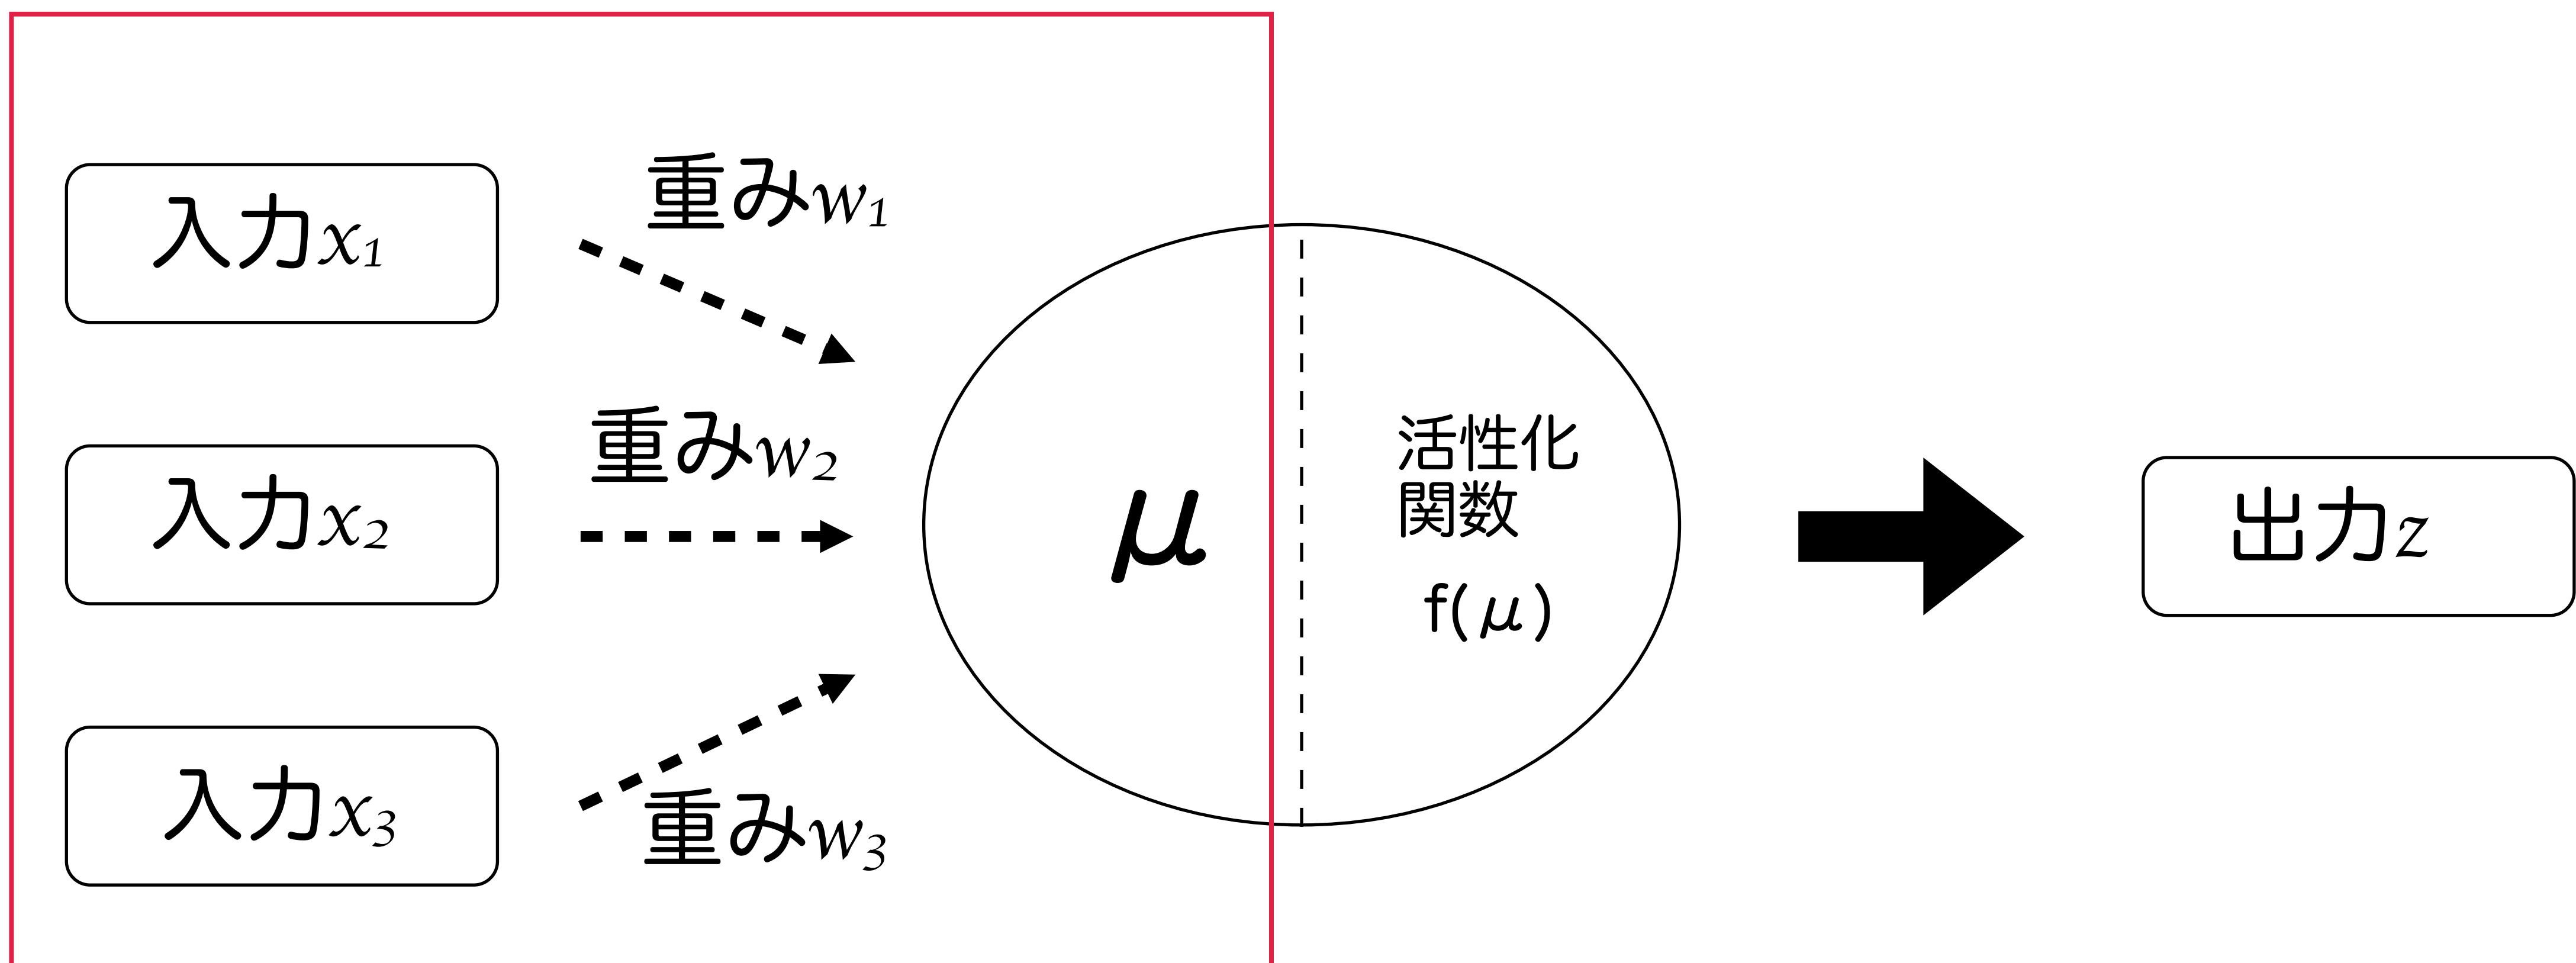
$f(\mu)$: 活性化関数. 閾値



ニューロンとパーセプトロン

μ は入力値に重みを掛け合わせた合計で計算される

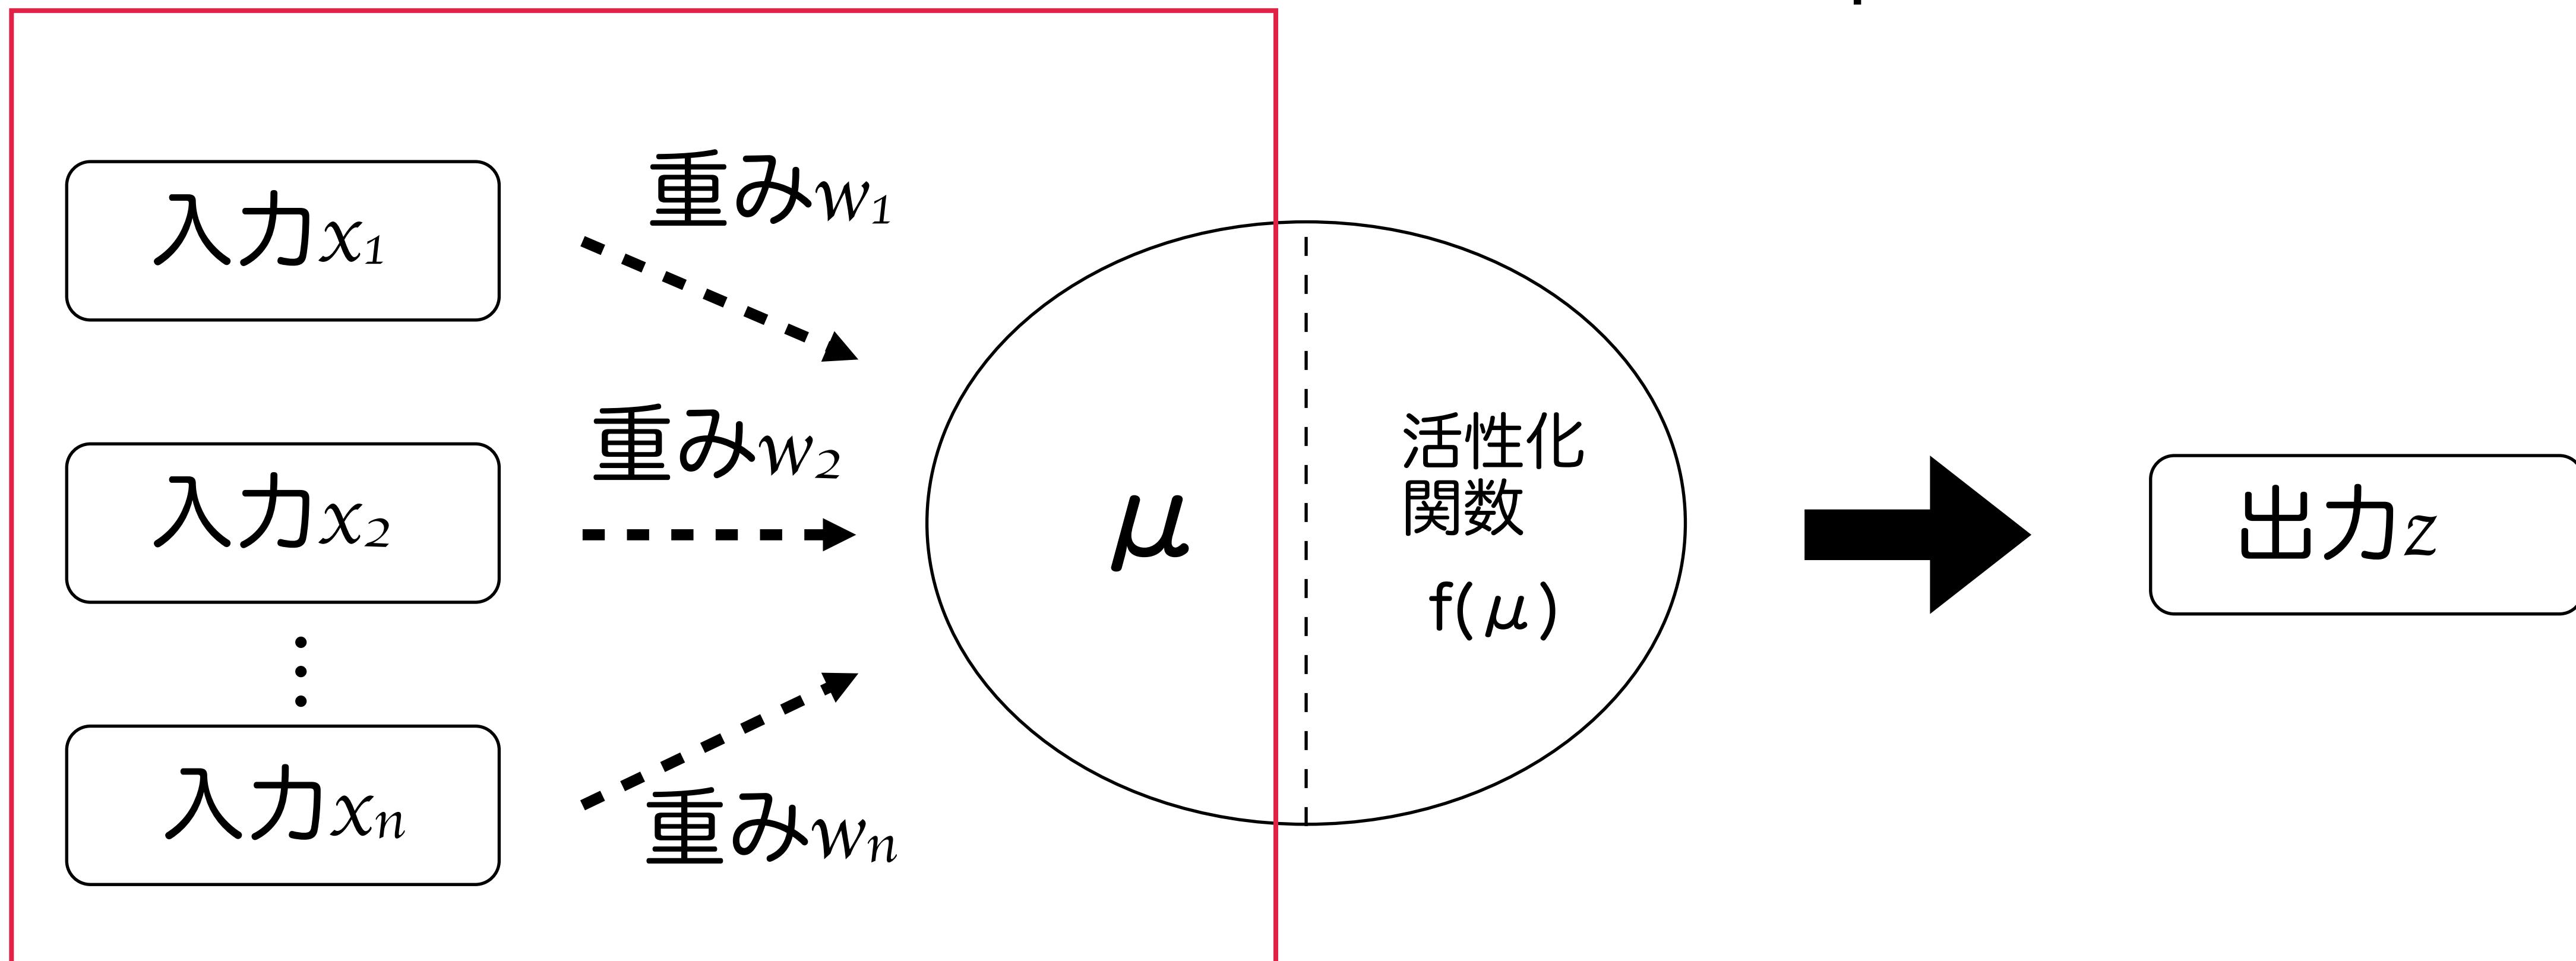
$$\mu = x_1 \times w_1 + x_2 \times w_2 + x_3 \times w_3$$



ニューロンとパーセプトロン

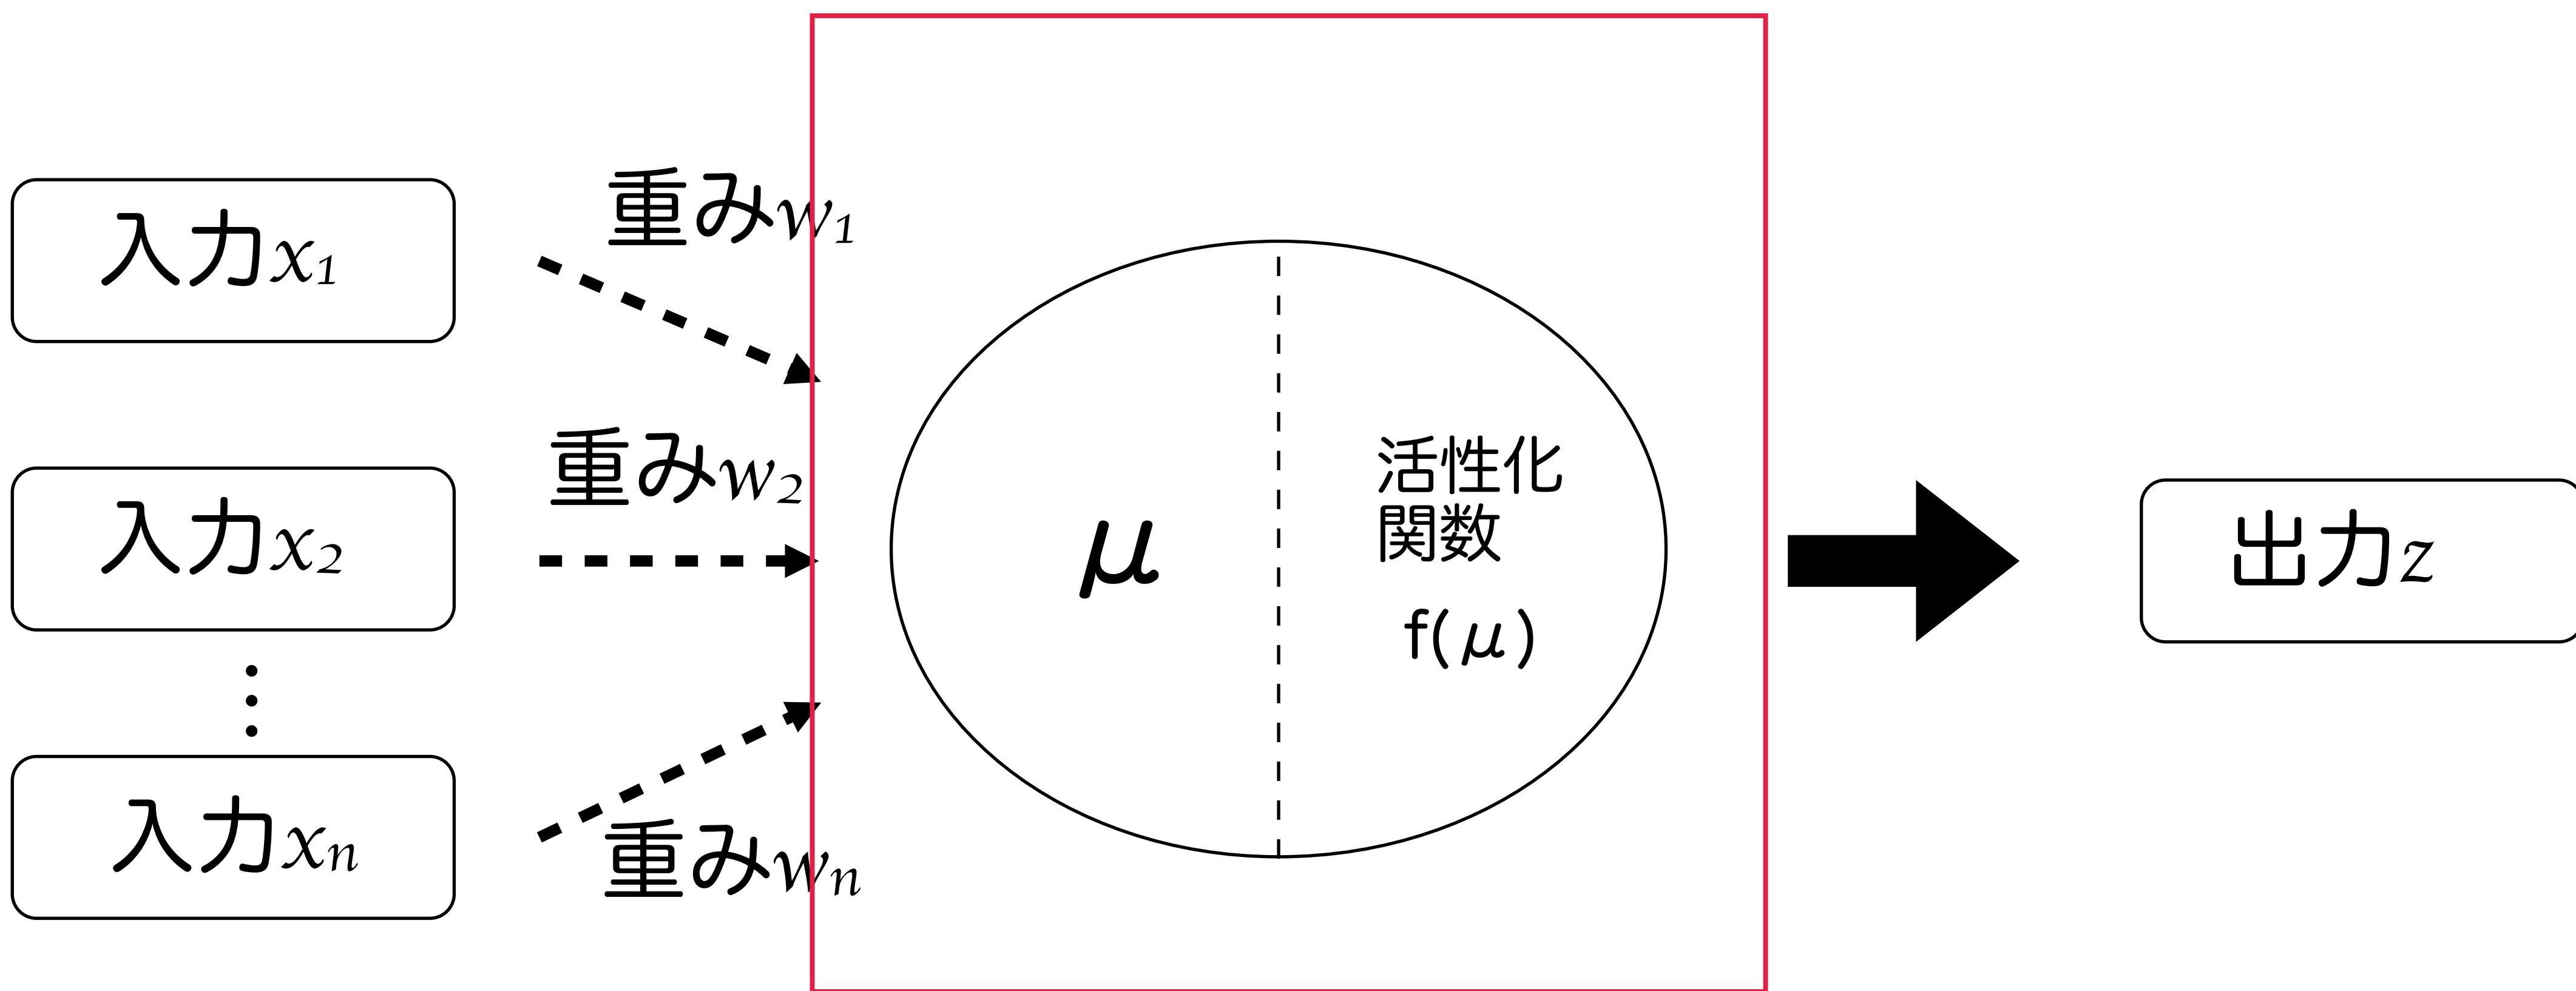
入力がn個あった場合は下のように一般化できる

$$\mu = x_1 \times w_1 + x_2 \times w_2 + \cdots + x_n \times w_n = \sum_i^n x_i w_i$$



活性化関数

(人工)ニューロンが受け取った値を発火するかしないか
判断するための関数を活性化関数という



活性化関数

(人工)ニューロンが受け取った値を発火するかしないか
判断するための関数を活性化関数という

活性化関数には多くの種類がある

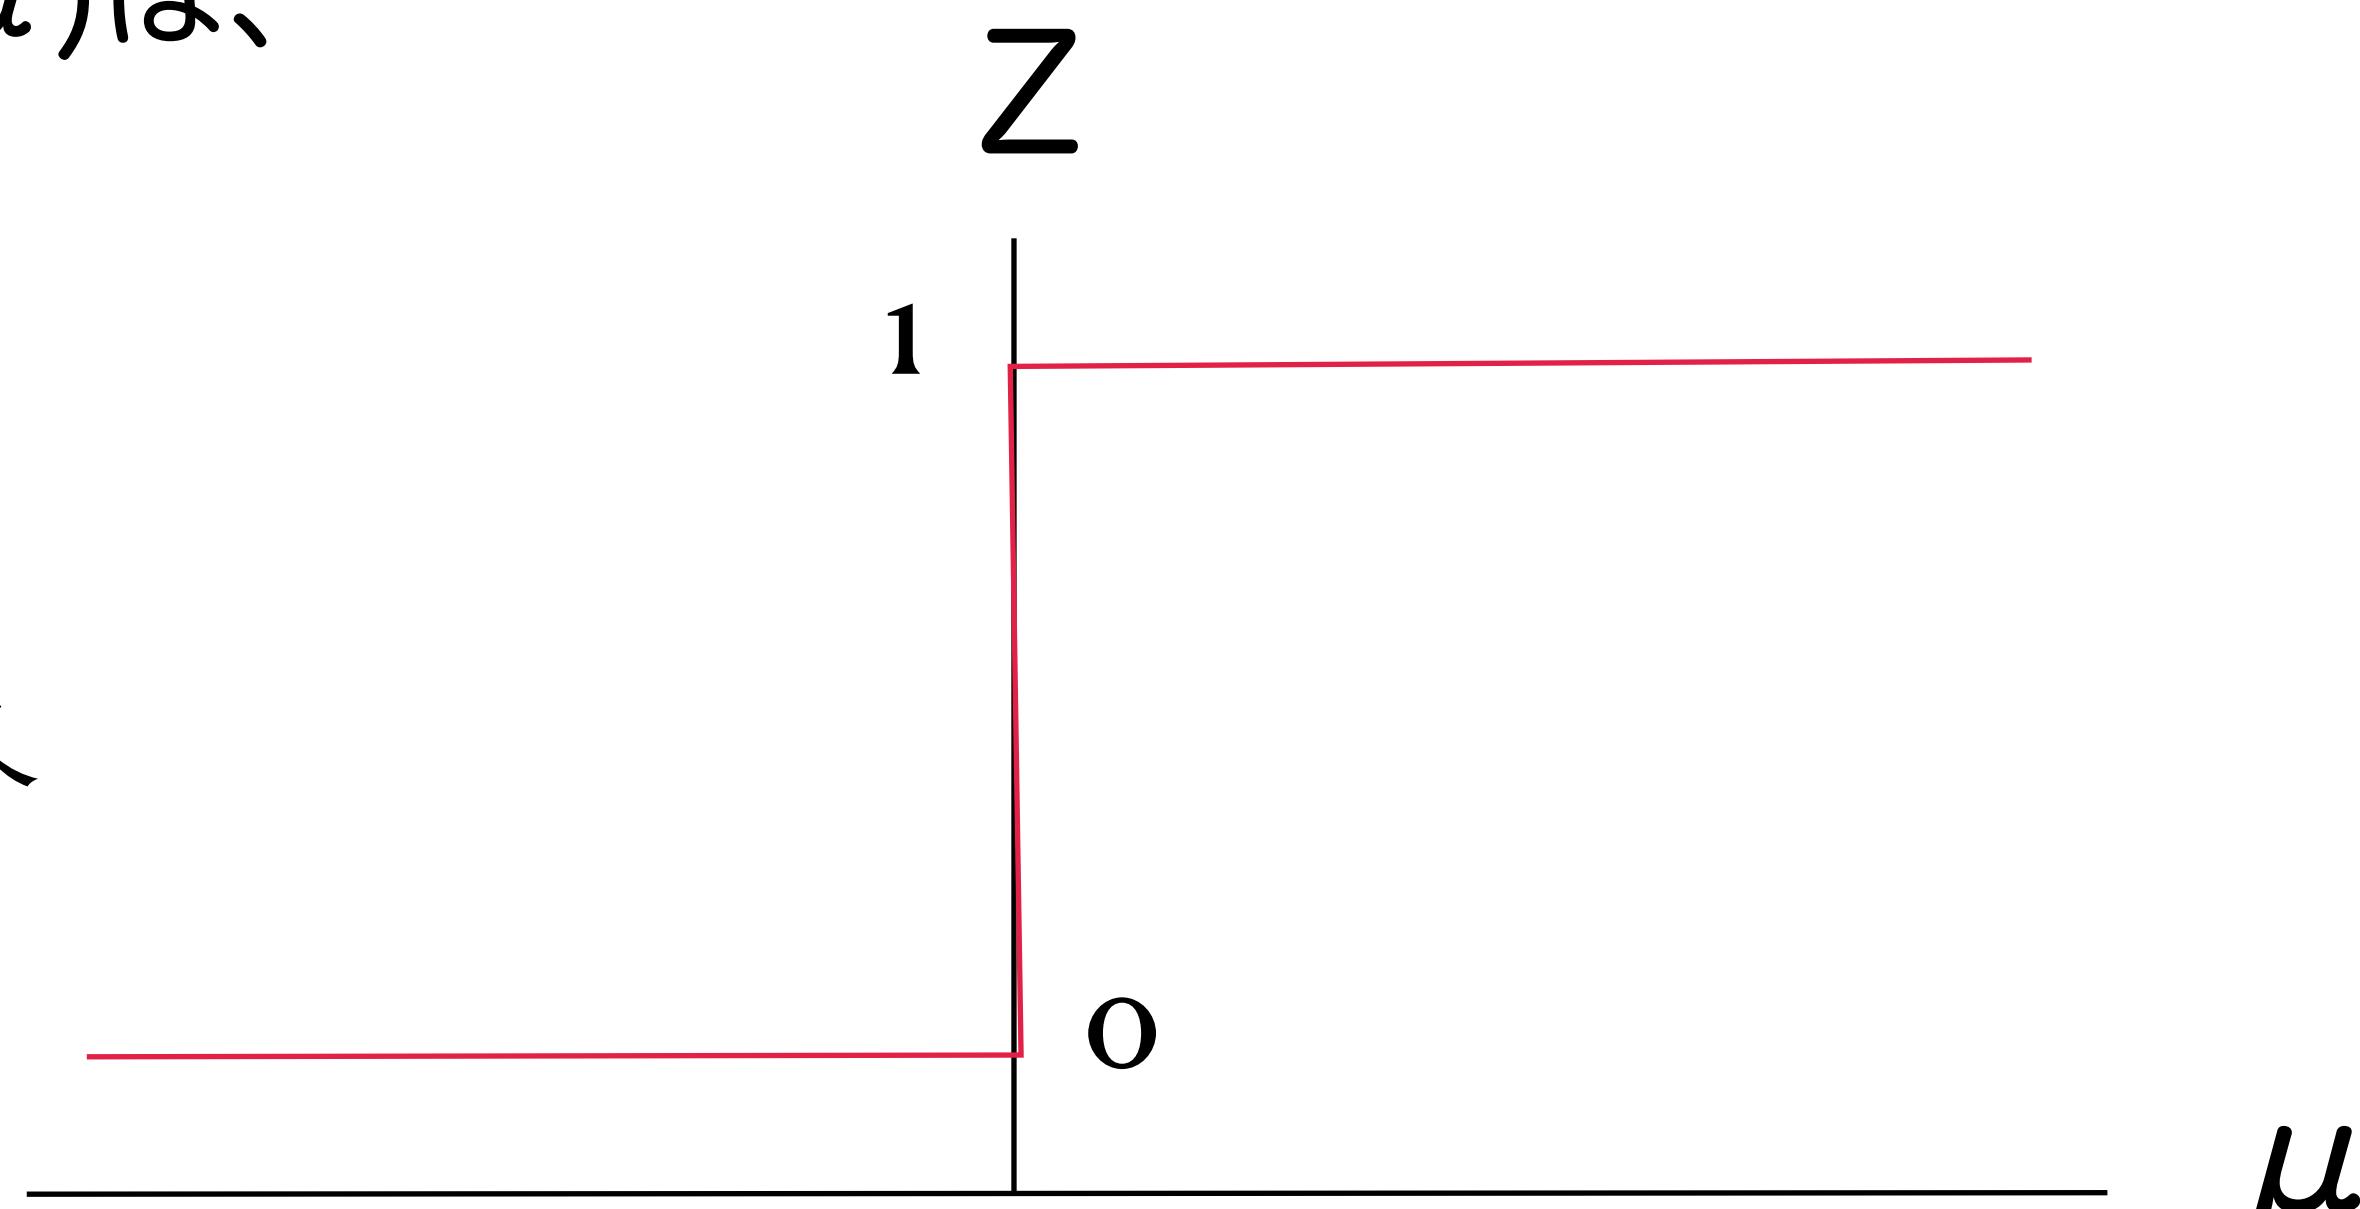
- ・ステップ関数
 - ・恒等関数
 - ・シグモイド関数
 - ・tanh関数
 - ・ReLU関数
 - ・ソフトプラス関数
 - ・Leaky ReLU
 - ・ソフトマックス関数
 - ・PReLU / Parametric ReLU
 - ・ELU
 - ・SELU
 - ・Swish関数
 - ・Mish関数
- など

例えば活性化関数にステップ関数を用いると

出力値をZとすると活性化関数 $f(\mu)$ は、

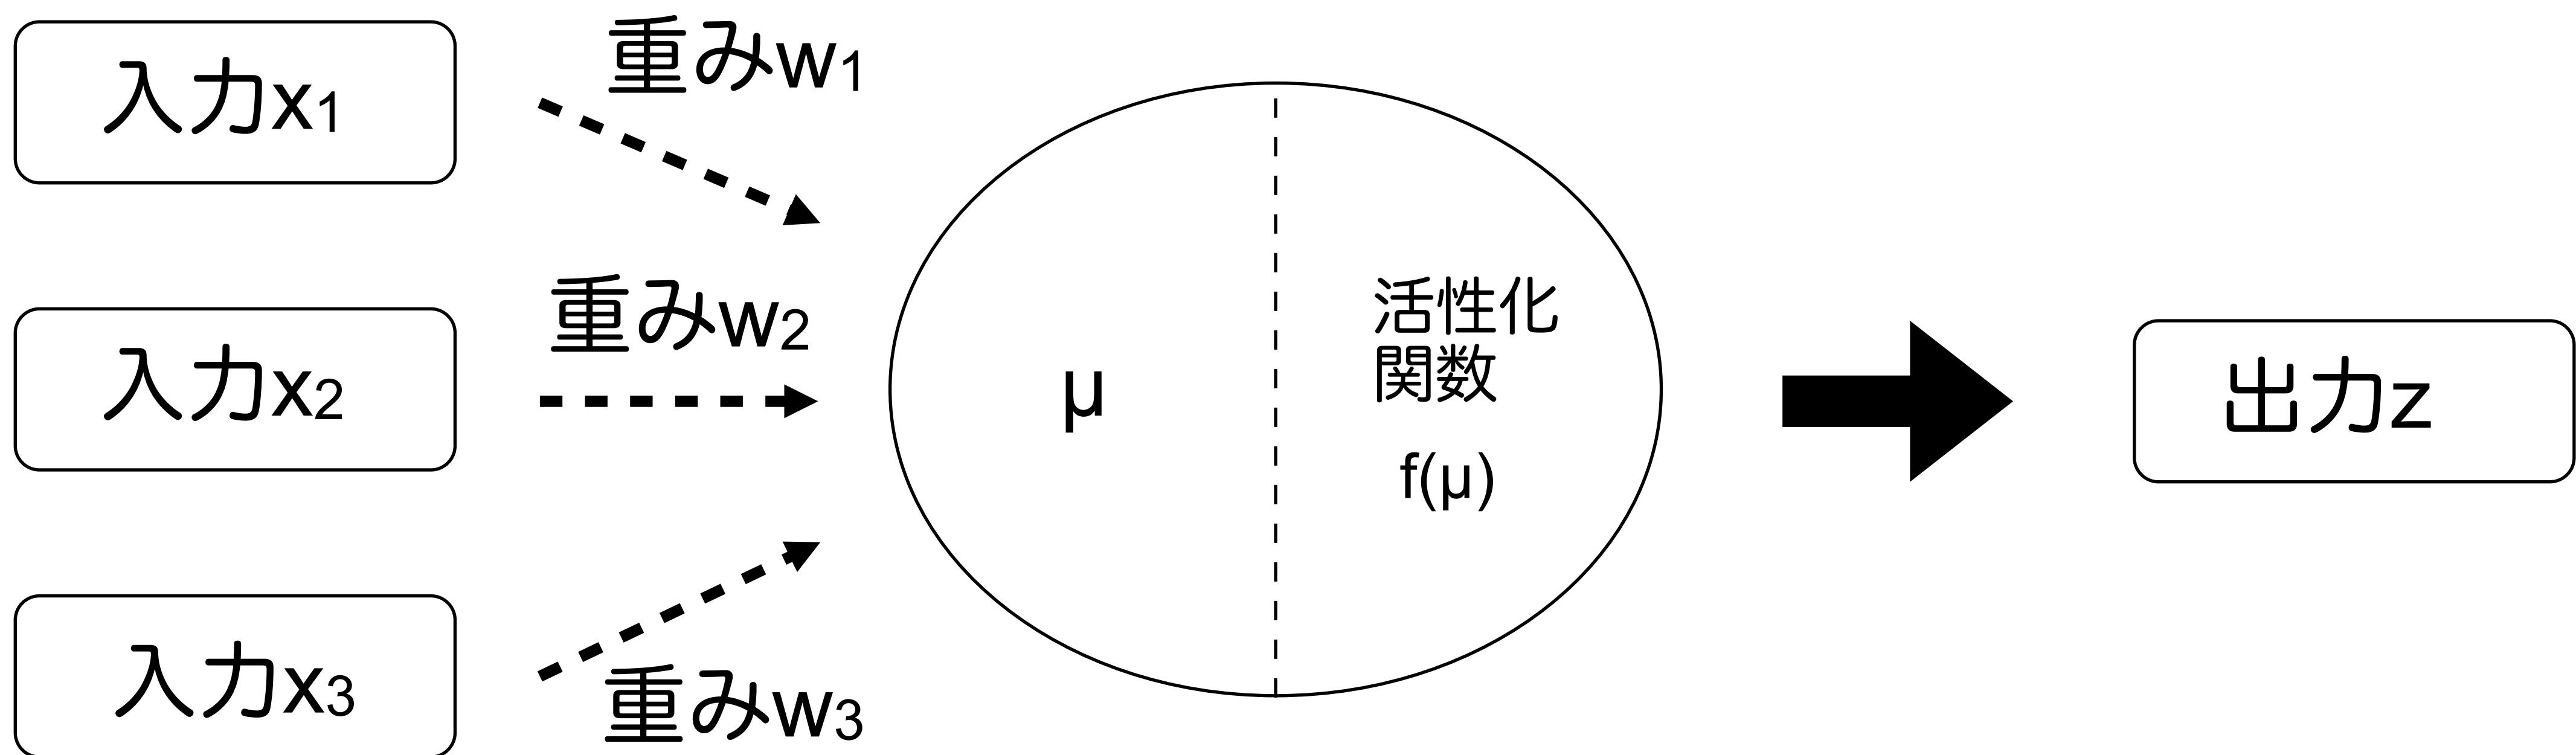
$$Z = f(\mu) = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$

μ がどんな値でも出力は
0か1のいずれかになる！



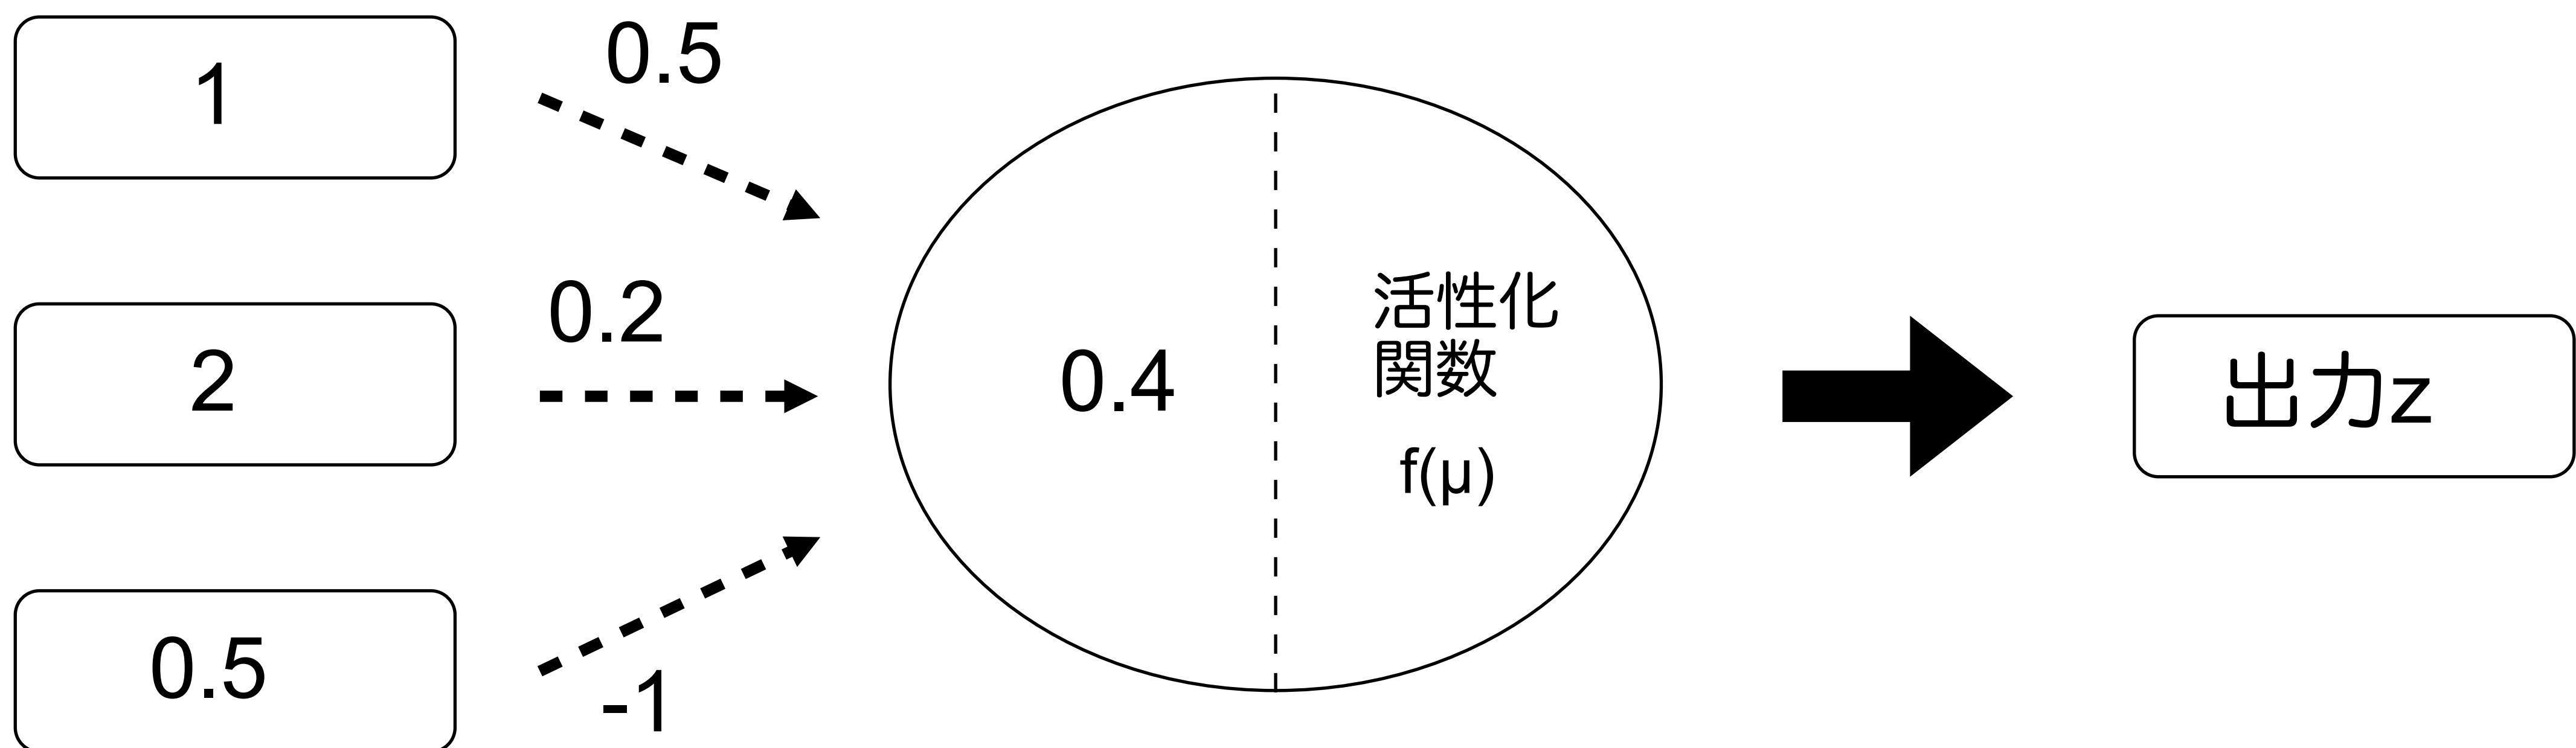
閾値を0とすると、 μ が0より大きければ Z は1となり(発火)、
0以下であれば0となる(発火しない)

例えば $x_1=1$ 、 $x_2=2$ 、 $x_3=0.5$ 、 $w_1=0.5$ 、 $w_2=0.2$ 、 $w_3=-1$ の時は？



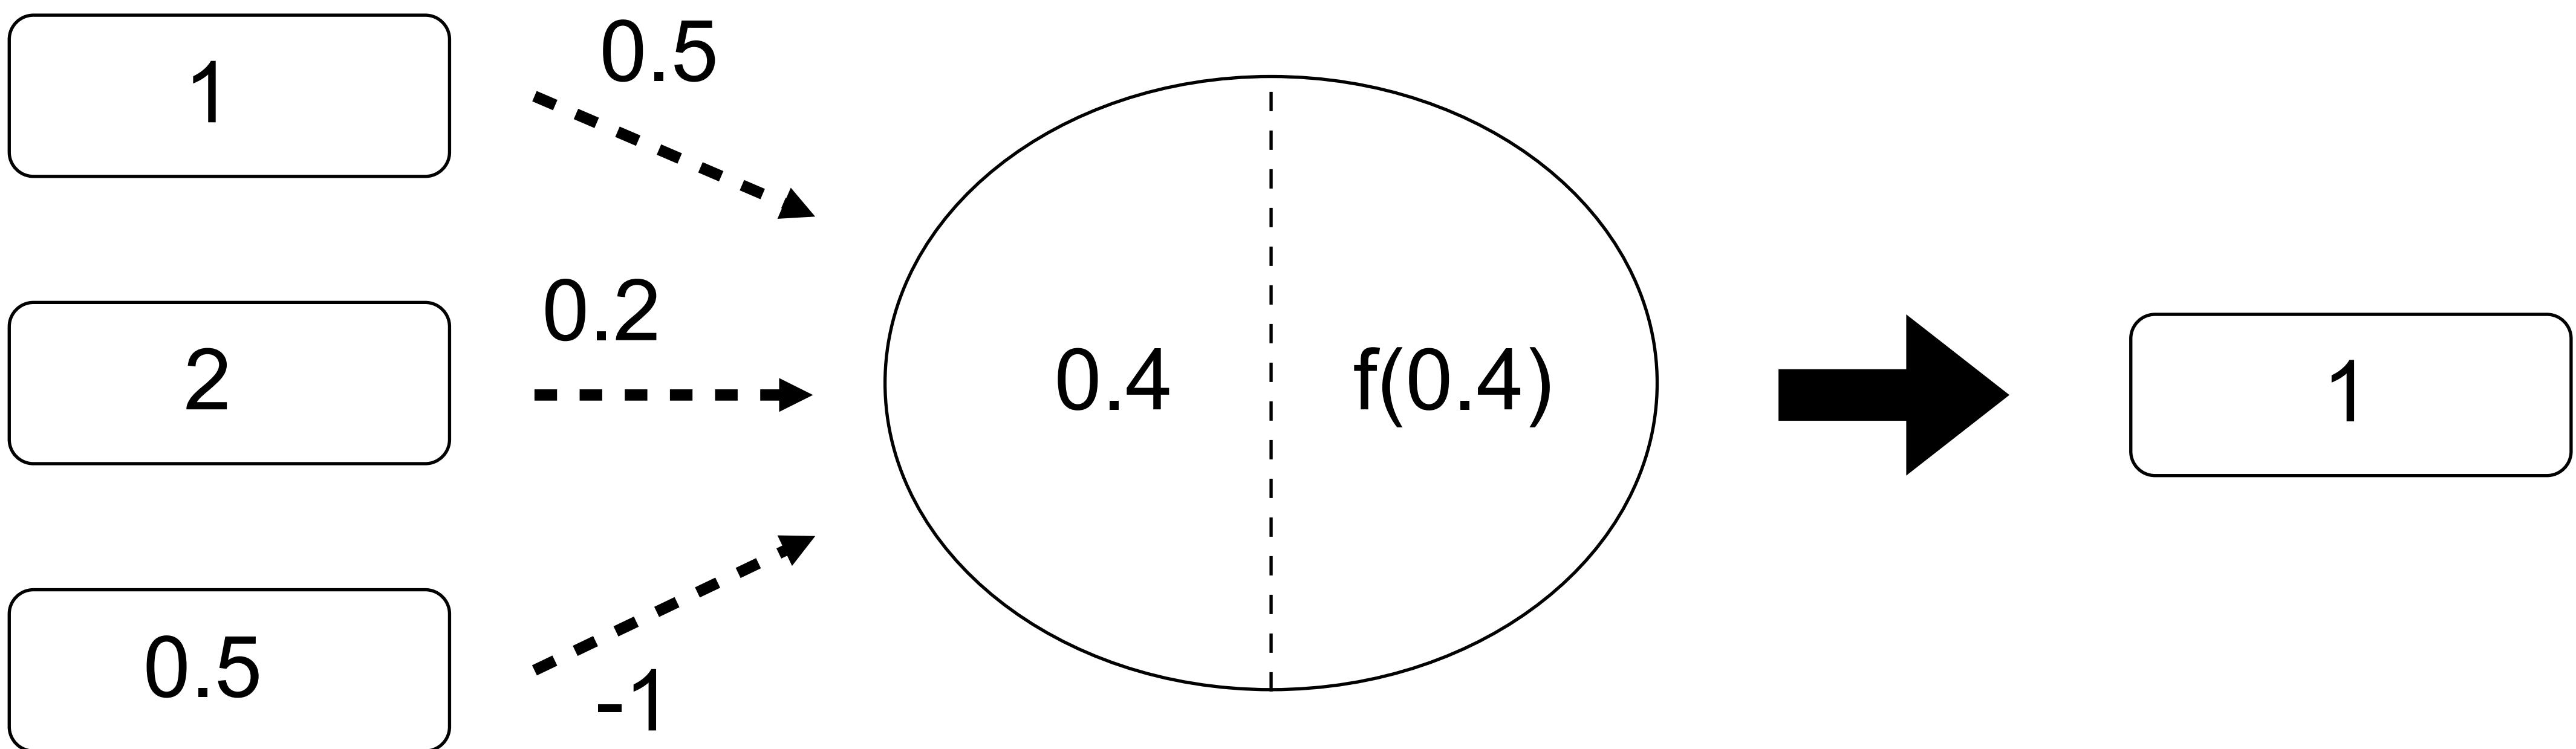
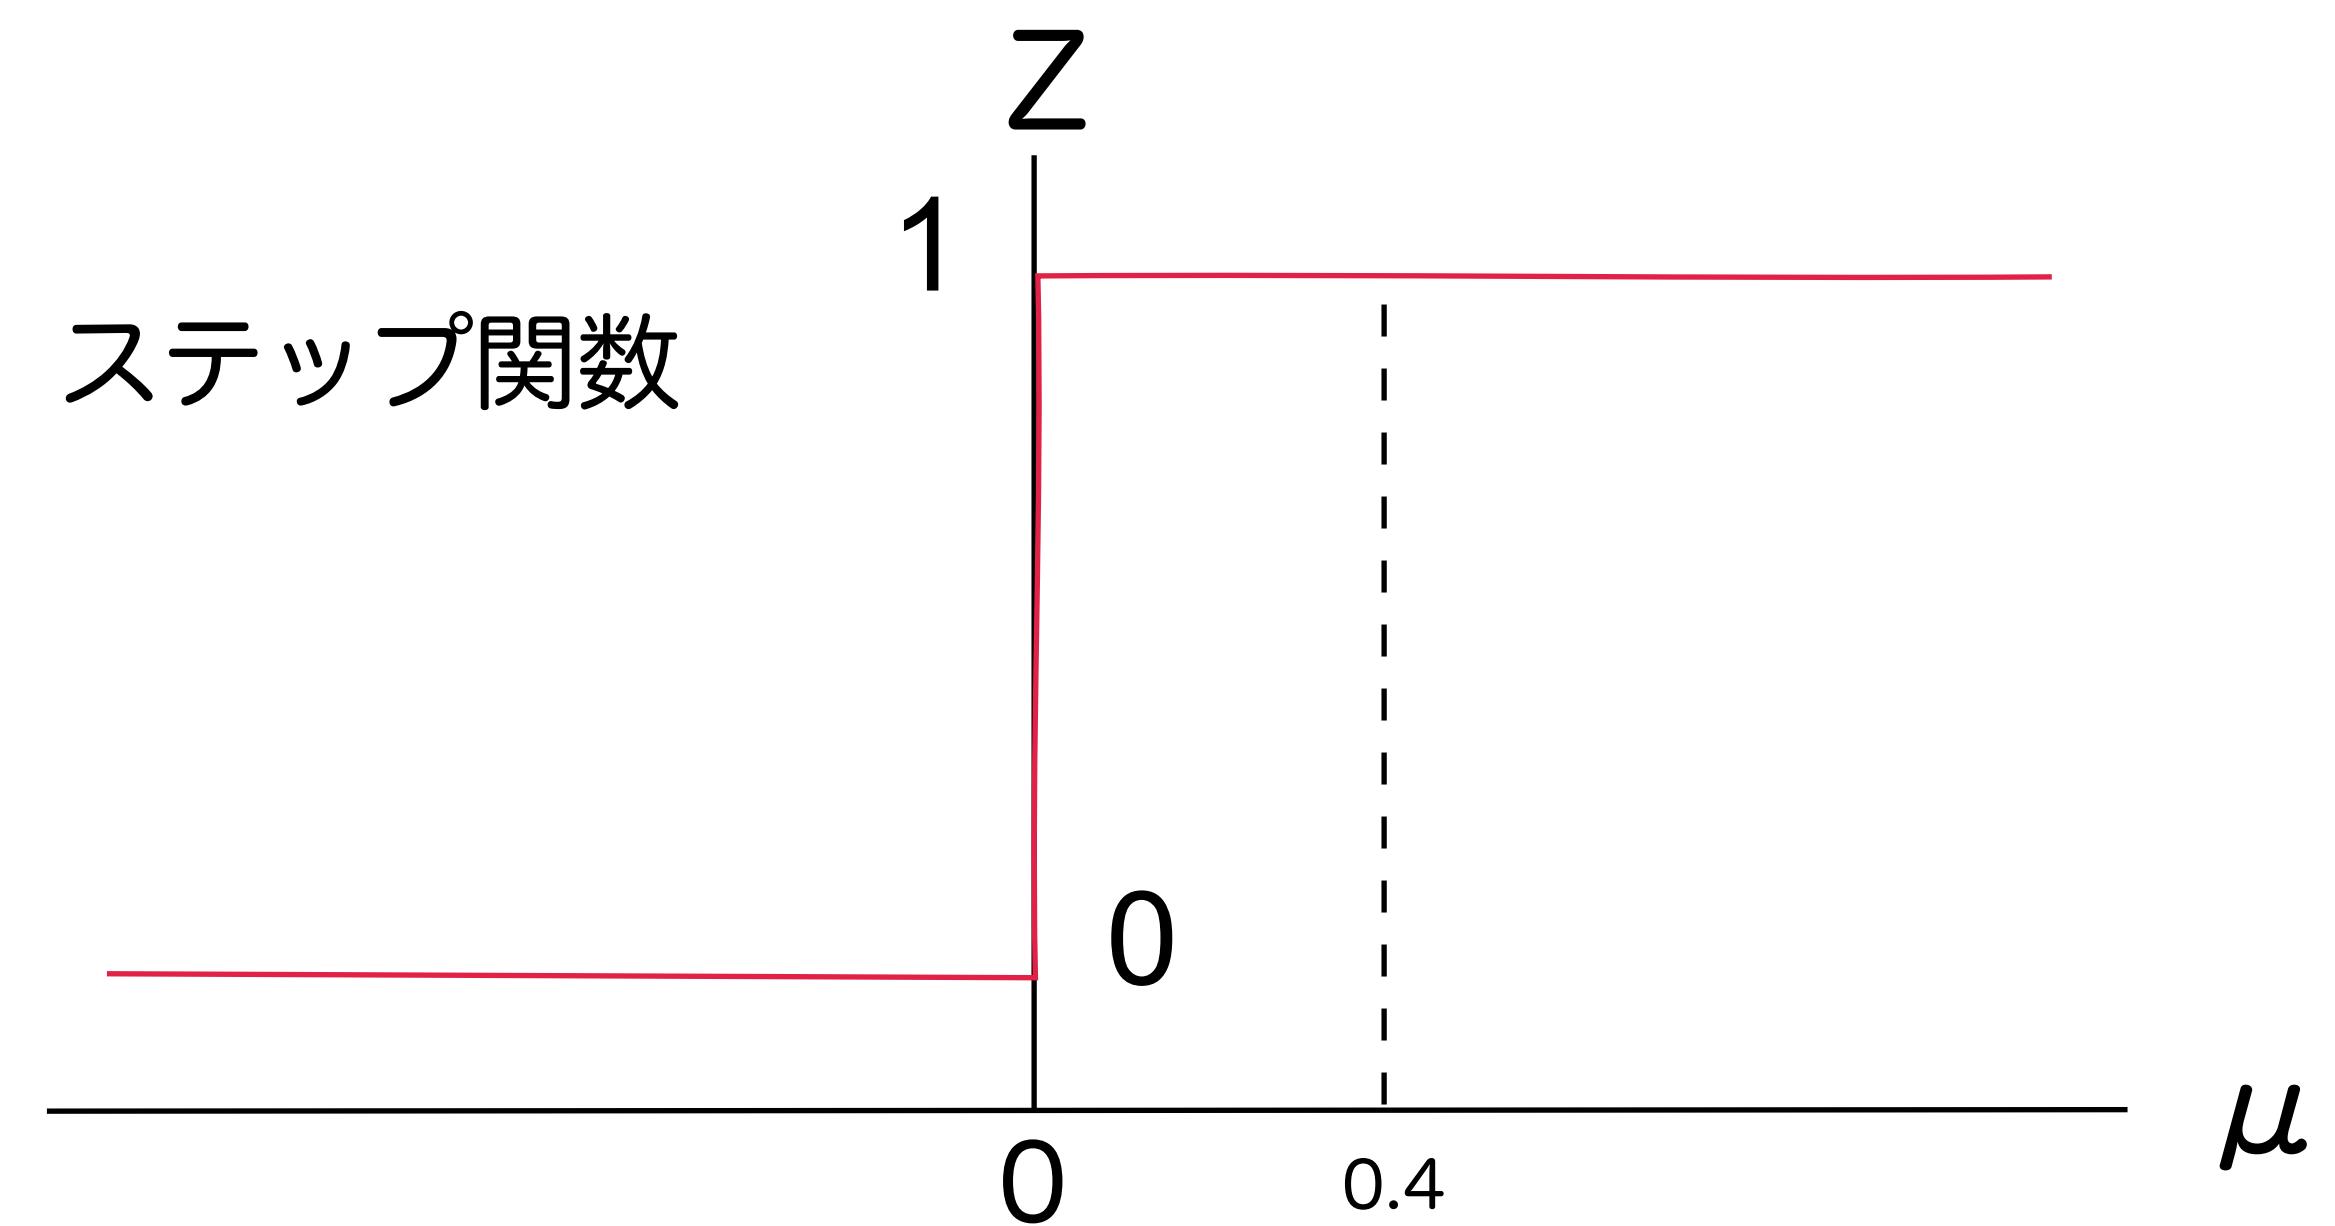
例えば $x_1=1$ 、 $x_2=2$ 、 $x_3=0.5$ 、 $w_1=0.5$ 、 $w_2=0.2$ 、 $w_3=-1$ の時は？

$$\mu = 1 \times 0.5 + 2 \times 0.2 + 0.5 \times (-1) = 0.4$$

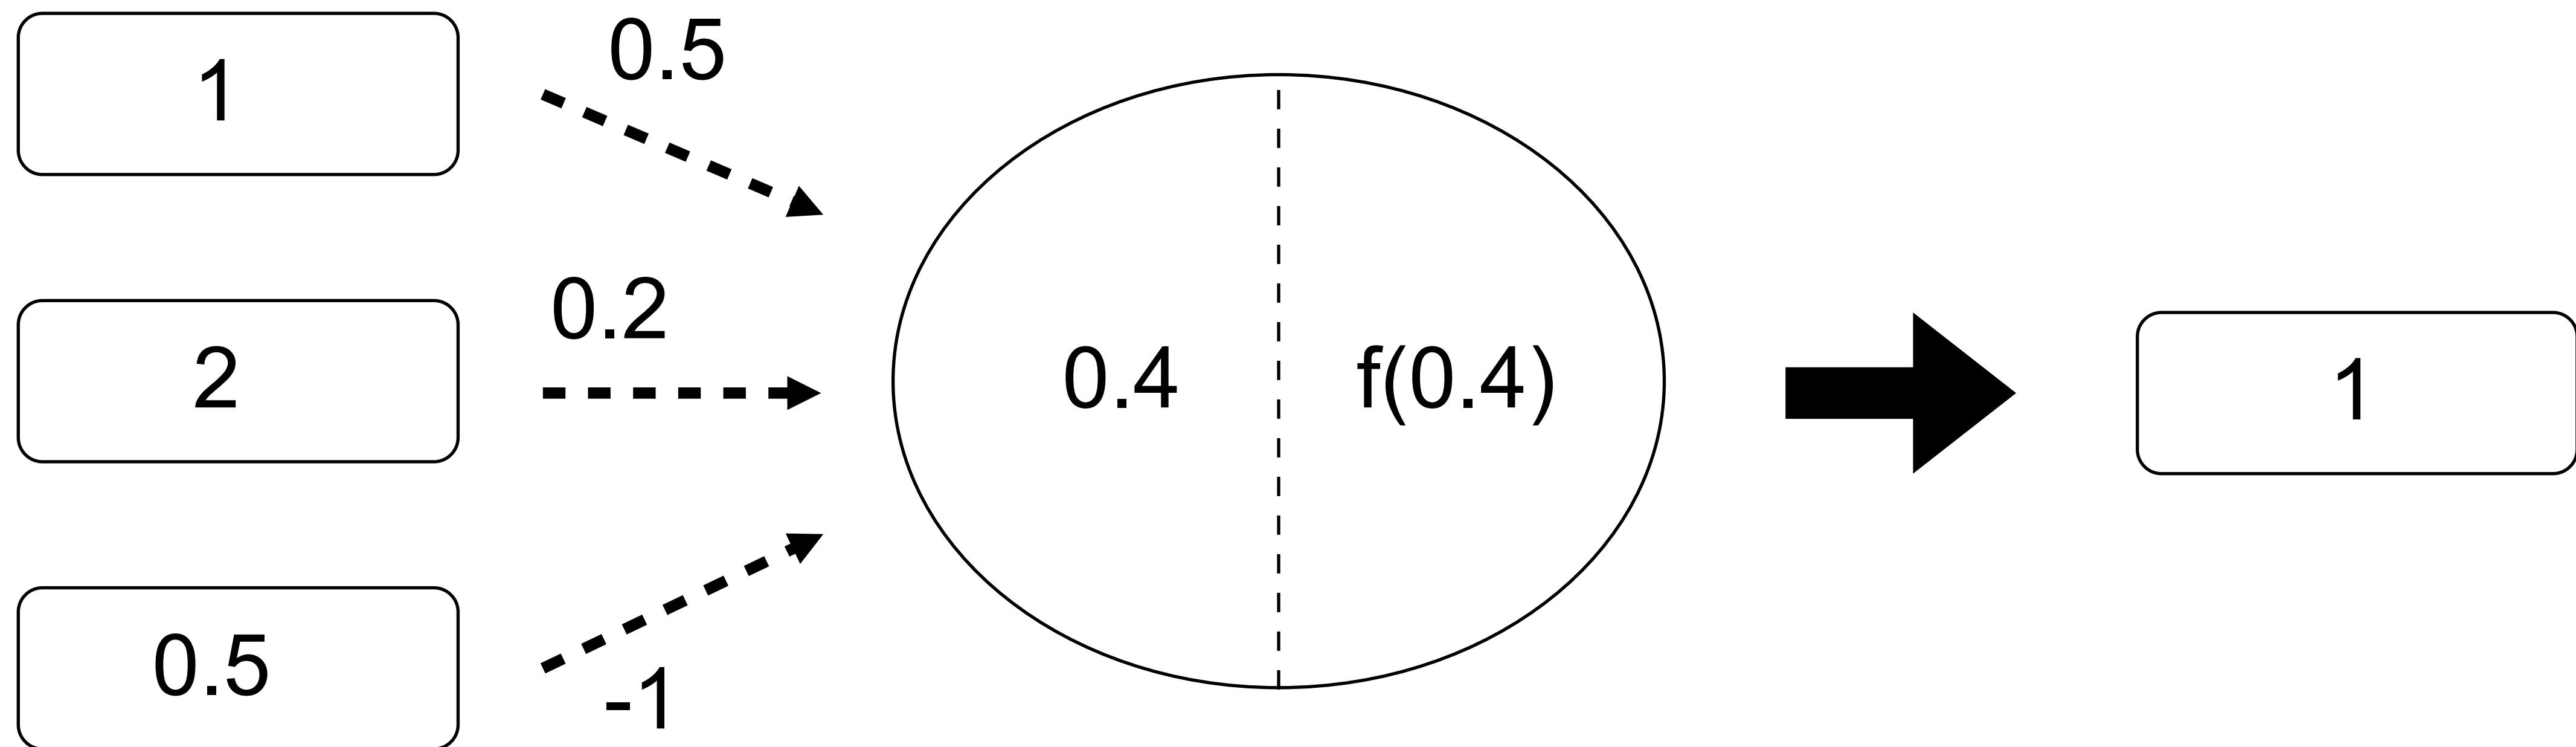


$$z = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$

ステップ関数



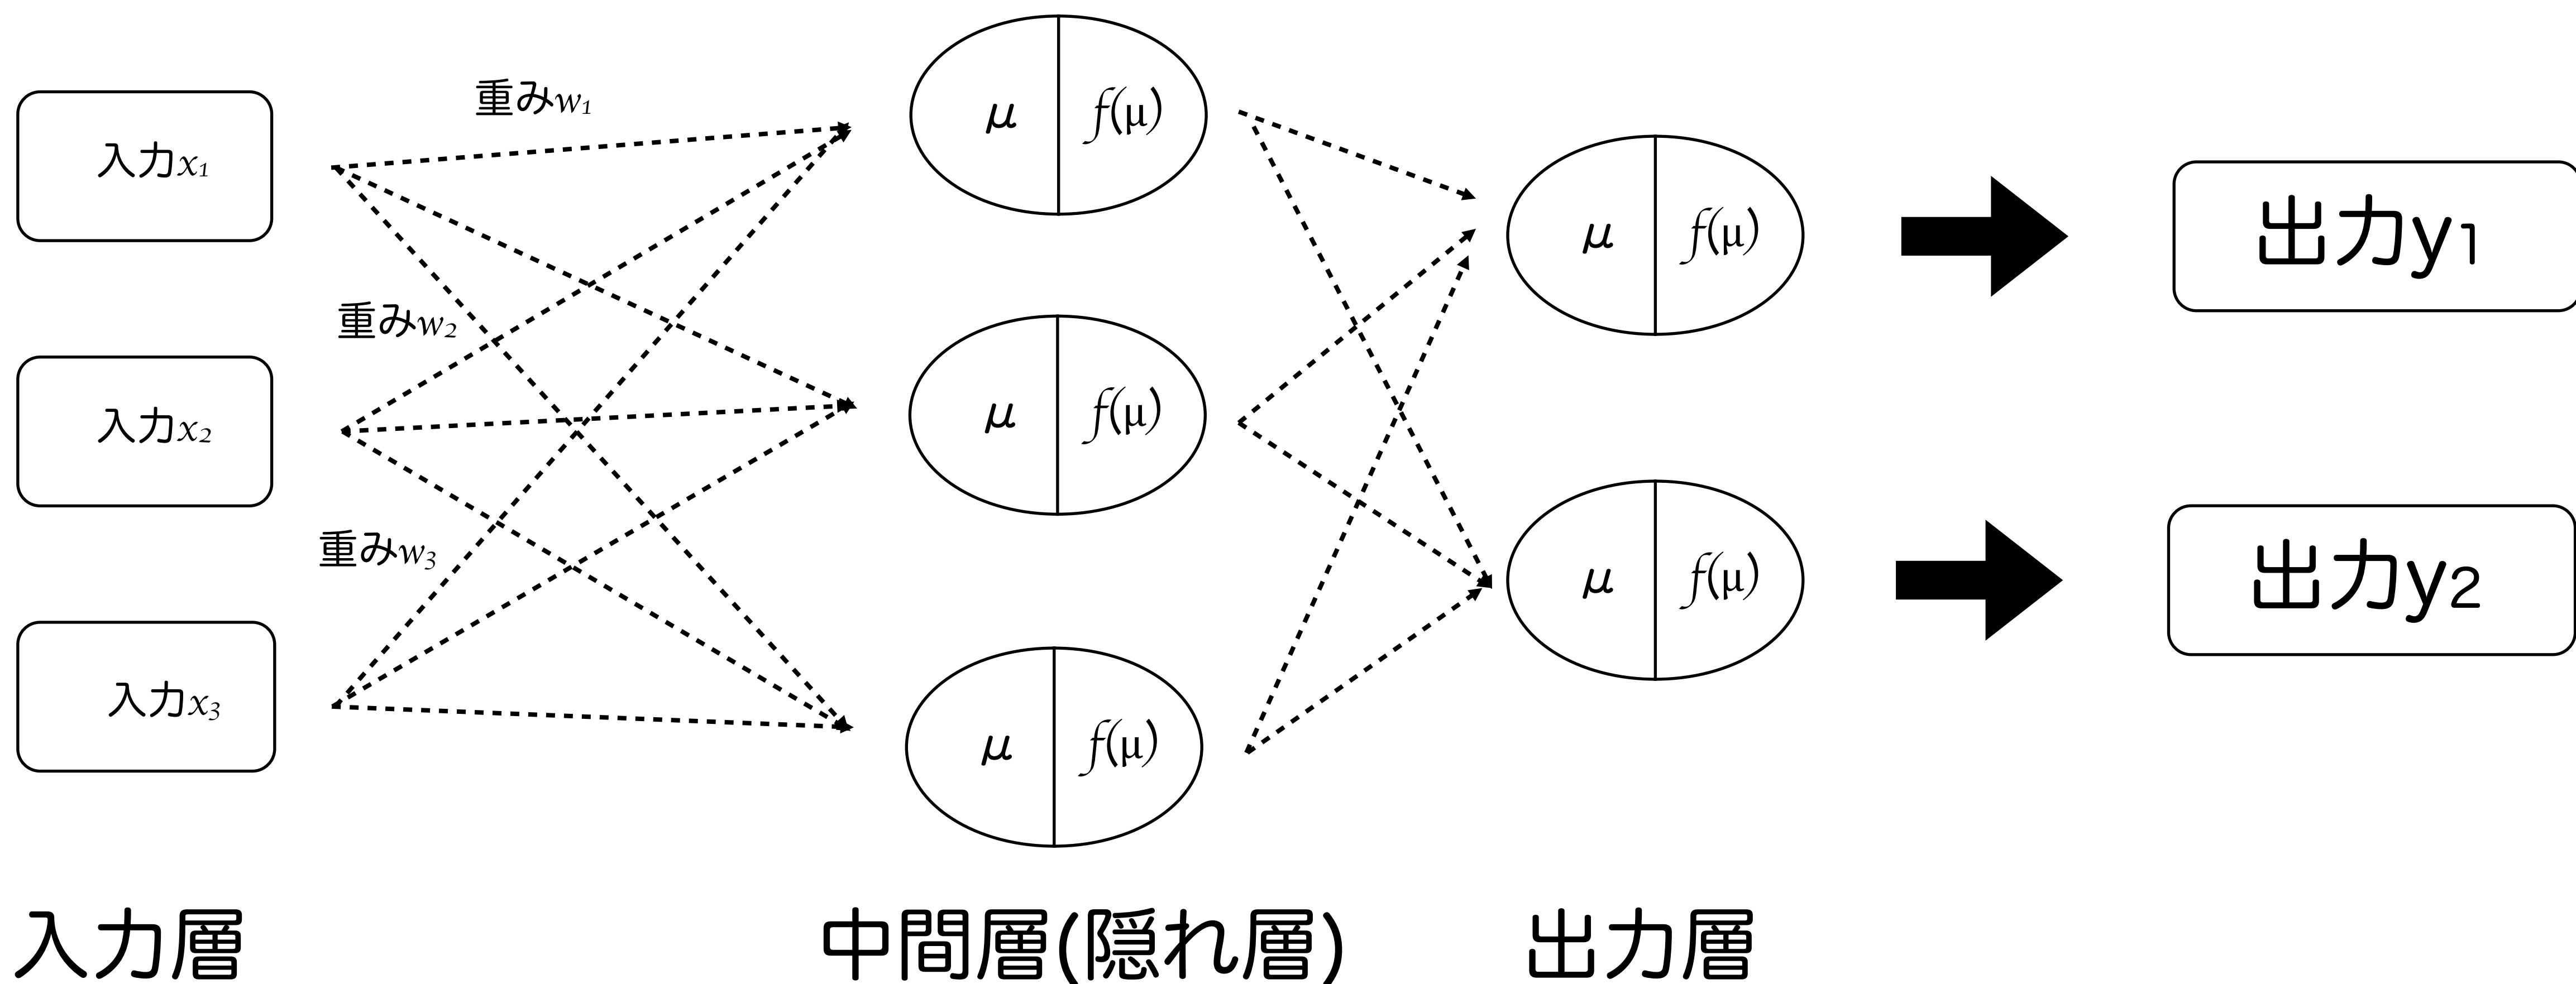
このような重み w_i や閾値を調整することができる
人工ニューラルネットワークで学習する仕組みをパーセプトロンと呼ぶ。



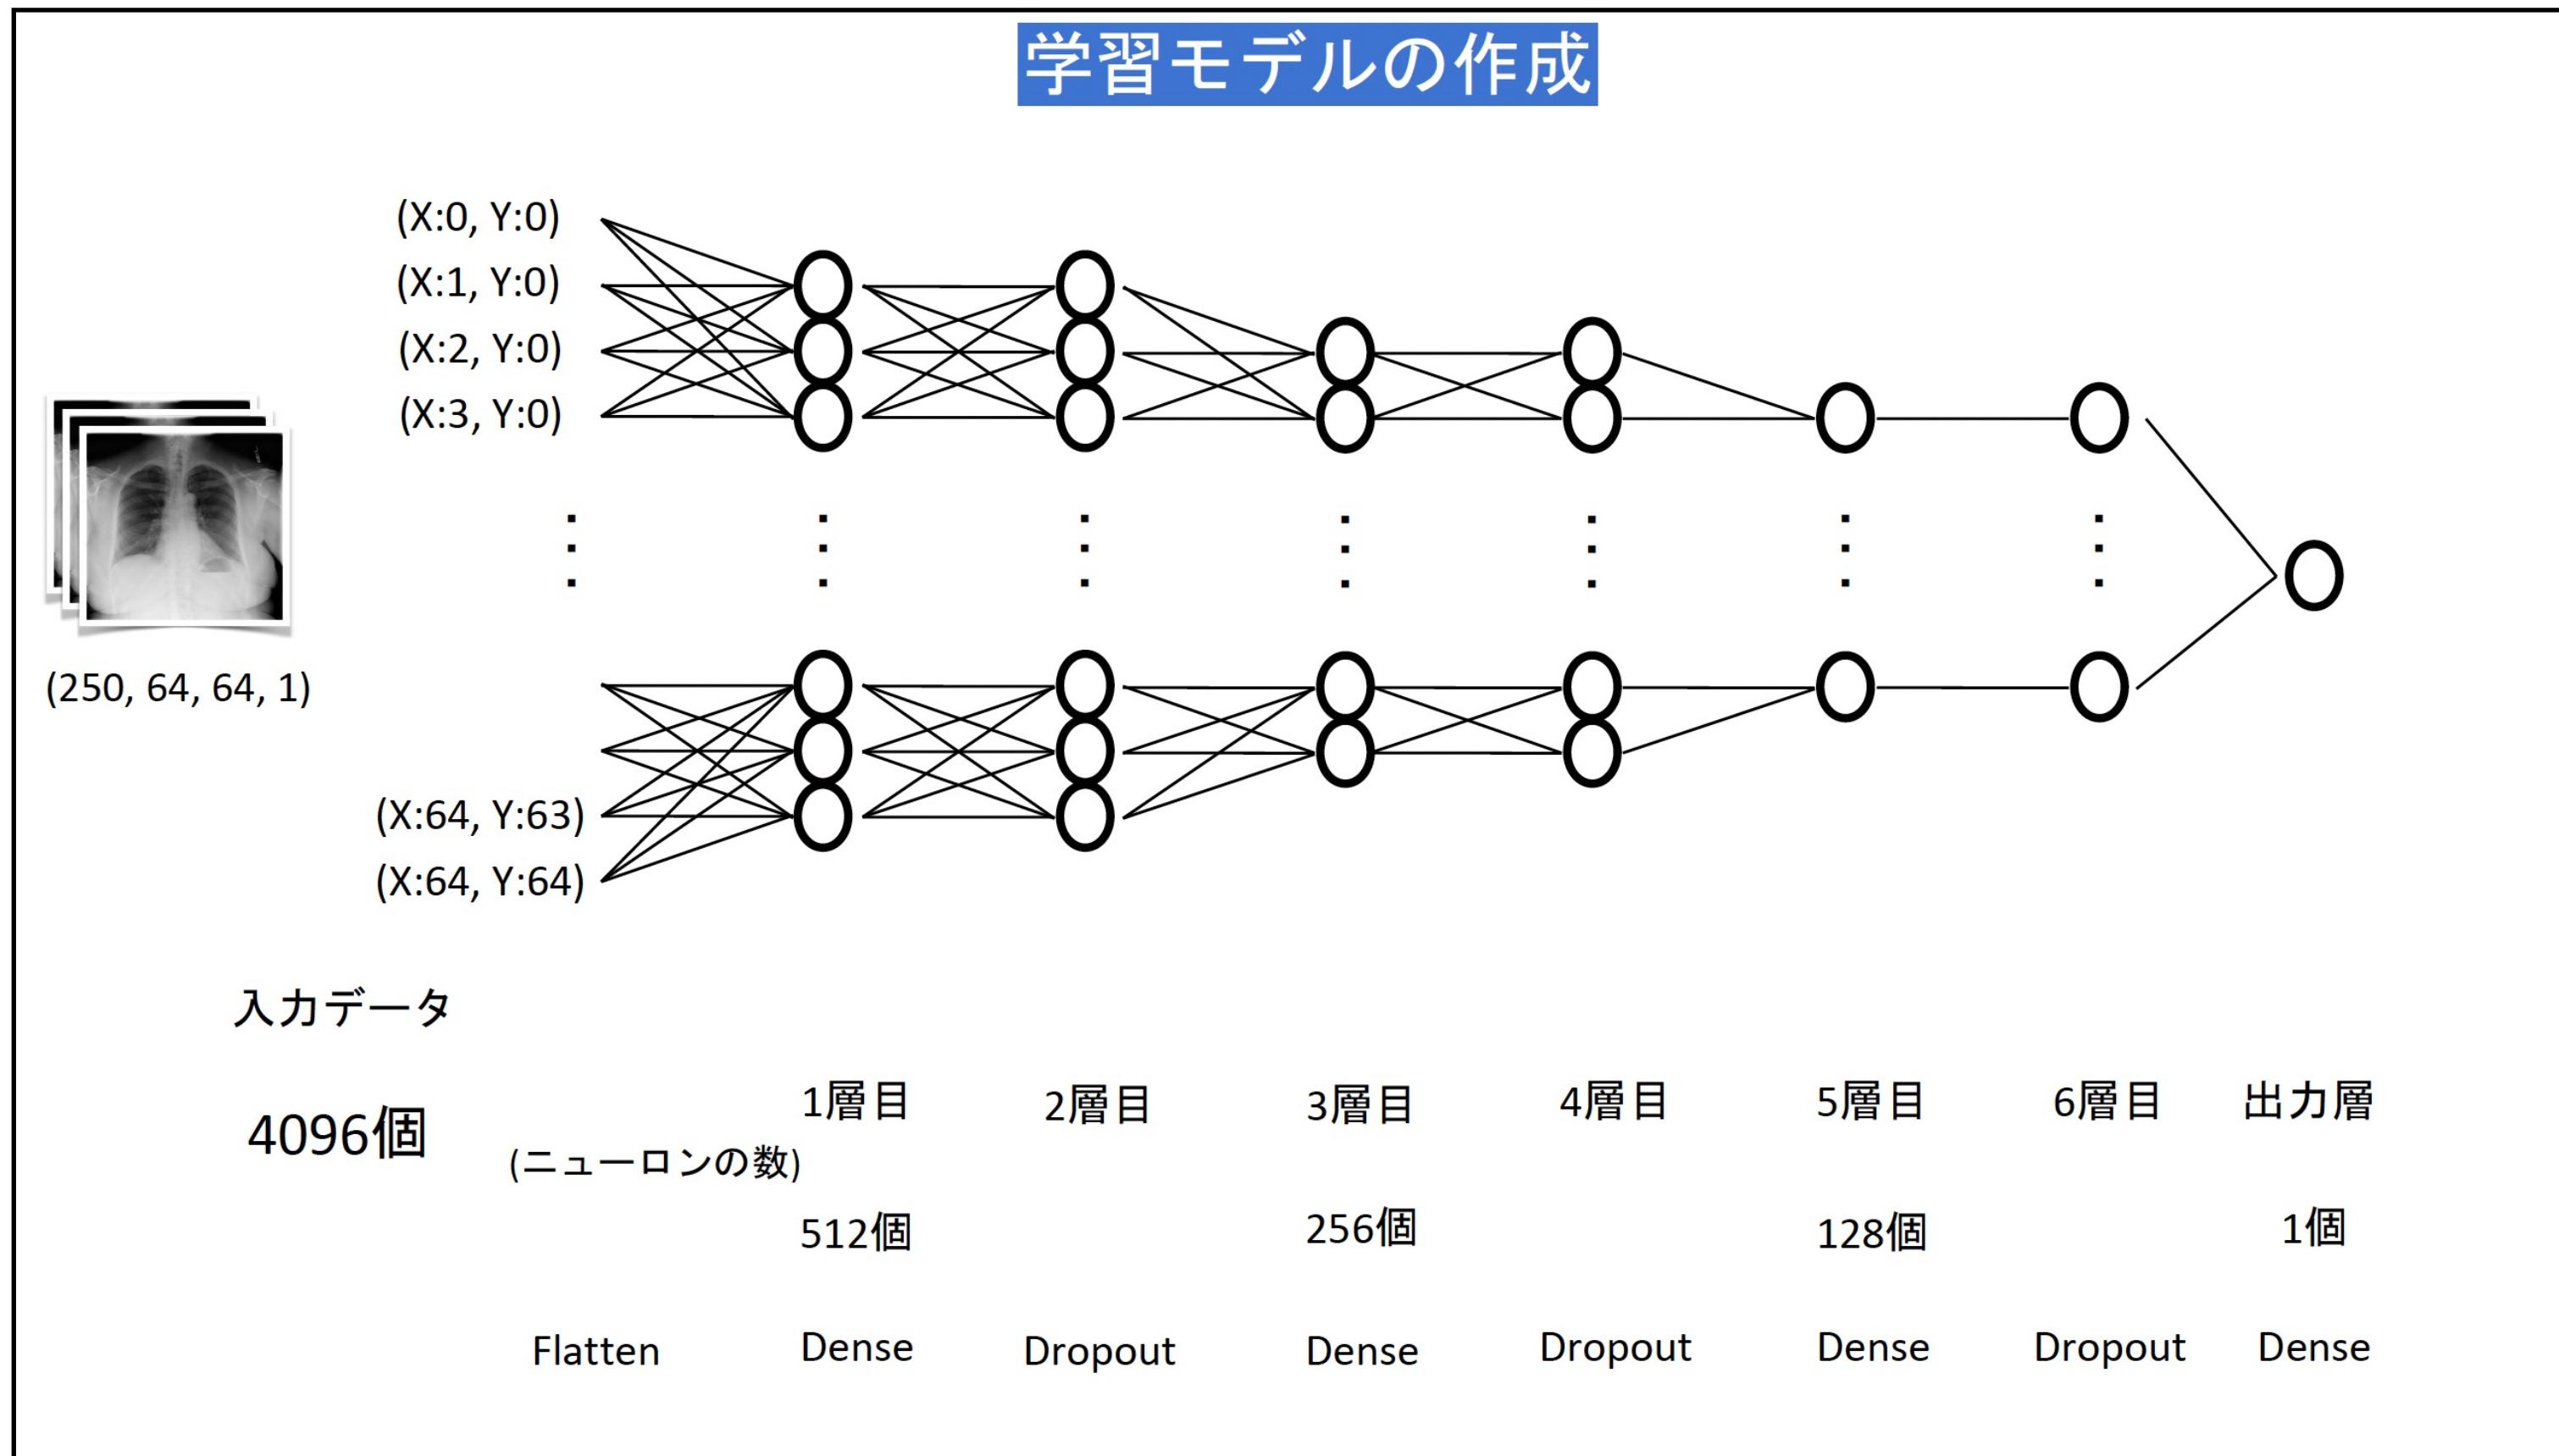
多層パーセプトロン (MLP : Multi Layer Perceptron)

複数のパーセプトロンを用いてパーセプトロンの層を作ったものを
多層パーセプトロンという

(この中間層を複数作ってどんどん層を深く出来るので**深層学習**という)

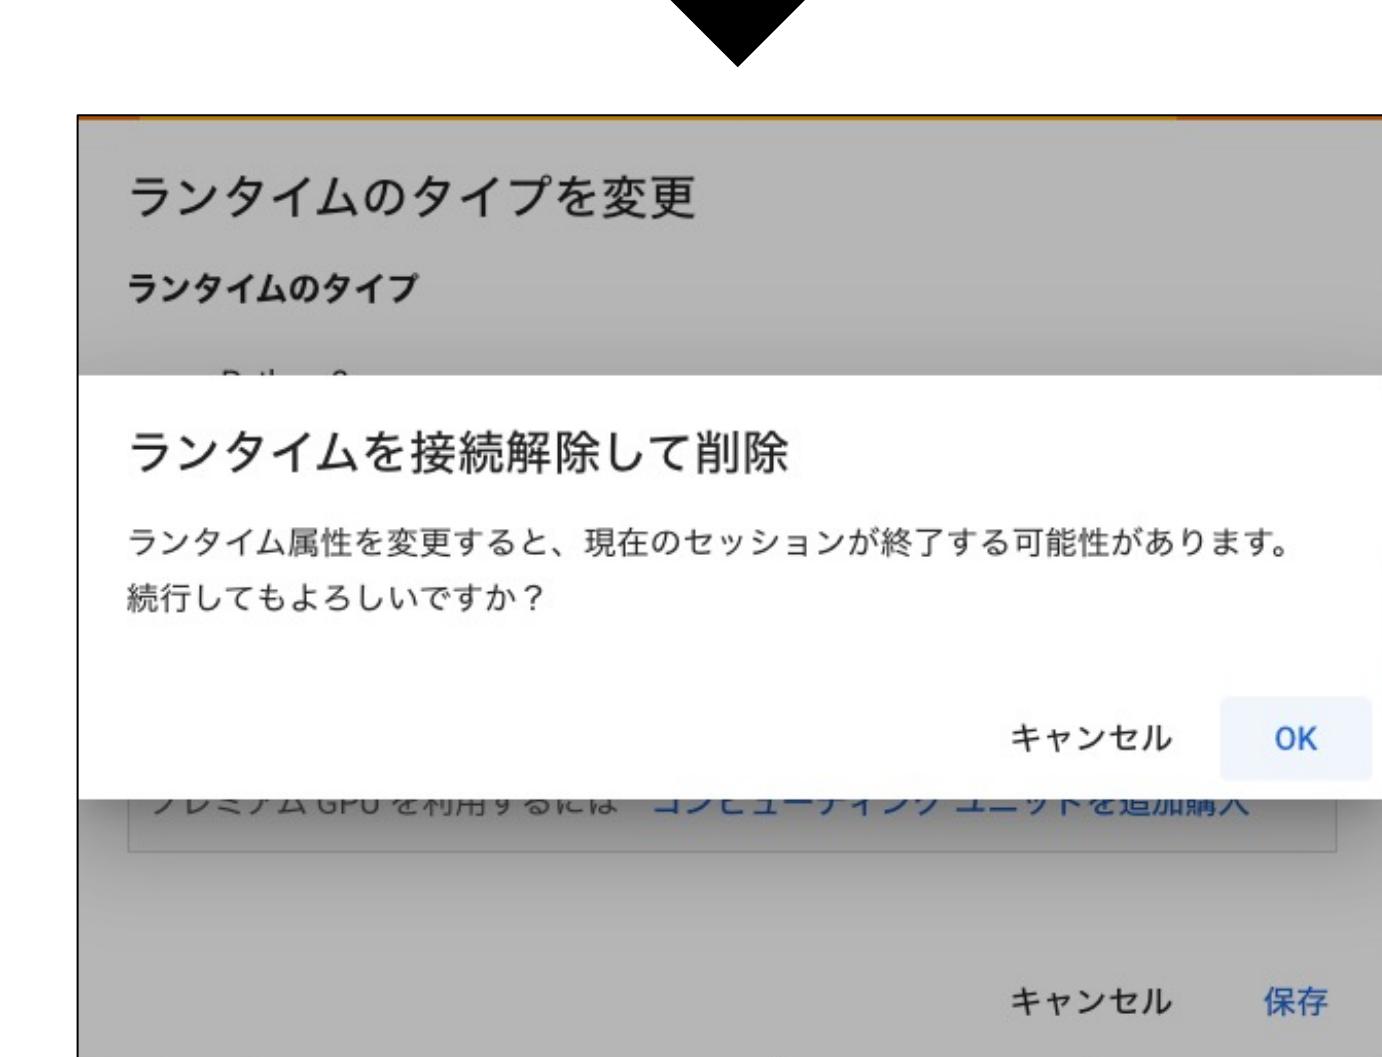


入門編で行った深層学習



これは実はMLP(Multi Layer Perceptron)

今日からGPUに切り替えて実行します 「ランタイム」→「ランタイムのタイプを変更」 ハードウェアタイプをCPUからT4 GPUに変更



(前回のファイルを開いて)
前処理までを再度実行しましょう

```
from tensorflow.keras.datasets import mnist  
(x_train, y_train), (x_test, y_test) = mnist.load_data()  
  
x_train = x_train.reshape(x_train.shape[0],784)/255  
x_test = x_test.reshape(x_test.shape[0],784)/255  
  
from tensorflow.keras.utils import to_categorical  
y_train = to_categorical(y_train,10)  
y_test = to_categorical(y_test,10)
```

前回のファイルが見つからない人は**webclass**の応用
4.20231102_template.ipynbをダウンロードして開いてください

```
from keras.datasets import mnist  
(x_train, y_train), (x_test, y_test) = mnist.load_data()
```

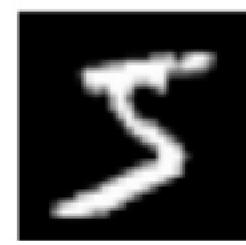
60000個

60000個

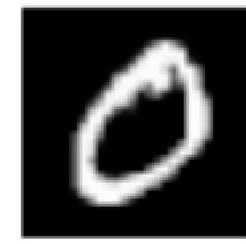
10000個

10000個

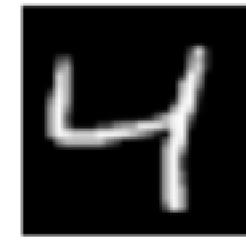
mnistのdataを読み込む



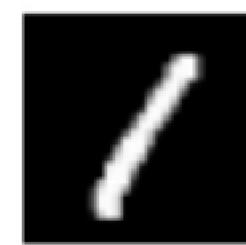
5



0



4

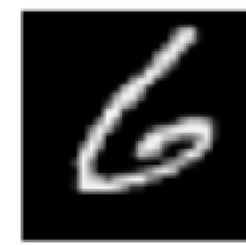


1

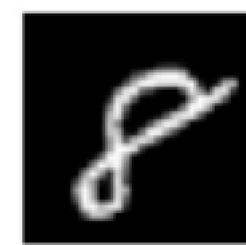
.

.

.



6



8



7



2

:

:



5



6

x_train : 60000枚の画像の配列データ

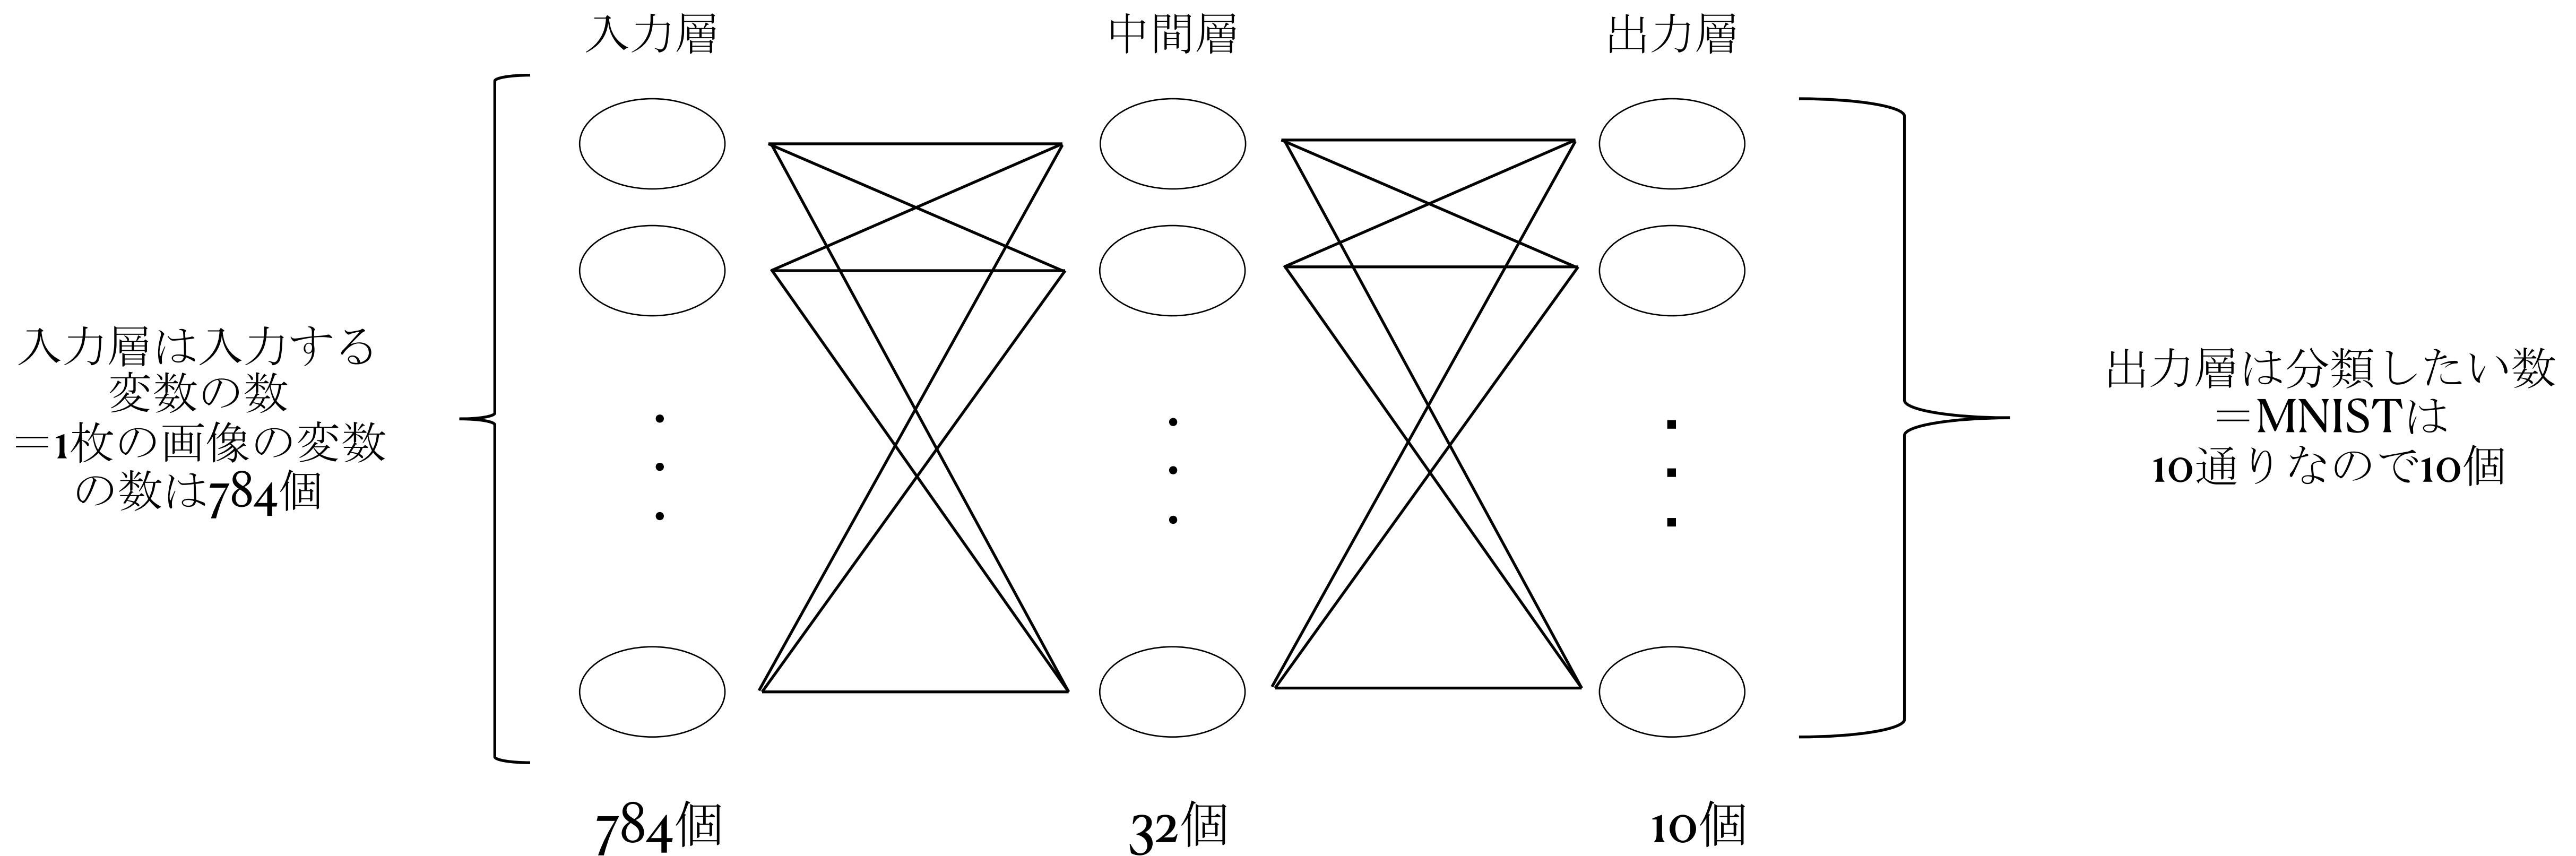
y_train : 60000枚の正解の数字の配列データ

x_test : 10000枚の画像の配列データ

y_test : 10000枚の正解の数字の配列データ

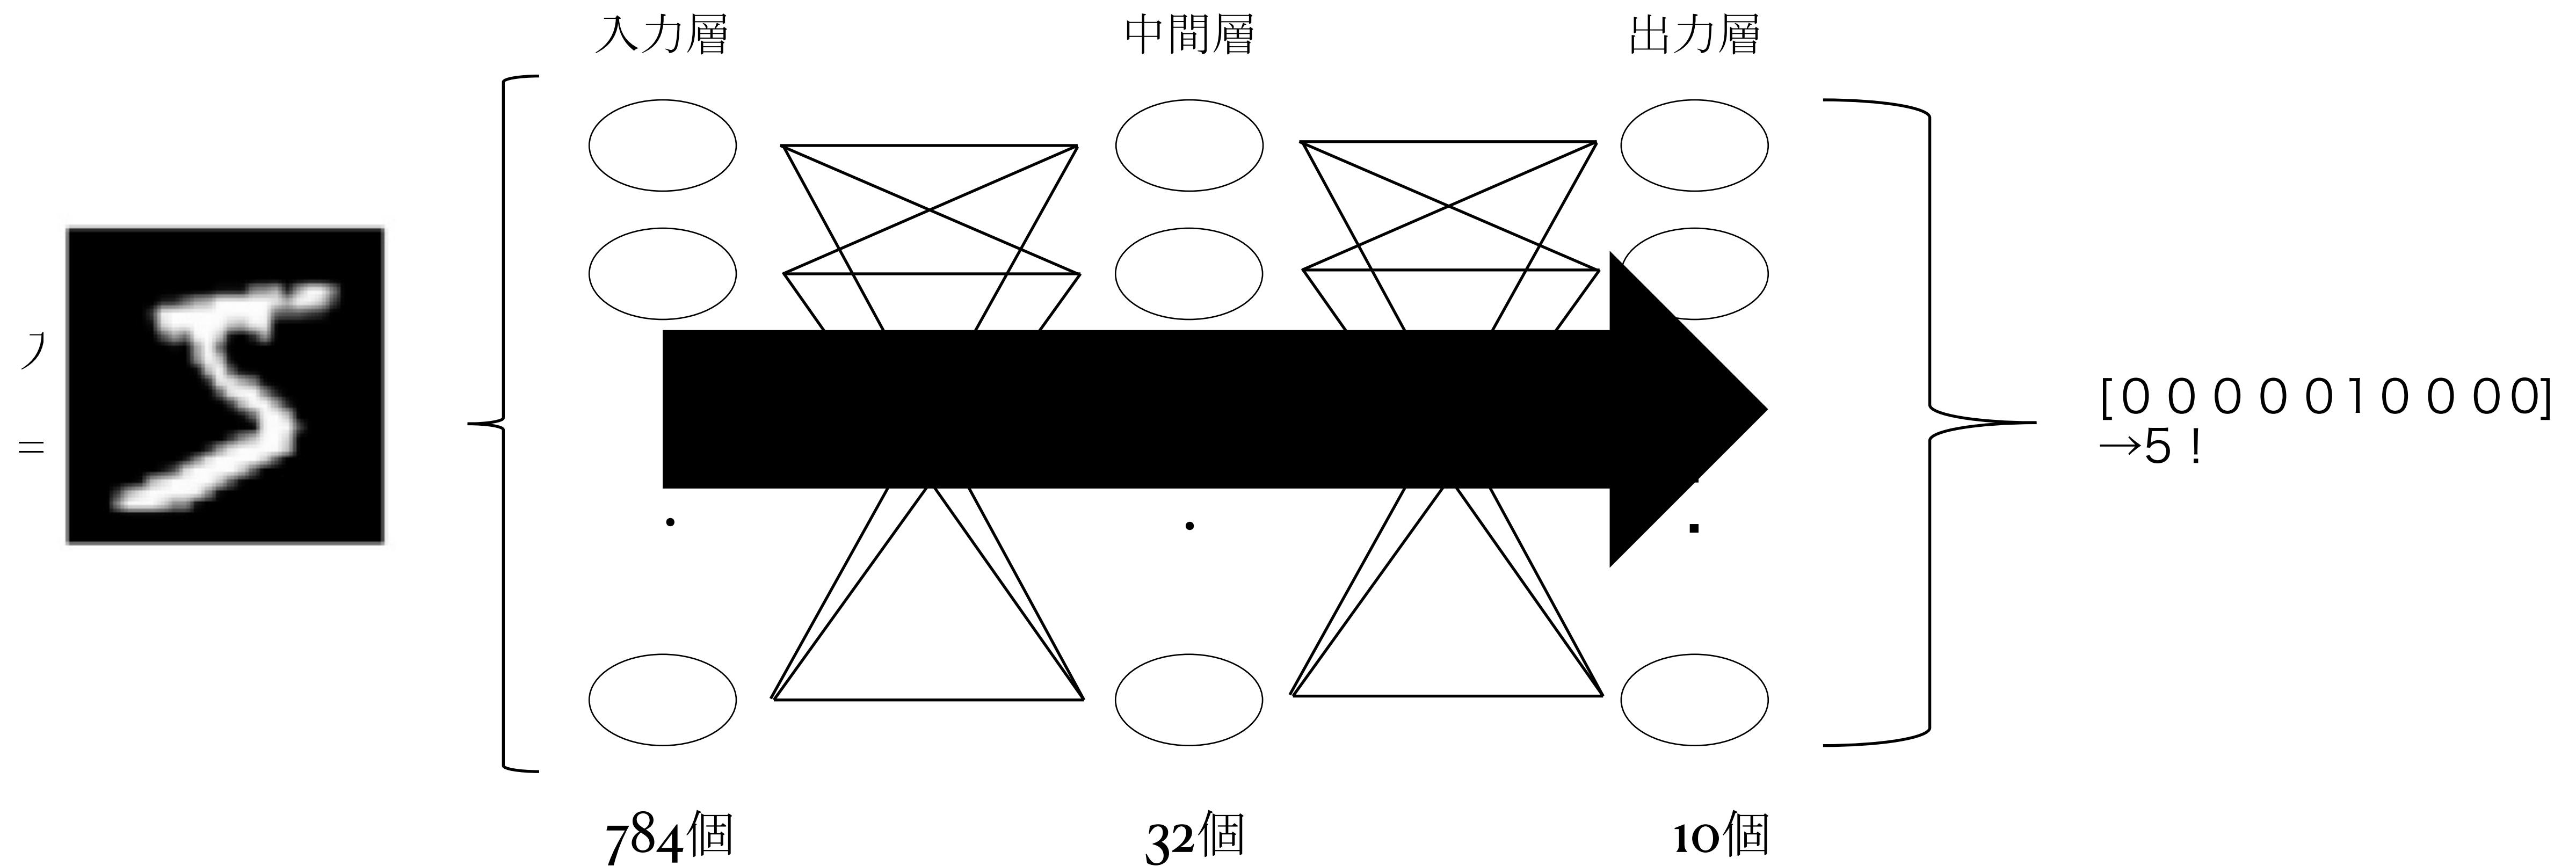
```
from keras.models import Sequential  
from keras.layers import Dense
```

```
model = Sequential()  
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))  
model.compile(loss='categorical_crossentropy', optimizer='Adam', metrics=['accuracy'])  
model.summary()
```



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

```
model = Sequential()  
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))  
model.compile(loss='categorical_crossentropy', optimizer='Adam', metrics=['accuracy'])  
model.summary()
```



```
from keras.models import Sequential
```

→tensorflowのkerasのmodelsの中のSequentialという関数を読み込む
→ここから下ではSequential()という書き方で使用できる

```
from keras.layers import Dense
```

→tensorflowのkerasのlayersの中のDenseという関数を読み込む
→ここから下ではDense()という書き方で使用できる

```
model = Sequential()
```

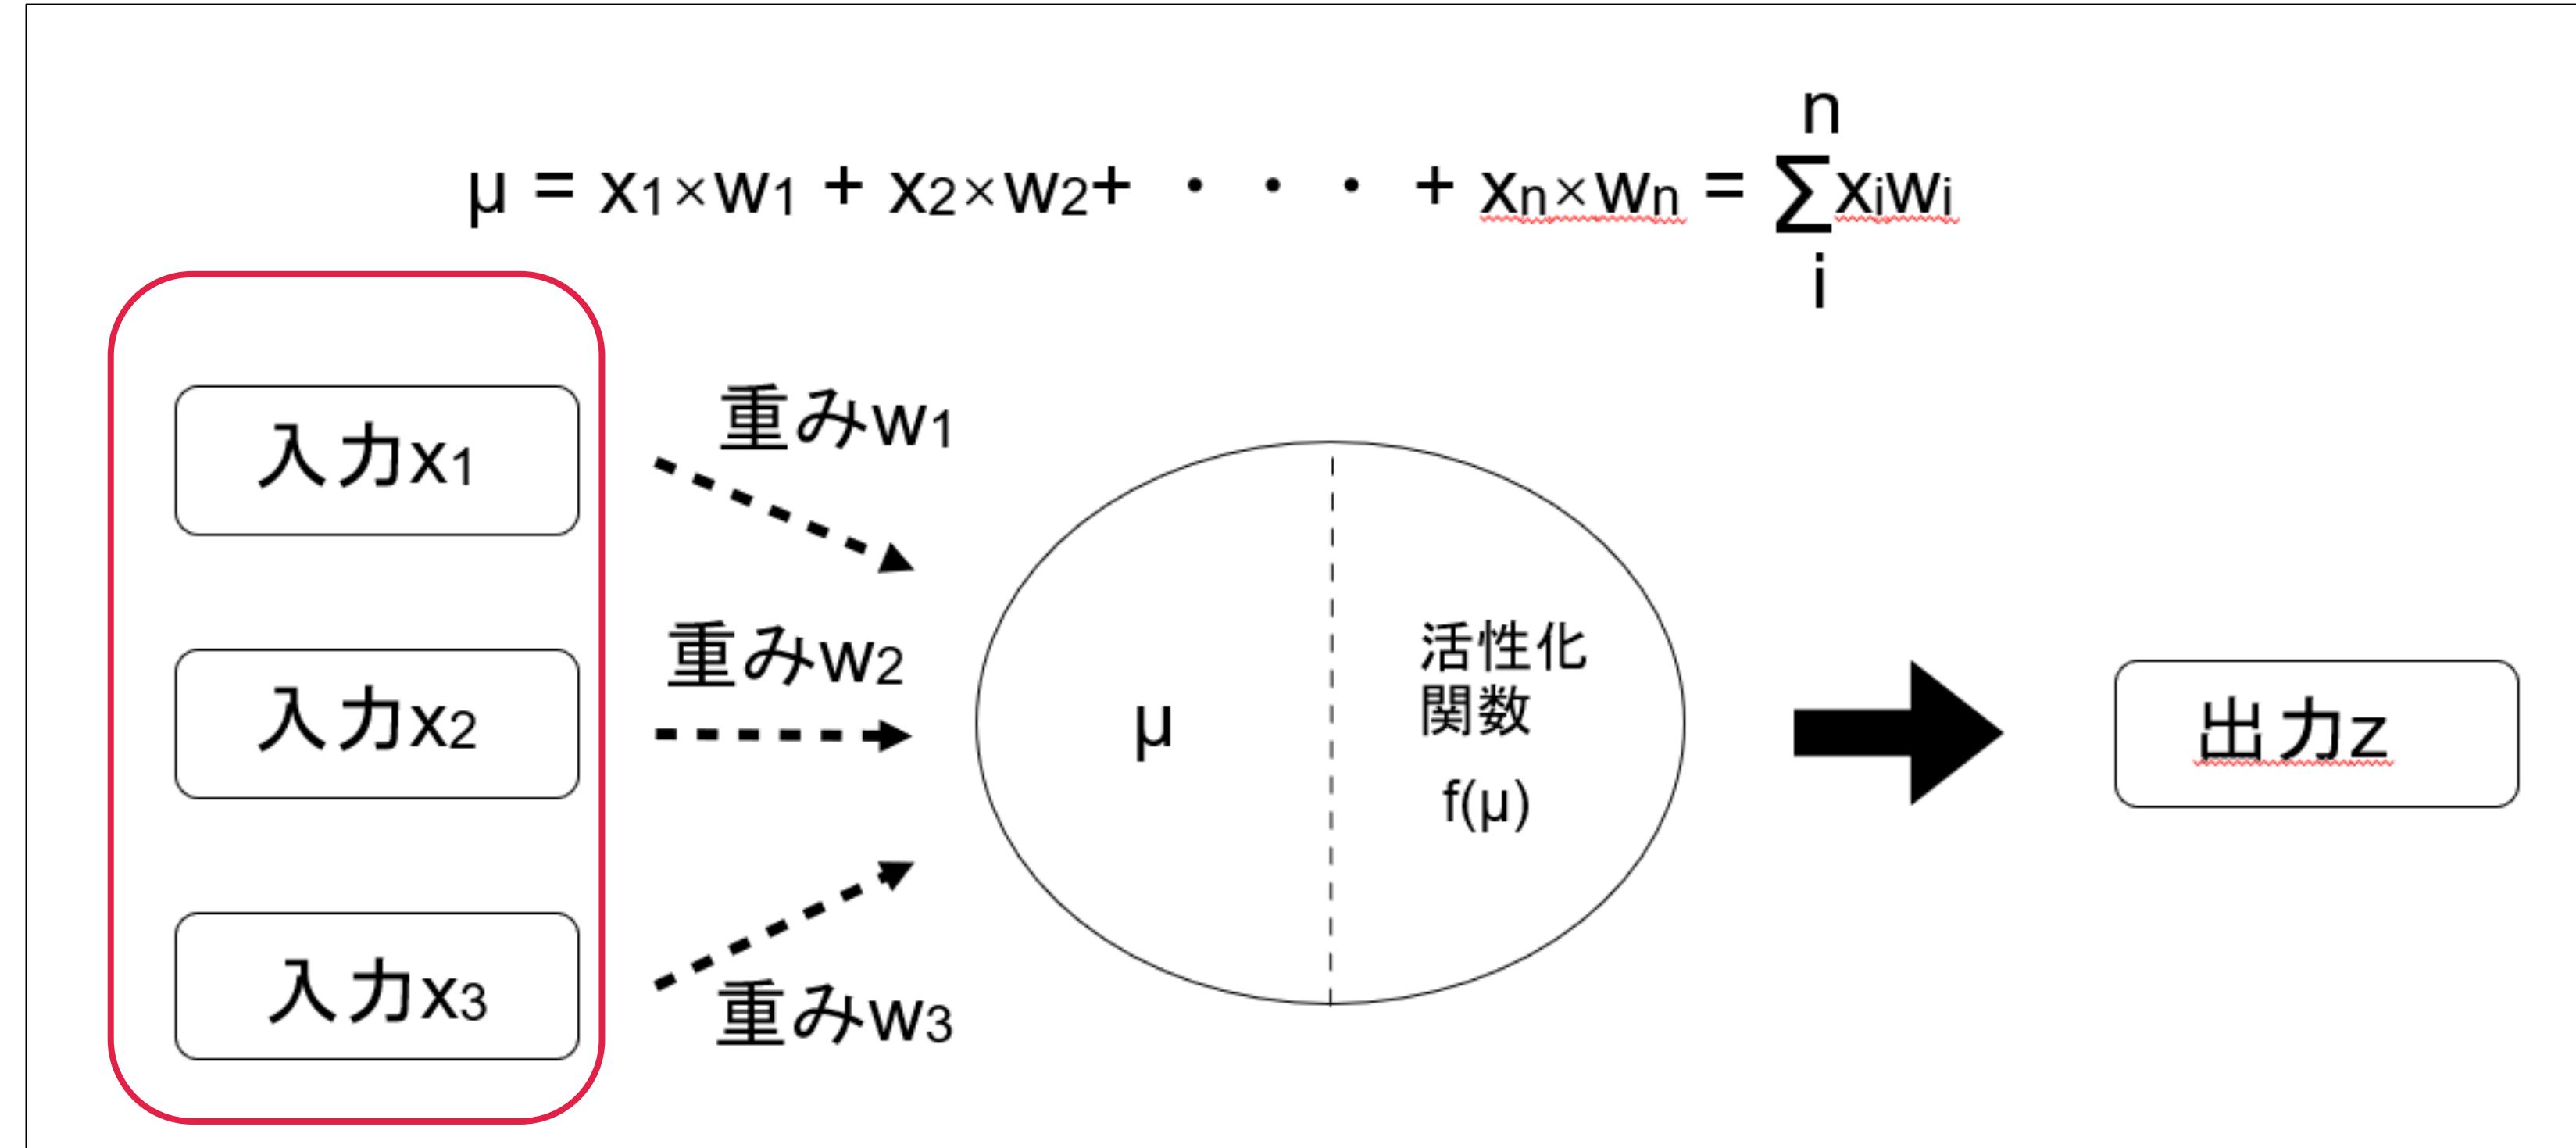
→"model"という変数名でSequential()を使用する
→ここからmodel.～～という書き方でSequential()の機能を使える

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))  
model.compile(loss='categorical_crossentropy', optimizer='Adam', metrics=['accuracy'])  
model.summary()
```

```
model.add(Dense(32, input_shape=(784,), activation='relu'))
model.add(Dense(10, activation='softmax'))
```

784個

- 0.53
- 0.24
- 0.88
- 0.34



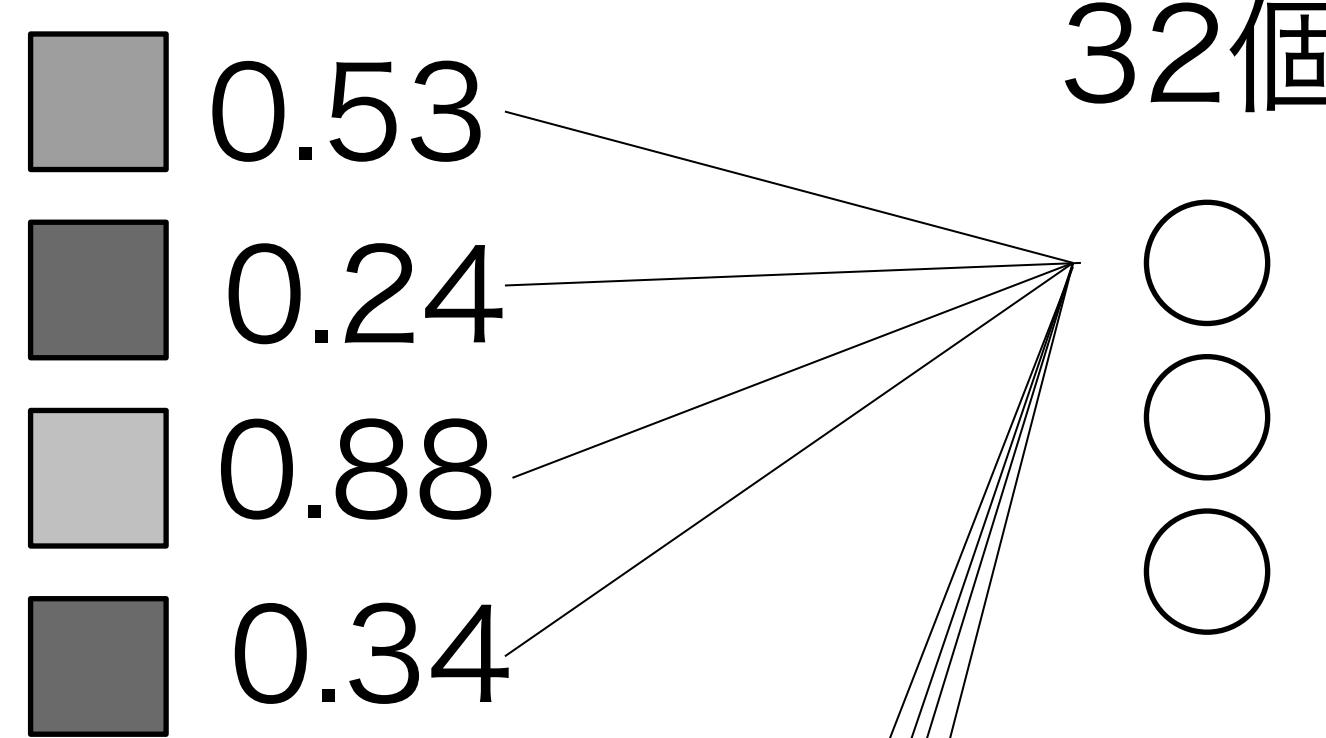
- 0.11
- 0.91
- 0.57

MLPでは1枚ずつモデルに入力する
1枚は784個の数値（0～1）で表されている
=上の図の入力値がX₁～X₇₈₄の784個ある

(バイアス項): b

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

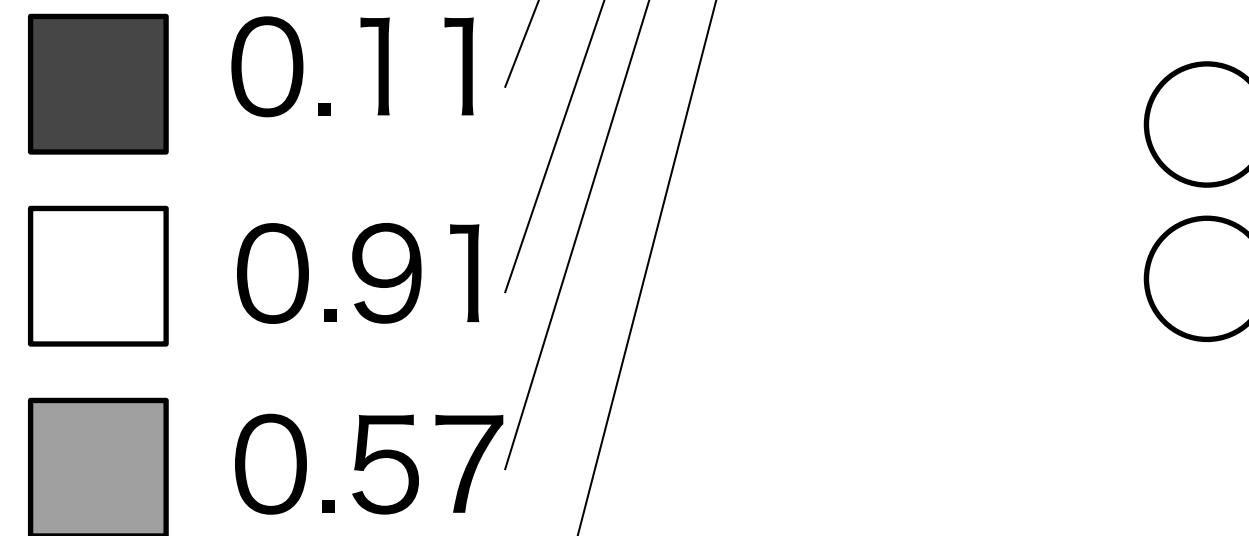
784個



32個

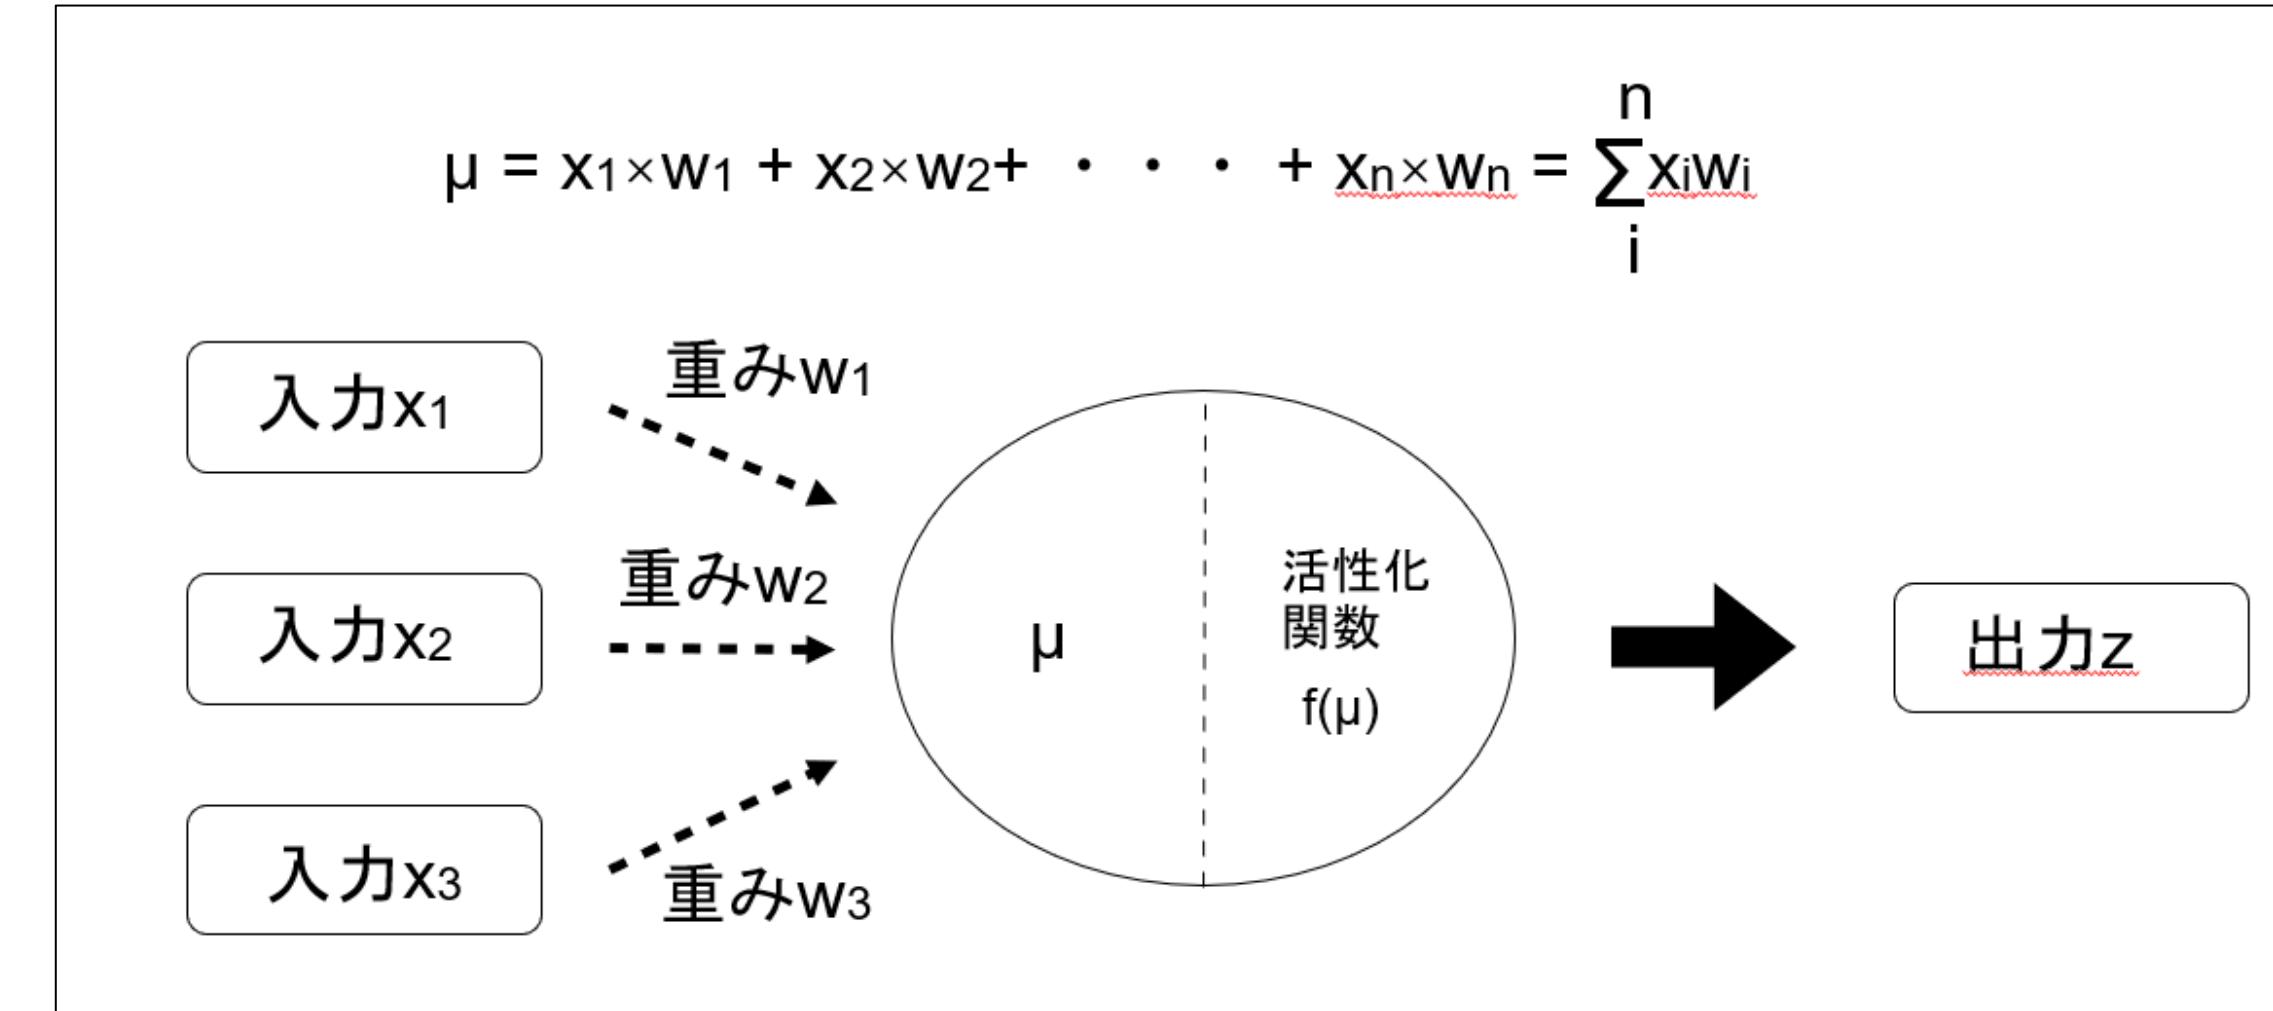
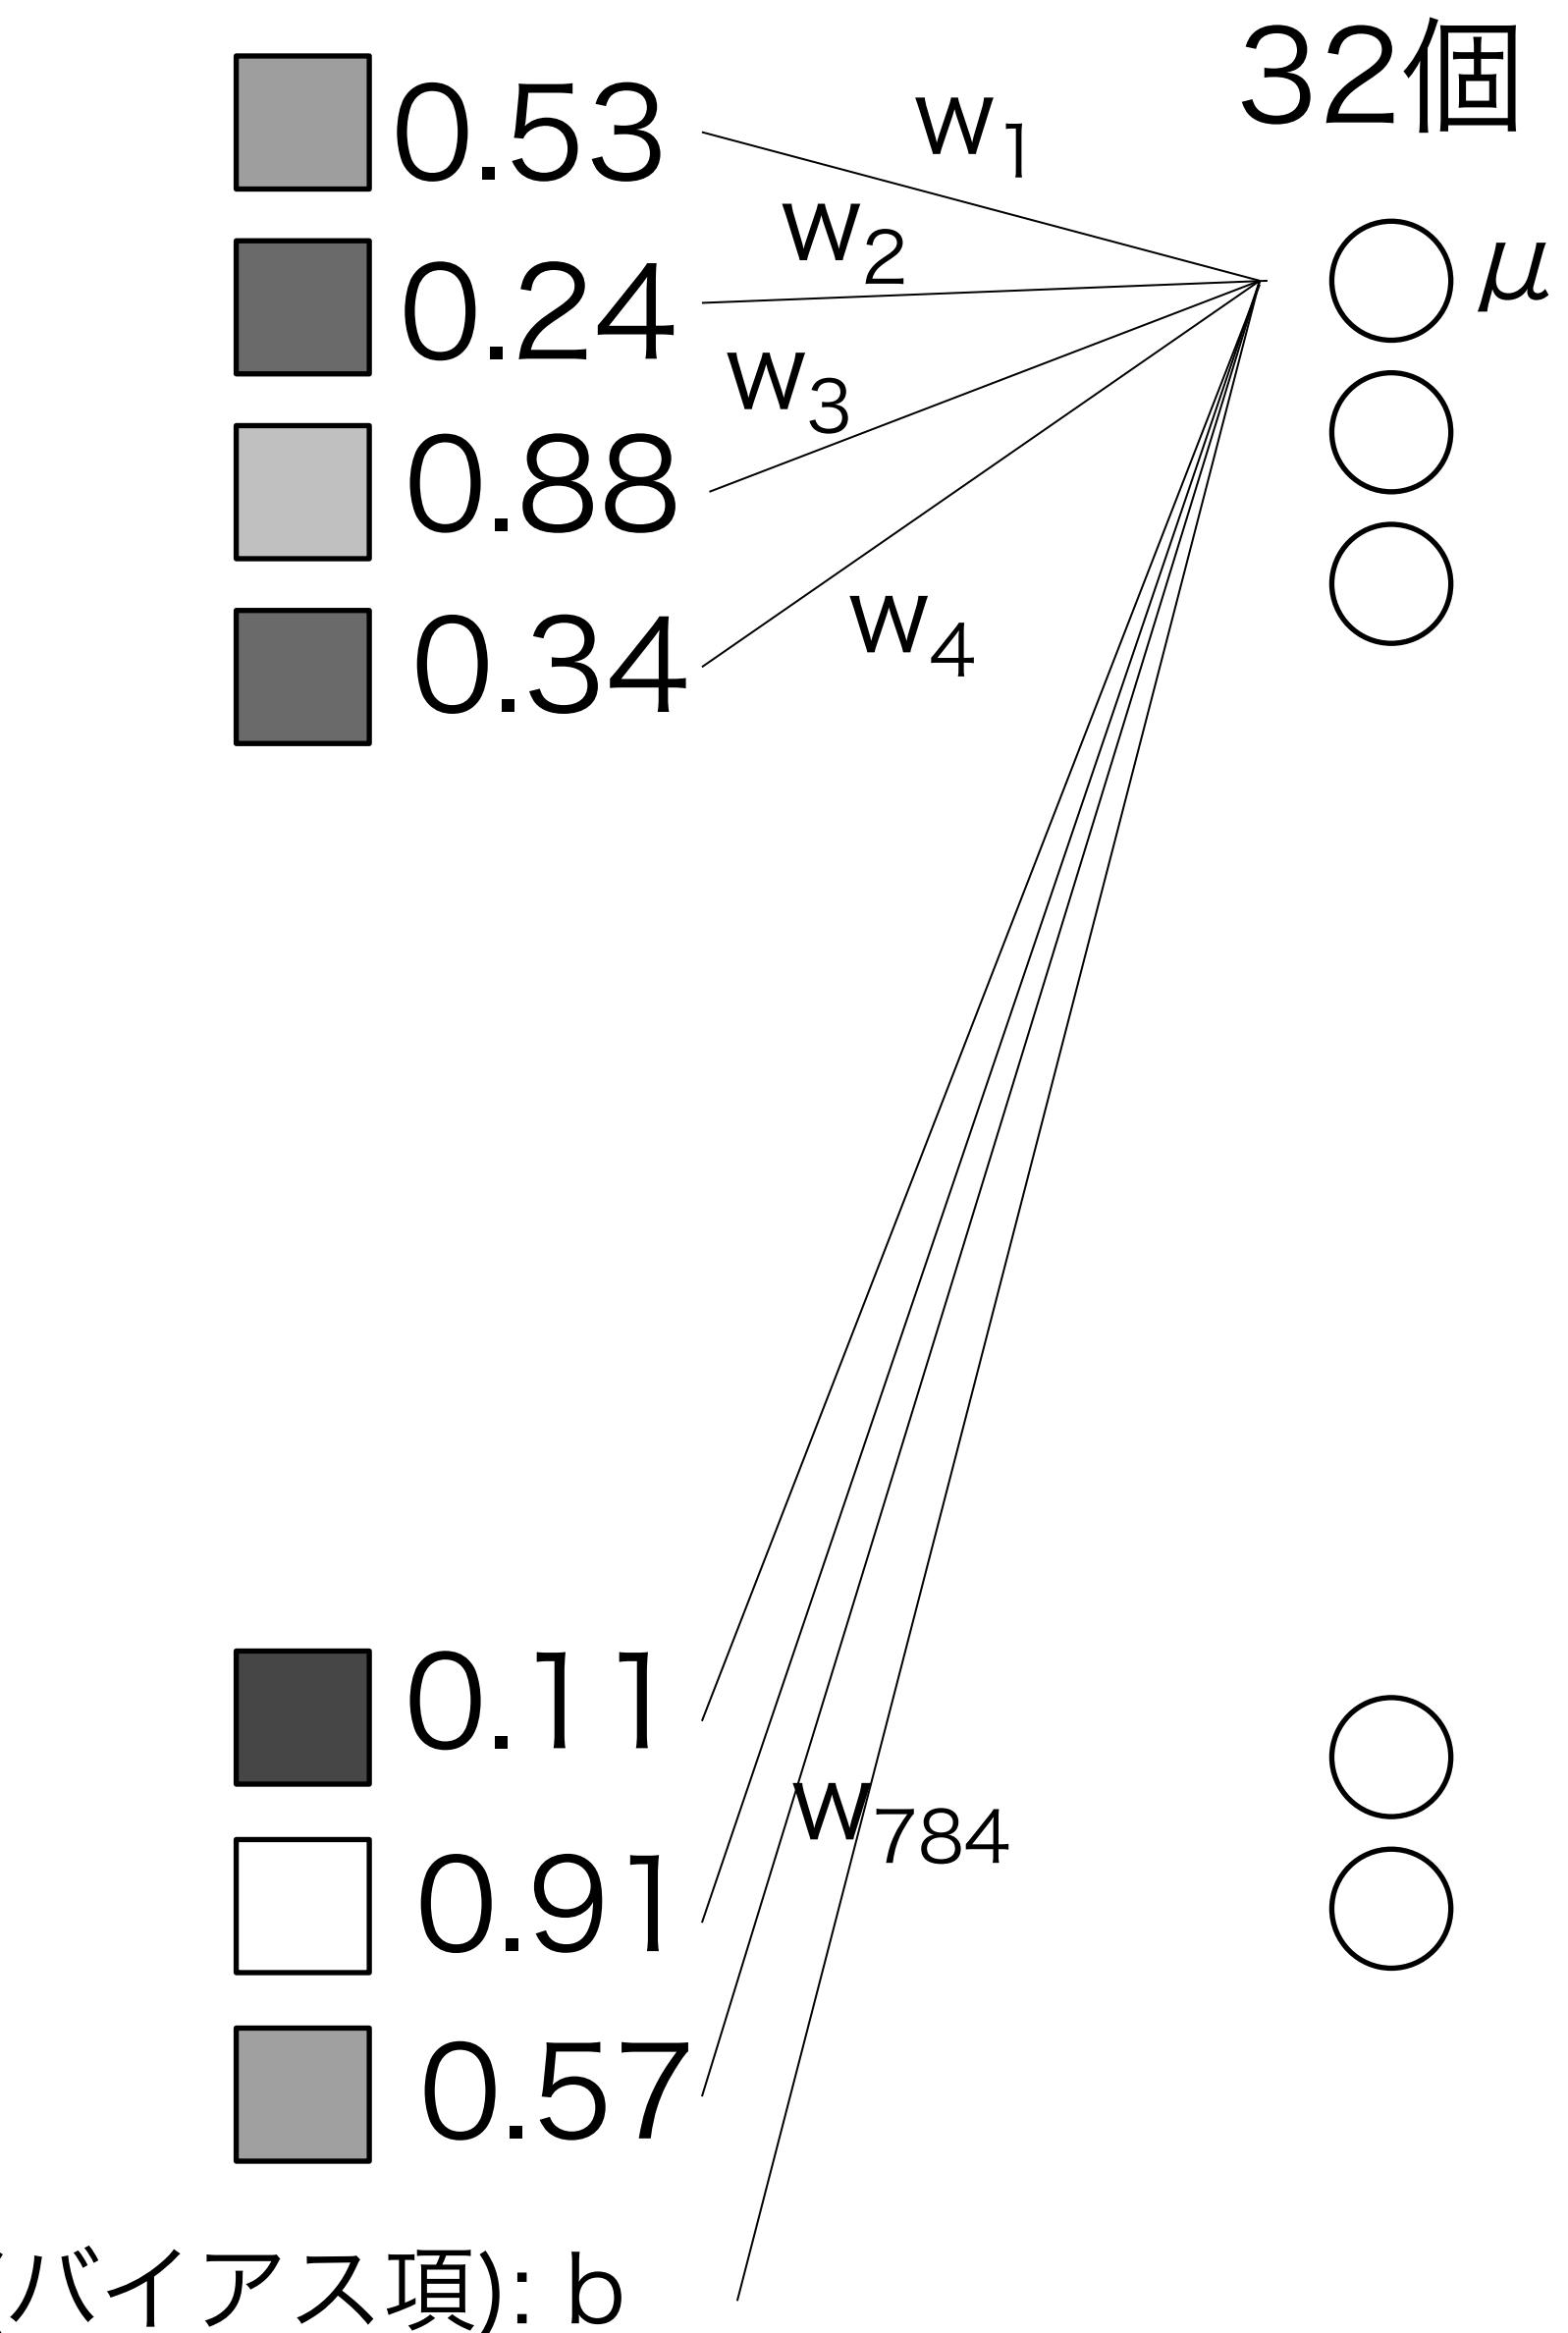
model.add()で層を追加する
Dense()で次の層のニューロンと全てつなげる(全結合)
(units=)32 : 次の層のニューロンの数が32個(unitsは省略可)
input_shape=(784,) : 入力する変数の数
(自動的にバイアス項という定数も1つ追加される)
activation='relu' : 活性化関数はReLU関数

(バイアス項): b



```
model.add(Dense(32, input_shape=(784,), activation='relu'))
model.add(Dense(10, activation='softmax'))
```

784個

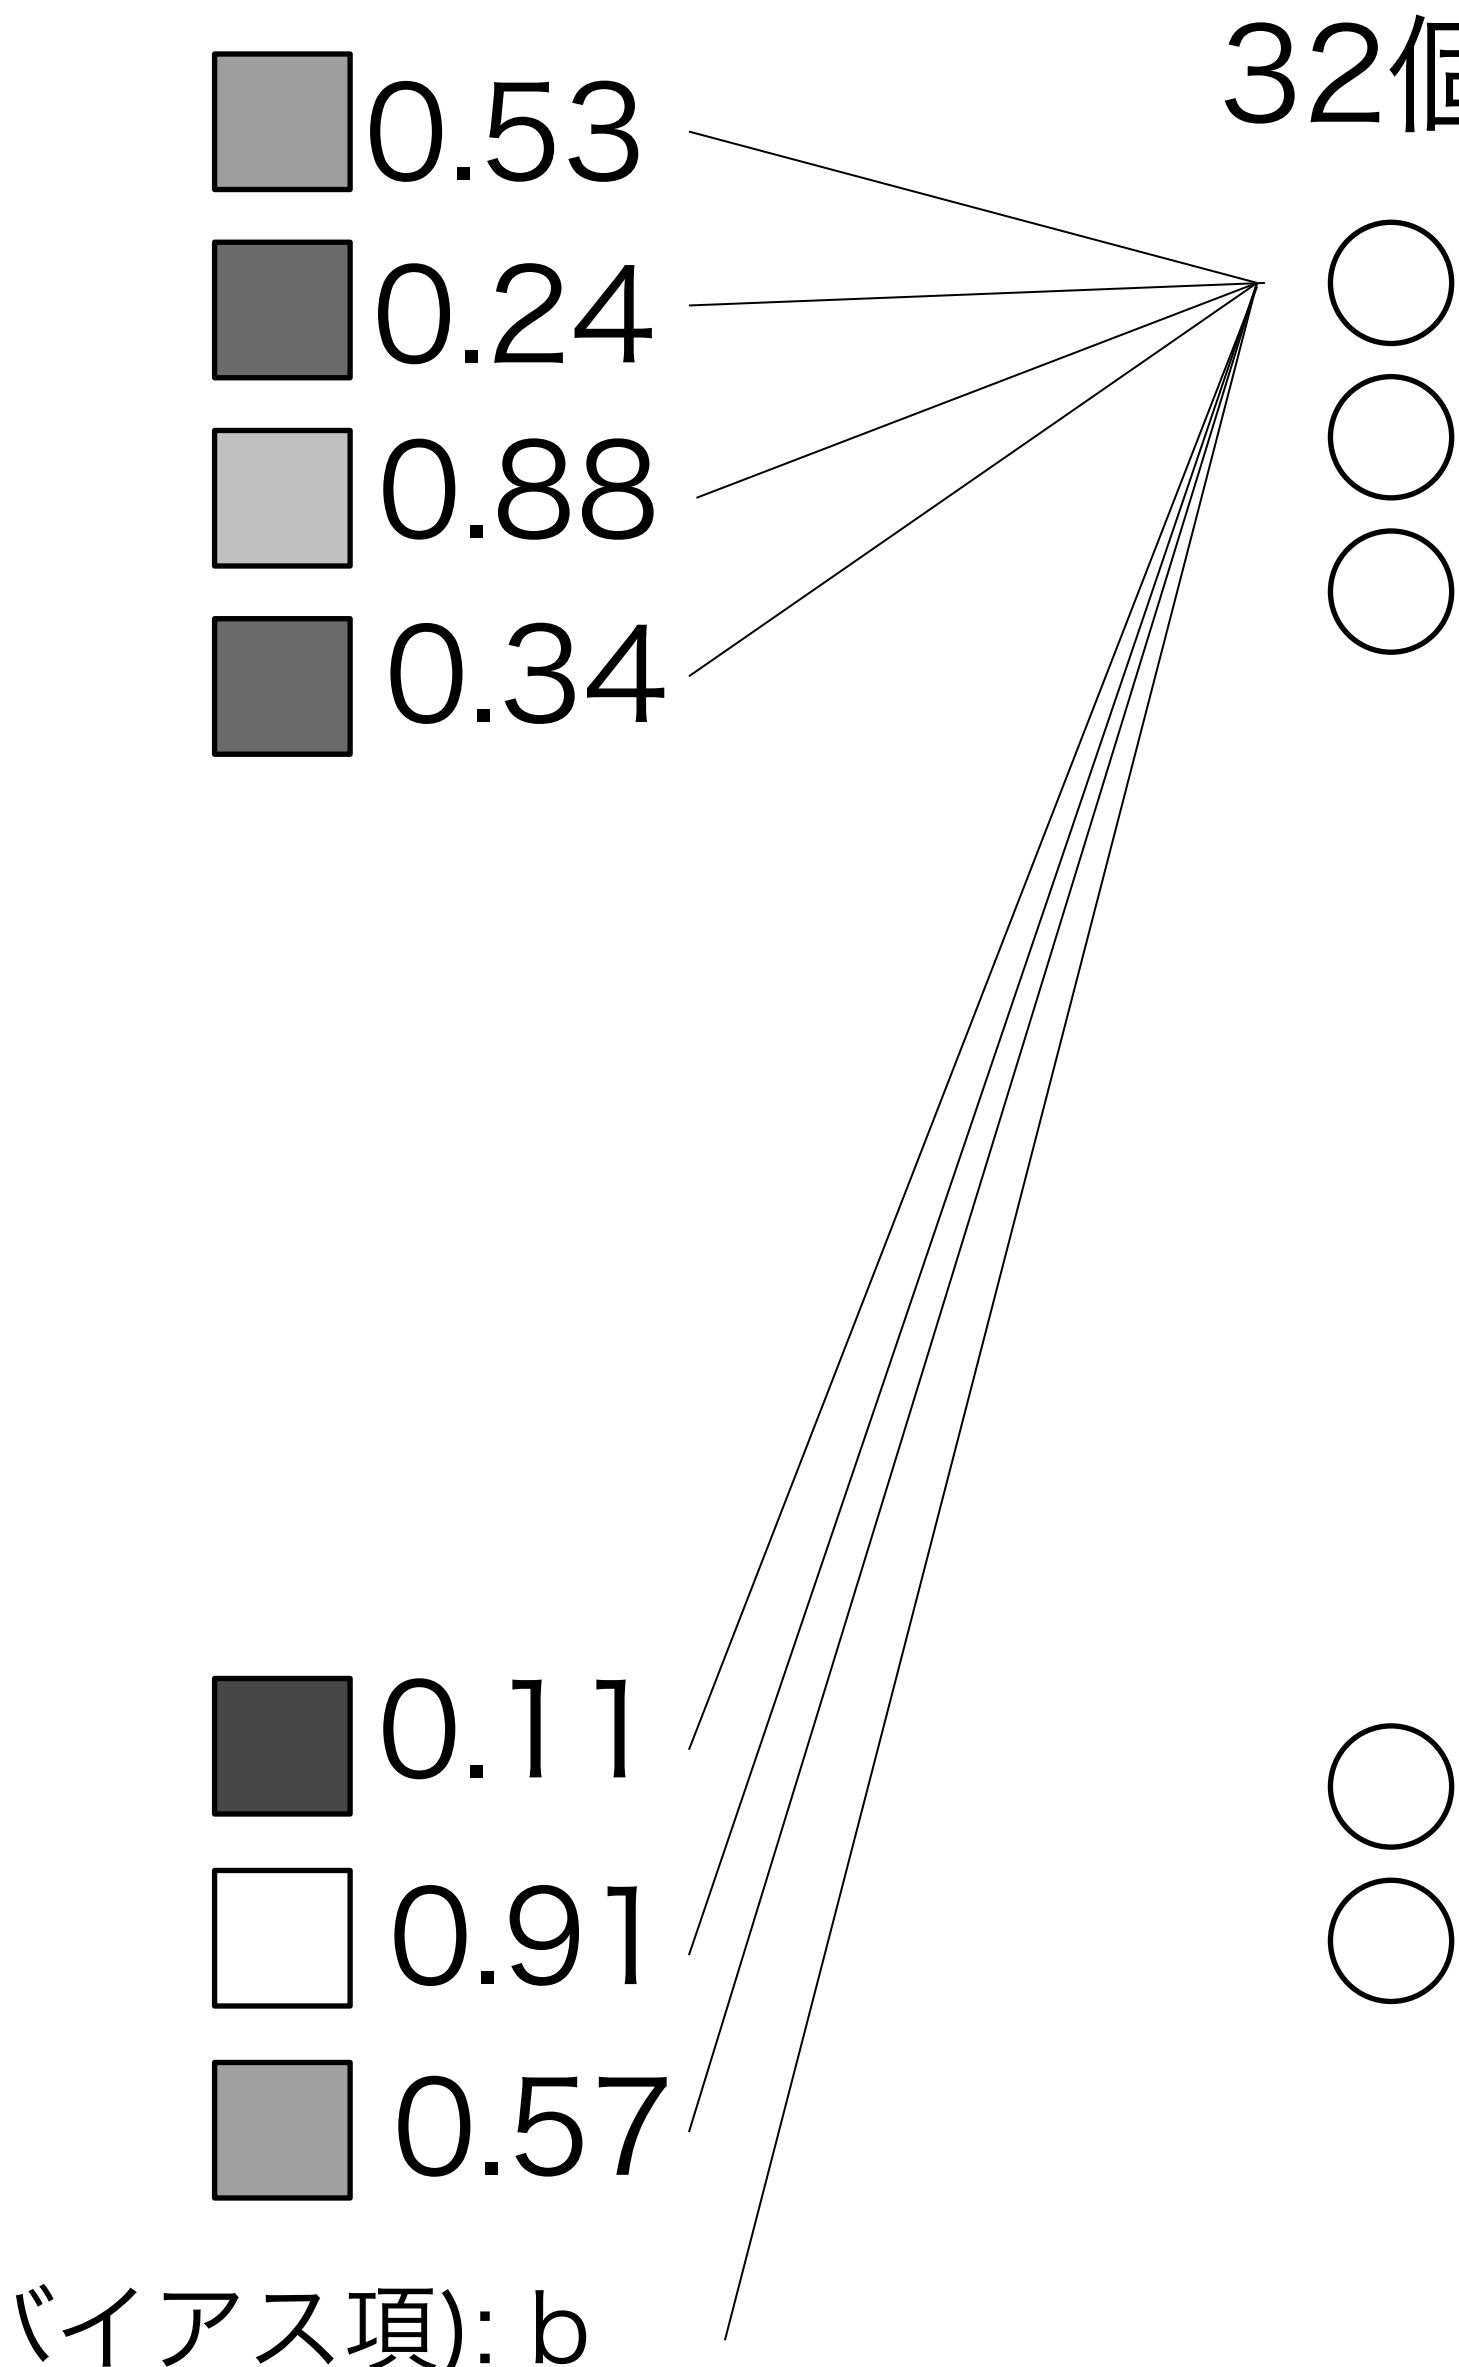


$$\mu_1 = 0.53 \times w_1 + 0.24 \times w_2 + 0.88 \times w_3 + \dots + 0.57 \times w_{784} + b$$

この時の重み w_1, w_2, \dots, w_{784} とバイアス項 b
はランダムに与えられる
(コンピュータがテキトーに値を決める)

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

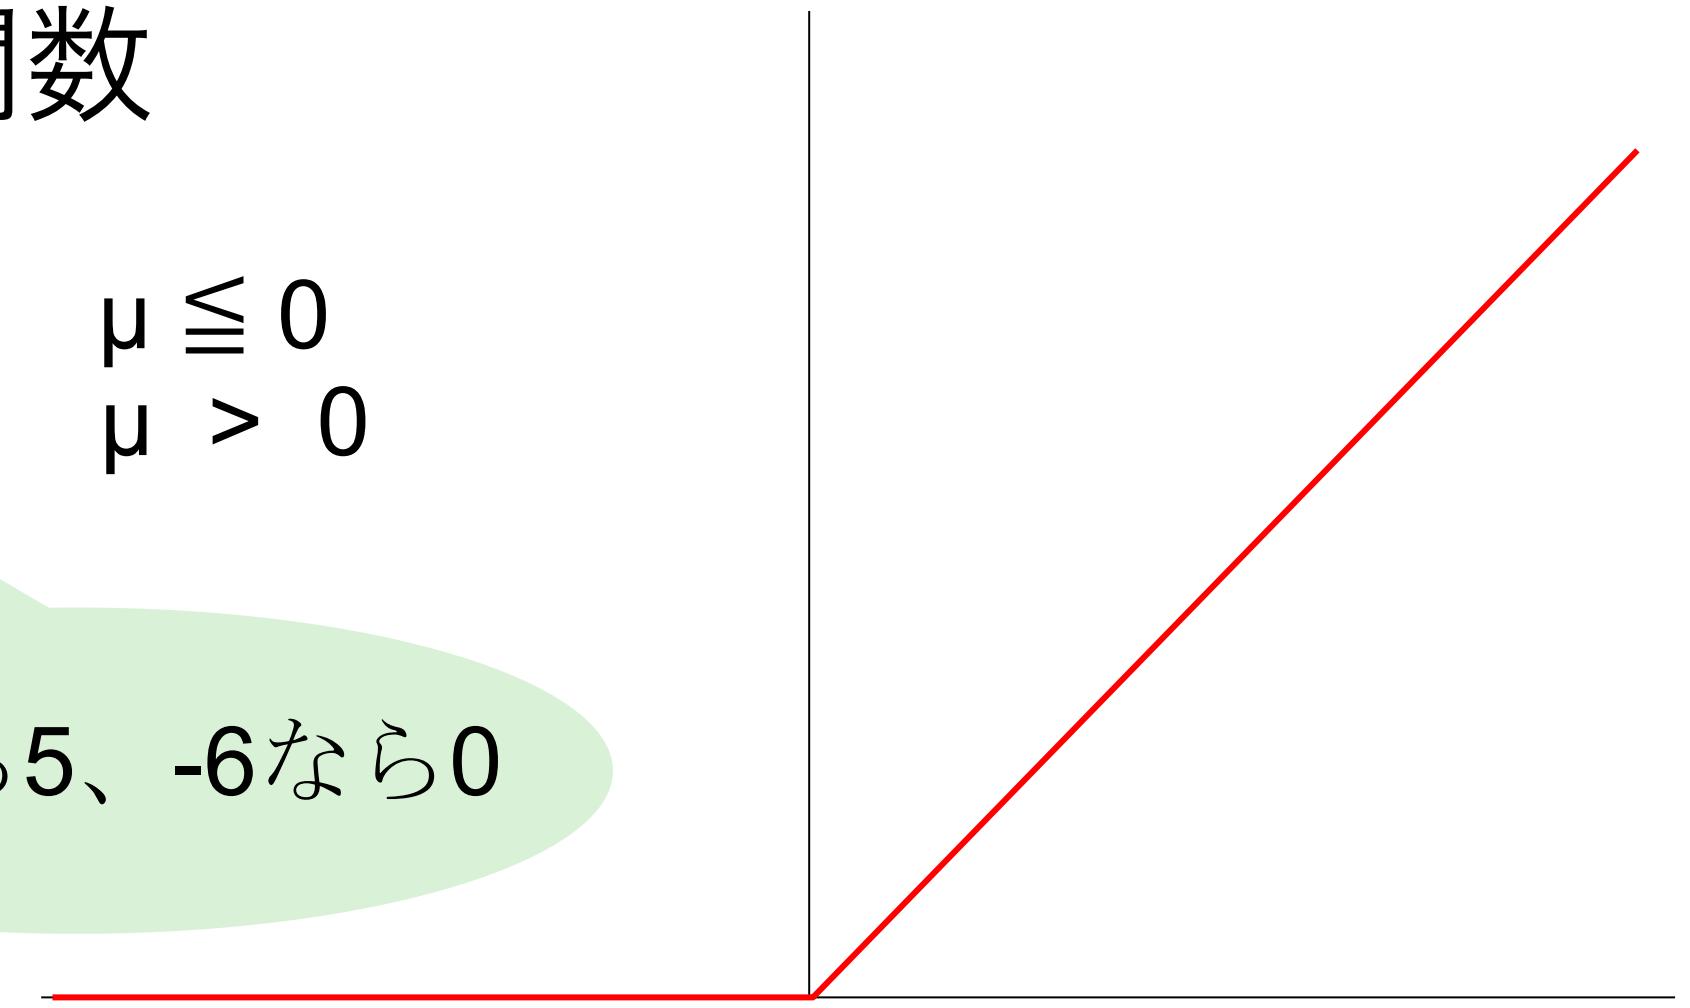
784個



ReLU関数

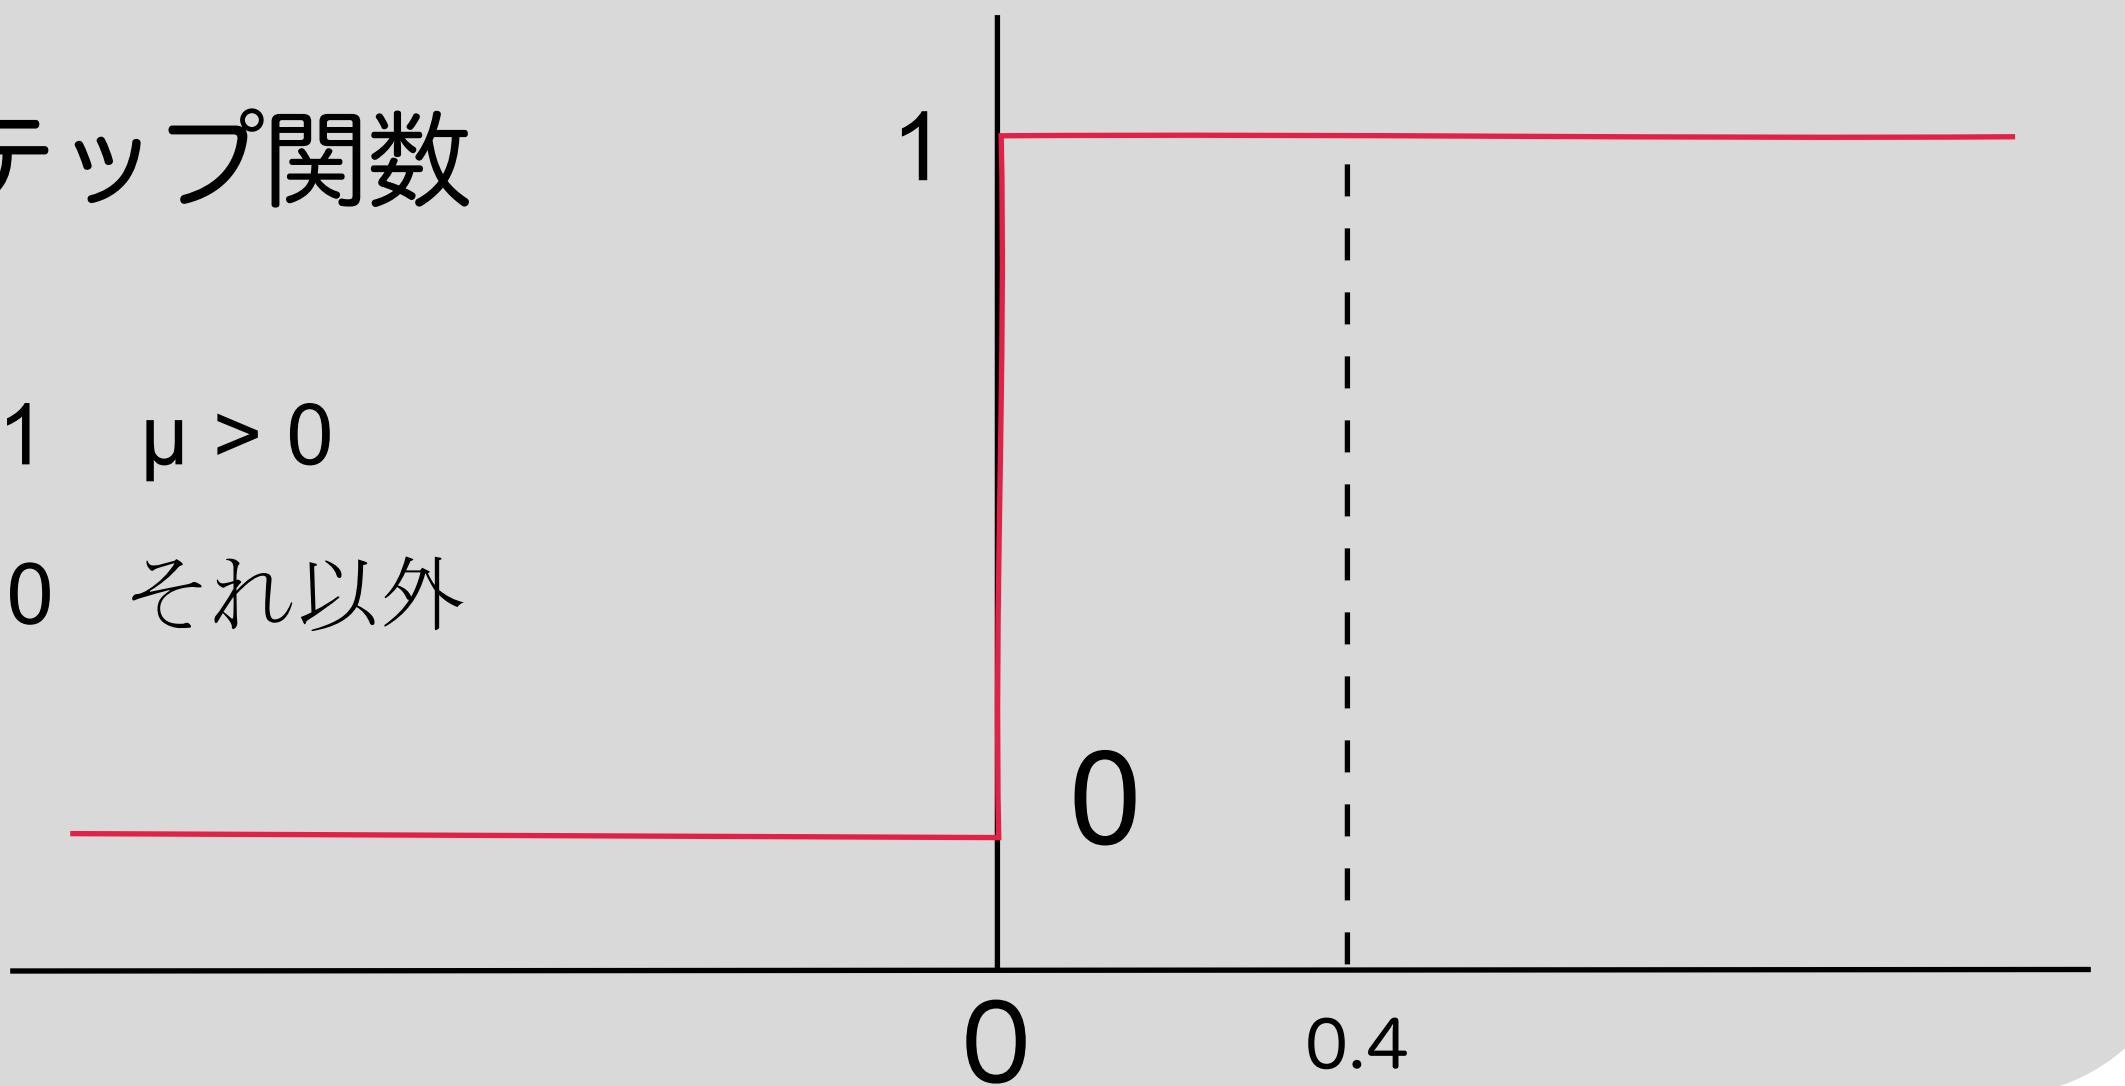
$$f(\mu) = \begin{cases} 0 & \mu \leq 0 \\ \mu & \mu > 0 \end{cases}$$

μ が5なら5、-6なら0



ステップ関数

$$f(\mu) = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$

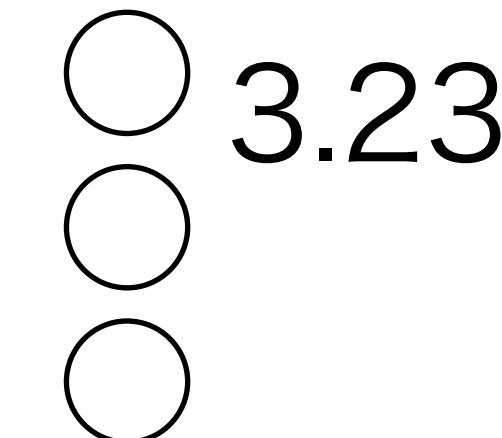


```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

784個

■ 0.53
■ 0.24
■ 0.88
■ 0.34

32個



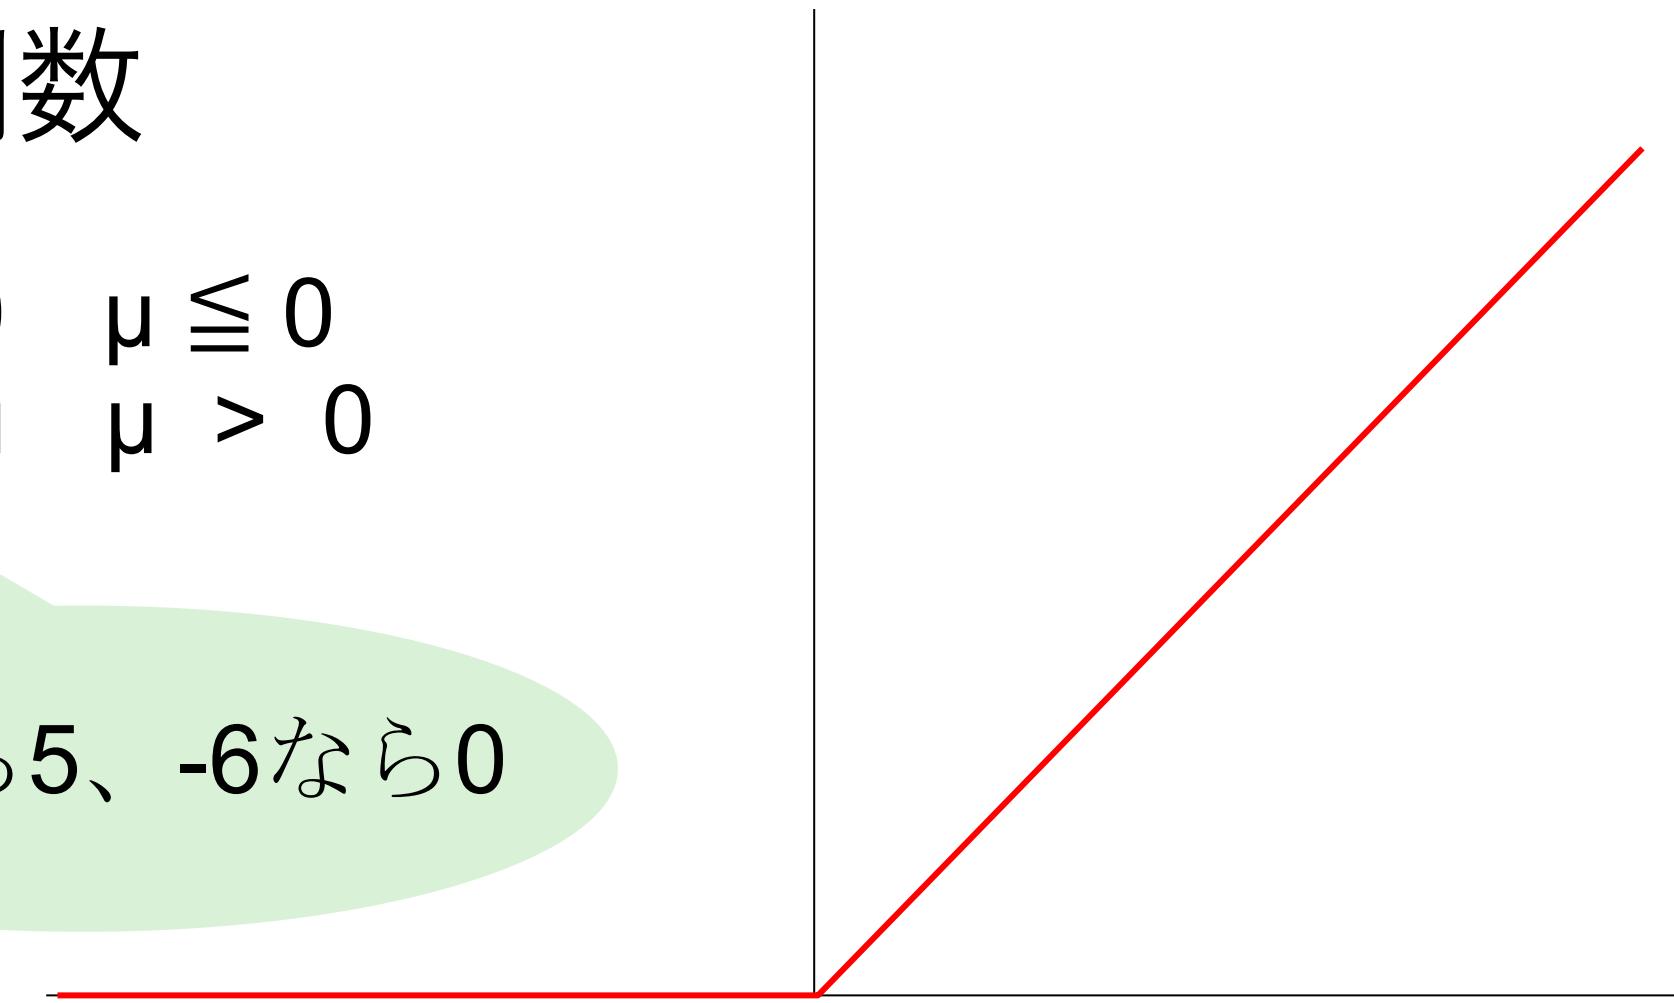
(バイアス項): b

■ 0.11
□ 0.91
■ 0.57

ReLU関数

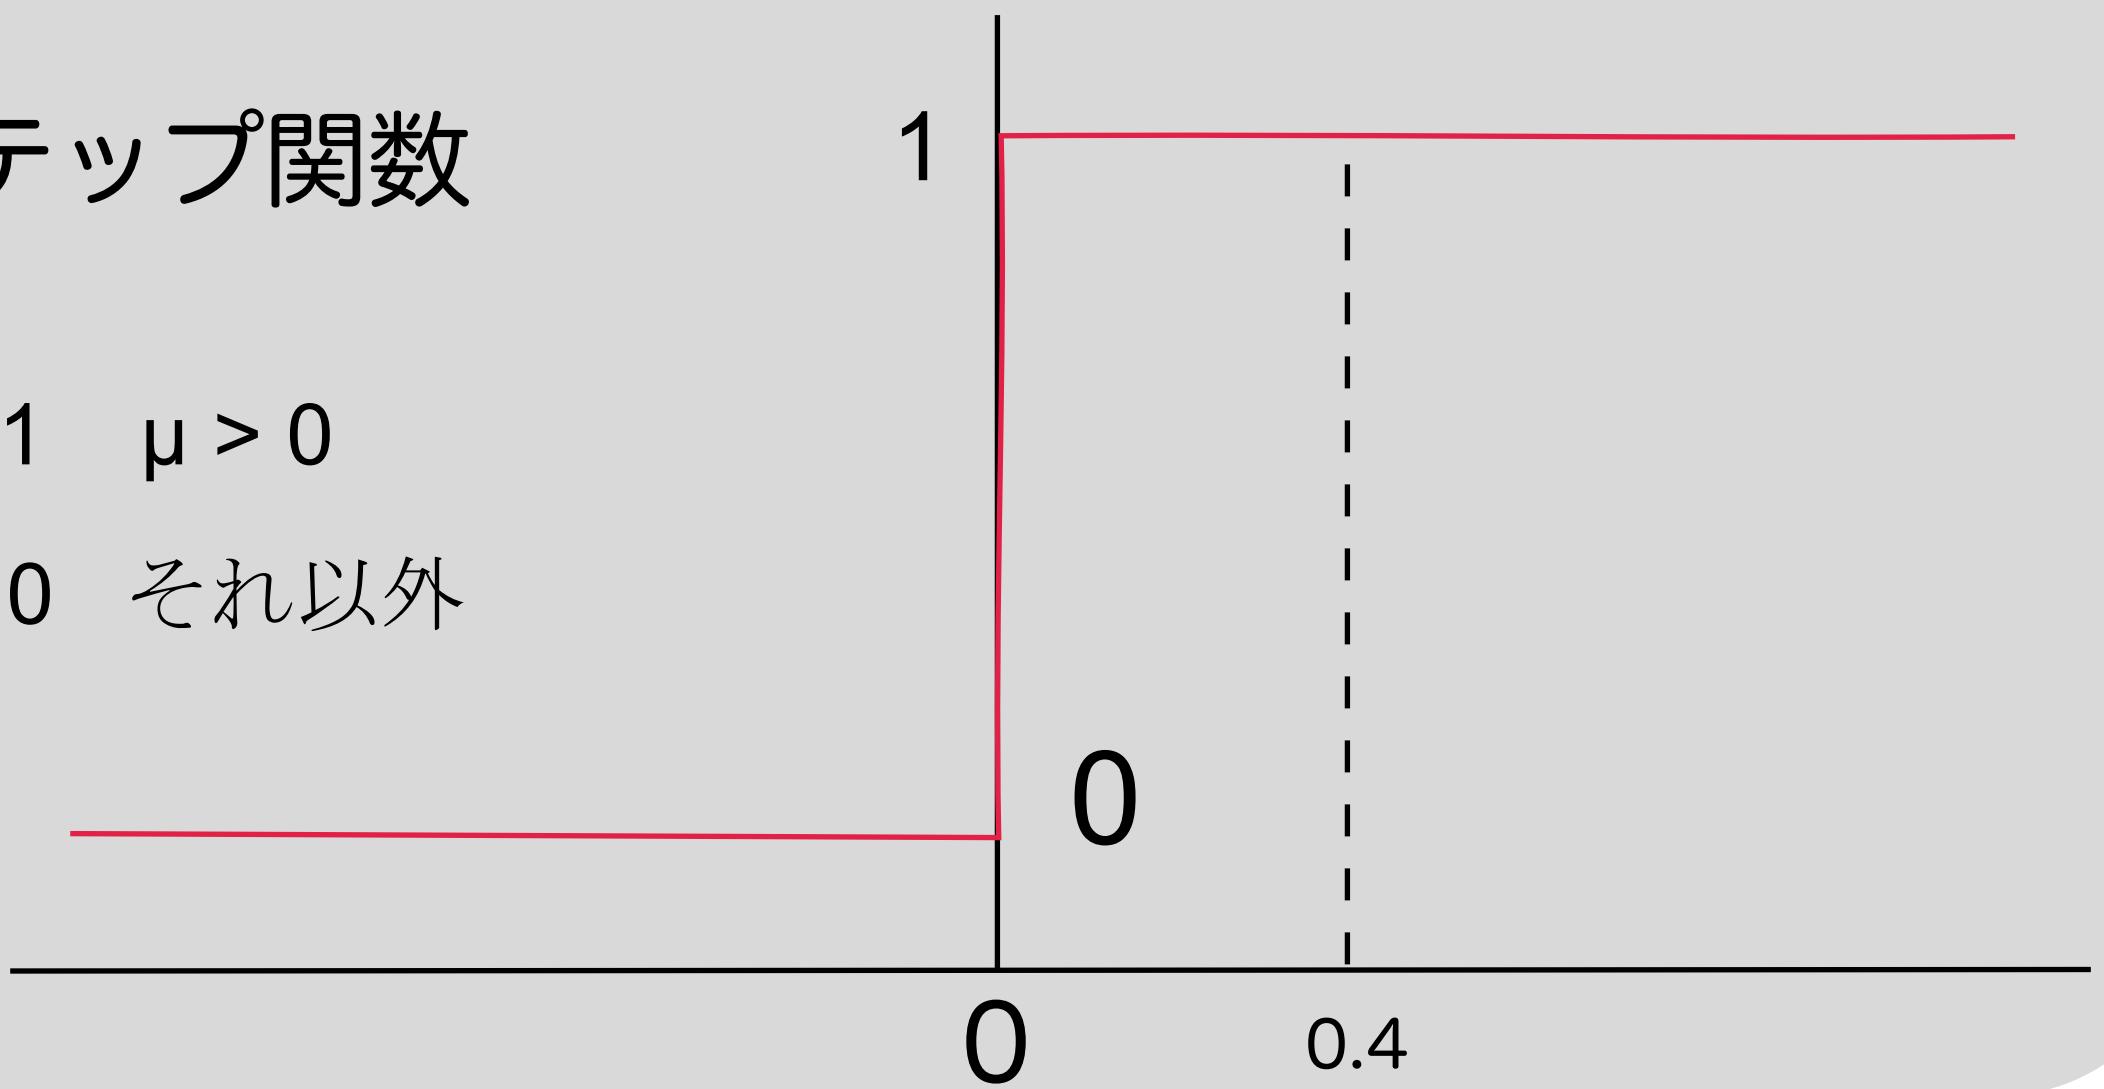
$$f(\mu) = \begin{cases} 0 & \mu \leq 0 \\ \mu & \mu > 0 \end{cases}$$

μ が5なら5、-6なら0



ステップ関数

$$f(\mu) = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$



```
model.add(Dense(32, input_shape=(784,), activation='relu'))
model.add(Dense(10, activation='softmax'))
```

784個

■ 0.53
■ 0.24
■ 0.88
■ 0.34

32個

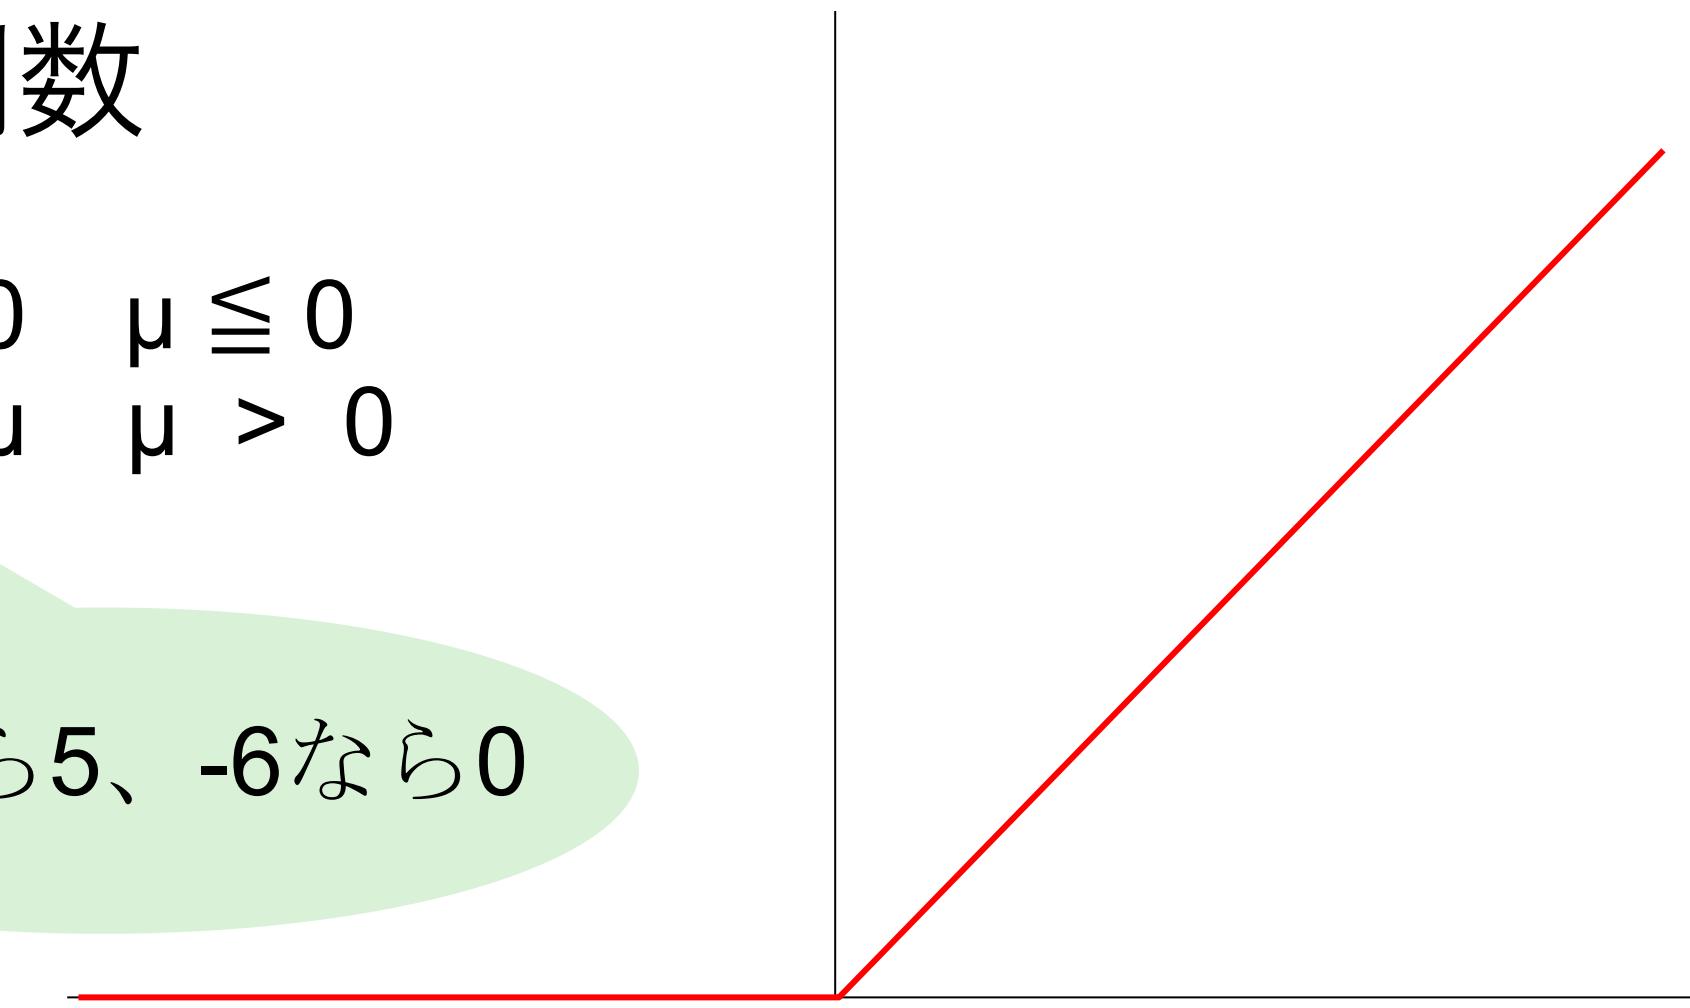
○ 3.23
○ 0
○ 8.45

(バイアス項): b

ReLU関数

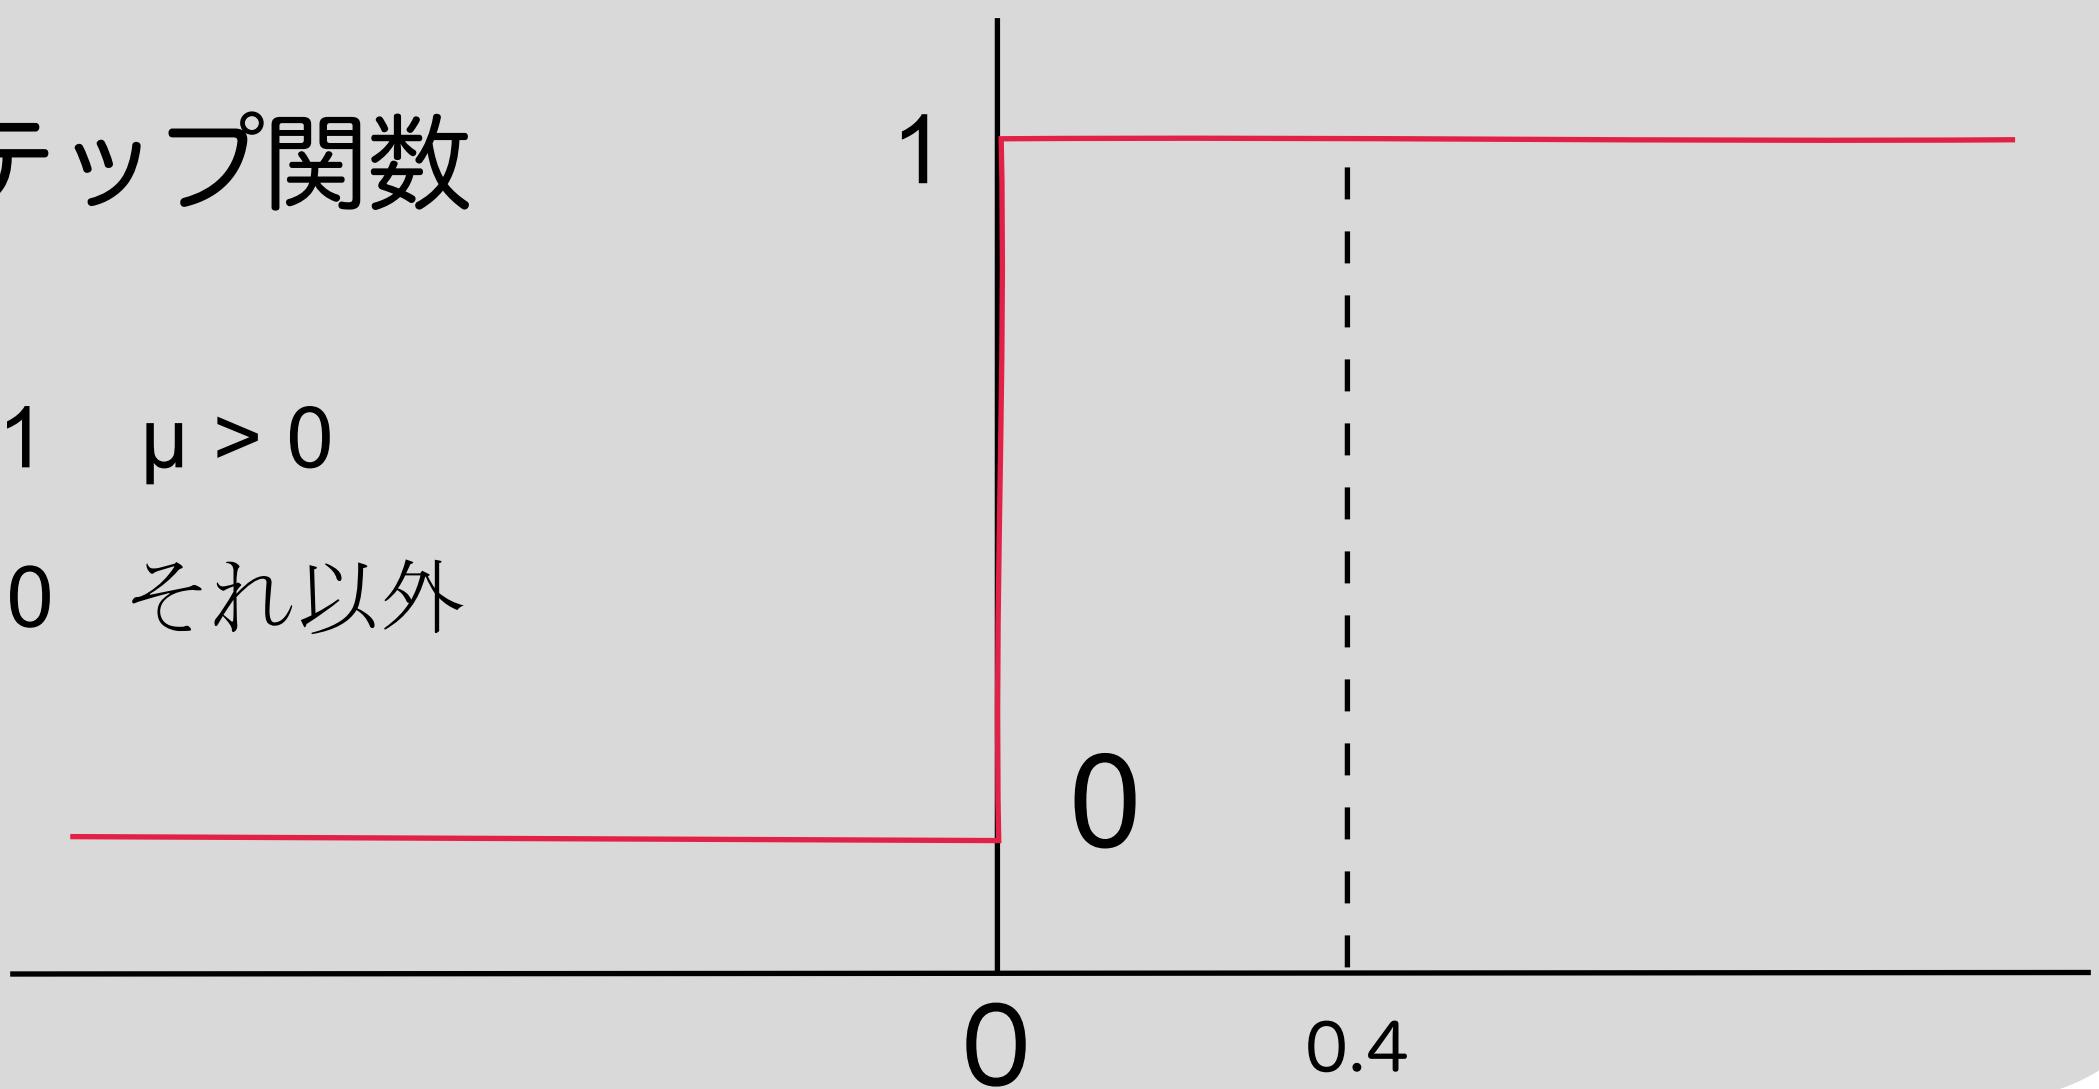
$$f(\mu) = \begin{cases} 0 & \mu \leq 0 \\ \mu & \mu > 0 \end{cases}$$

μ が5なら5、-6なら0



ステップ関数

$$f(\mu) = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$



```
model.add(Dense(32, input_shape=(784,), activation='relu'))
model.add(Dense(10, activation='softmax'))
```

784個

■ 0.53
■ 0.24
■ 0.88
■ 0.34

32個

○ 3.23
○ 0
○ 8.45

(バイアス項): b

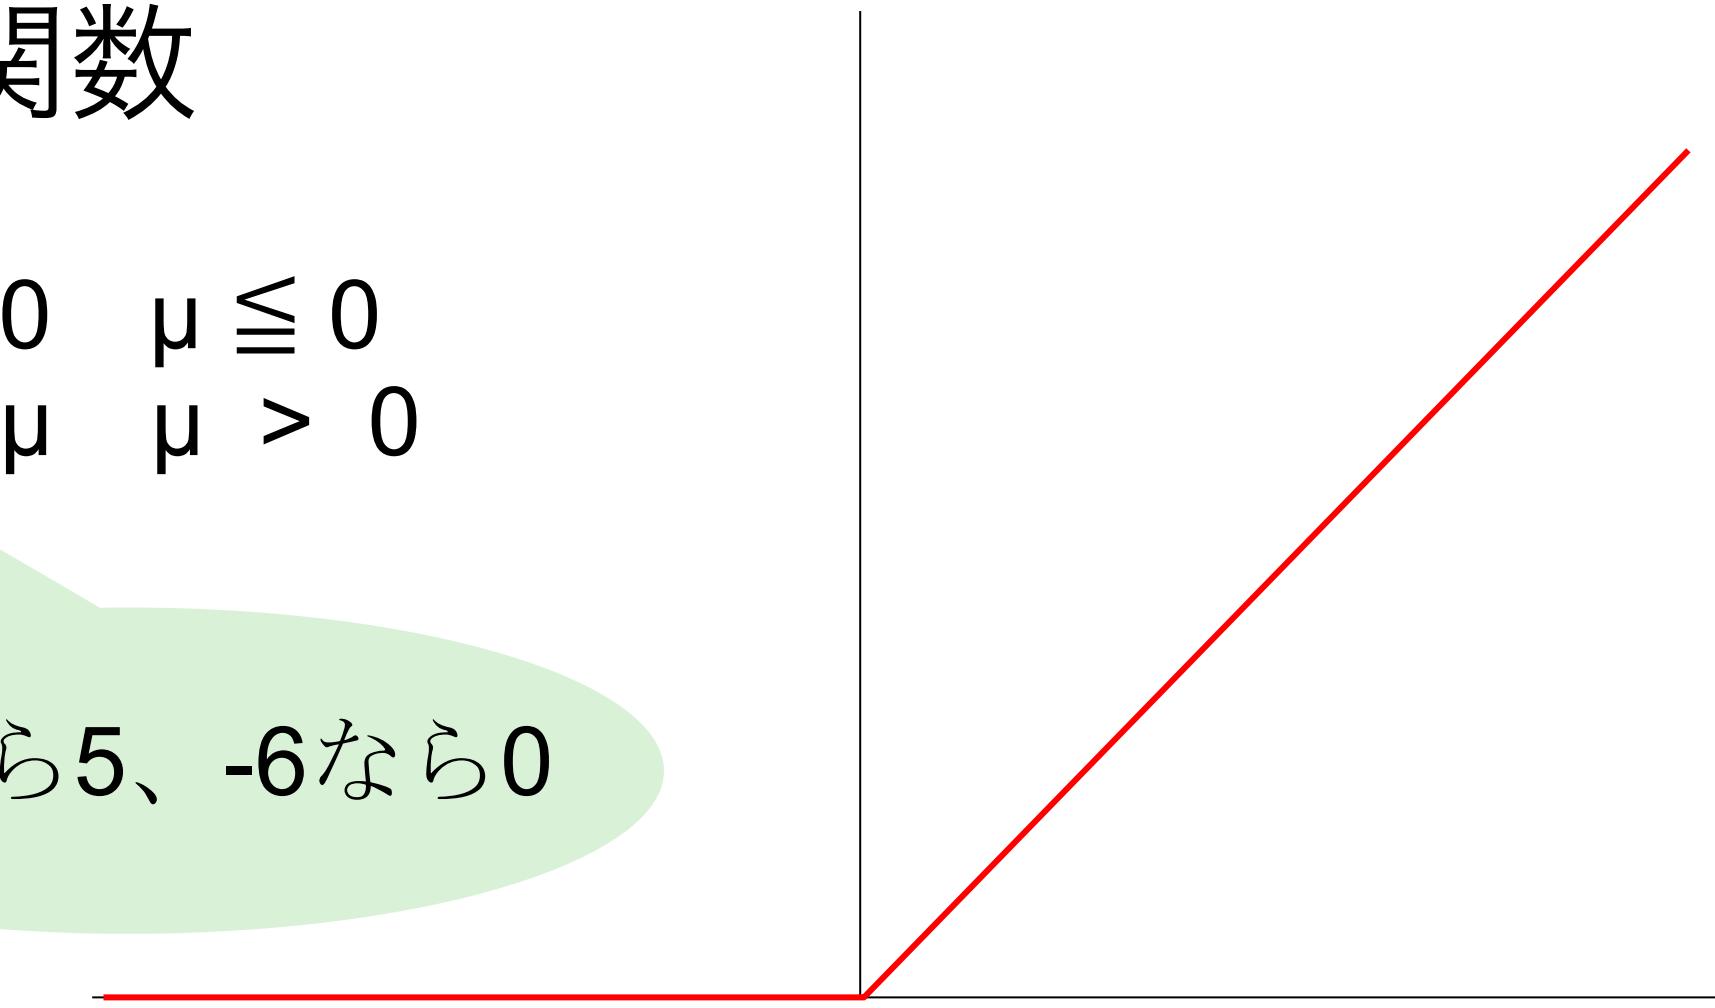
■ 0.11
□ 0.91
■ 0.57

○ 0
○ 4.33

ReLU関数

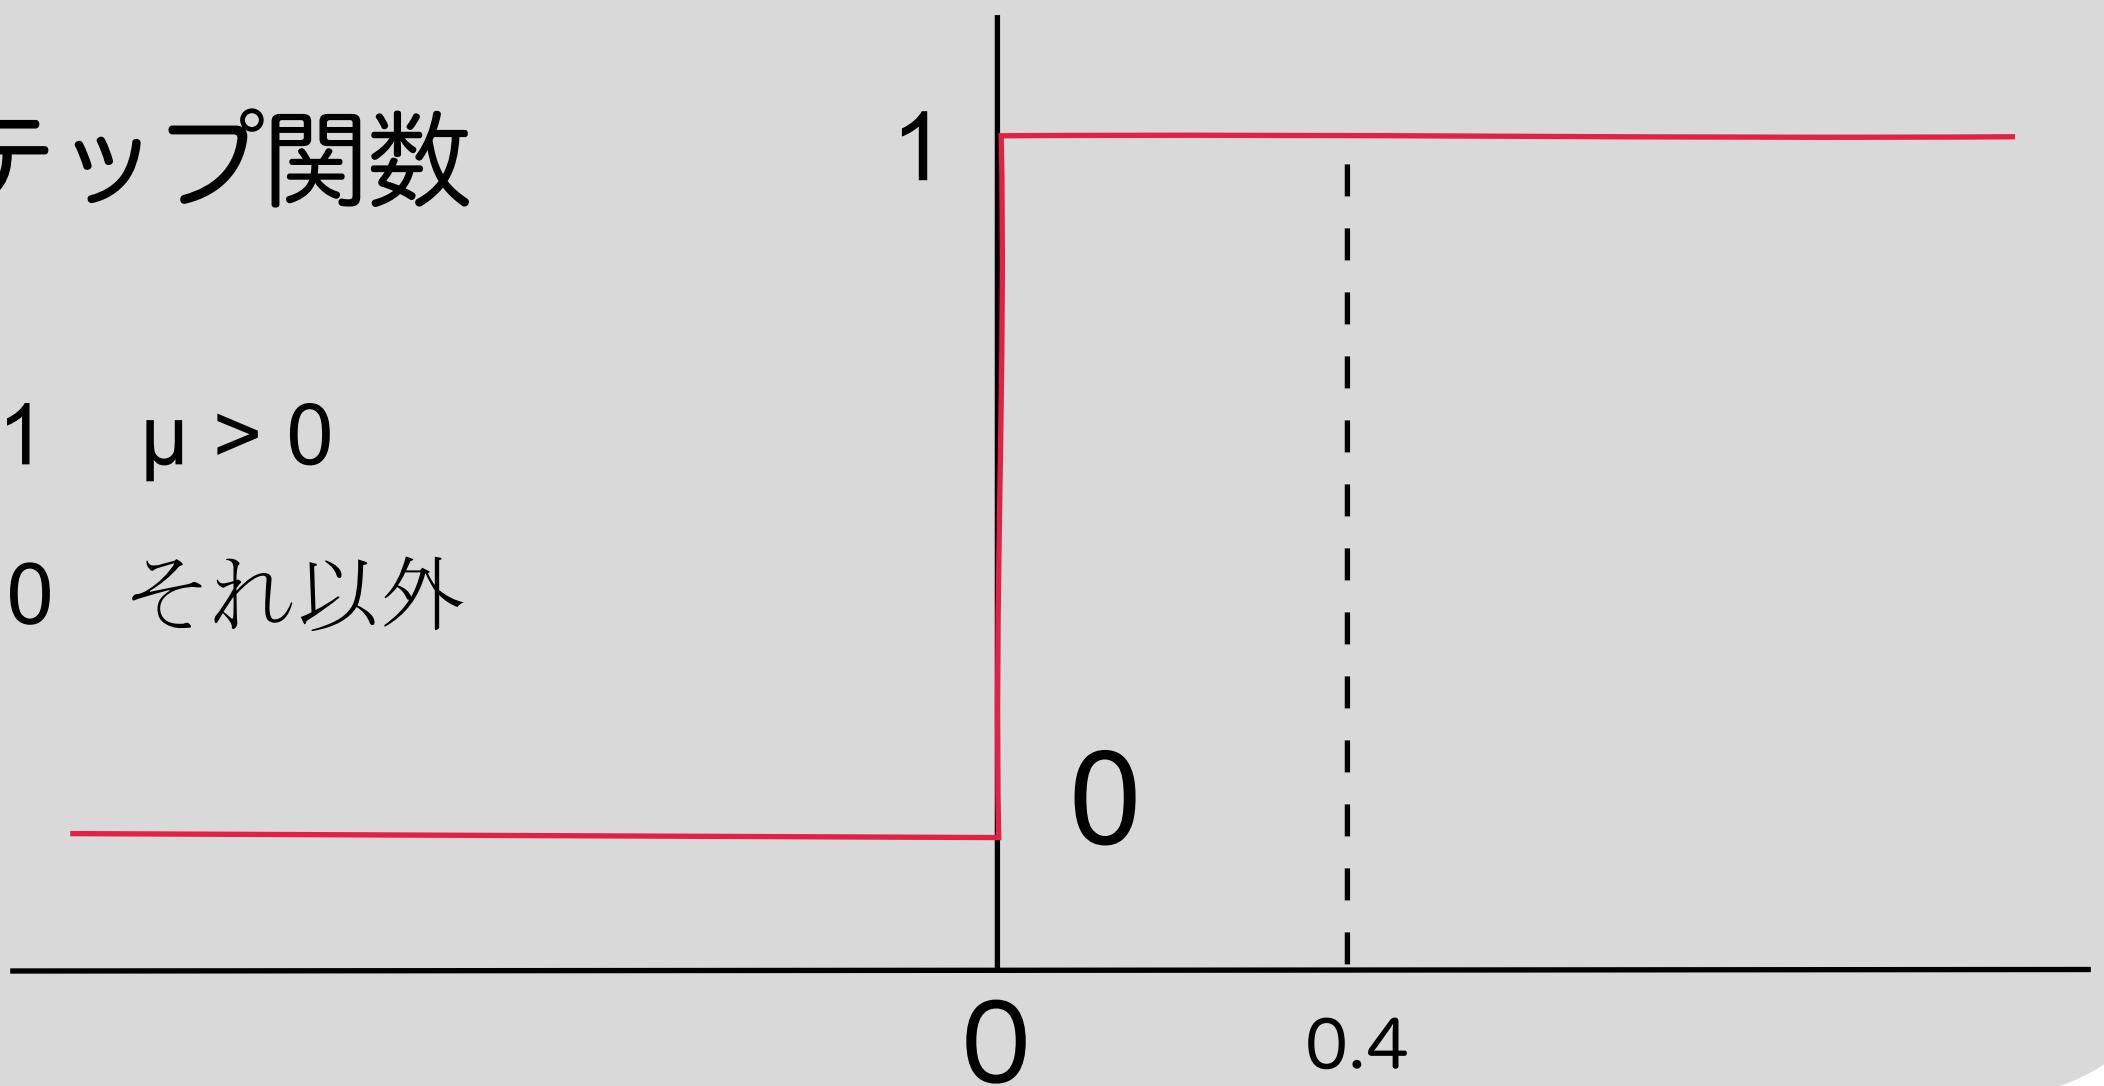
$$f(\mu) = \begin{cases} 0 & \mu \leq 0 \\ \mu & \mu > 0 \end{cases}$$

μ が5なら5、 -6なら0

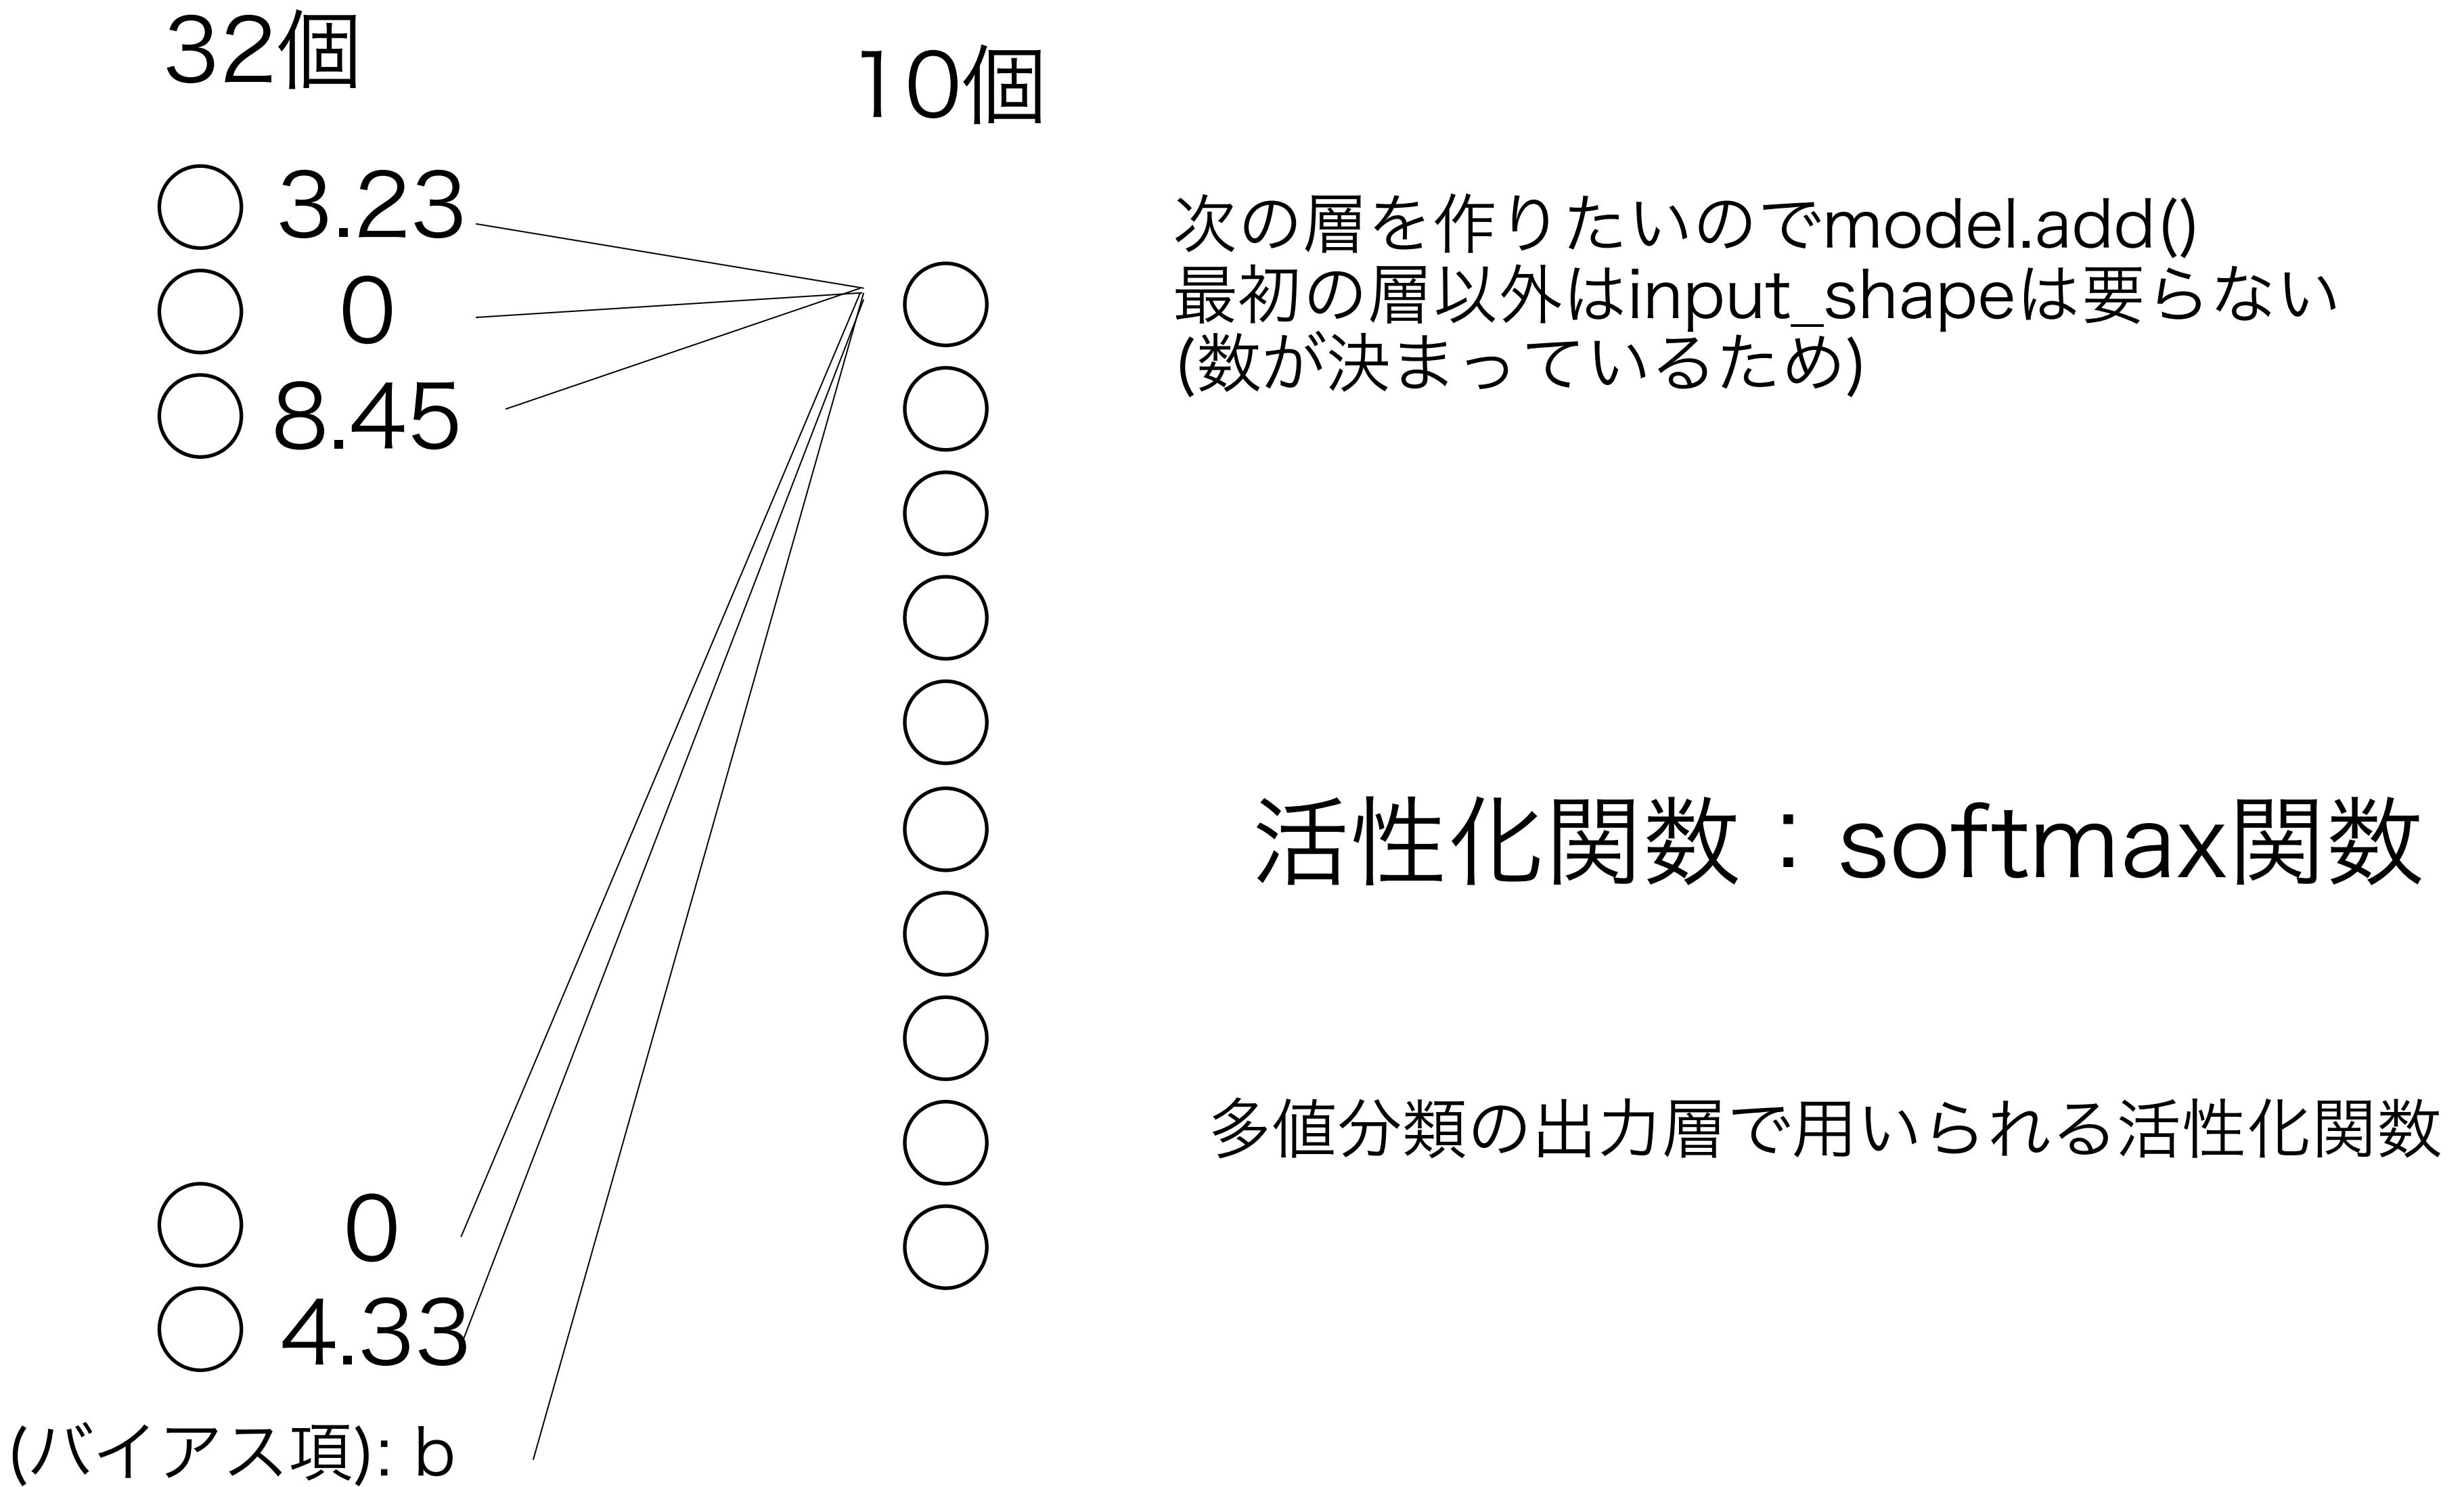


ステップ関数

$$f(\mu) = \begin{cases} 1 & \mu > 0 \\ 0 & \text{それ以外} \end{cases}$$



```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```



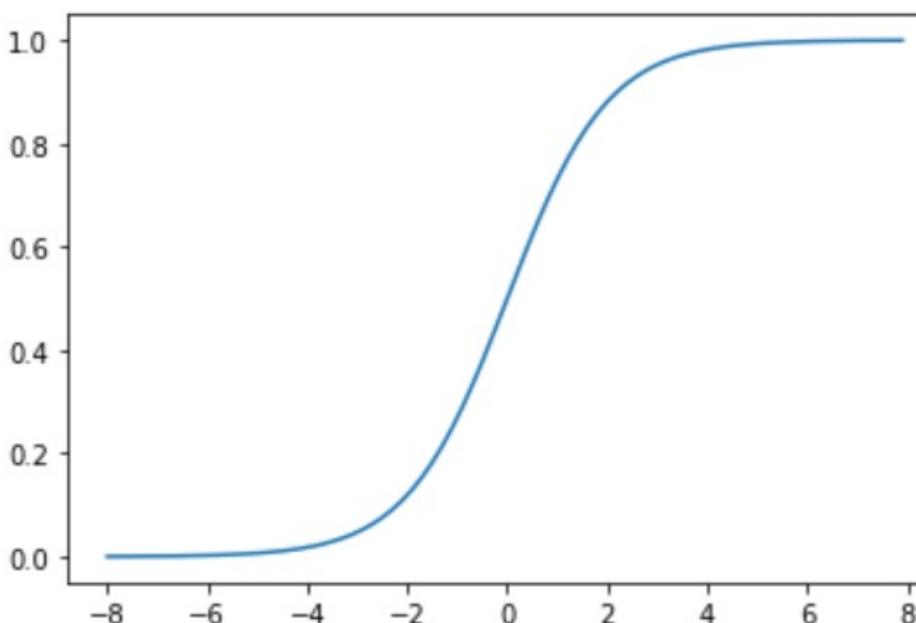
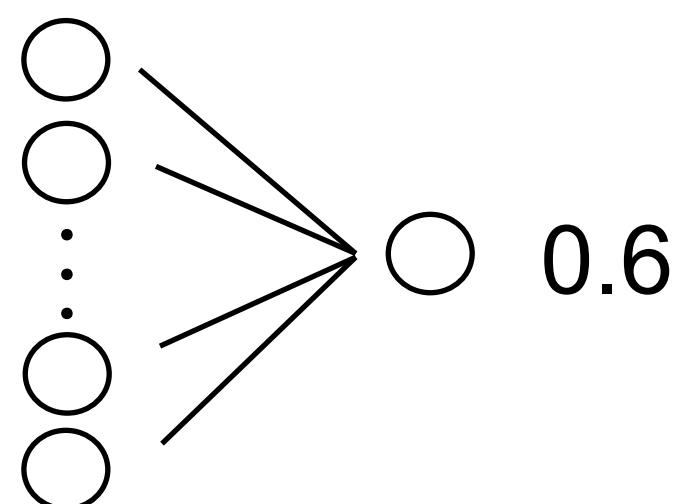
```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

2値分類

ねこかいぬか
○か×か
病気か否か
0か1か

出力層でよく使われる活性化関数

sigmoid関数
(activation='sigmoid')



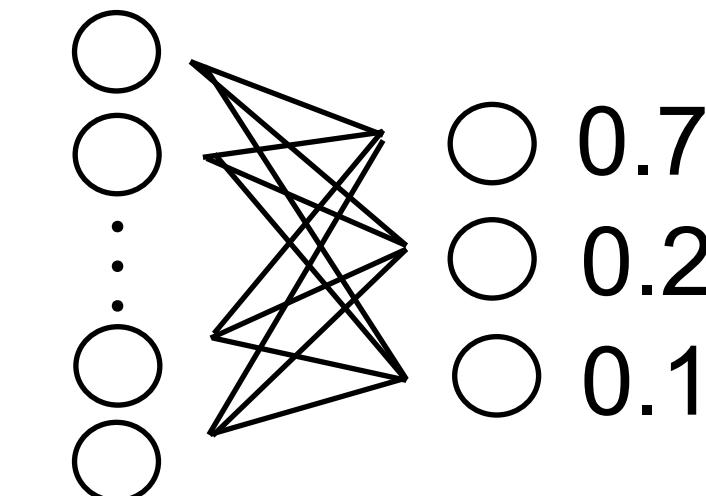
最後が1つのニューロンで0から1の値(確率)を出力
ex) 猫である確率が0.6 (=犬である確率は0.4)

多値分類

晴れか雨か曇りか
数学か国語か英語か物理か
1か2か3か4か5か

出力層でよく使われる活性化関数

softmax関数
(activation='softmax')



最後が分類したい数のニューロンで全てを足すと1になるように値(確率)を出力
ex) 晴れである確率が0.7、雨が0.2、曇りが0.1

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

32個

- 3.23
- 0
- 8.45

10個

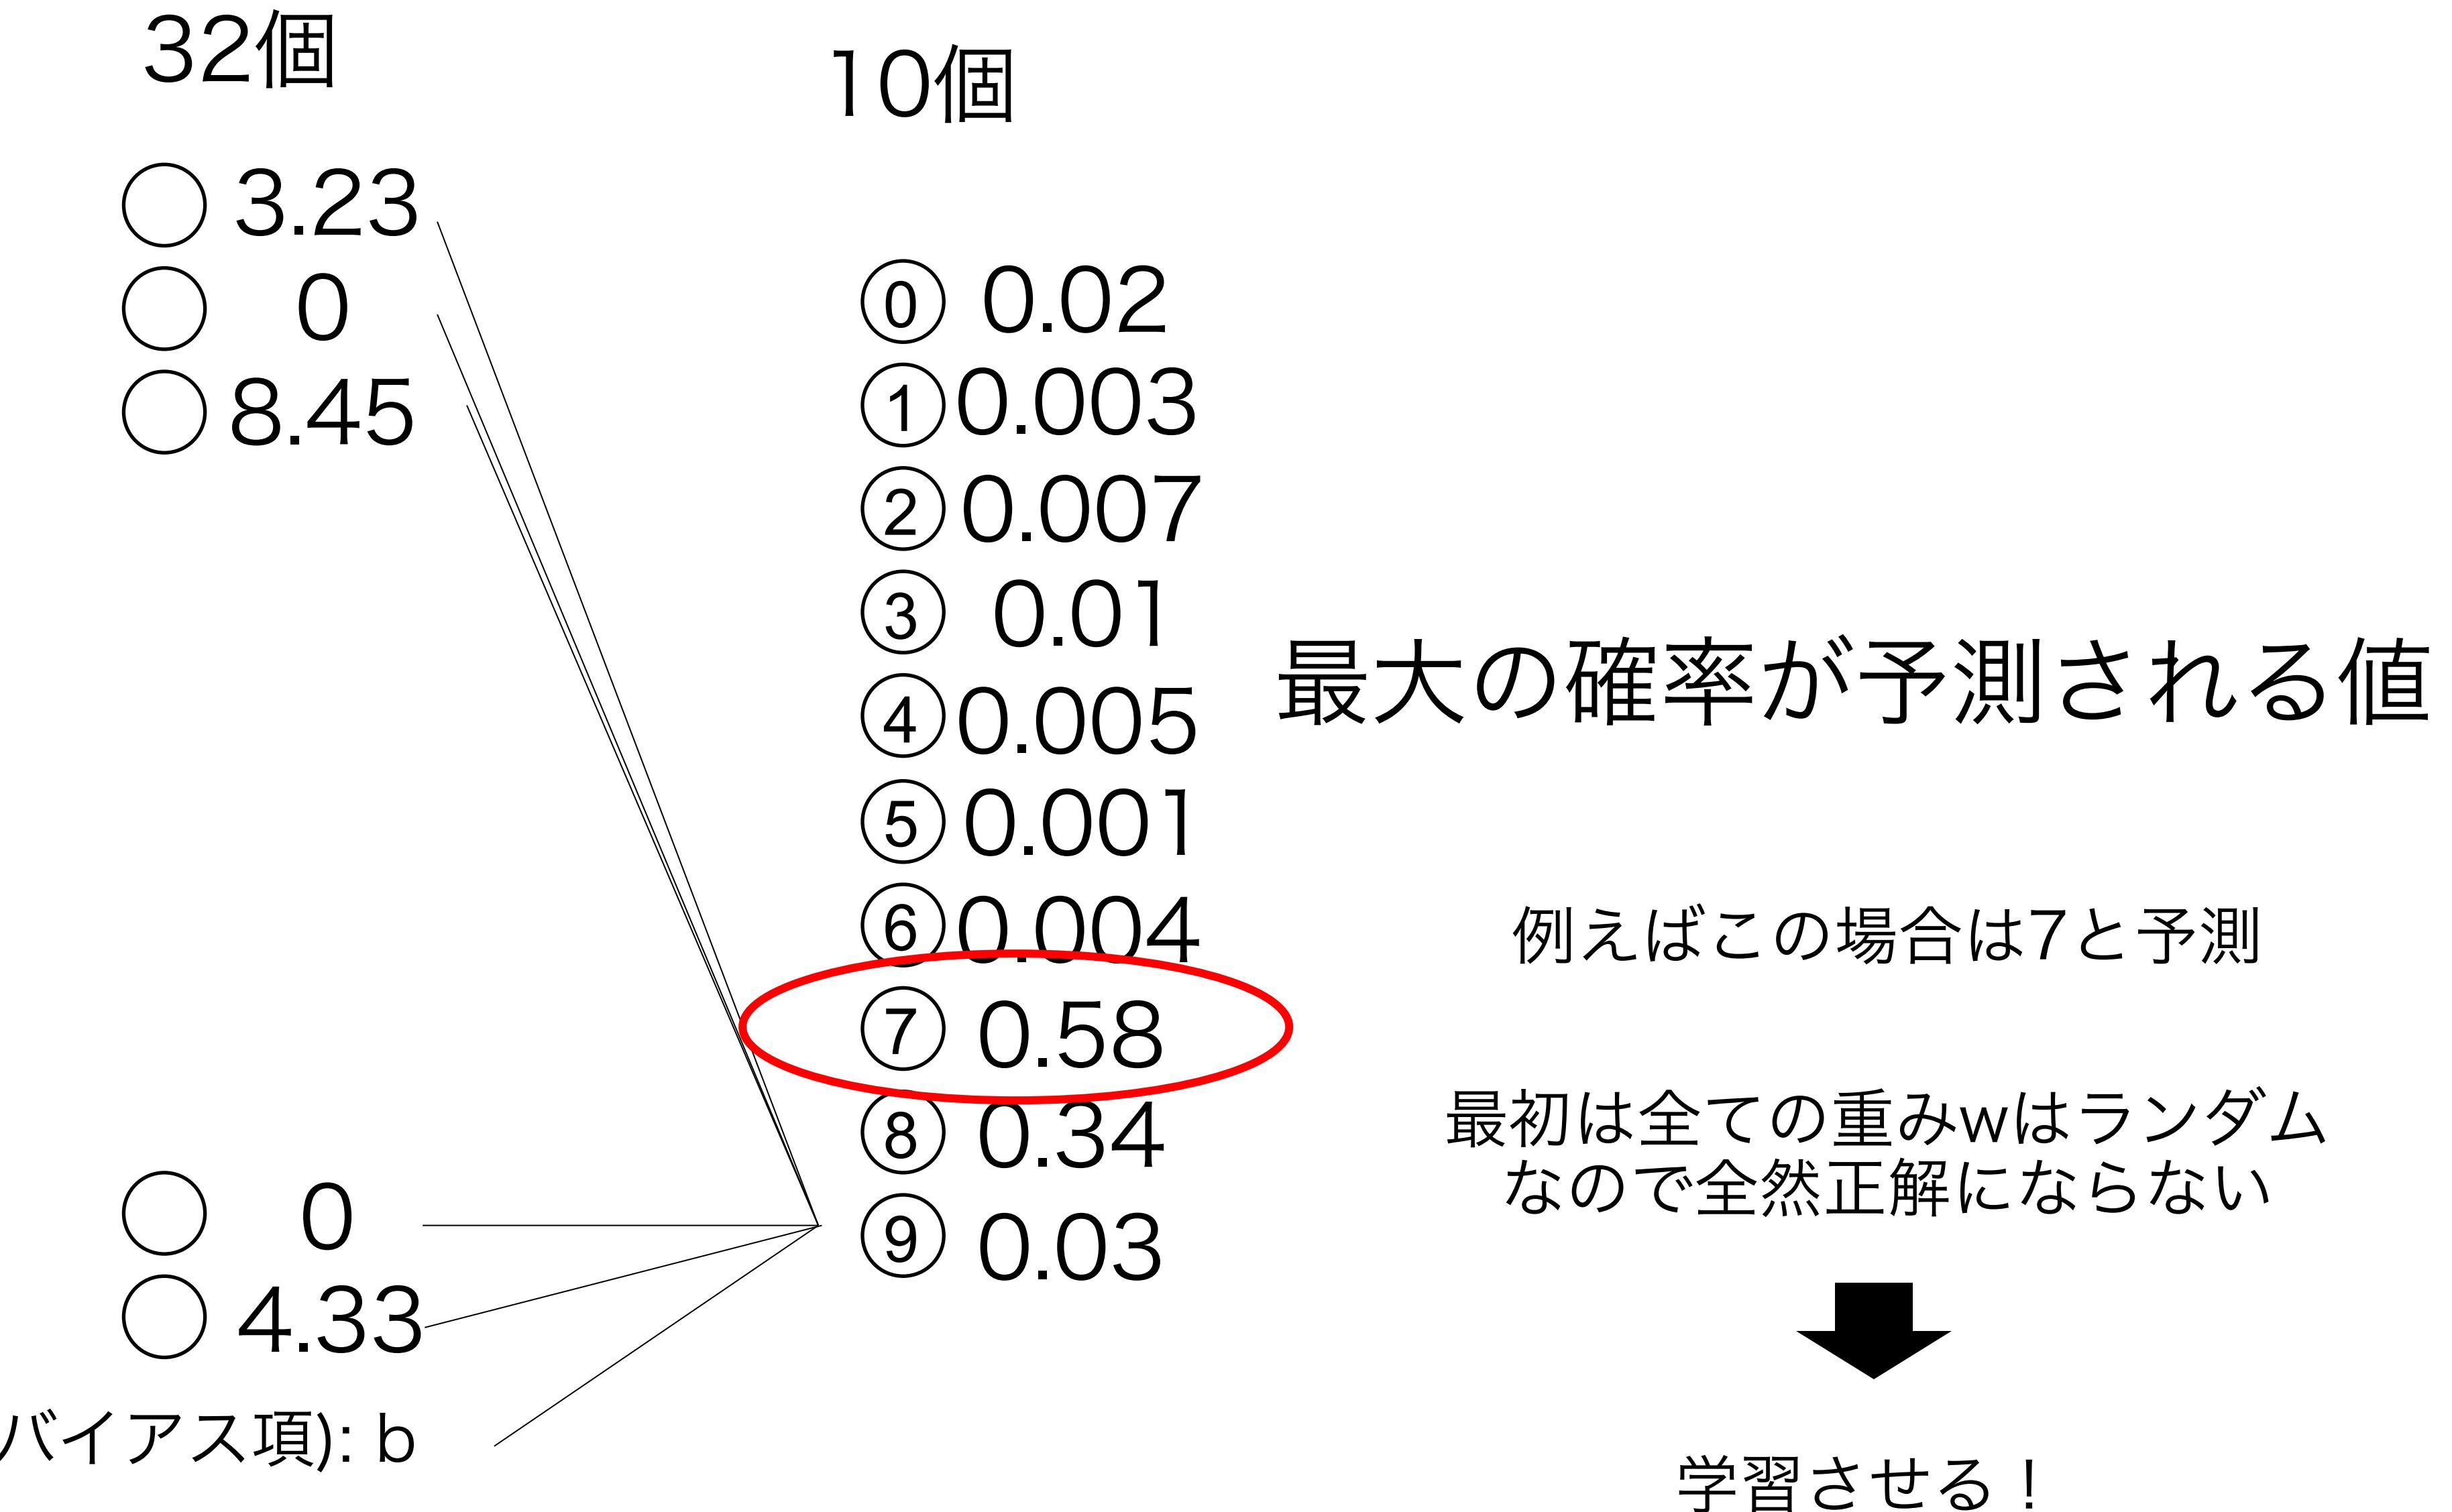
- ① 0.02
- ② 0.003
- ③ 0.007
- ④ 0.01
- ⑤ 0.005
- ⑥ 0.001
- ⑦ 0.004
- ⑧ 0.58
- ⑨ 0.34
- ⑩ 0.03

(バイアス項): b

mnistは10クラスあるので
出力するニューロンの数は10個

最大の確率が予測される値

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```



```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```

32個

○ 3.23

○ 0

○ 0.45

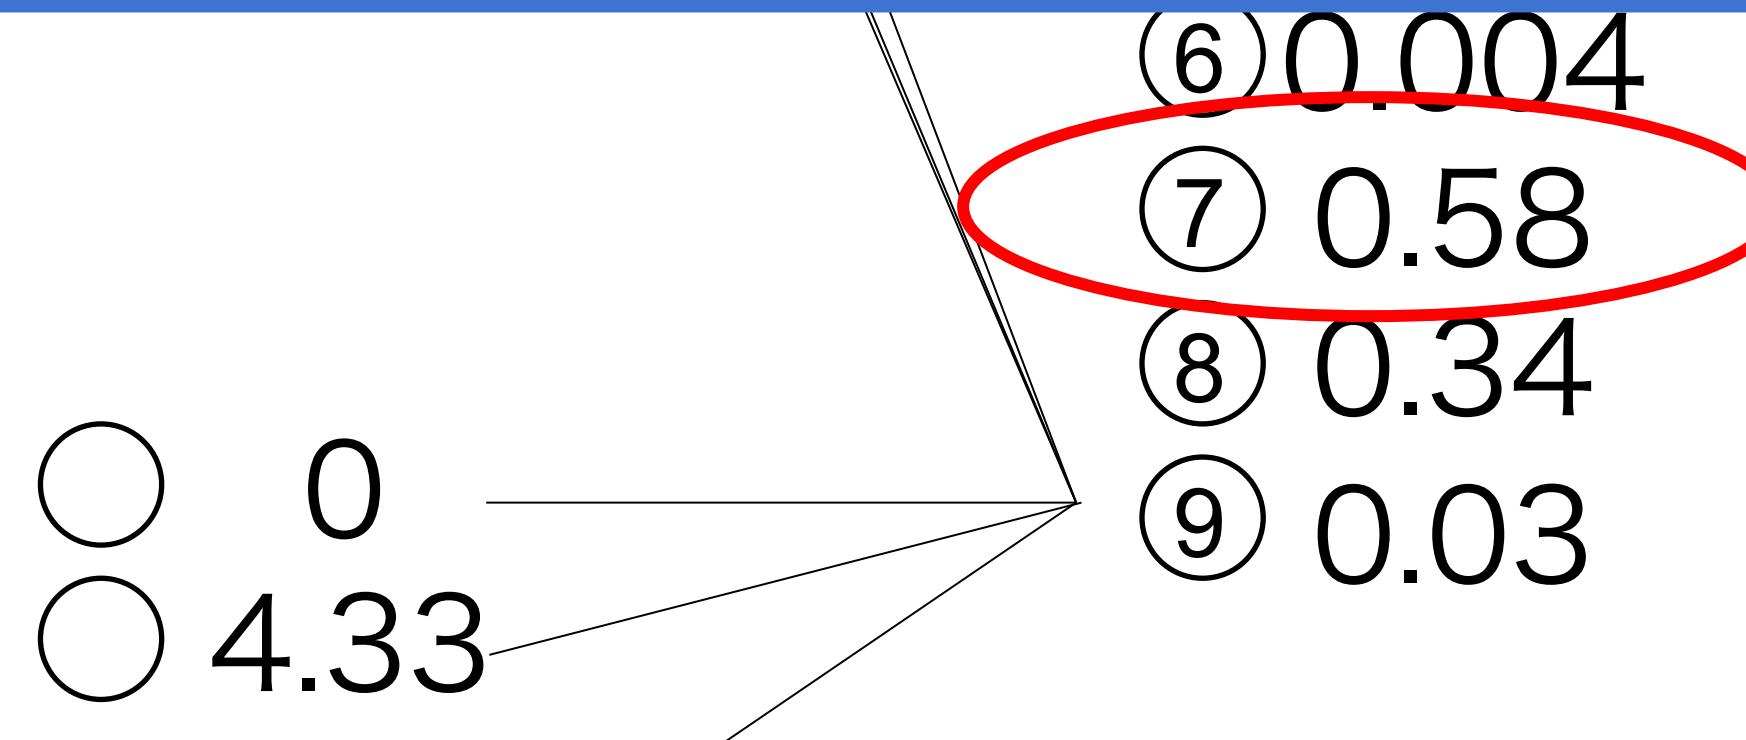
10個

○ 0.02

○ 0.002

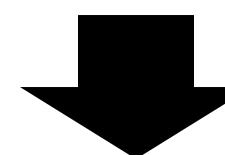
学習とは、コンピューターがランダムに振った各重みとバイアスを最適な値に更新していくこと

る値



例えばこの場合は7と予測

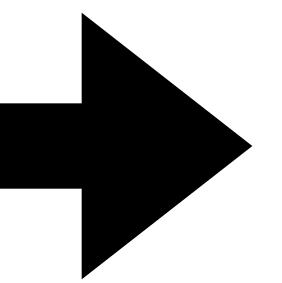
最初は全ての重みwはランダム
なので全然正解にならない



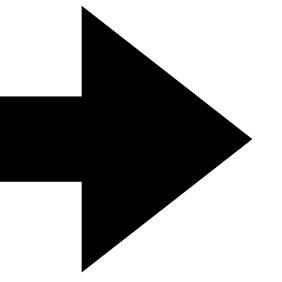
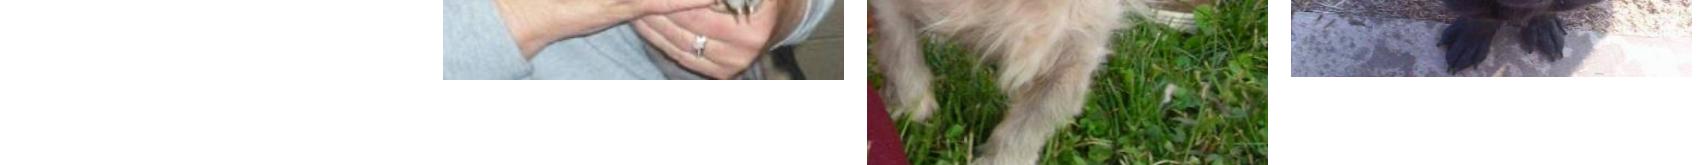
学習させる！

学習の仕組みの概要

仮に猫と犬の画像の2値分類で考えると、



これらの画像の正解は猫(=1とする)



これらの画像の正解は犬(=0とする)

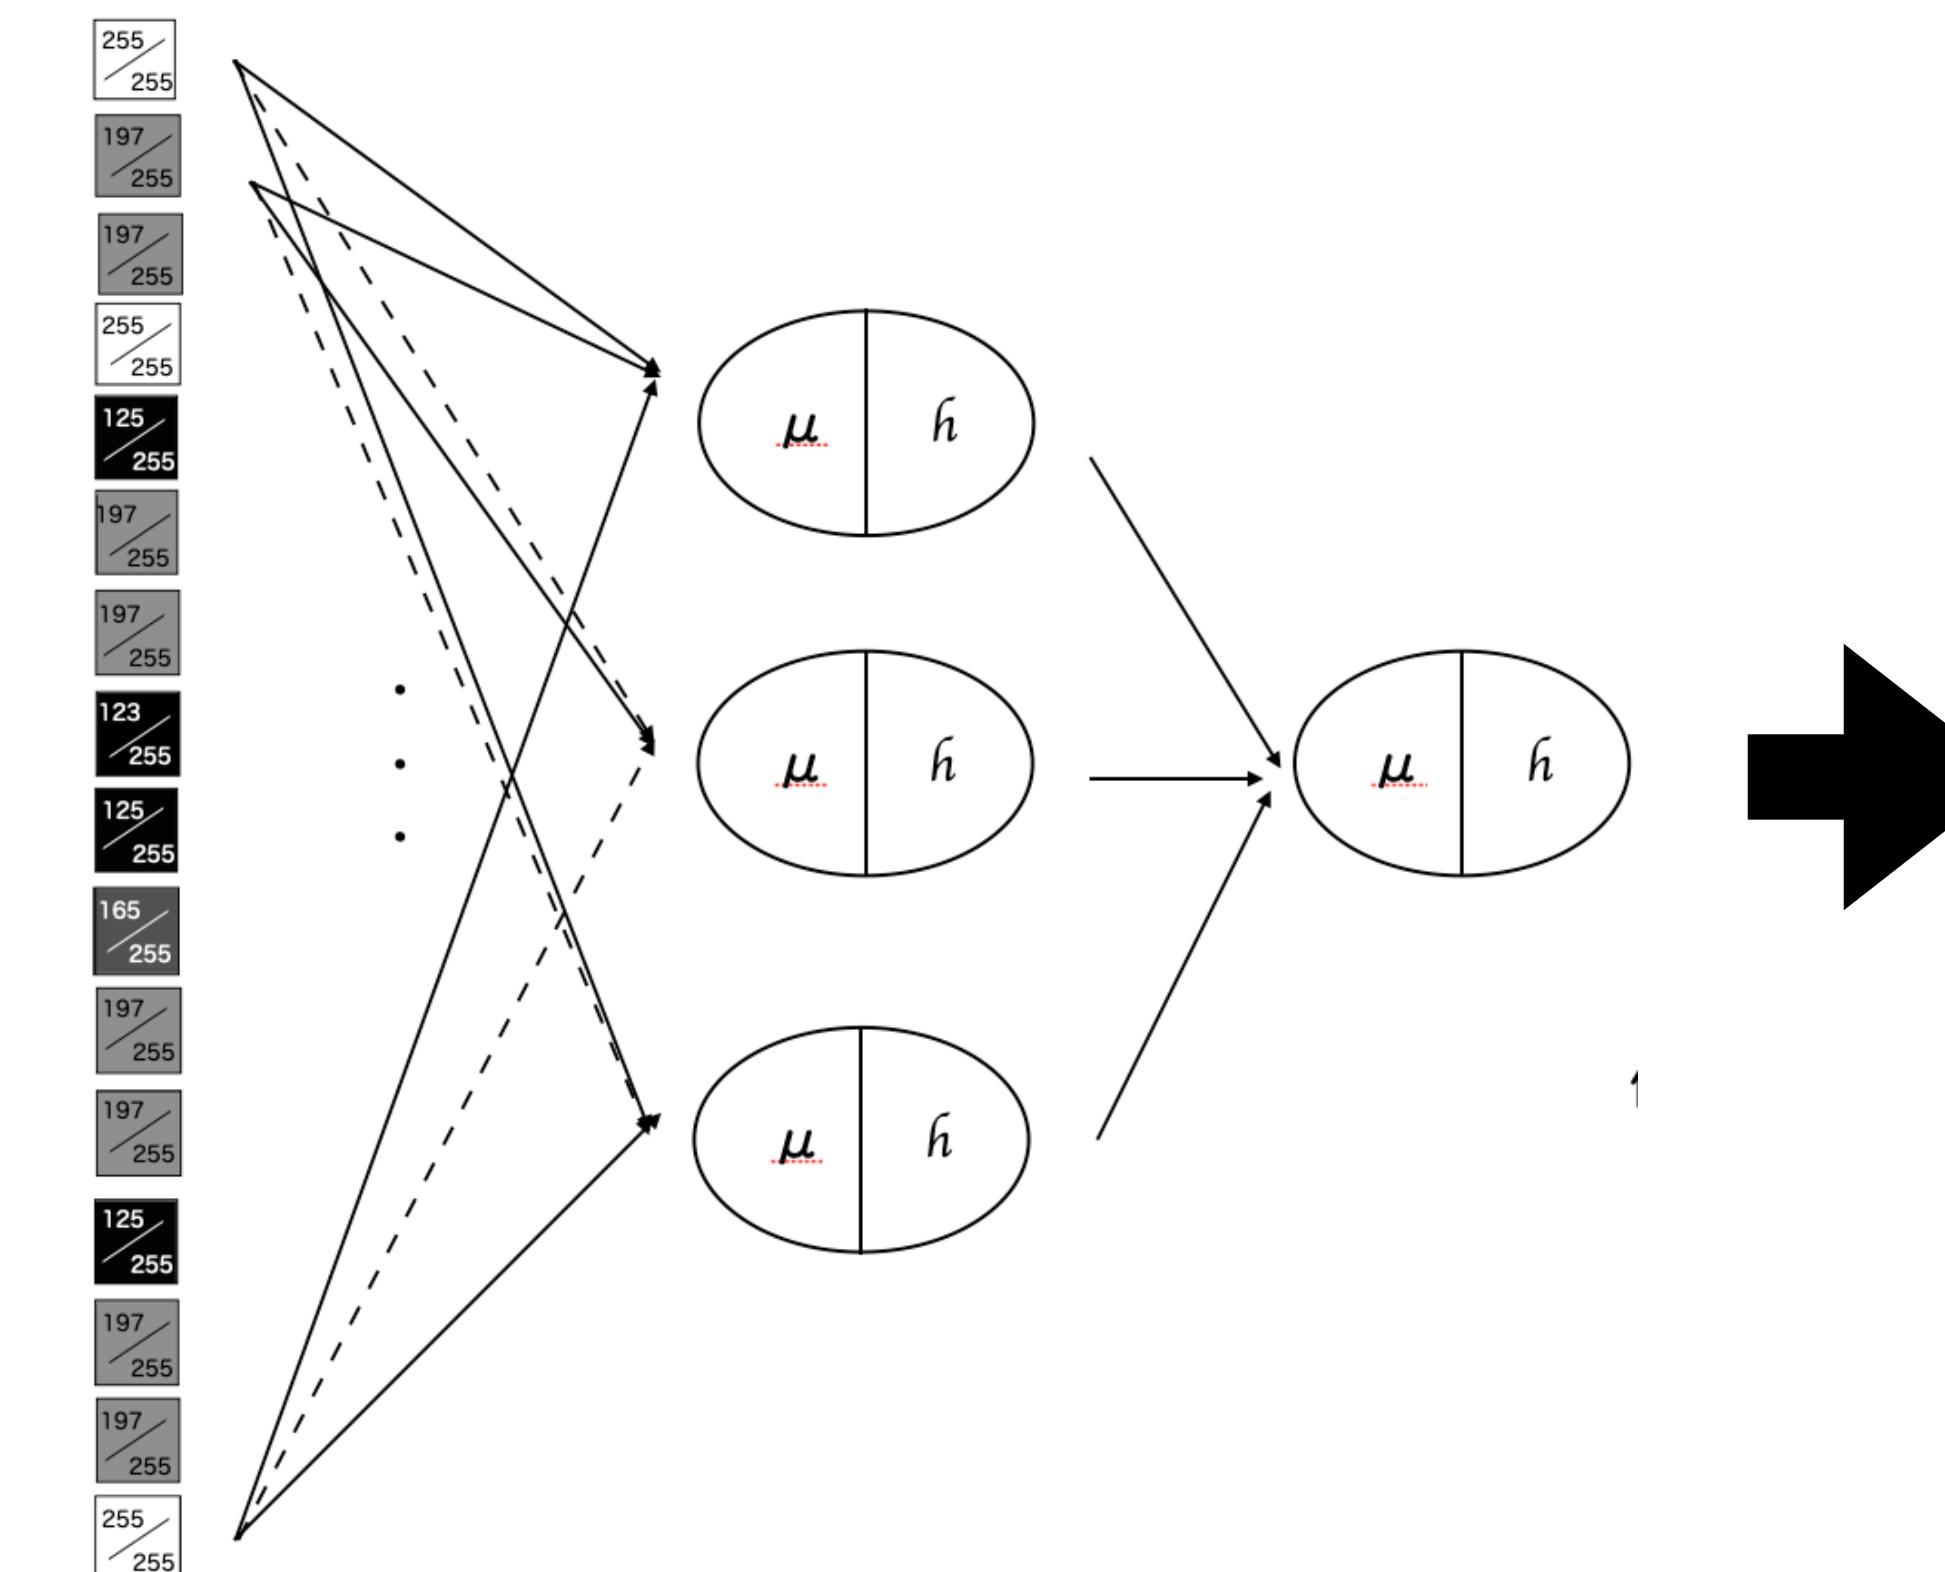


一部を取り出して予測する(ここでは仮に8枚)



255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255

255	197	197	255	255
125	197	197	123	255
125	165	197	197	255
125	197	197	255	255
125	197	197	255	255

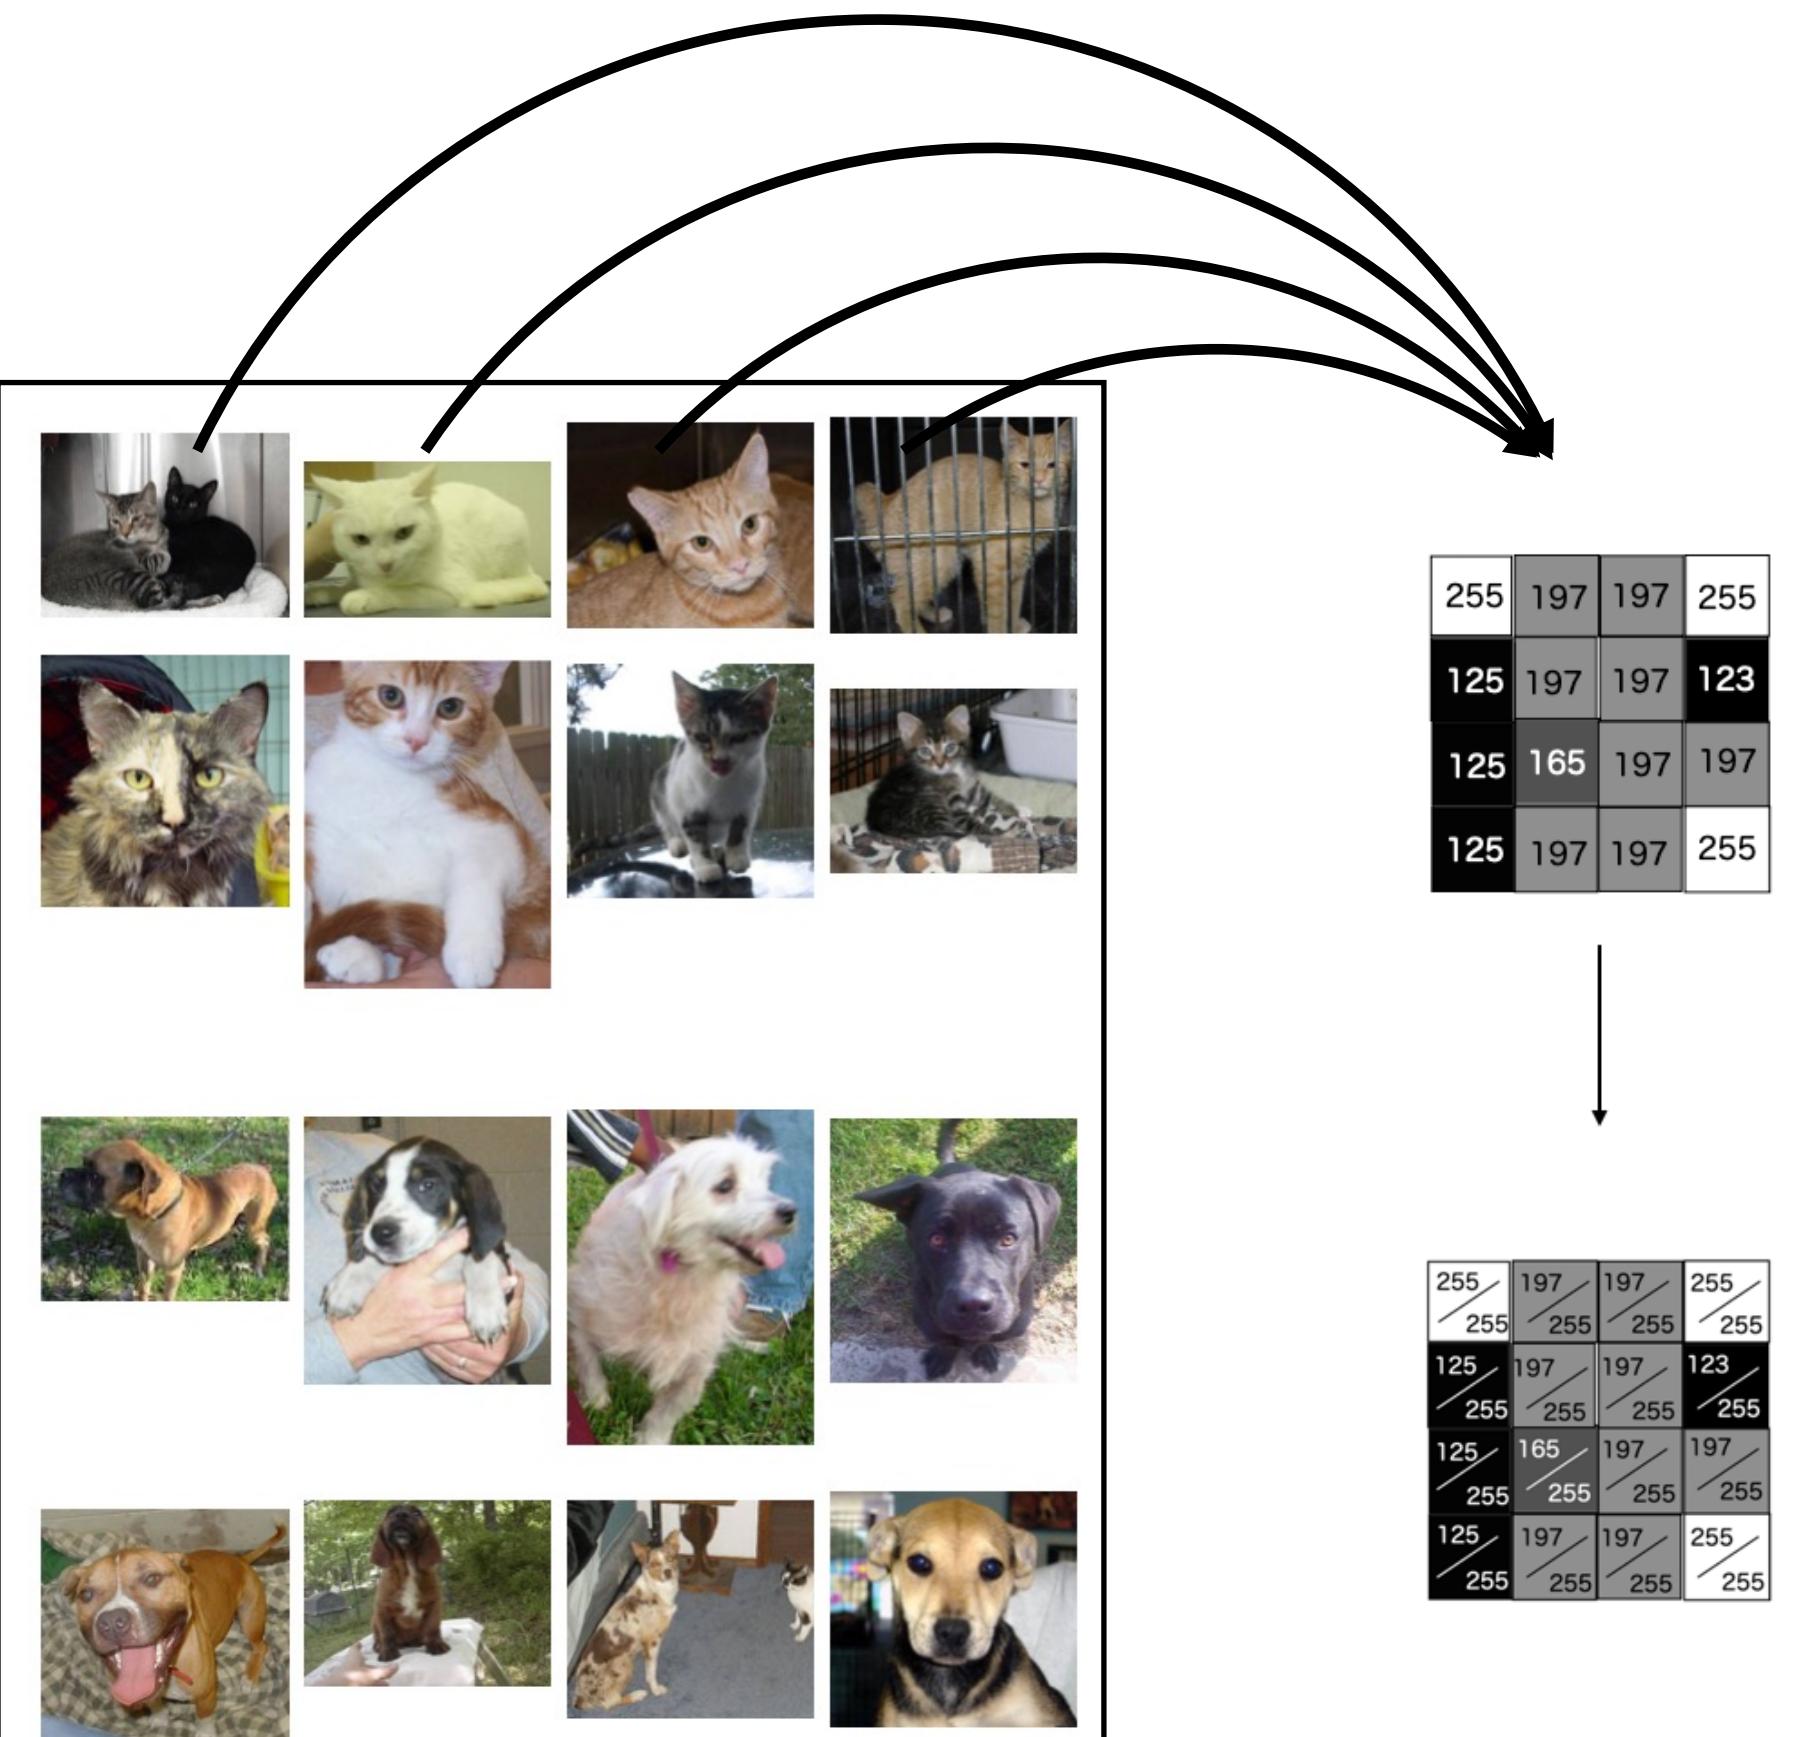


猫が 1 , 犬が 0

No.	出力	正解
1	0.5	1
2	0.3	1
3	0.6	1
4	0.7	1
5	0.5	0
6	0.3	0
7	0.7	0
8	0.5	0

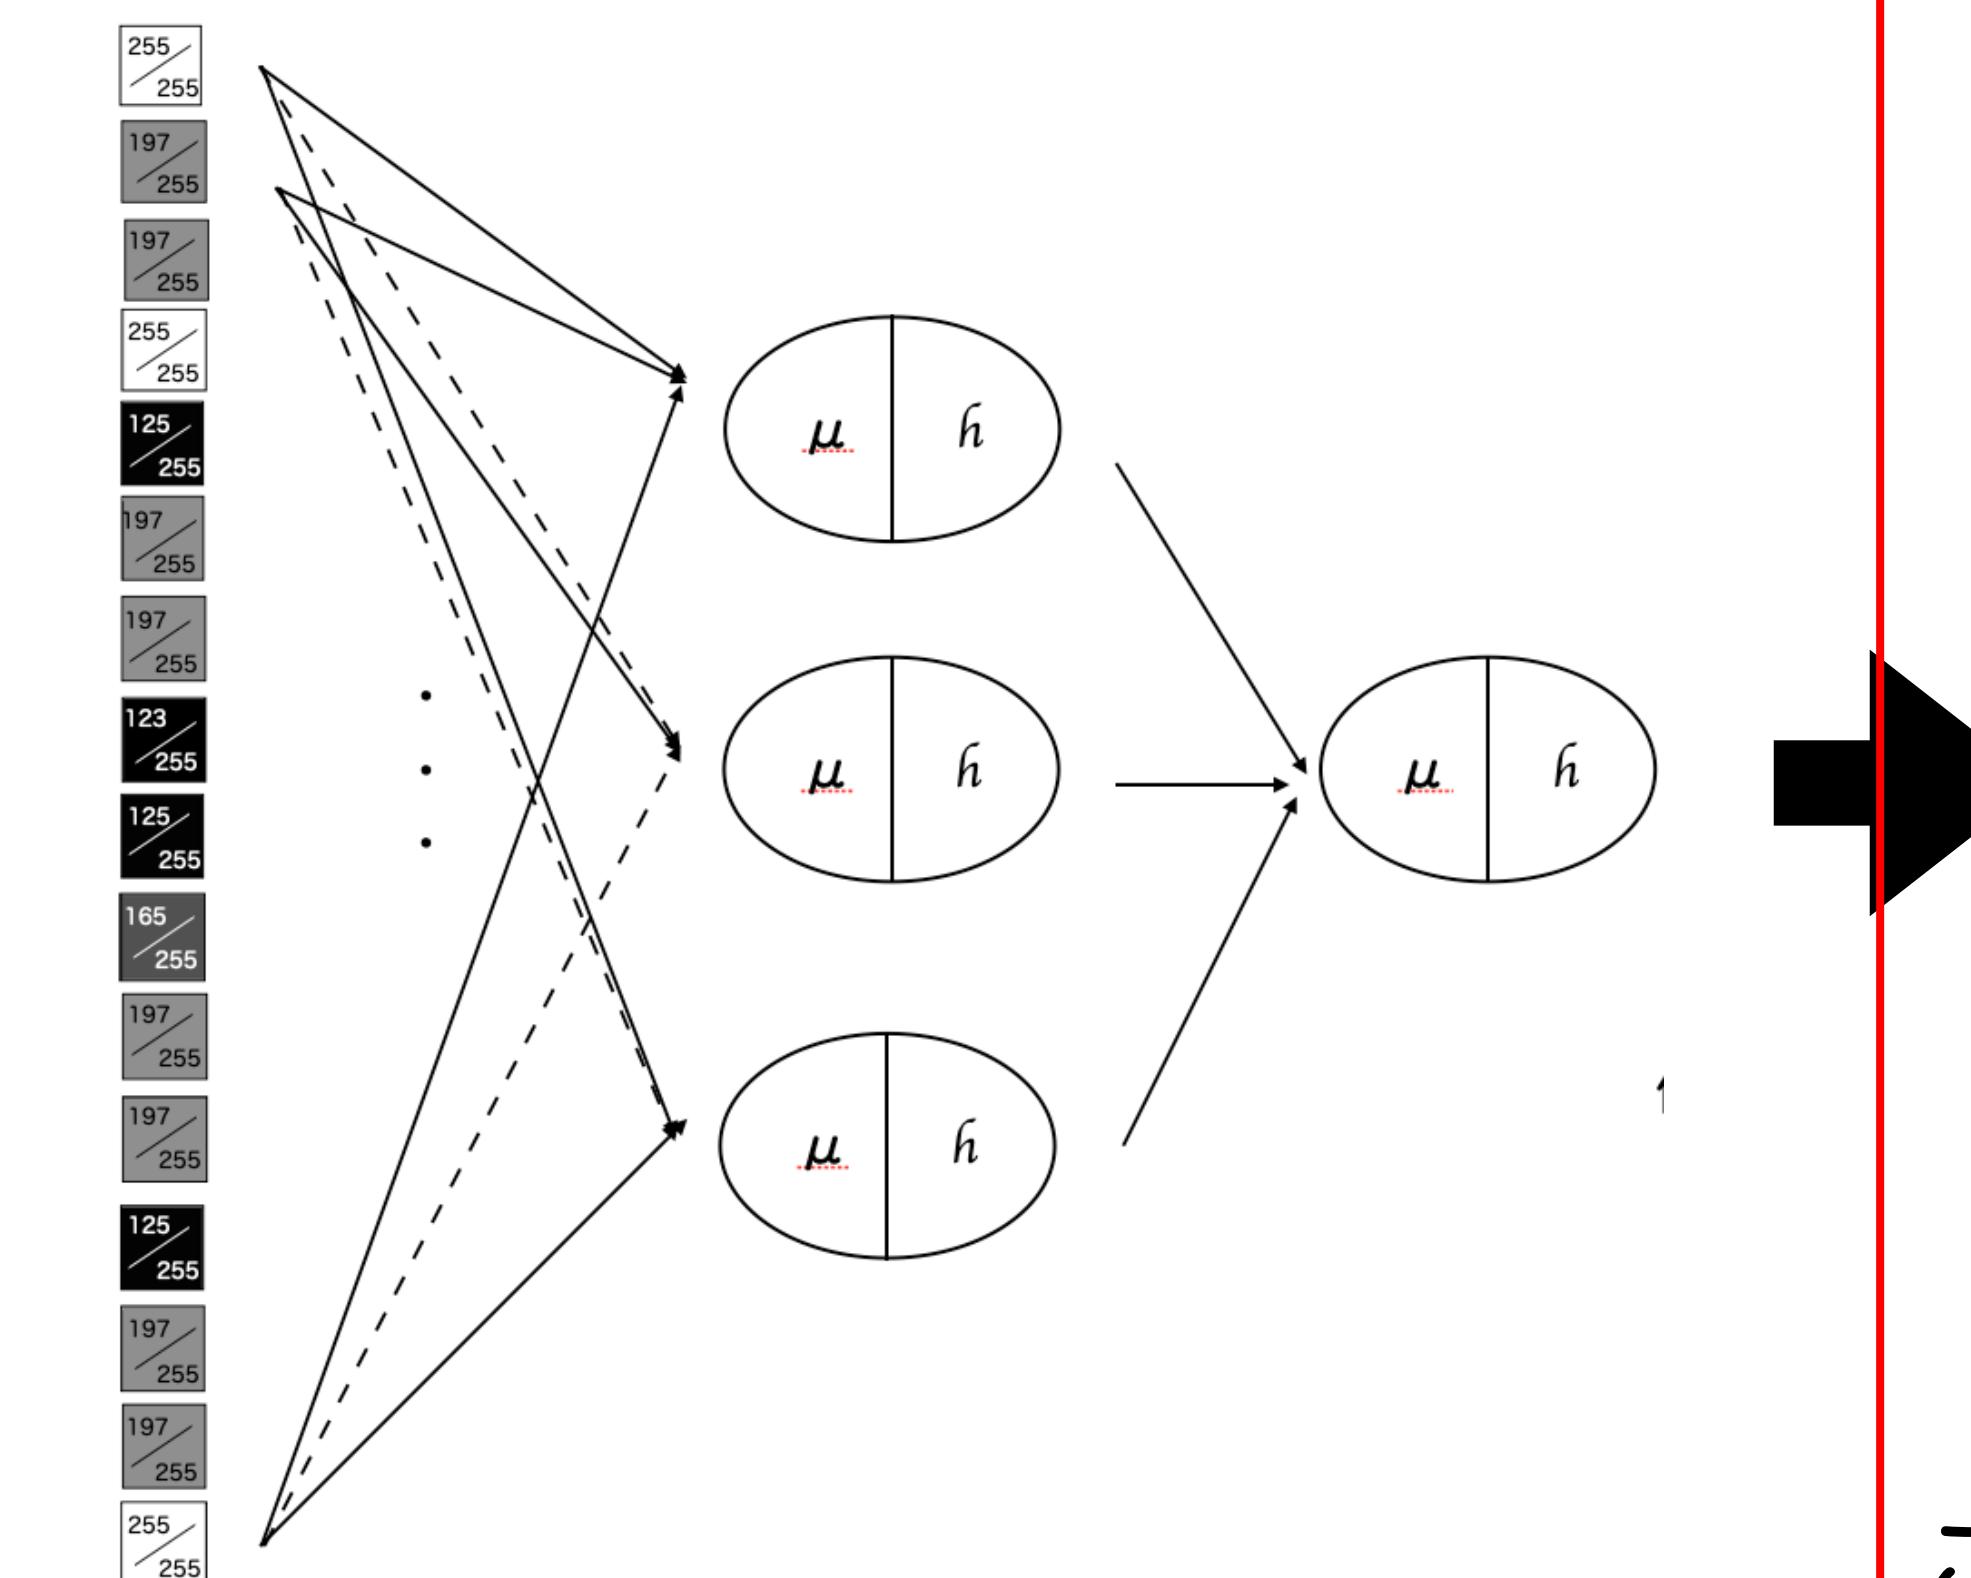
最初はテキトーな重みwとバイアスbなので正解にならない
(=確率が低い)

一部を取り出して予測する(ここでは仮に8枚)



255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255

255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255
125	197	197	255
125	197	197	255
125	197	197	255
125	197	197	255



猫が 1 , 犬が 0

No.	出力	正解
1	0.5	1
2	0.3	1
3	0.6	1
4	0.7	1
5	0.5	0
6	0.3	0
7	0.7	0
8	0.5	0

この出力と正解の
ズレ(誤差)を数値化
したい

最初はテキトーな重みwとバイアスbなので正解にならない
(=確率が低い)

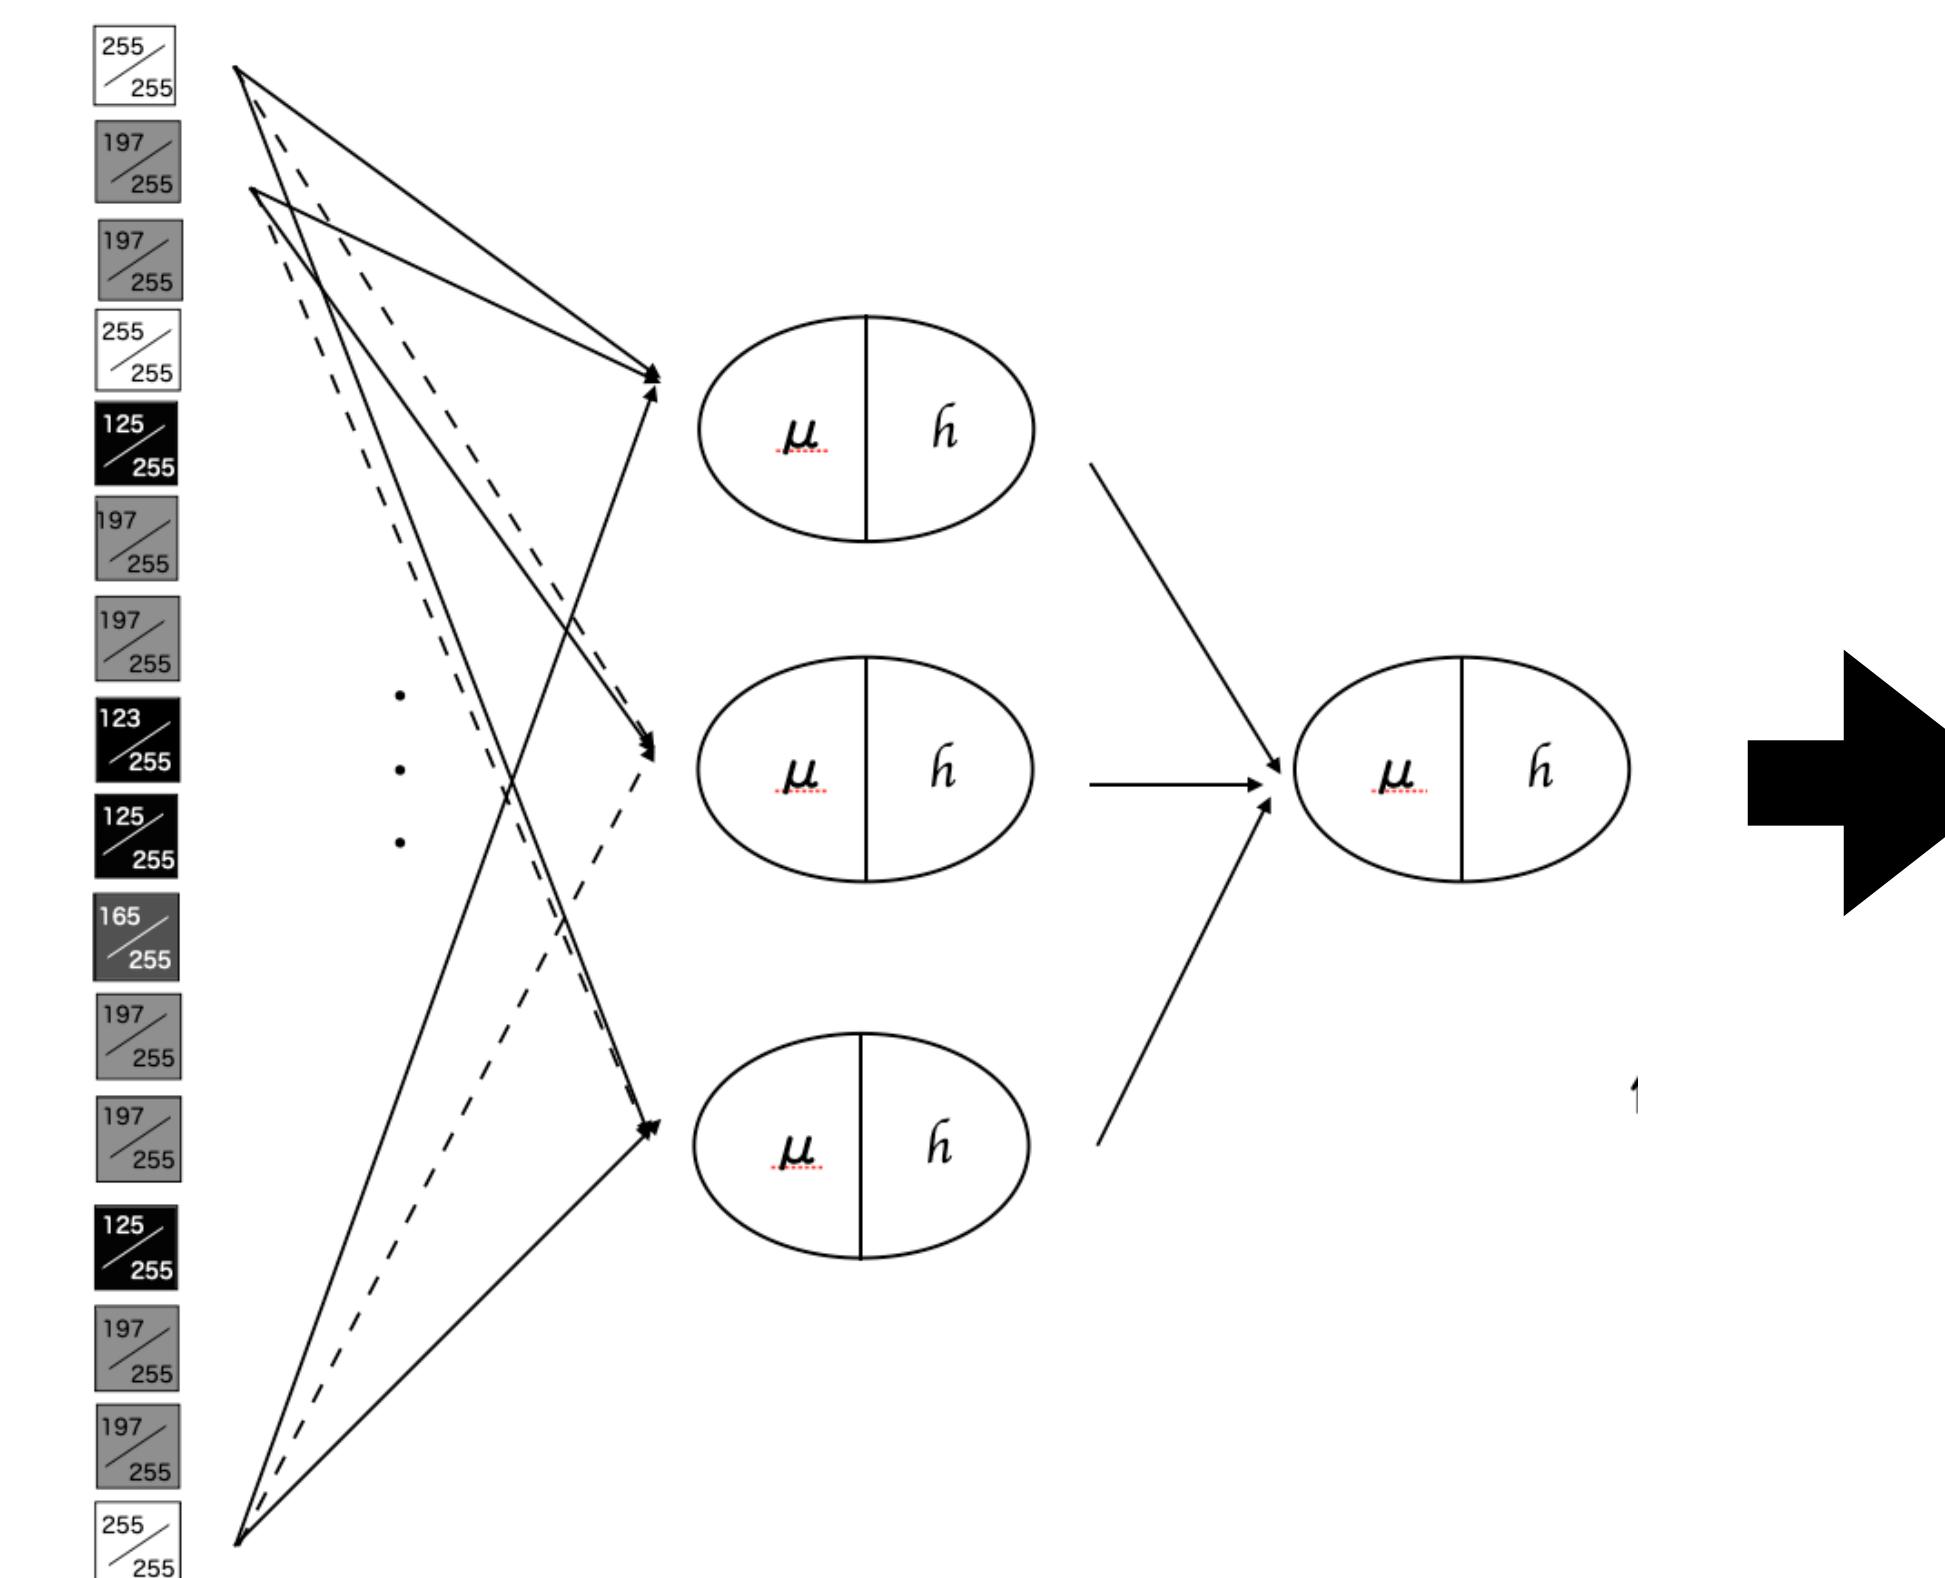
誤差の計算方法(損失関数)にはいろんな方法がある



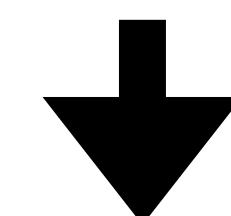
255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255



255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255
125	197	197	255



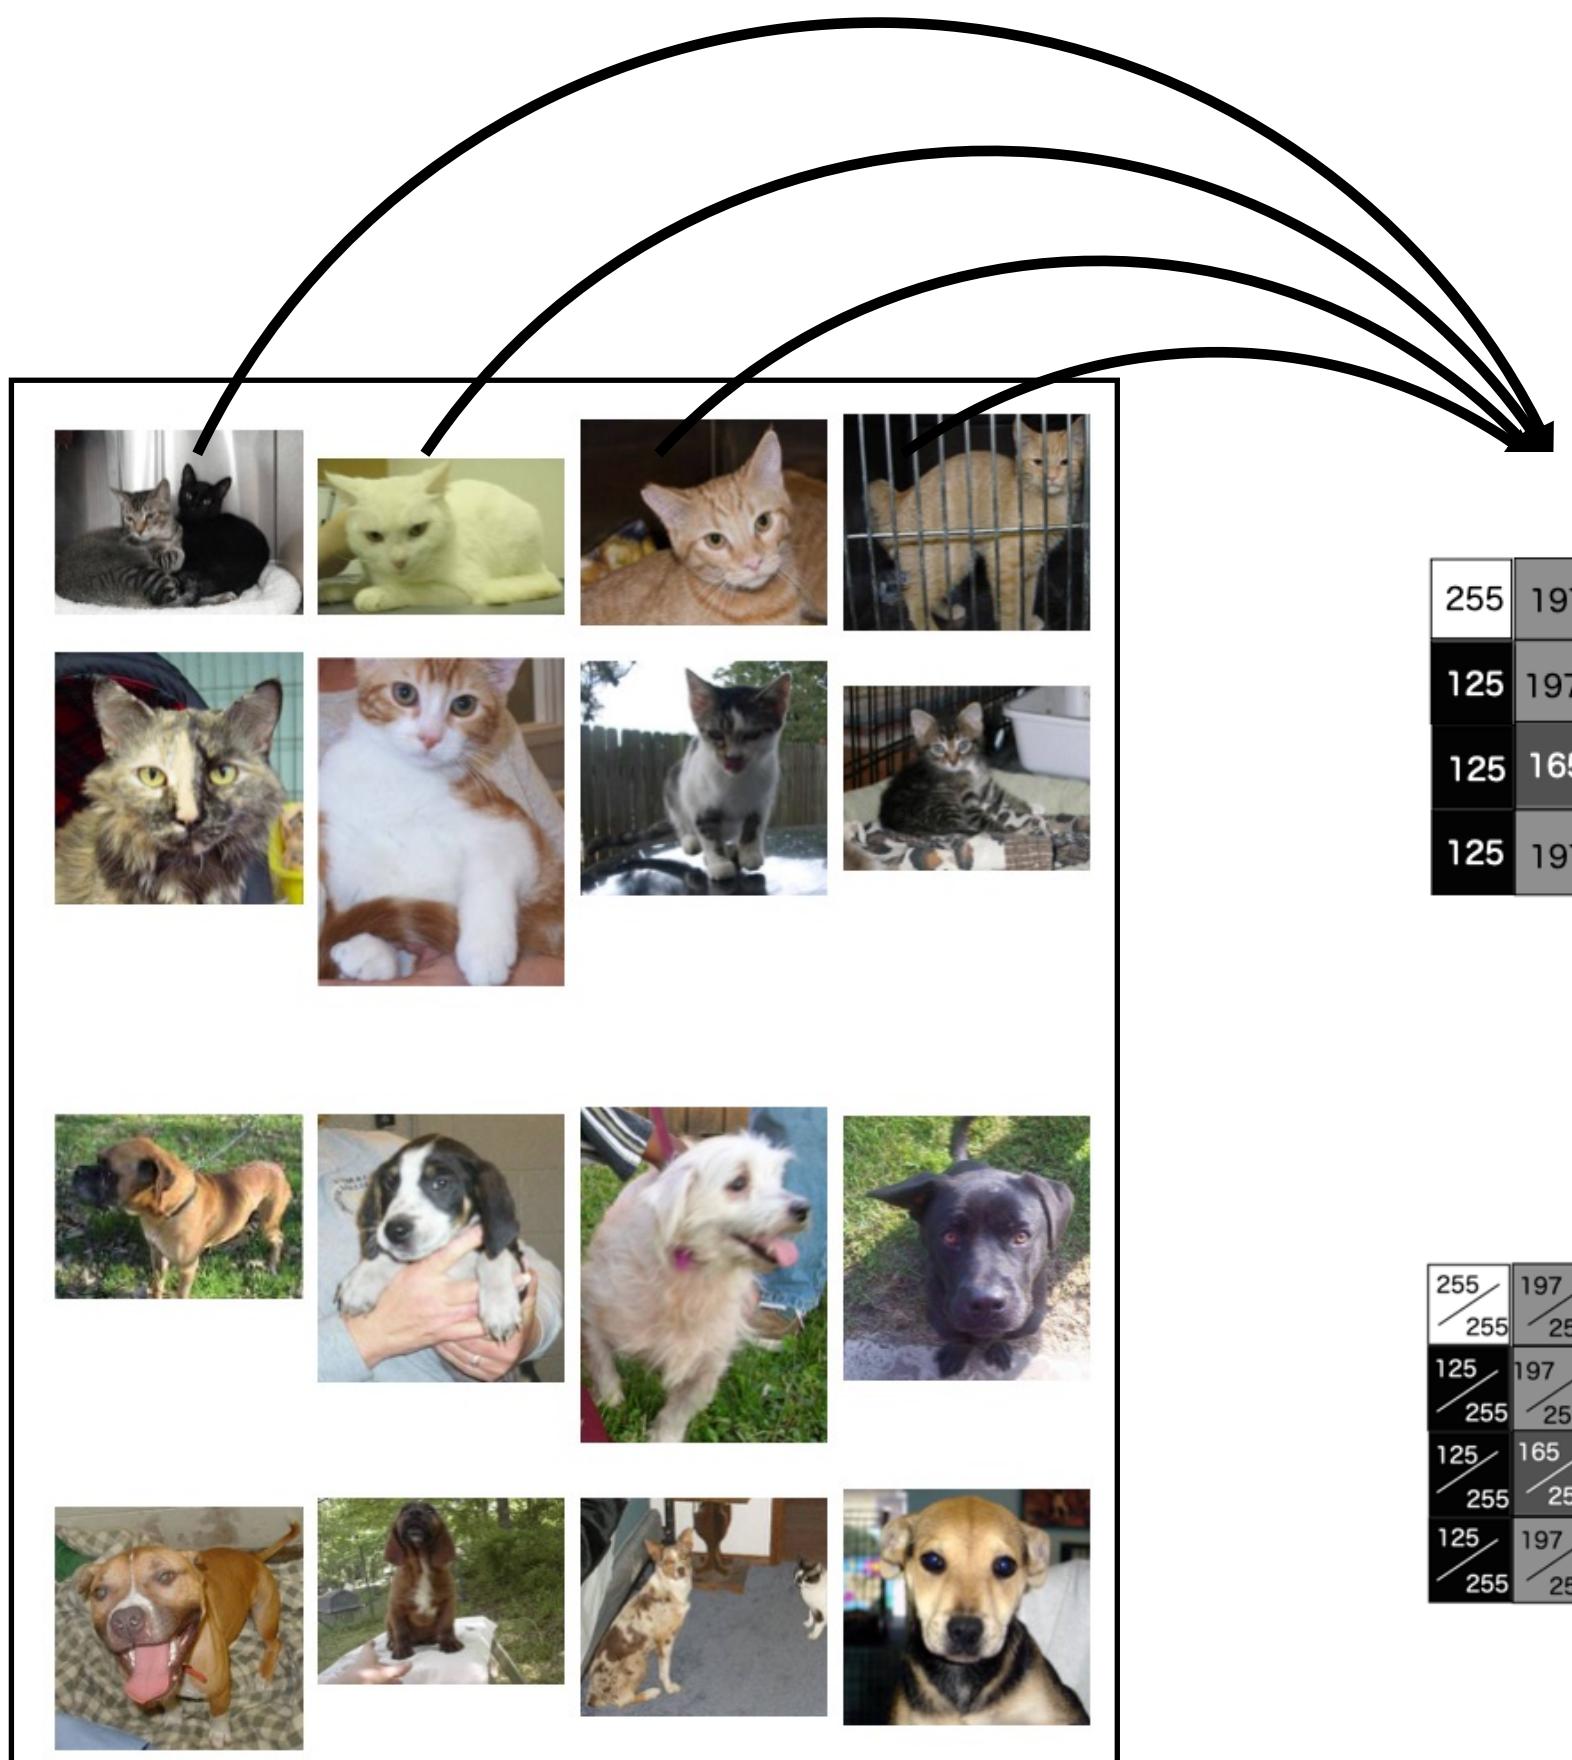
No.	出力	正解
1	0.5	1
2	0.3	1
3	0.6	1
4	0.7	1
5	0.5	0
6	0.3	0
7	0.7	0
8	0.5	0



2値分類の時はbinary crossentropy
多値分類の時はcategorical crossentropy がよく使われる

誤差E = 0.8
(だったとします)

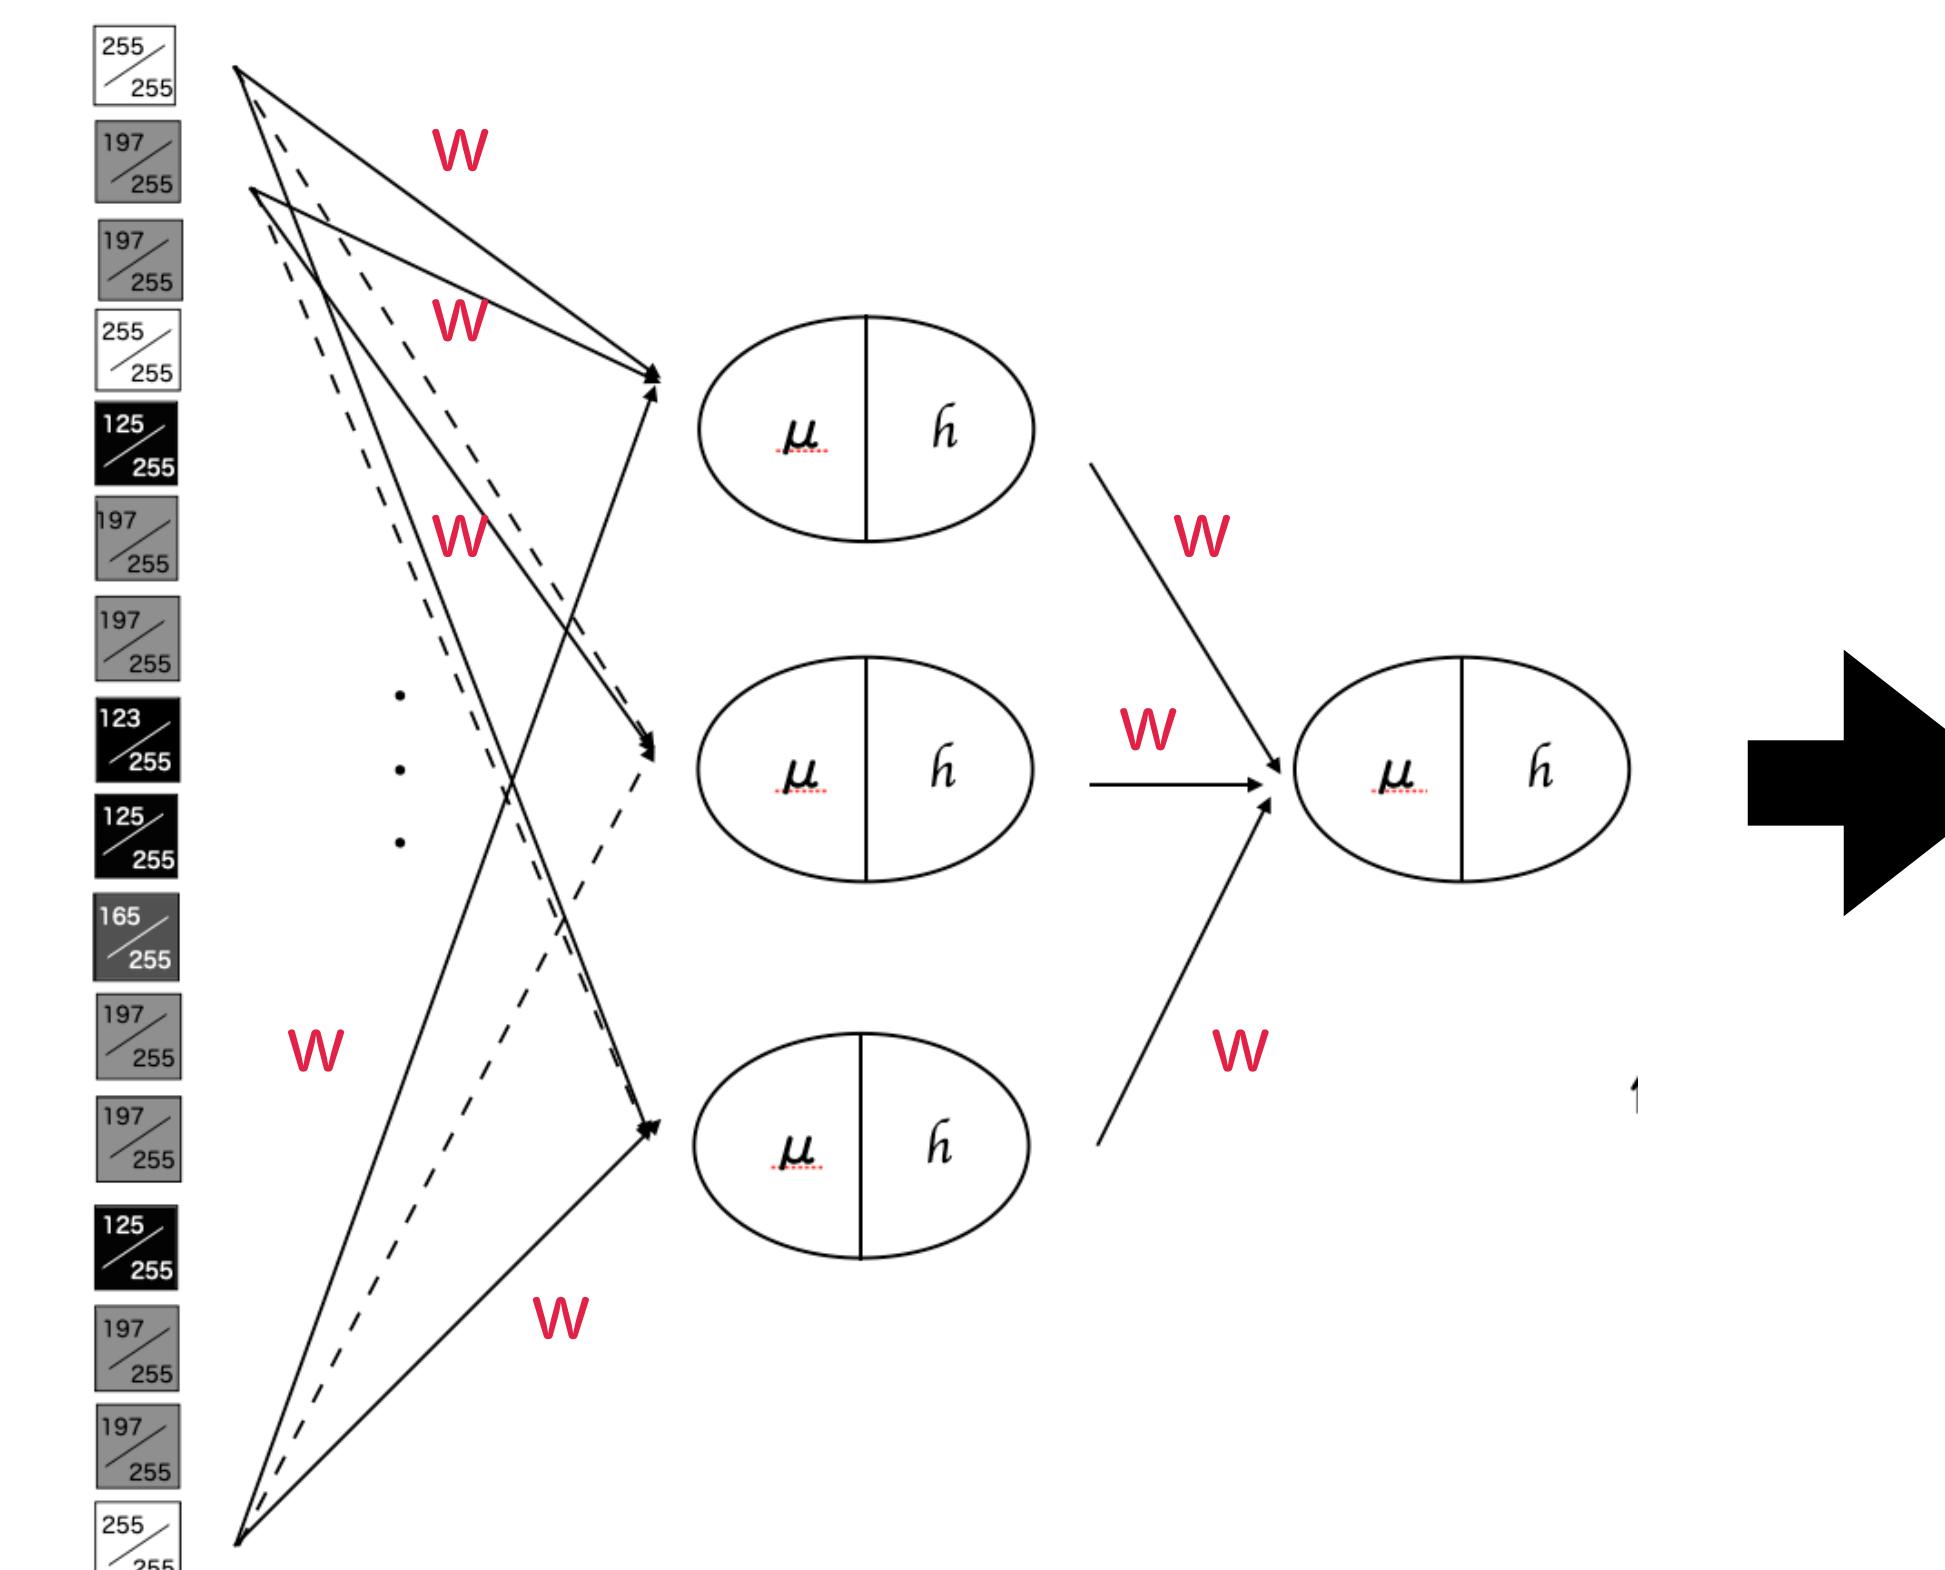
損失関数は重みとバイアスの式で表せる $E(w,b) = 0.8$



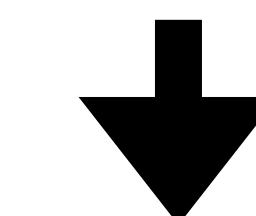
最適化関数で誤差(損失関数)を小さくなる
ように重みを更新する

255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255

255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255
255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255



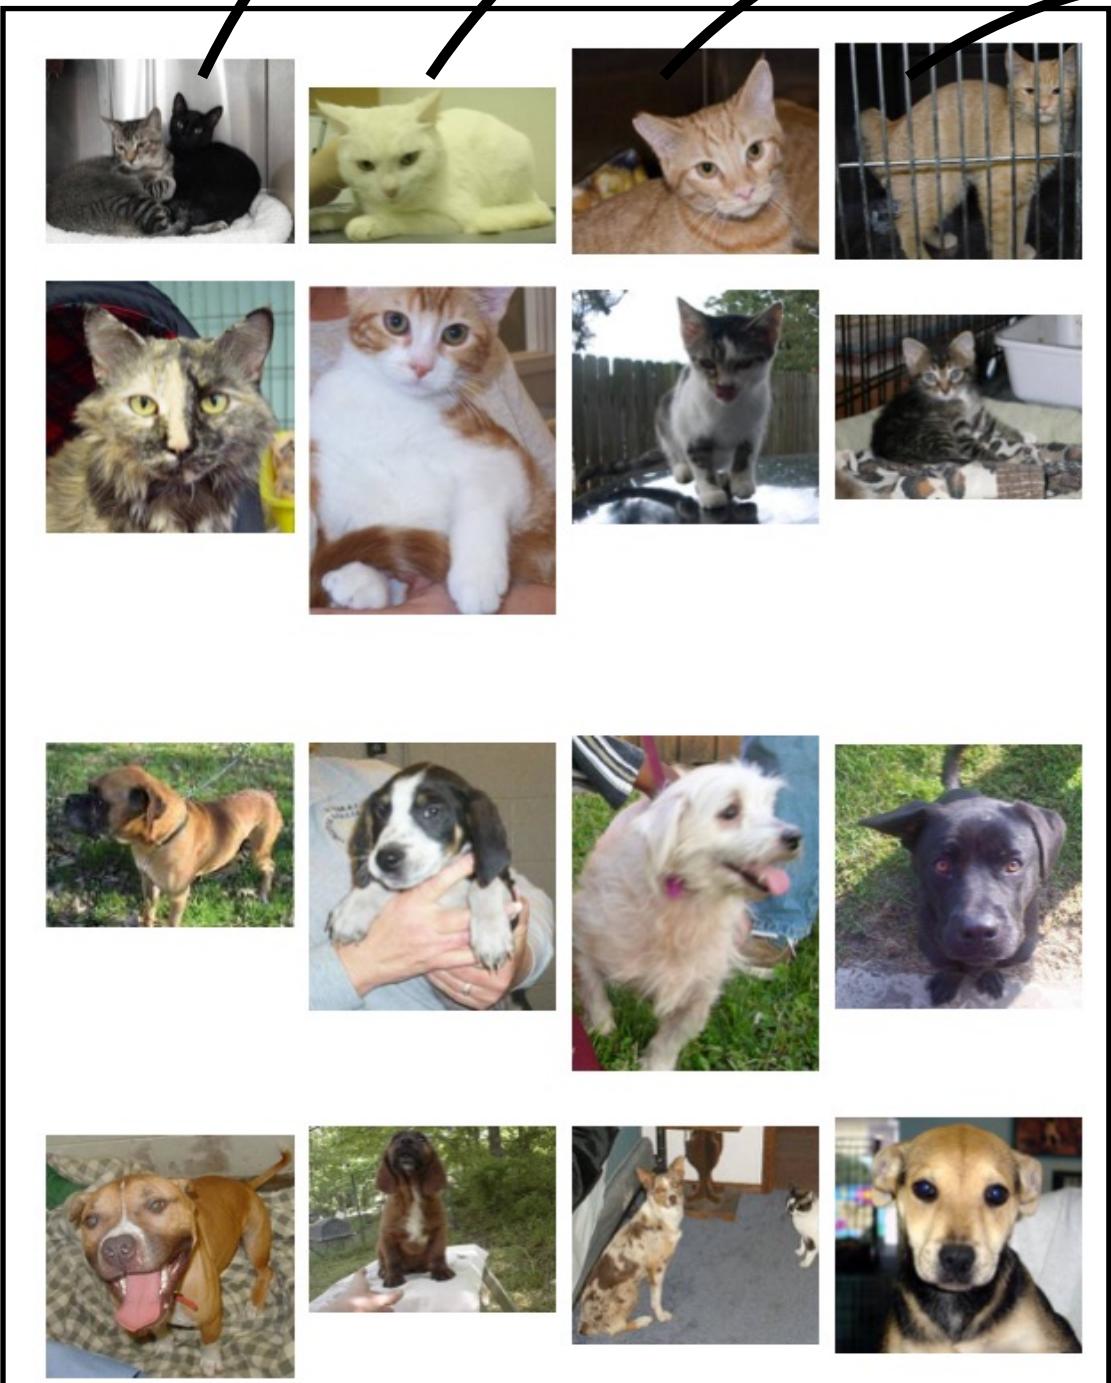
No.	出力	正解
1	0.5	1
2	0.3	1
3	0.6	1
4	0.7	1
5	0.5	0
6	0.3	0
7	0.7	0
8	0.5	0



誤差 $E = 0.8$

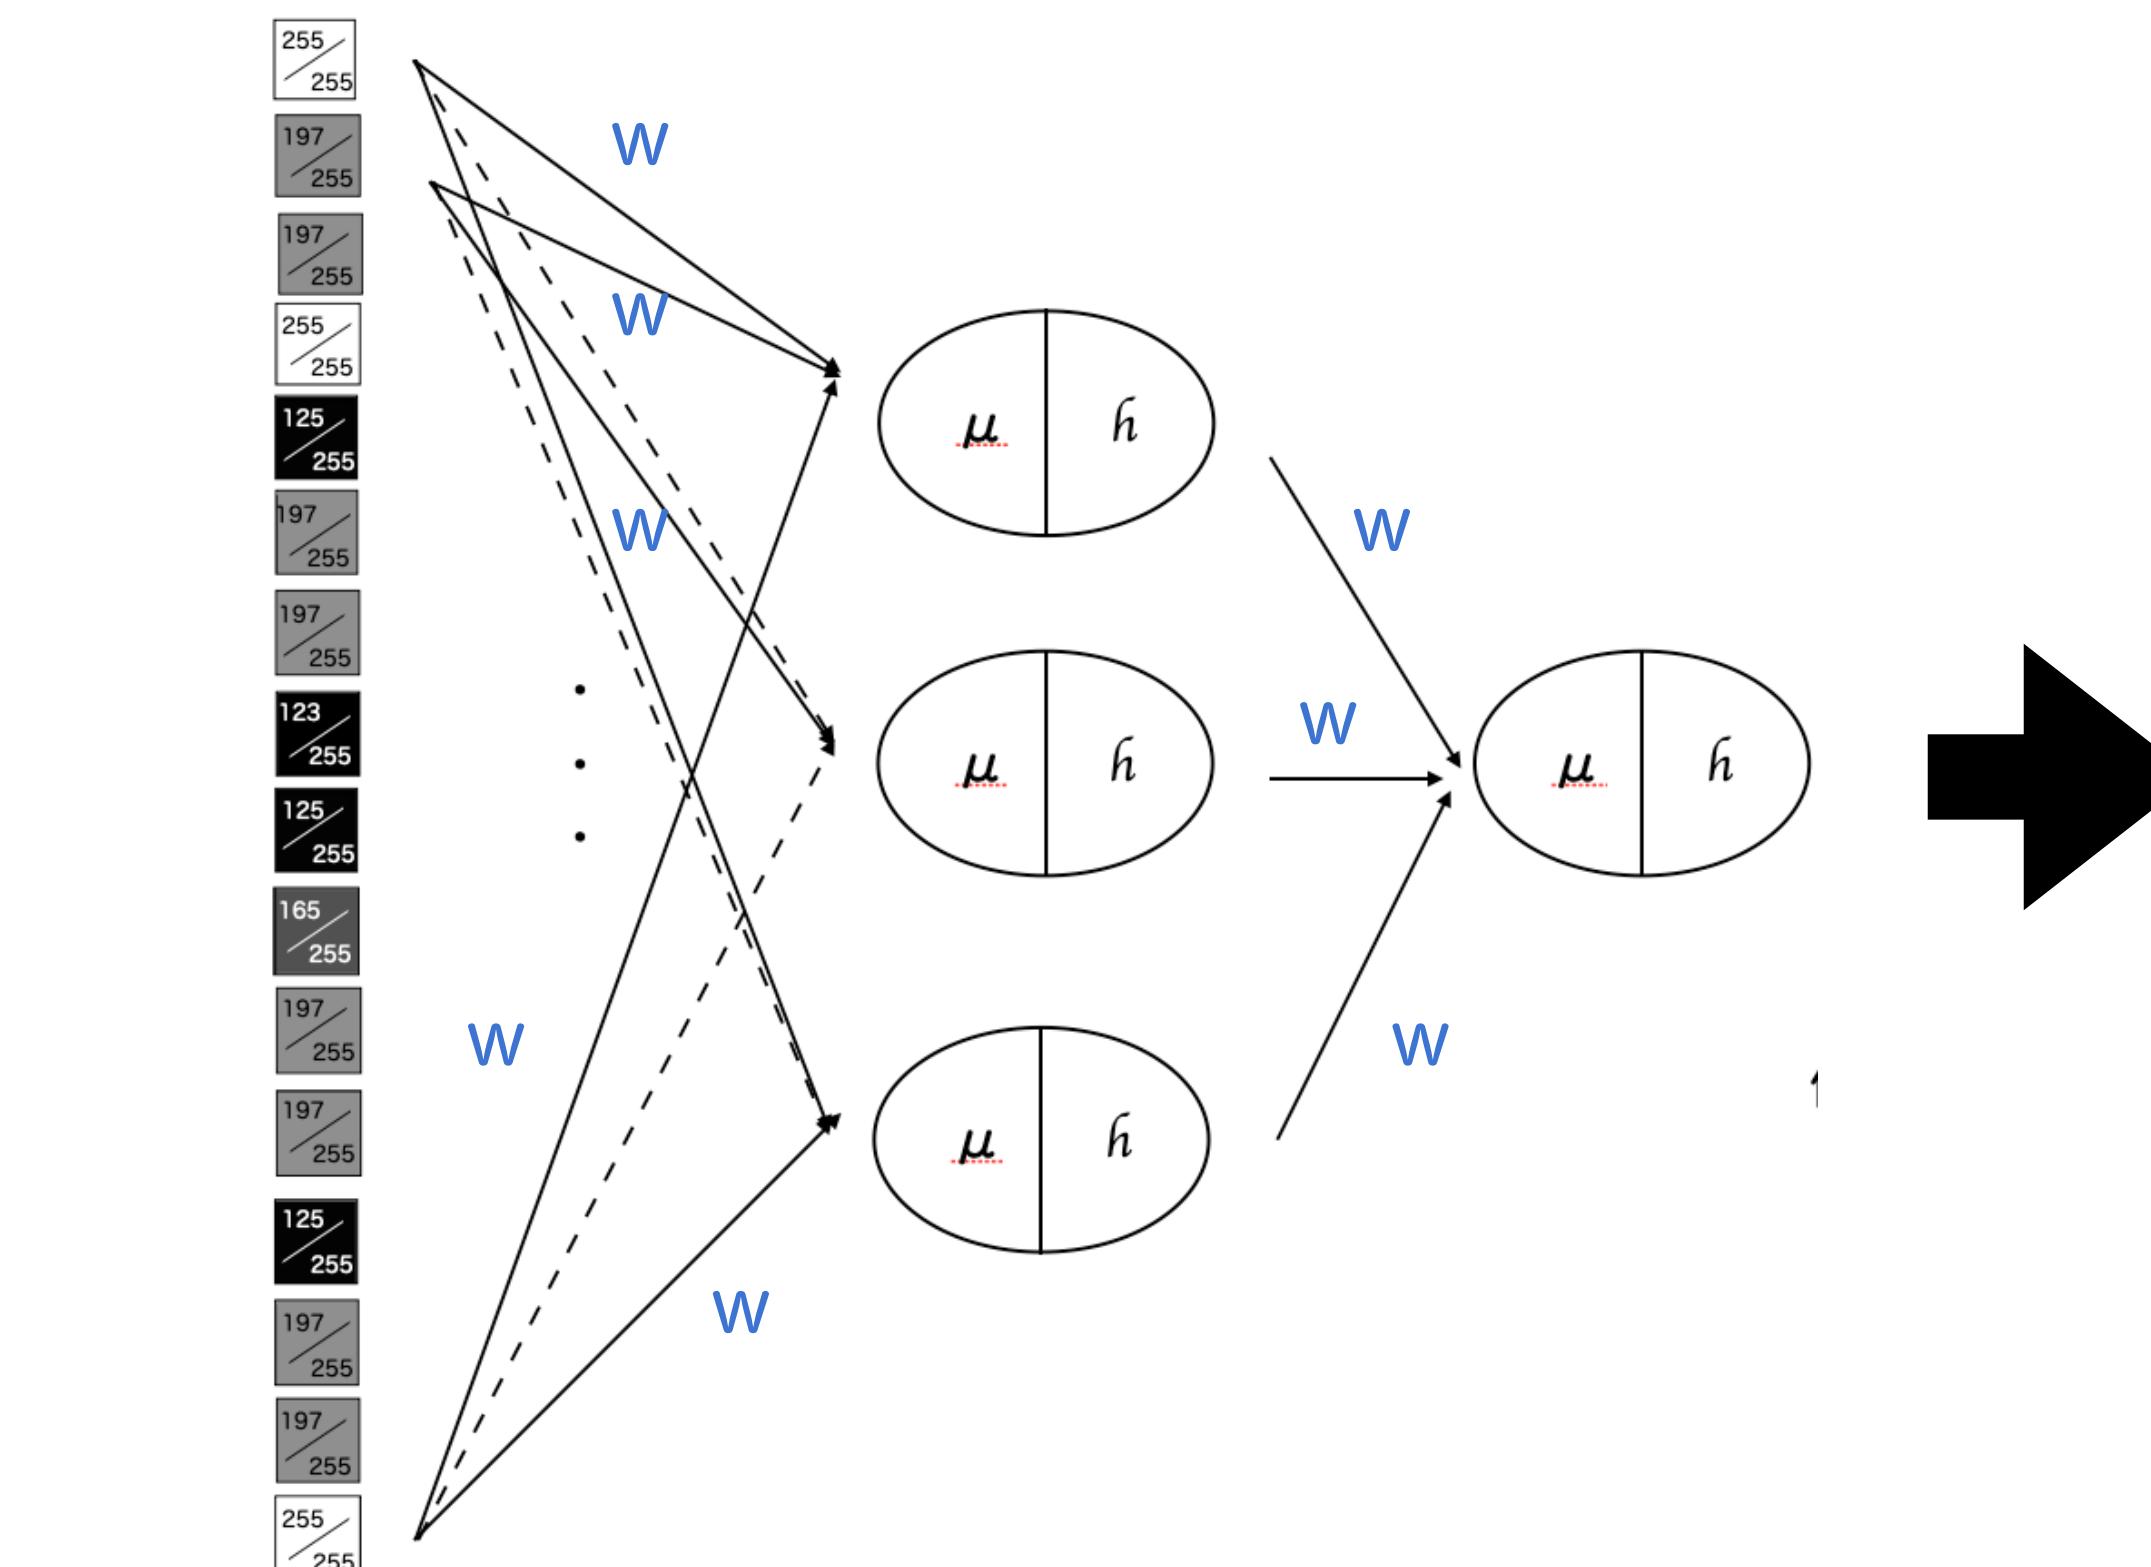
損失関数は重みとバイアスの式で表せる $E(w,b) = 0.8$

最適化関数で誤差(損失関数)を小さくなる
ように重みを更新する



255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255

255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255
255	197	197	255
125	197	197	123
125	165	197	197
125	197	197	255



No.	出力	正解
1	0.5	1
2	0.3	1
3	0.6	1
4	0.7	1
5	0.5	0
6	0.3	0
7	0.7	0
8	0.5	0

次の画像セットで
再度学習

重みとバイアスを更新
各ニューロンのwとbが変わる

最適化関数
Adam

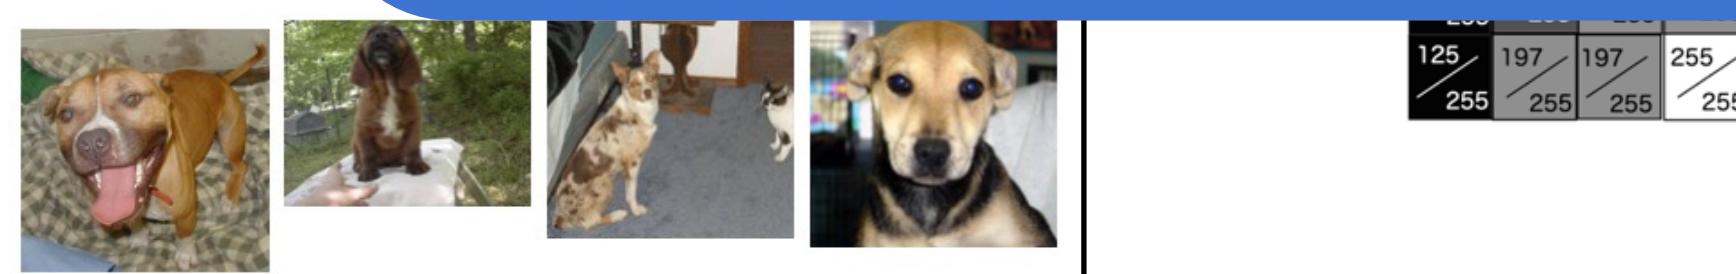
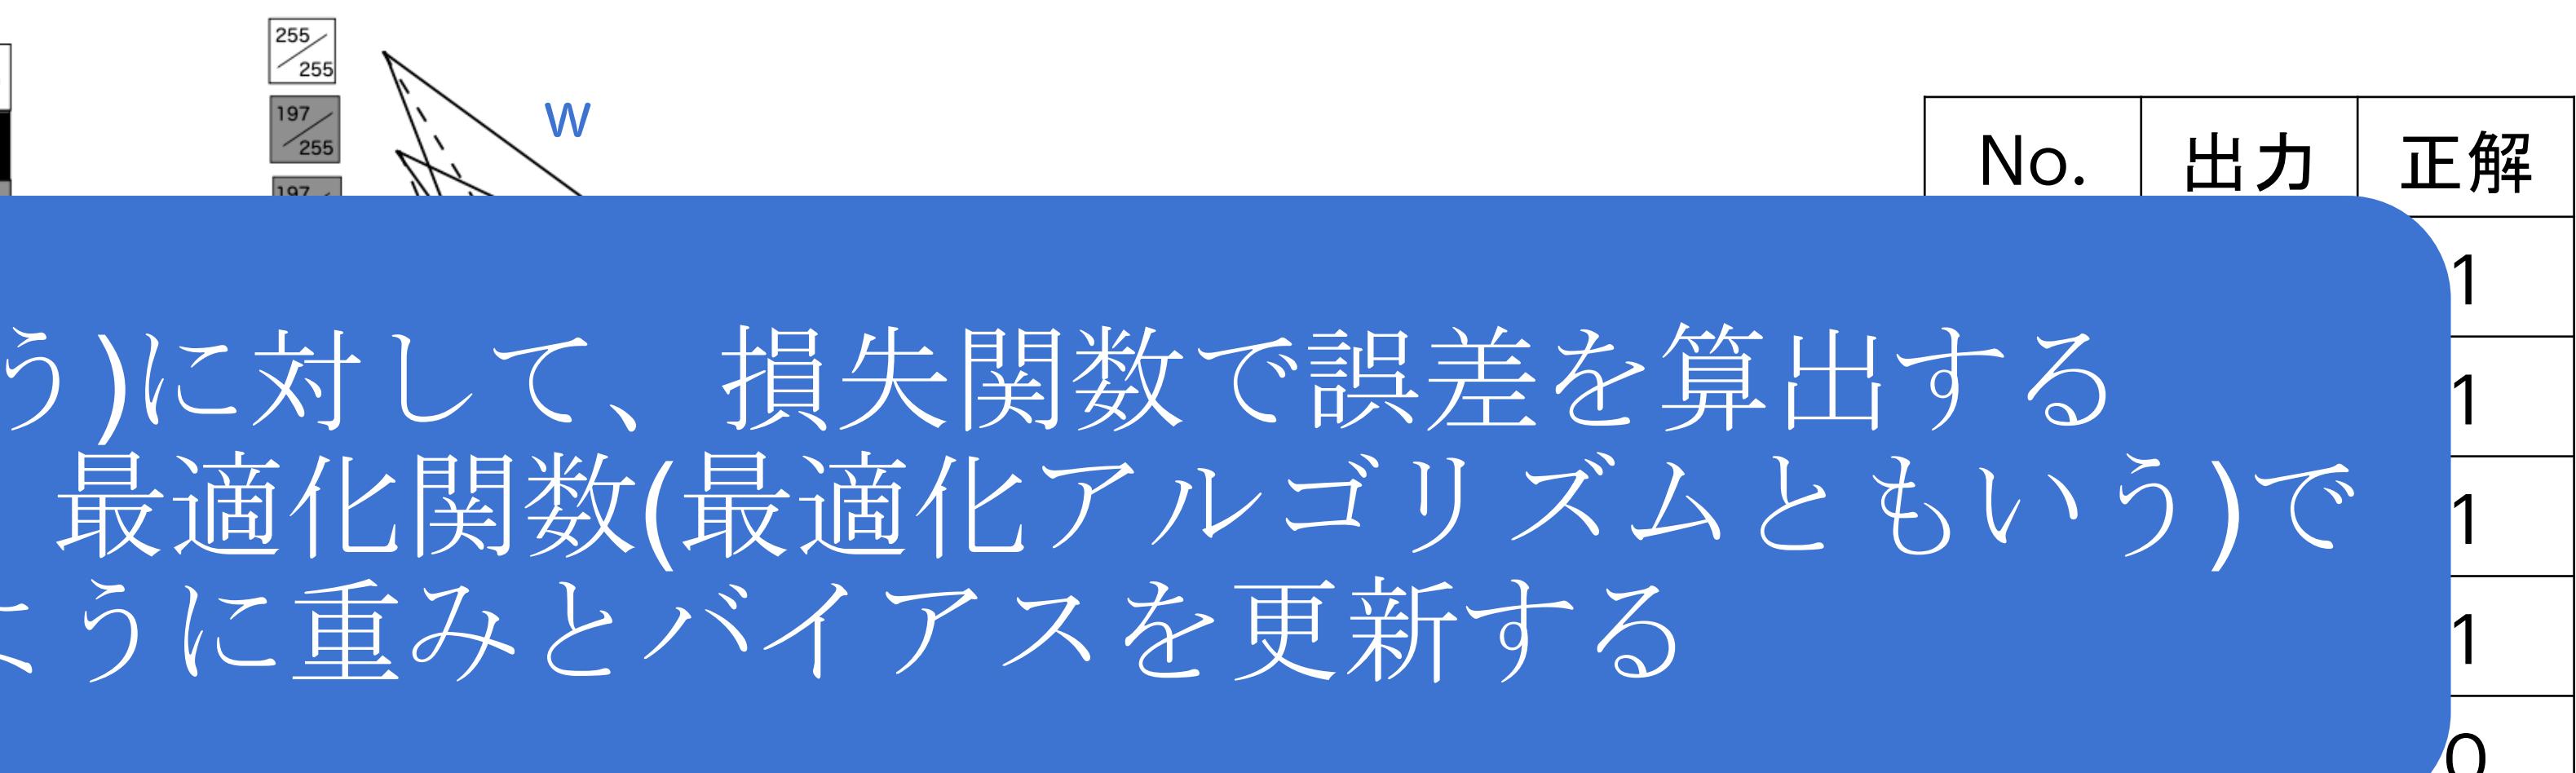
誤差 $E = 0.8$

損失関数は重みとバイアスの式で表せる $E(w,b) = 0.8$

最適化関数で誤差(損失関数)を小さくなる
ように重みを更新する



- 予測結果(推論という)に対して、損失関数で誤差を算出する
- 損失関数に対して、最適化関数(最適化アルゴリズムともいう)で誤差が小さくなるように重みとバイアスを更新する

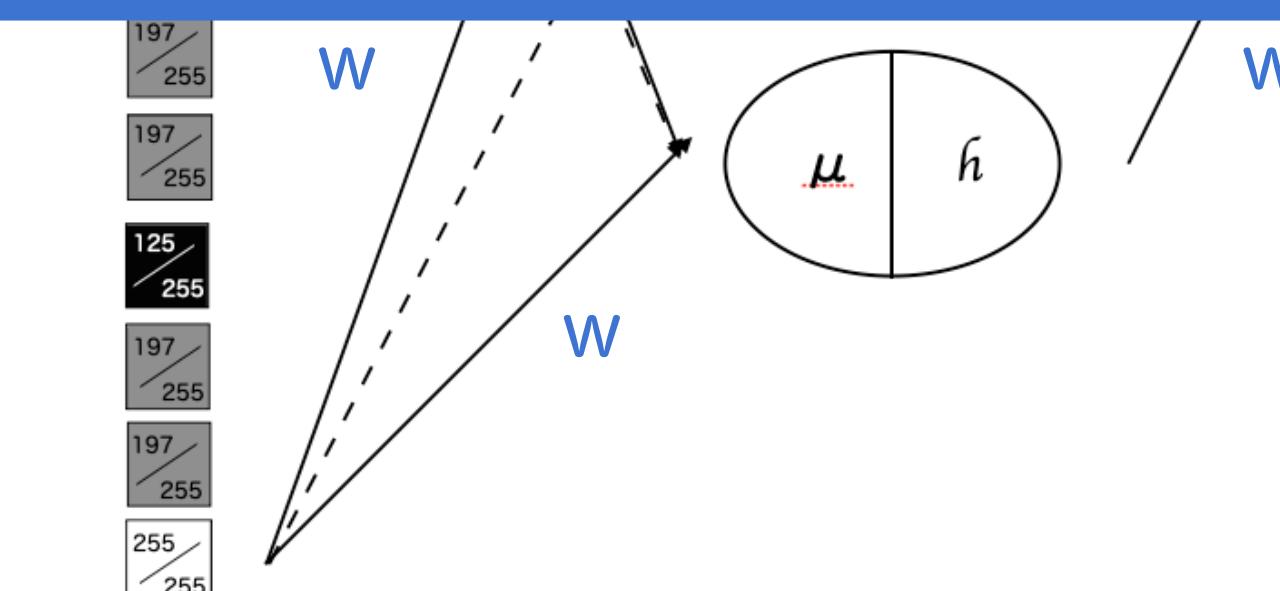


次の画像セットで
再度学習

重みとバイアスを更新
各ニューロンのwとbが変わる

最適化関数
Adam

誤差 $E = 0.8$



```
model.compile(loss='categorical_crossentropy', optimizer='Adam', metrics=['accuracy'])
```

model.compile()で評価方法を決める

loss=損失関数は‘categorical_crossentropy’

optimizer=最適化関数は‘Adam’

metrics=評価関数(モデルの評価方法)は[‘accuracy’](正解率)を指定

```
model.summary()
```

作ったモデルの要約を表示する

Layer (type)	Output Shape	Param #
=====		
dense_12 (Dense)	(None, 32)	25120
=====		
dense_13 (Dense)	(None, 10)	330
=====		
Total params:	25,450	
Trainable params:	25,450	
Non-trainable params:	0	

paramsはパラメーター(変数)
のことわざwとbの数

$$(784+1) \times 32 = 25120$$

$$(32+1) \times 10 = 330$$

$$25120 + 330 = 25450$$

まずはそのまま予測してみる

予測はmodel.predict()

test = model.predict(x_test)で、10000枚の予測結果がtestに入る

```
test = model.predict(x_test)
```

```
313/313 [=====] - 5s 2ms/step
```

test.shapeは(10000,10)で10個の要素からなる列が10000 行

```
test.shape
```

```
(10000, 10)
```

[[x_test[0]の0の確率, x_test[0]の1の確率, ..., x_test[0]の9の確率]
[x_test[1]の0の確率, x_test[1]の1の確率, ..., x_test[1]の9の確率]

10000行

·

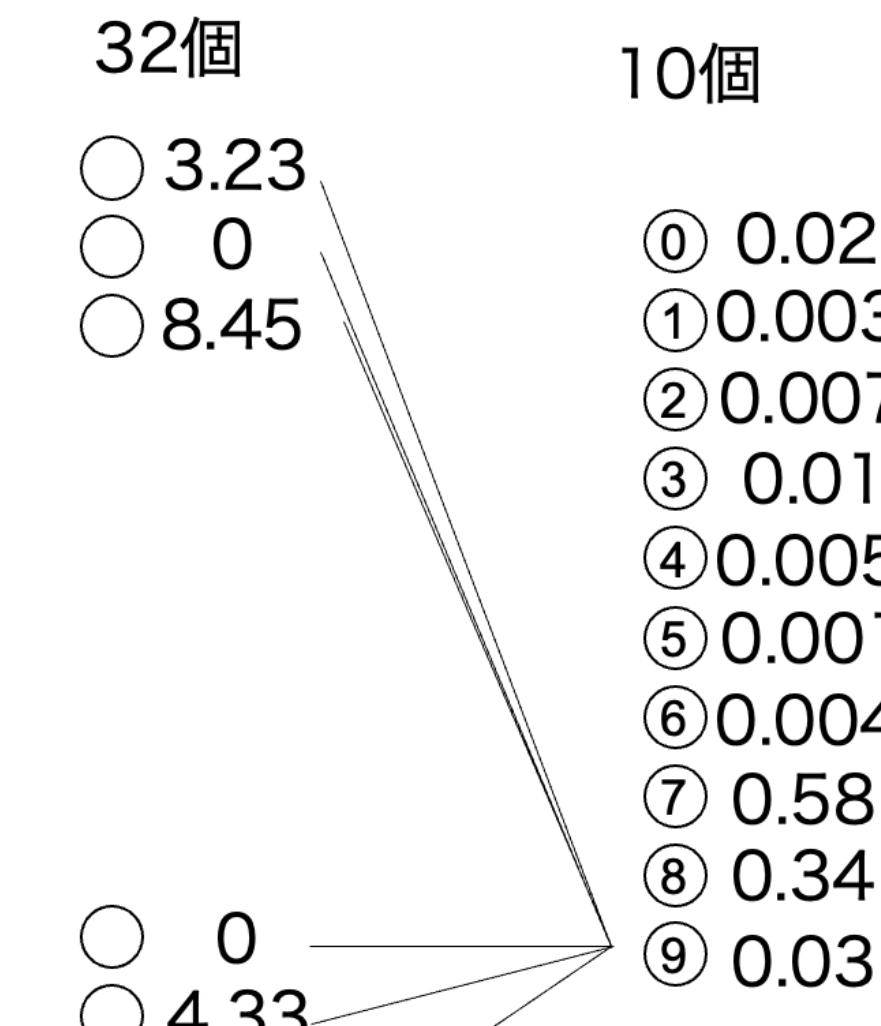
·

·

[[x_test[9998]の0の確率, x_test[9998]の1の確率, ..., x_test[9998]の9の確率]
[x_test[9999]の0の確率, x_test[9999]の1の確率, ..., x_test[9999]の9の確率]

10列

```
model.add(Dense(32, input_shape=(784,), activation='relu'))  
model.add(Dense(10, activation='softmax'))
```



mnistは10クラスあるので
出力するニューロンの数は10個

最大の確率が予測される値

まずはそのまま予測してみる

予測はmodel.predict()

x_test[1]は2なので、

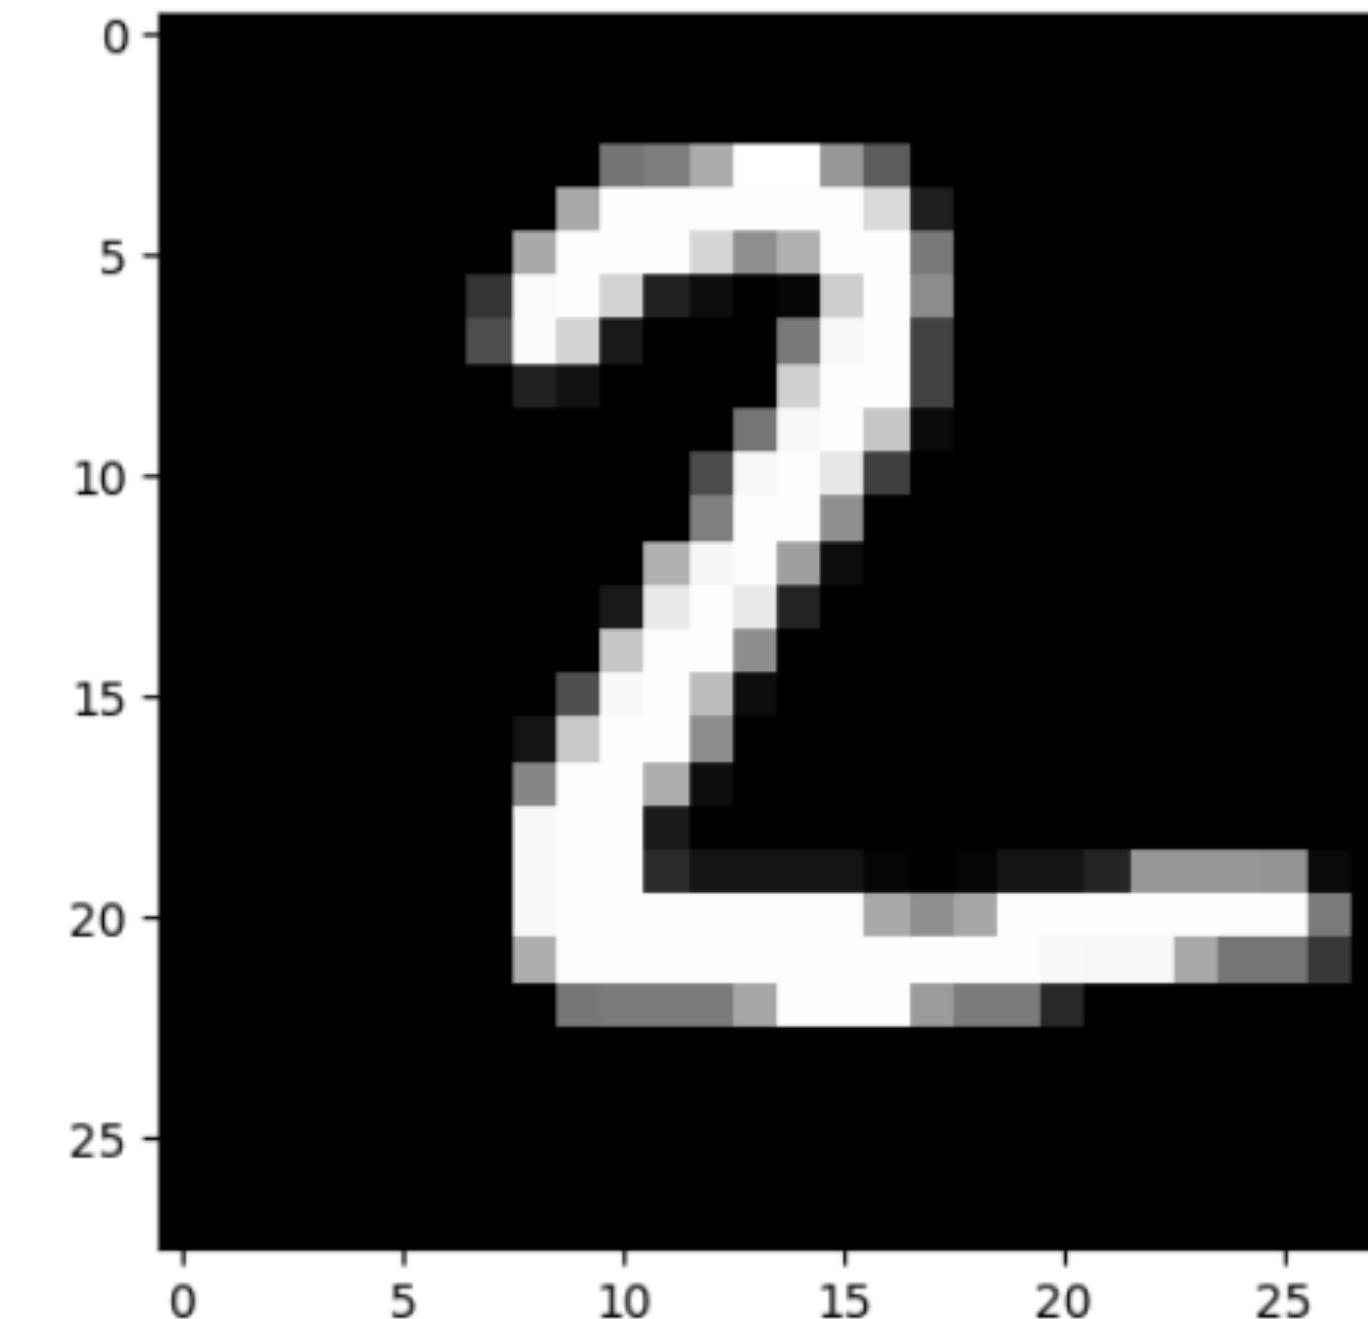
```
print(test[1])
print(y_test[1])
```

```
[0.06218787 0.13608842 0.06215866 0.06640156 0.28793582 0.04967605
 0.067972 0.10699823 0.11715493 0.04342646]
[0. 0. 1. 0. 0. 0. 0. 0. 0.]
```

まだ学習していないので、予想結果は全く合っていない

学習するとどうなるか

```
import matplotlib.pyplot as plt
plt.imshow(x_test[1], 'gray')
plt.show()
```



```
print(y_test[1])
```

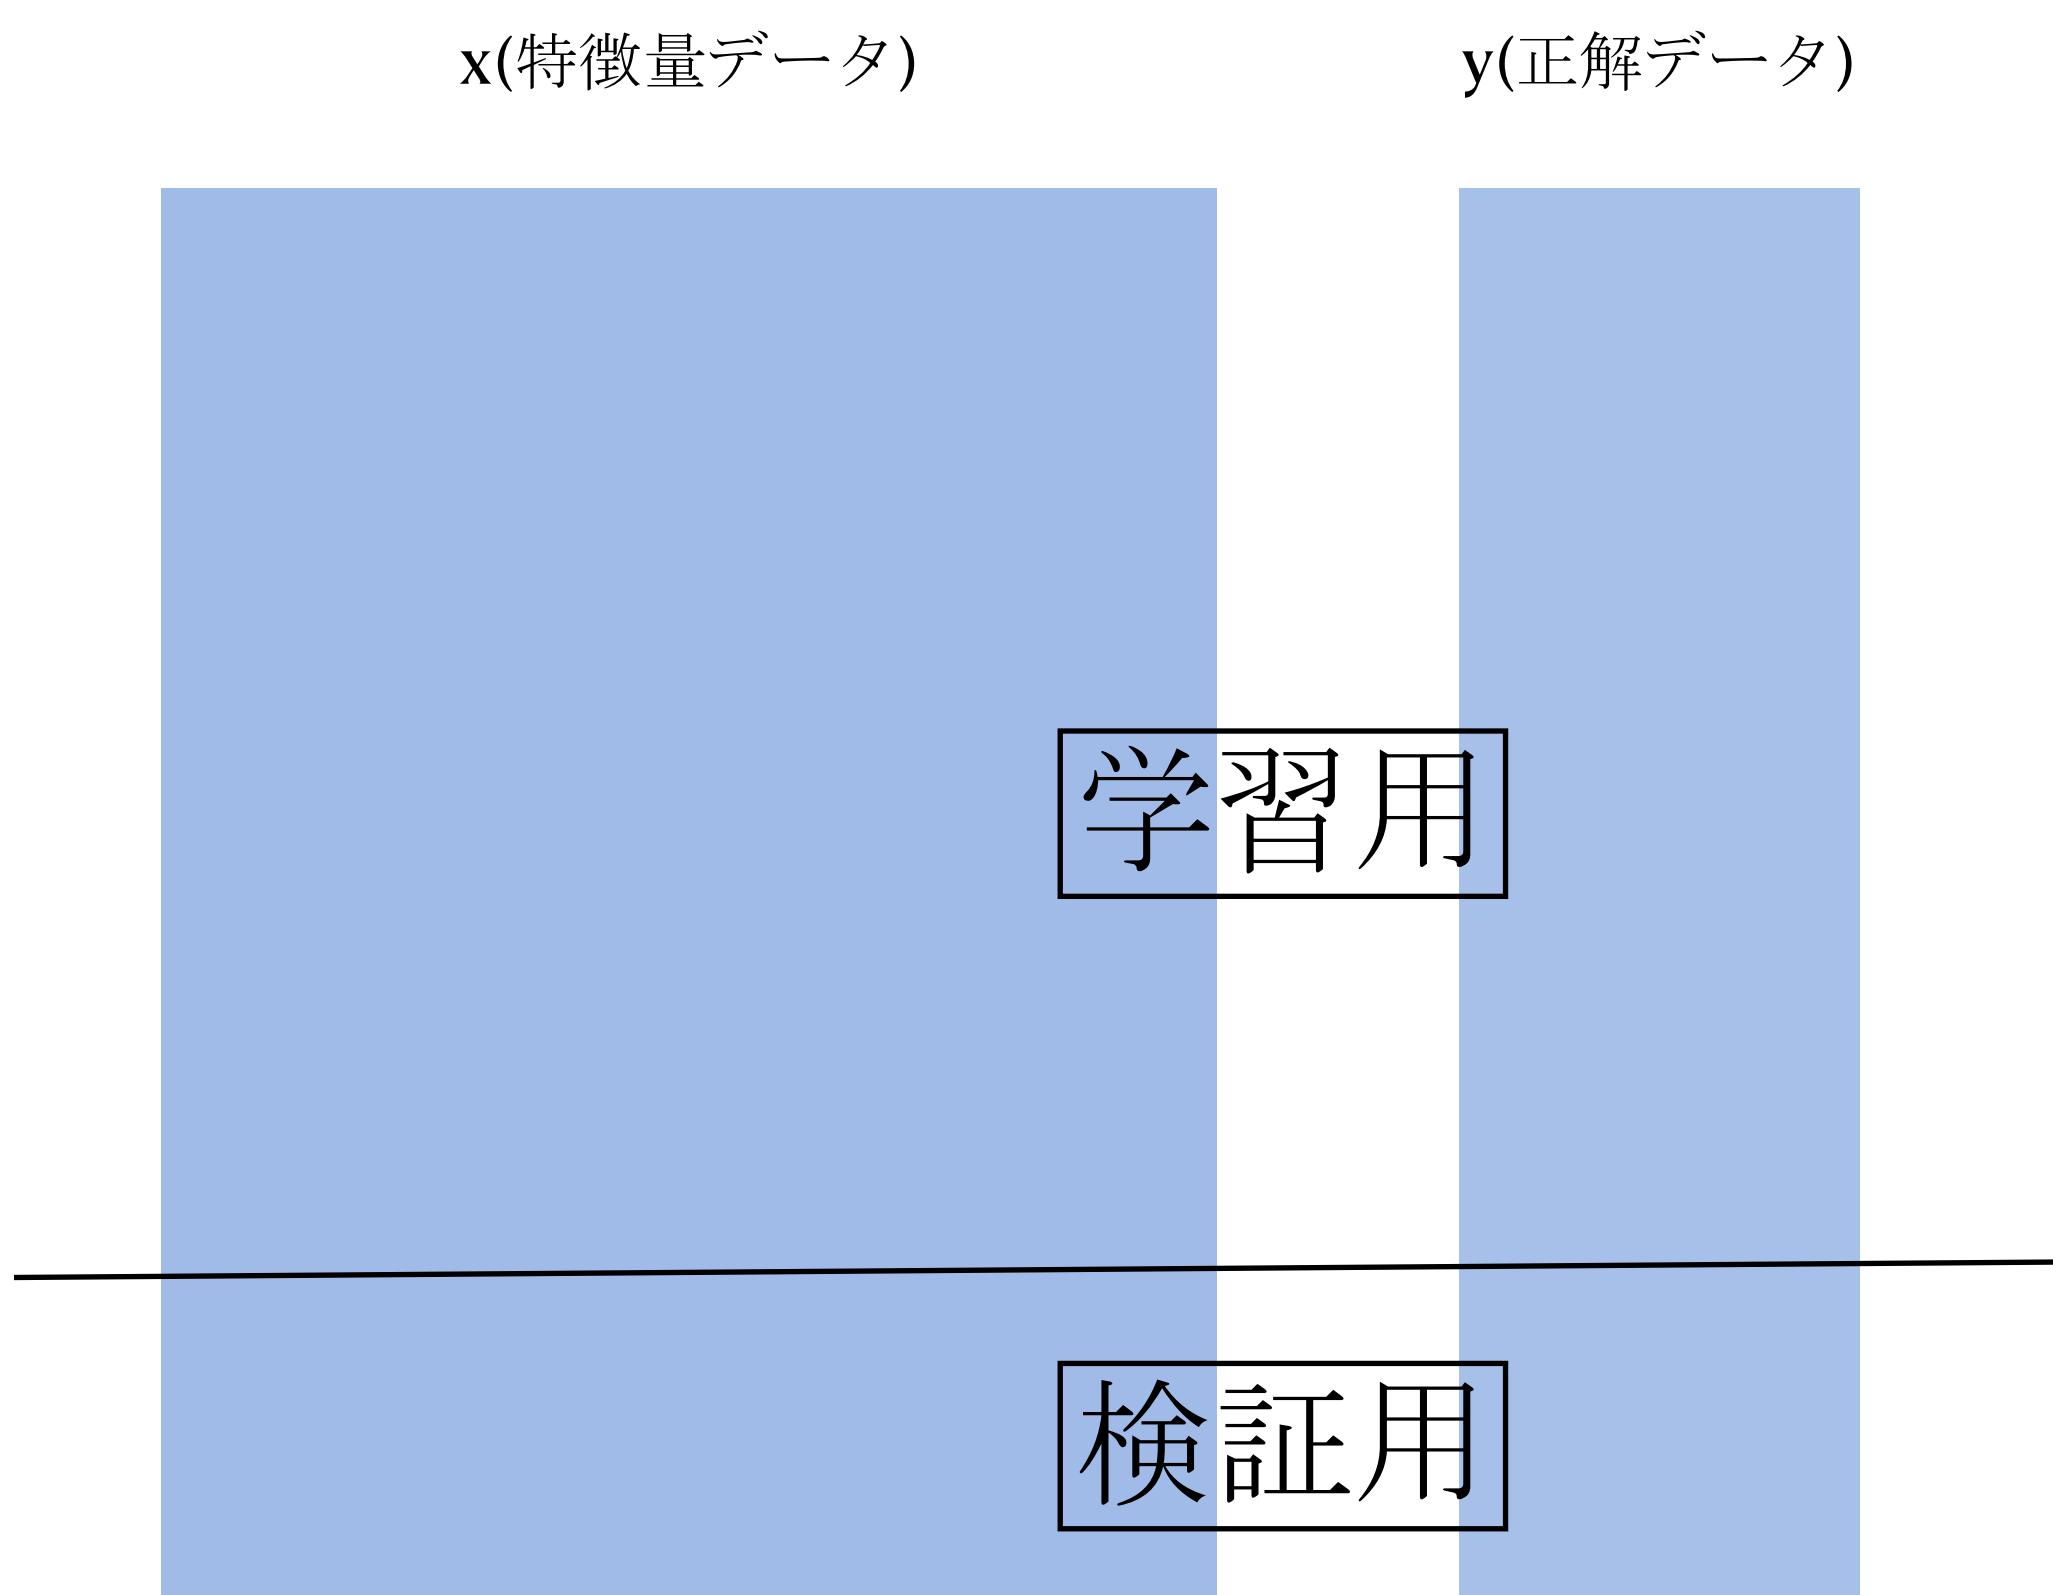
```
result = model.fit(x_train, y_train, epochs=30, batch_size=64, validation_split=0.2)
```

```
Epoch 1/30  
750/750 [=====] - 4s 4ms/step - loss: 0.4633 - accuracy: 0.8709 - val_loss: 0.2517 - val_accuracy: 0.9298  
Epoch 2/30  
750/750 [=====] - 3s 4ms/step - loss: 0.2401 - accuracy: 0.9309 - val_loss: 0.2020 - val_accuracy: 0.9448  
Epoch 3/30  
750/750 [=====] - 3s 4ms/step - loss: 0.1906 - accuracy: 0.9456 - val_loss: 0.1802 - val_accuracy: 0.9498  
.  
.  
Epoch 28/30  
750/750 [=====] - 3s 4ms/step - loss: 0.0288 - accuracy: 0.9922 - val_loss: 0.1434 - val_accuracy: 0.9629  
Epoch 29/30  
750/750 [=====] - 4s 5ms/step - loss: 0.0270 - accuracy: 0.9930 - val_loss: 0.1353 - val_accuracy: 0.9660  
Epoch 30/30  
750/750 [=====] - 3s 4ms/step - loss: 0.0264 - accuracy: 0.9930 - val_loss: 0.1381 - val_accuracy: 0.9654
```

model.fit()で実際に学習が行われる

学習は学習用データを全て使いません！
なぜだか覚えてますか？

ホールドアウト法



新たにデータを用意するのではなく、
全データを学習用と検証用に分割する
(20~30%で分割するのが一般的)

```
result = model.fit(x_train, y_train, epochs=30, batch_size=64, validation_split=0.2)
```

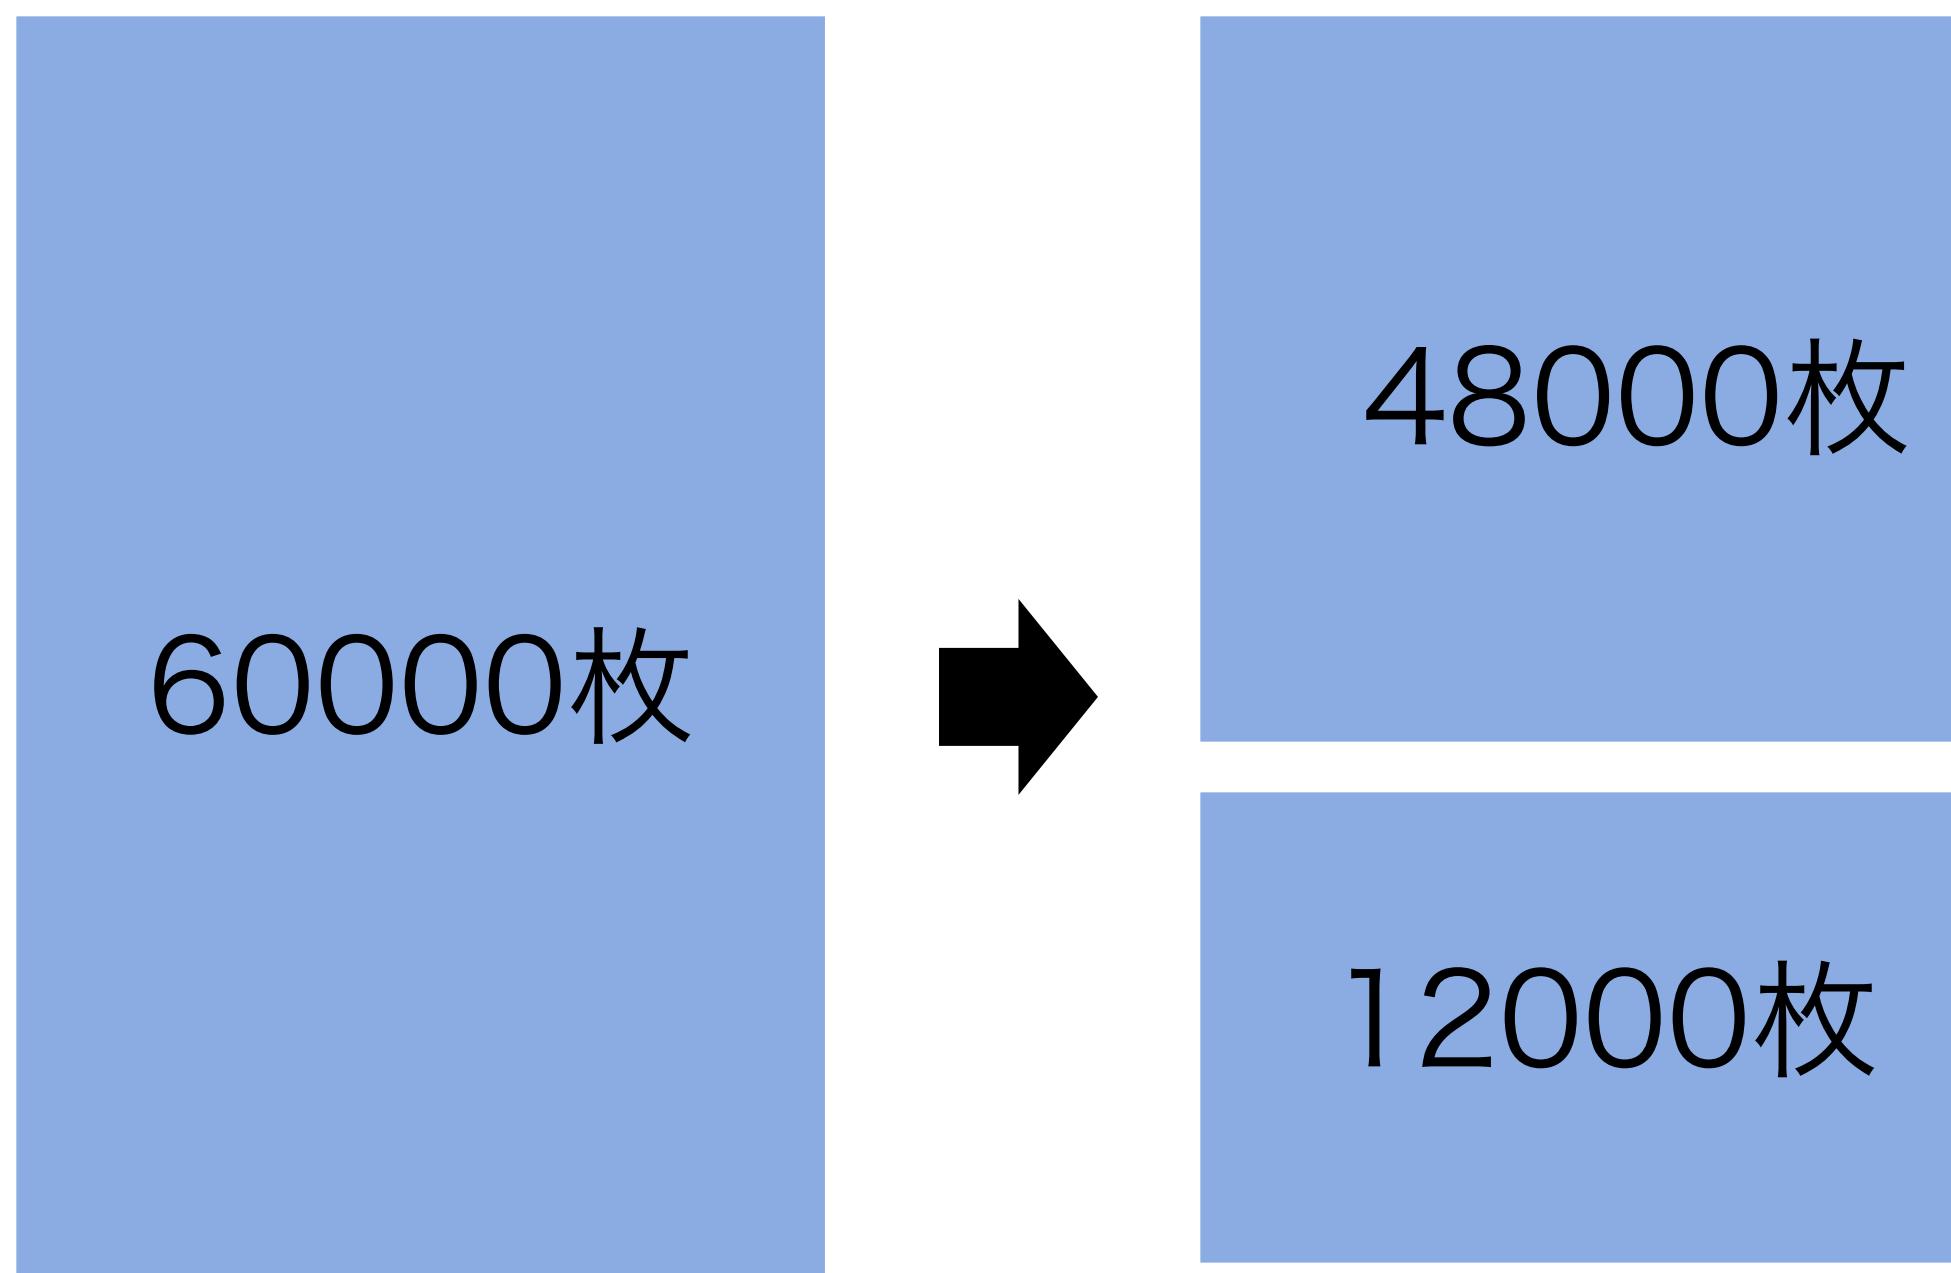
x_train : 60000枚の画像

y_train : 60000枚の画像の正解ラベル

epochs : 30回学習させる

batch_size : 64枚ずつ取り出して学習させる

validation_split : 学習用データの0.2(2割)を検証用データに使用する



64枚ずつ取り出して学習
 $64 \times 750 = 48000$
→750回重みを更新

↓
12000枚の画像で検証

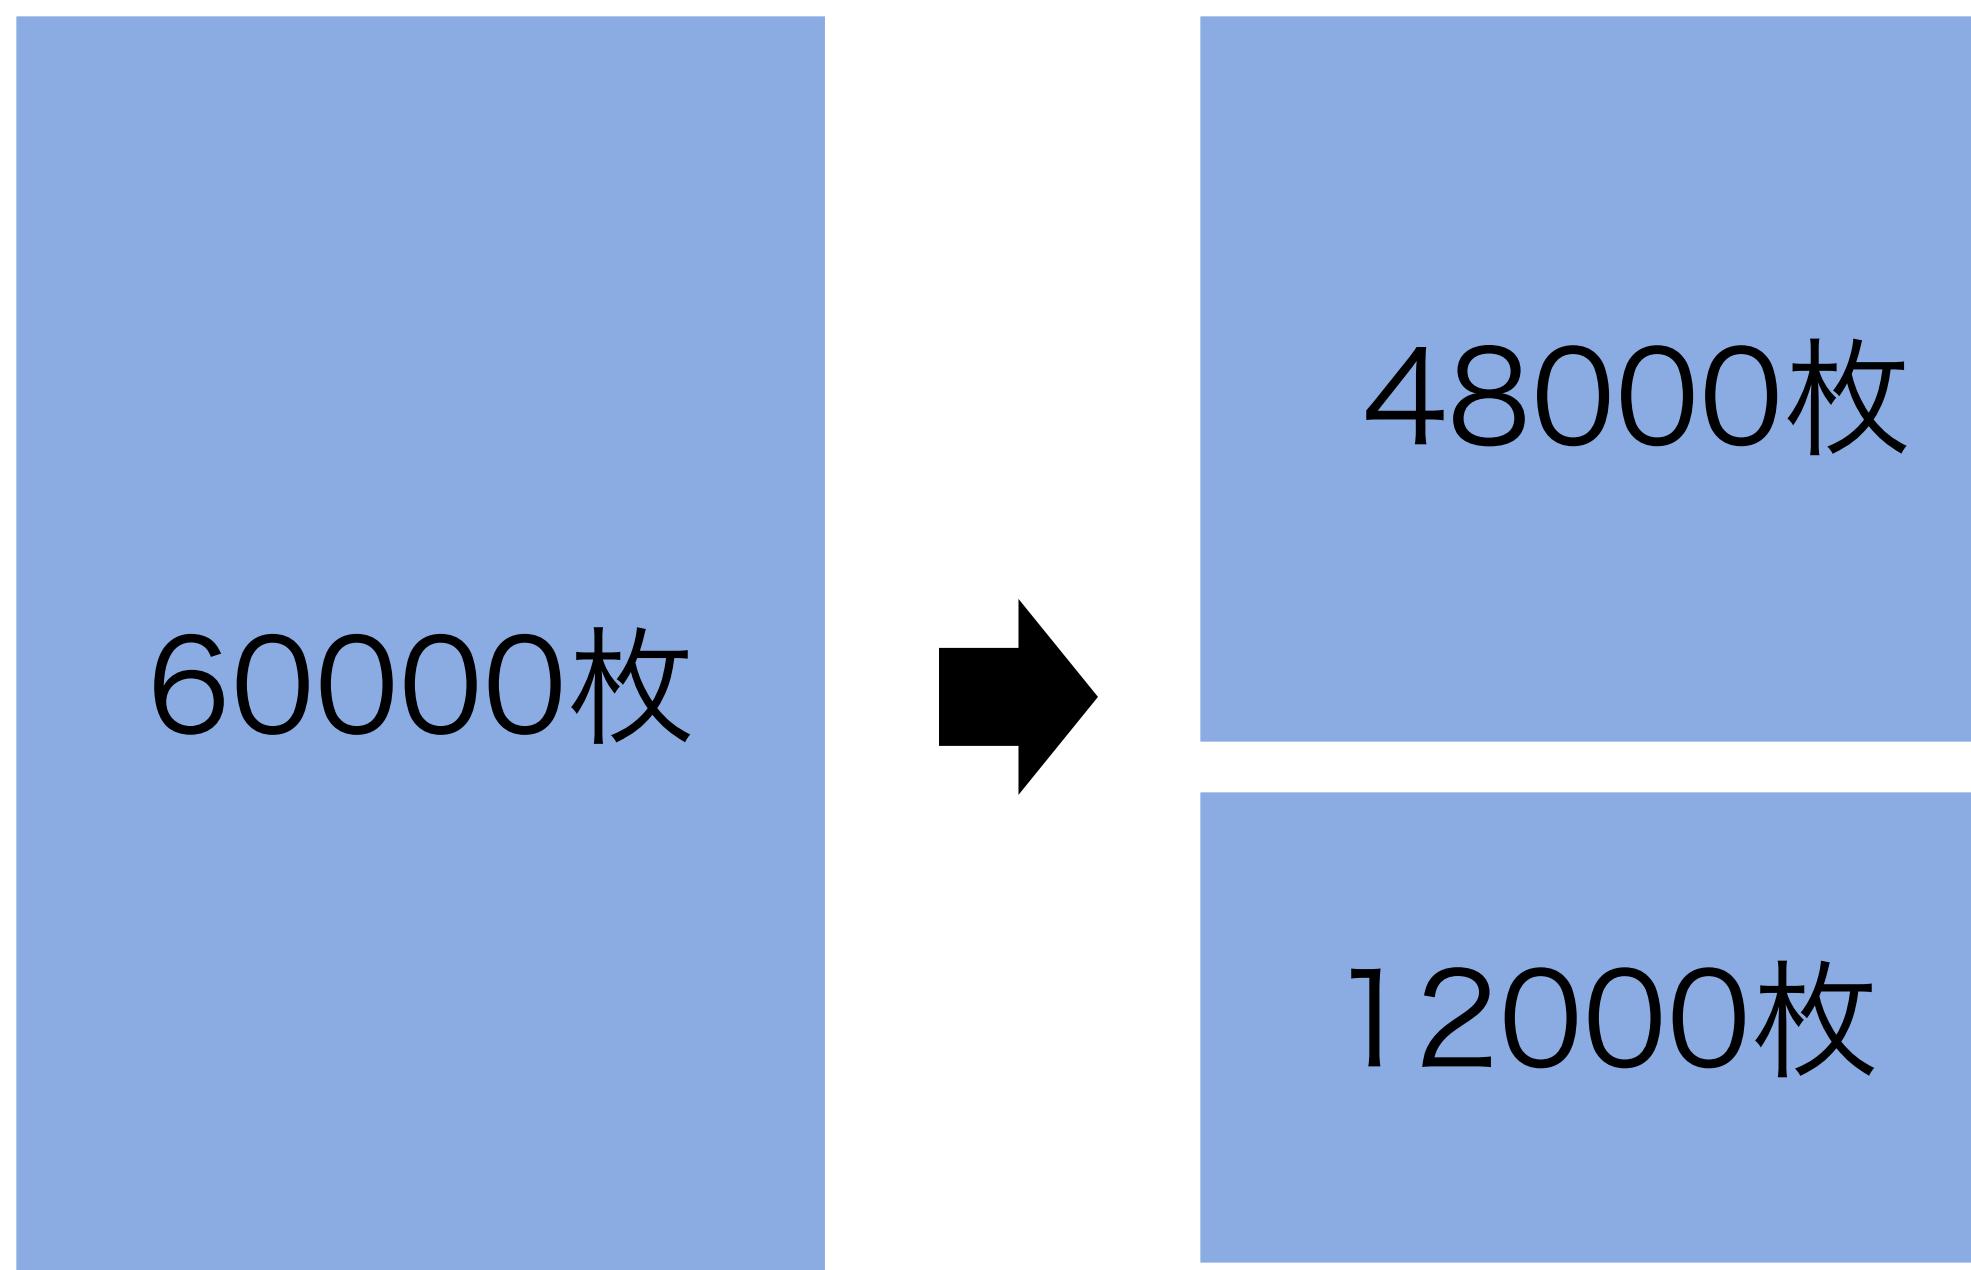
この作業を
30回繰り返す

```
result = model.fit(x_train, y_train, epochs=30, batch_size=64, validation_split=0.2)
```

```
Epoch 1/30  
750/750 [=====] - 4s 4ms/step - loss: 0.4633 - accuracy: 0.8709 - val_loss: 0.2517 - val_accuracy: 0.9298  
Epoch 2/30  
750/750 [=====] - 3s 4ms/step - loss: 0.2401 - accuracy: 0.9309 - val_loss: 0.2020 - val_accuracy: 0.9448  
Epoch 3/30  
750/750 [=====] - 3s 4ms/step - loss: 0.1906 - accuracy: 0.9456 - val_loss: 0.1802 - val_accuracy: 0.9498
```

⋮
⋮

```
Epoch 28/30  
750/750 [=====] - 3s 4ms/step - loss: 0.0288 - accuracy: 0.9922 - val_loss: 0.1434 - val_accuracy: 0.9629  
Epoch 29/30  
750/750 [=====] - 4s 5ms/step - loss: 0.0270 - accuracy: 0.9930 - val_loss: 0.1353 - val_accuracy: 0.9660  
Epoch 30/30  
750/750 [=====] - 3s 4ms/step - loss: 0.0264 - accuracy: 0.9930 - val_loss: 0.1381 - val_accuracy: 0.9654
```



64枚ずつ取り出して学習
 $64 \times 750 = 48000$
→750回重みを更新

↓
12000枚の画像で検証

この作業を
30回繰り返す

最後に再度予測してみる

予測はmodel.predict()

一応名前を変更して学習後はtest2とする

```
test2 = model.predict(x_test)  
313/313 [=====] - 1s 2ms/step
```

2枚目を再度確認

```
print(test2[1])  
[8.0701529e-11 3.9249046e-10 9.9999940e-01 8.3521821e-09 1.4485680e-28  
 6.2819618e-07 2.5197353e-11 1.3647900e-22 2.3160052e-10 1.9060435e-24]
```

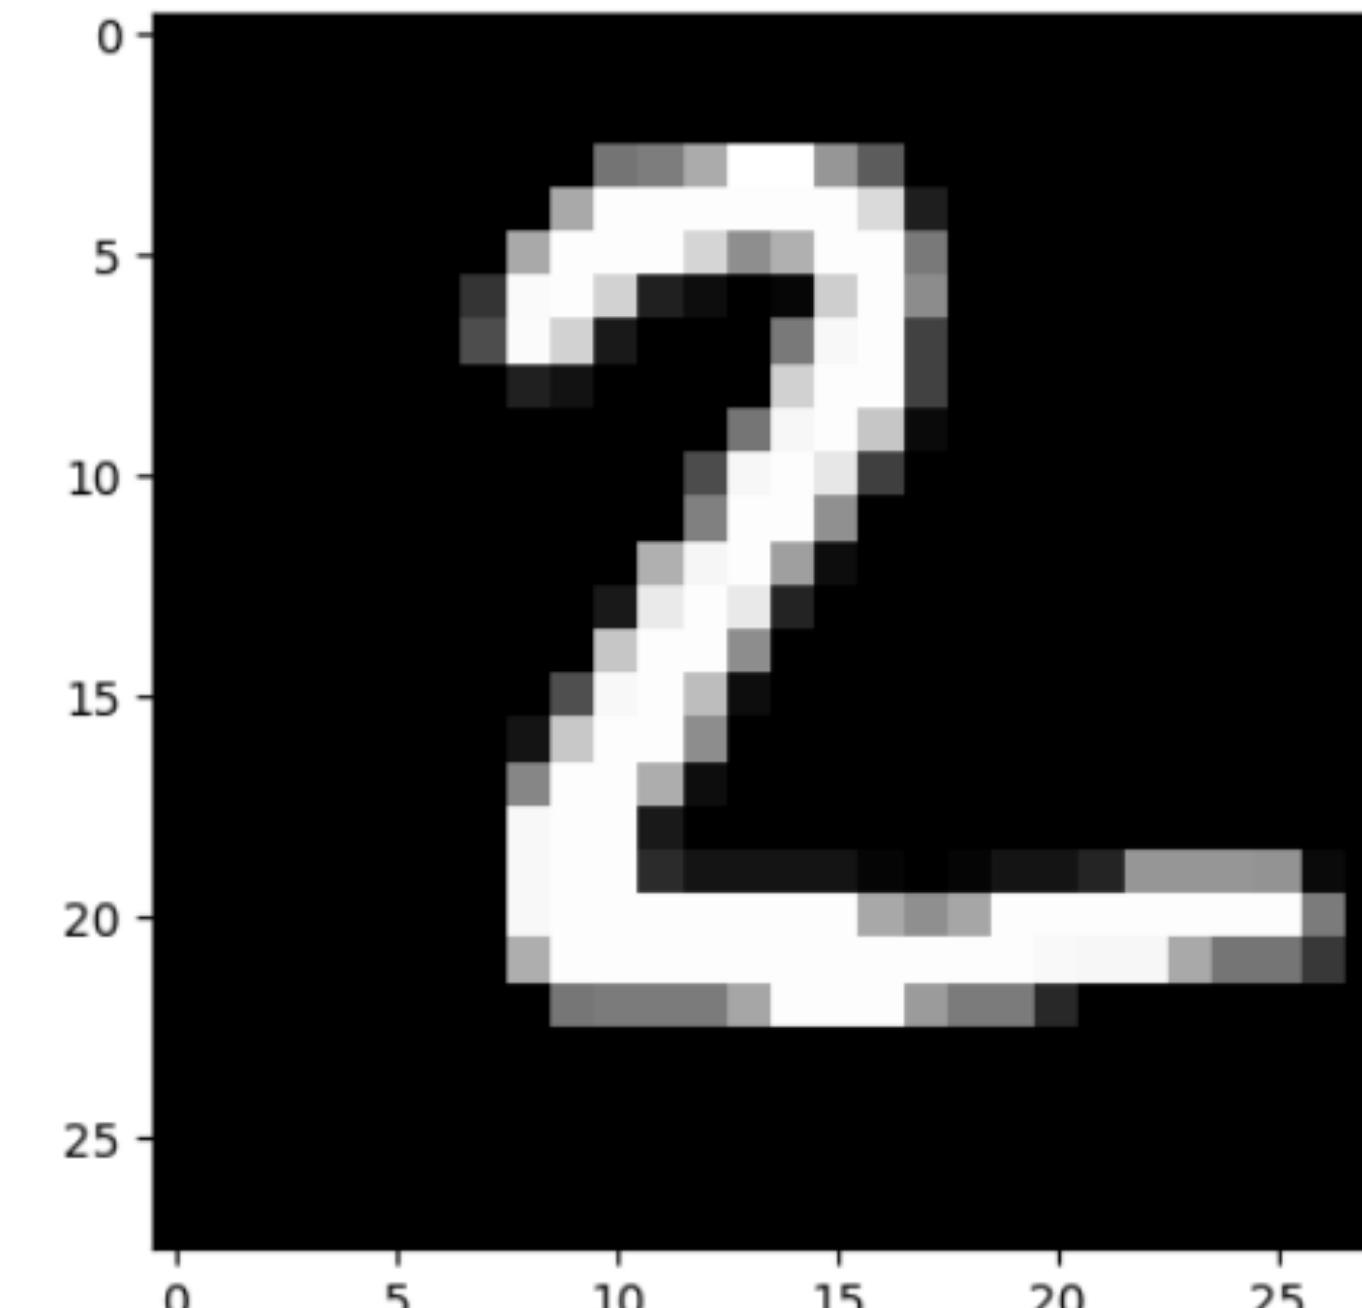
8.07e-11 は $8.07 \times 10^{-11} = 0.0000000000807$

```
import numpy as np  
print(np.around(test2[1],3))  
print(y_test[1])  
  
[0. 0. 1. 0. 0. 0. 0. 0. 0.]  
[0. 0. 1. 0. 0. 0. 0. 0. 0.]
```

np.aroung(配列, num)で、
配列を少数第num位で四捨五入

99.9999...%で2と予想している

```
import matplotlib.pyplot as plt  
plt.imshow(x_test[1],'gray')  
plt.show()
```



```
print(y_test[1])
```

課題

- ・WebClassにある"kadai4.ipynb"をやってみましょう
- ・実行したら"学籍番号_名前_4.ipynb"という名前で保存して提出して下さい。

締め切りは2週間後の11/16の23:59です。

締め切りを過ぎた課題は受け取らないので注意して下さい

医療とAI・ビッグデータ応用

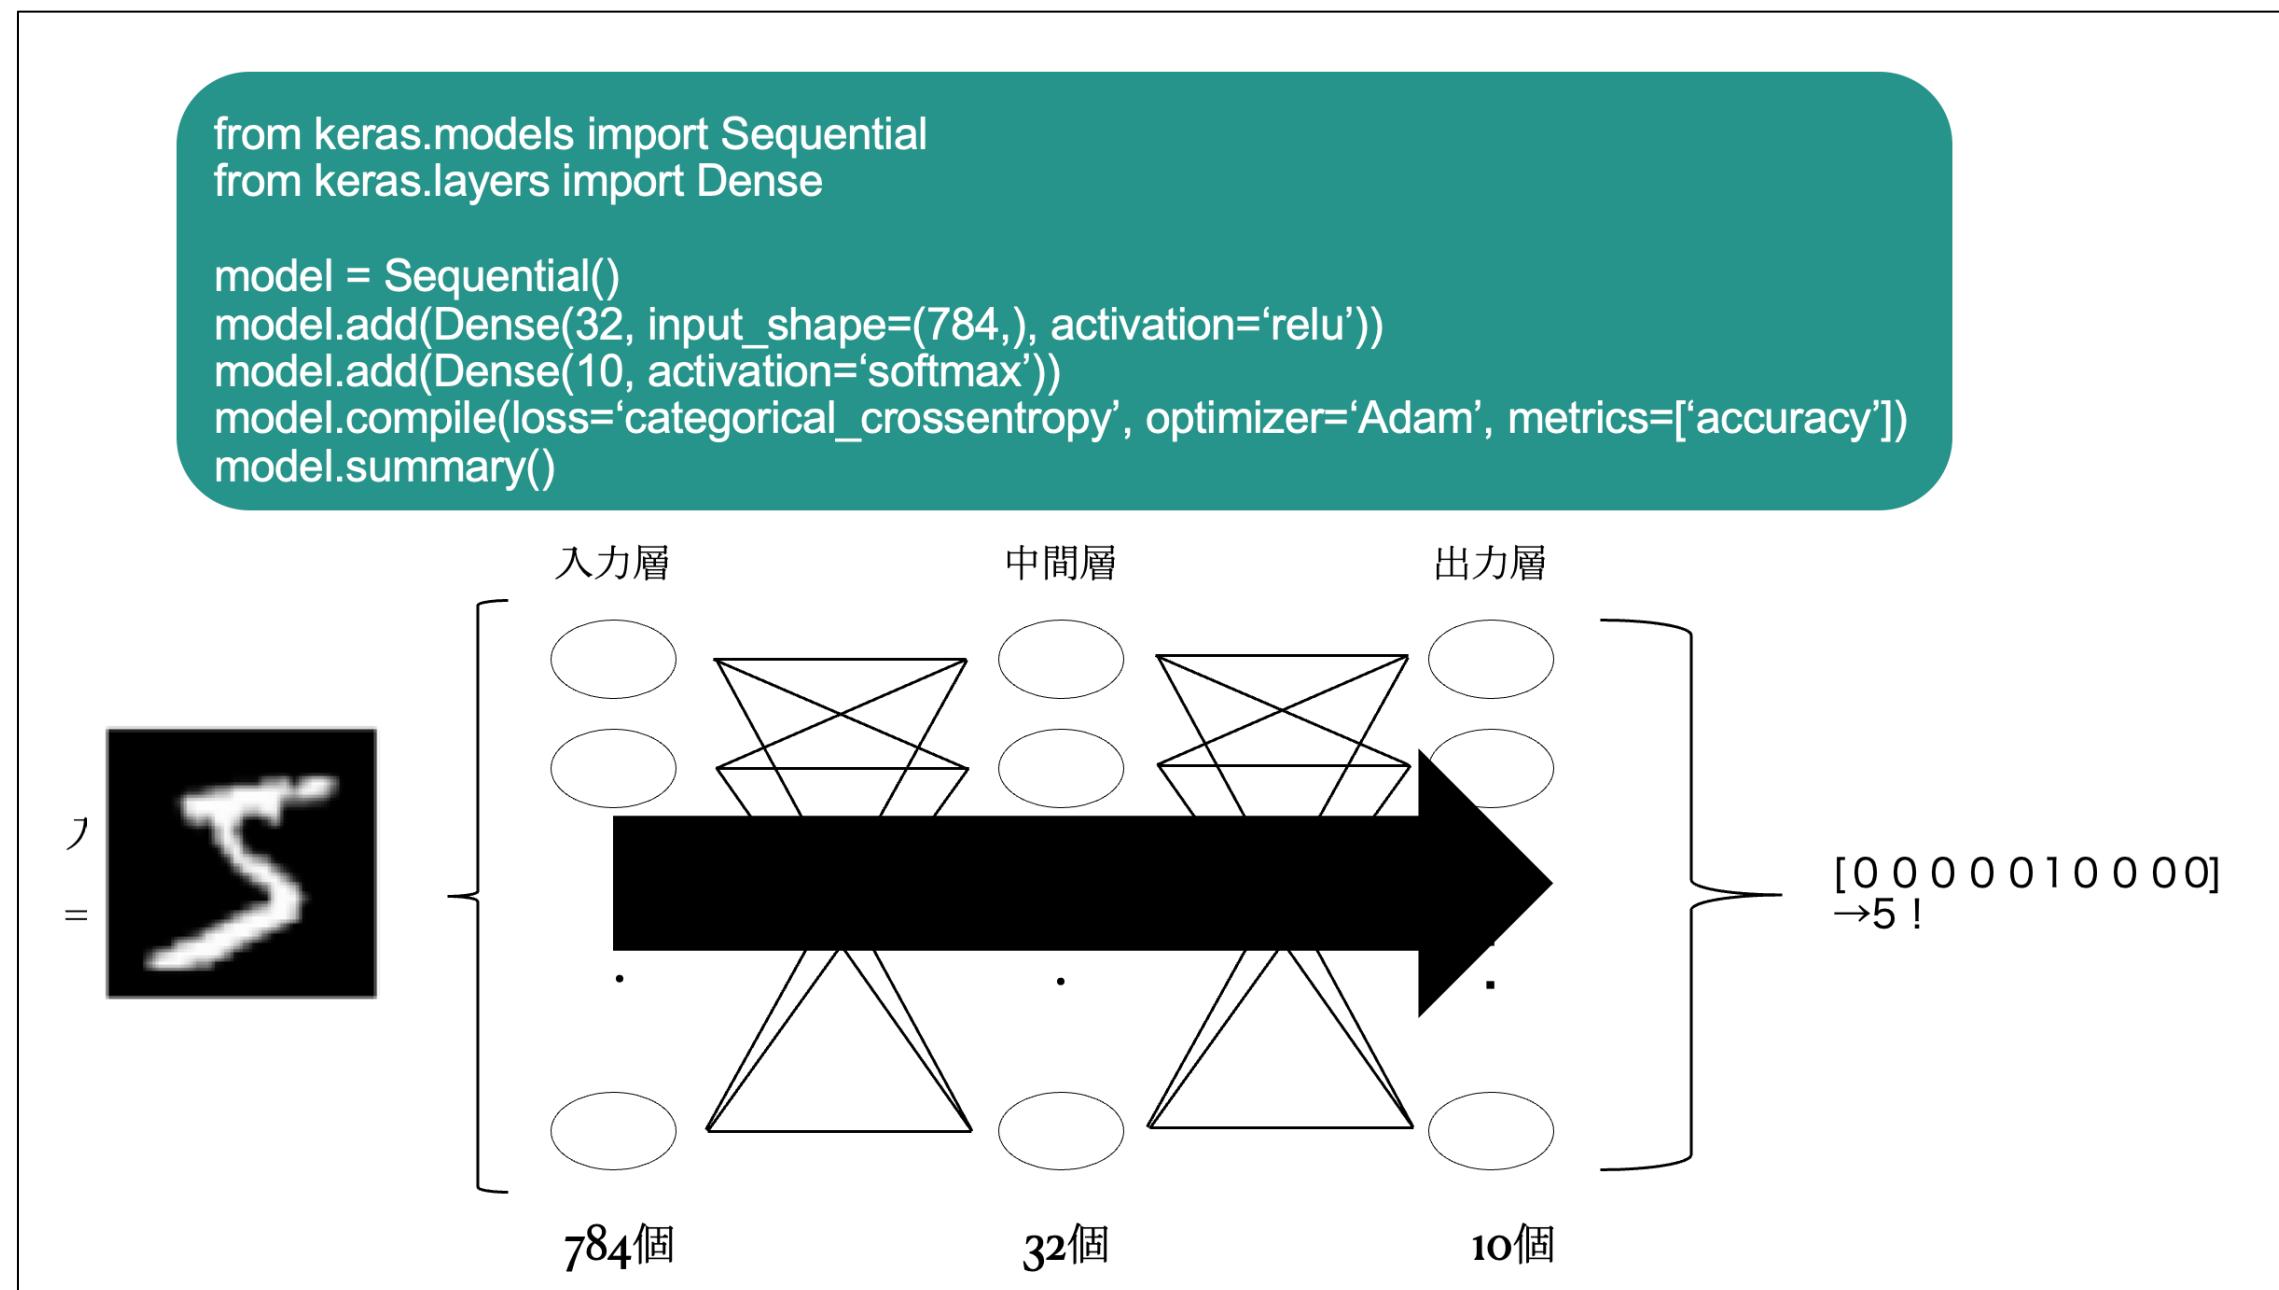
MLP②

統合教育機構
須藤毅顕

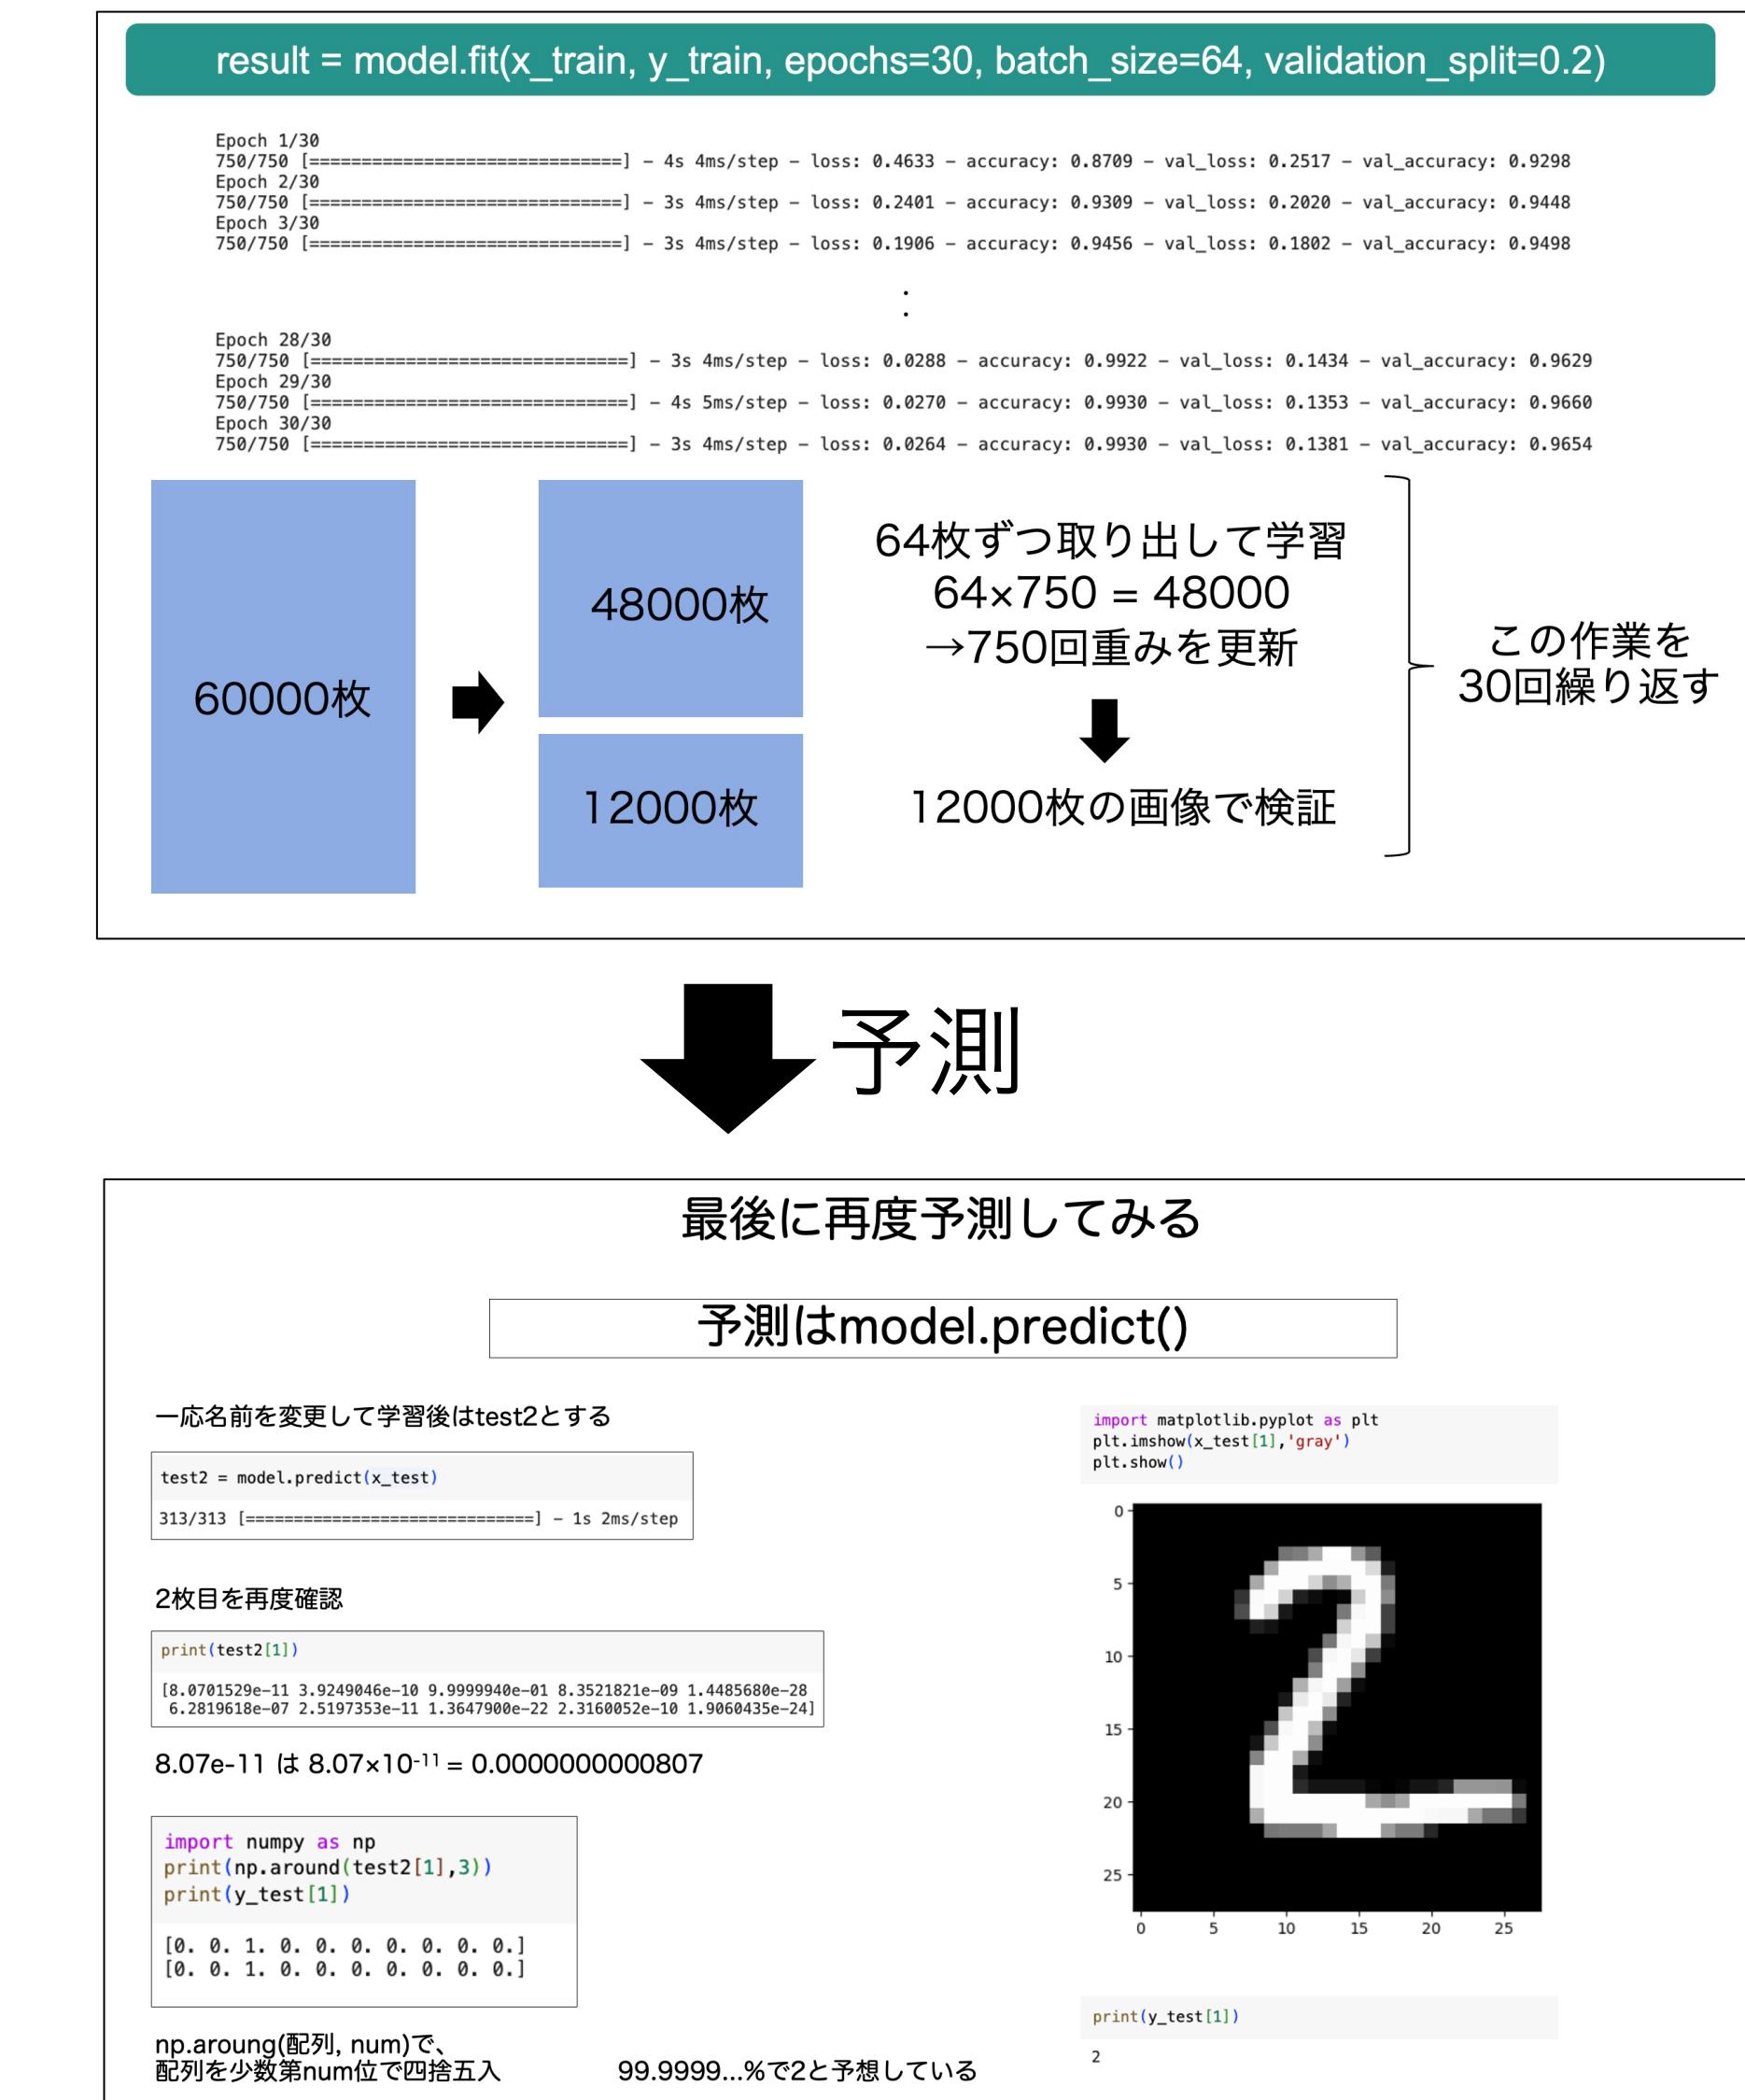
前回までの復習

学習

モデルの作成



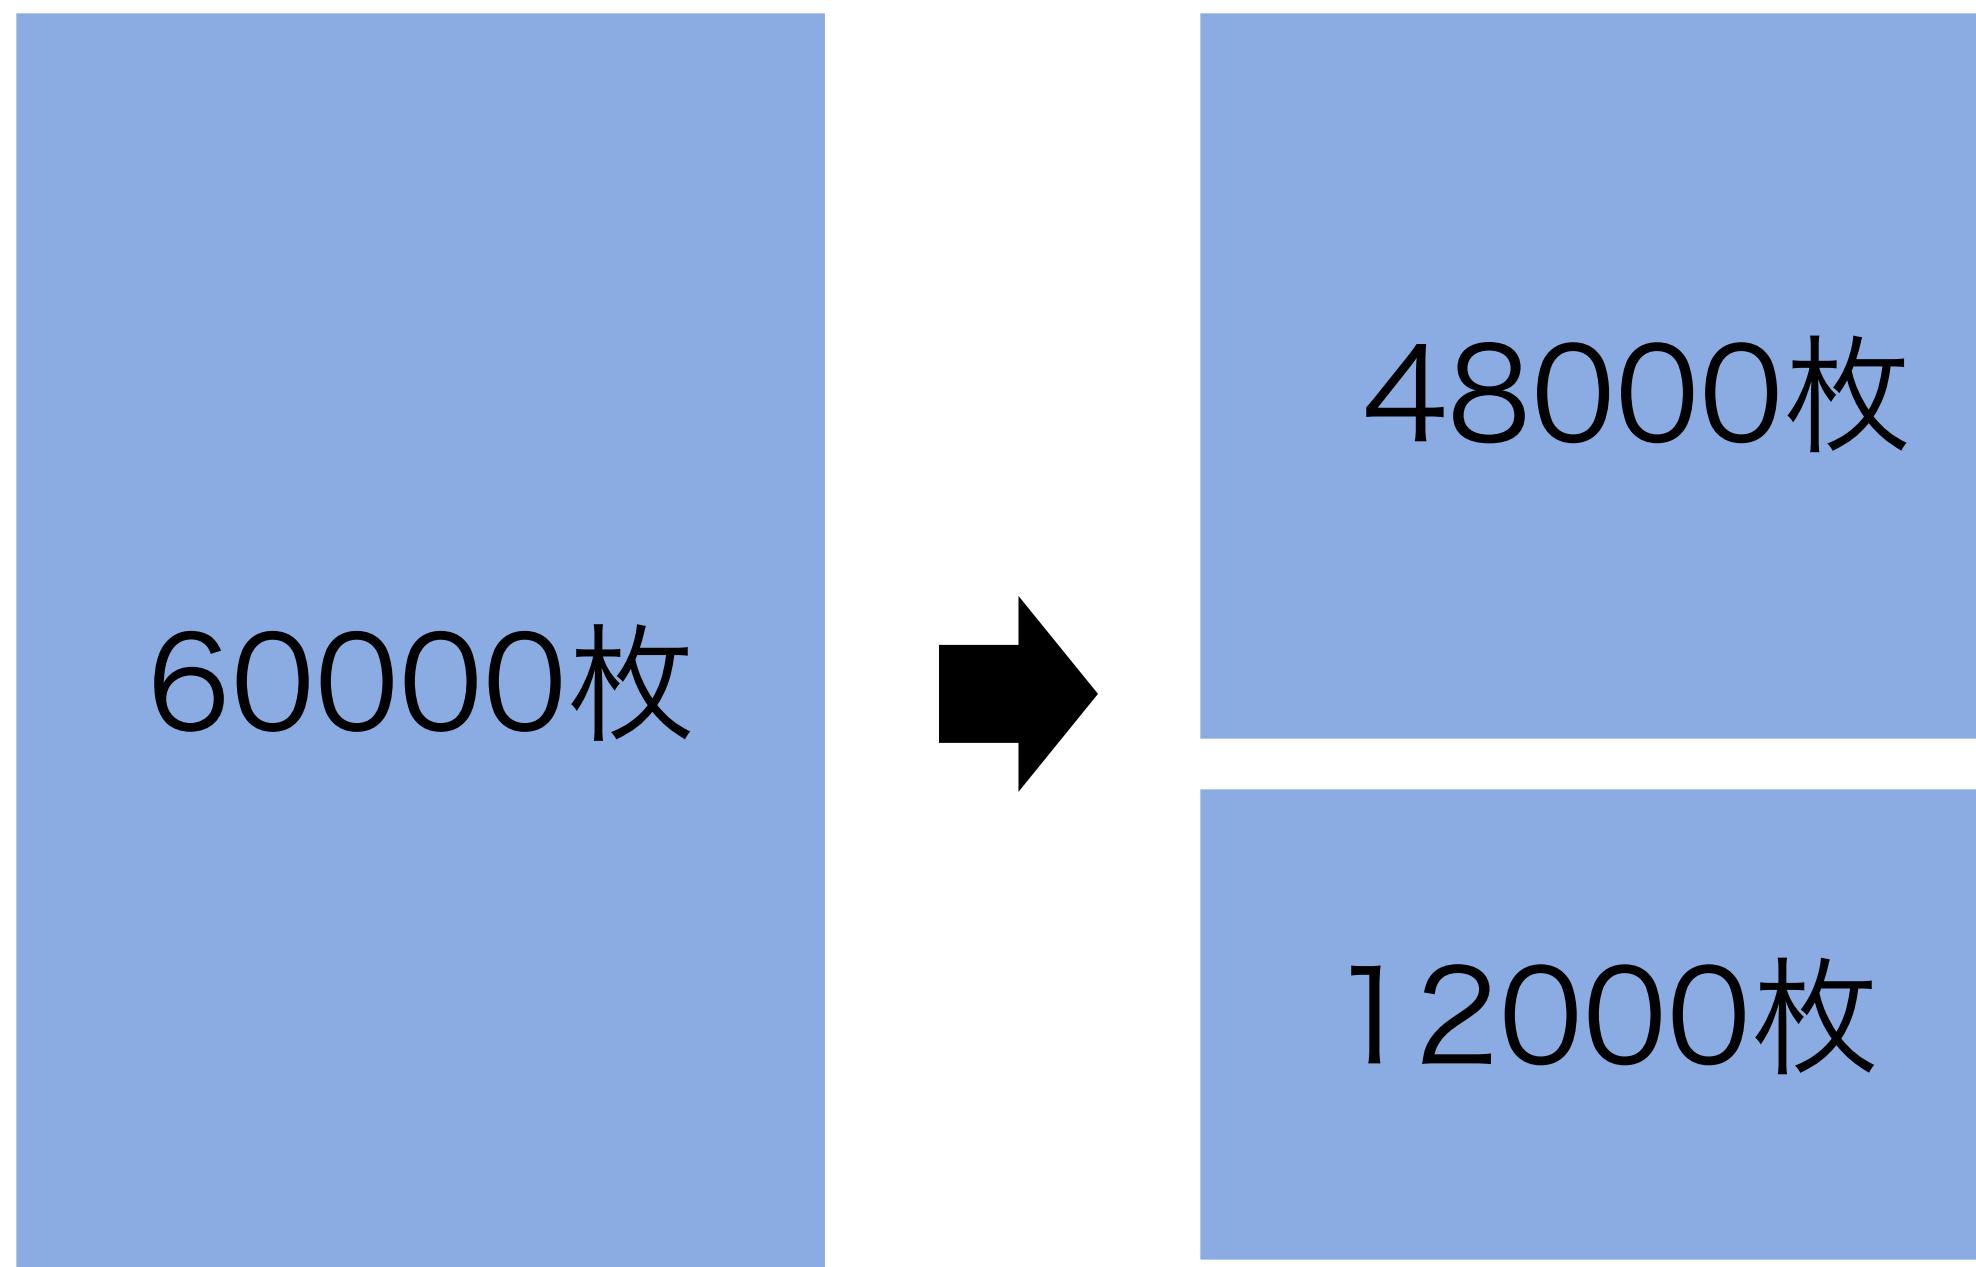
WebClassに「応用5_20231109_template.ipynb」
があるので開いて実行していきましょう
(GPUに変更してください)



epoch=50で実行し直しましょう

```
result = model.fit(x_train, y_train, epochs=50, batch_size=64, validation_split=0.2)
```

```
Epoch 1/50 750/750 [=====] - 2s 2ms/step - loss: 0.6172 - accuracy: 0.7892 - val_loss: 0.4628 - val_accuracy: 0.8407
Epoch 2/50 750/750 [=====] - 1s 2ms/step - loss: 0.4376 - accuracy: 0.8482 - val_loss: 0.4198 - val_accuracy: 0.8545
Epoch 3/50 750/750 [=====] - 1s 2ms/step - loss: 0.4035 - accuracy: 0.8605 - val_loss: 0.4151 - val_accuracy: 0.8565
Epoch 4/50 750/750 [=====] - 1s 2ms/step - loss: 0.3793 - accuracy: 0.8673 - val_loss: 0.3926 - val_accuracy: 0.8601
Epoch 5/50 750/750 [=====] - 1s 2ms/step - loss: 0.3628 - accuracy: 0.8721 - val_loss: 0.3776 - val_accuracy: 0.8664
.
.
.
Epoch 47/50 750/750 [=====] - 1s 2ms/step - loss: 0.1602 - accuracy: 0.9409 - val_loss: 0.4712 - val_accuracy: 0.8773
Epoch 48/50 750/750 [=====] - 1s 2ms/step - loss: 0.1564 - accuracy: 0.9427 - val_loss: 0.4850 - val_accuracy: 0.8735
Epoch 49/50 750/750 [=====] - 1s 2ms/step - loss: 0.1570 - accuracy: 0.9425 - val_loss: 0.4780 - val_accuracy: 0.8767
Epoch 50/50 750/750 [=====] - 1s 2ms/step - loss: 0.1542 - accuracy: 0.9434 - val_loss: 0.5010 - val_accuracy: 0.8724
```



64枚ずつ取り出して学習
 $64 \times 750 = 48000$
→750回重みを更新

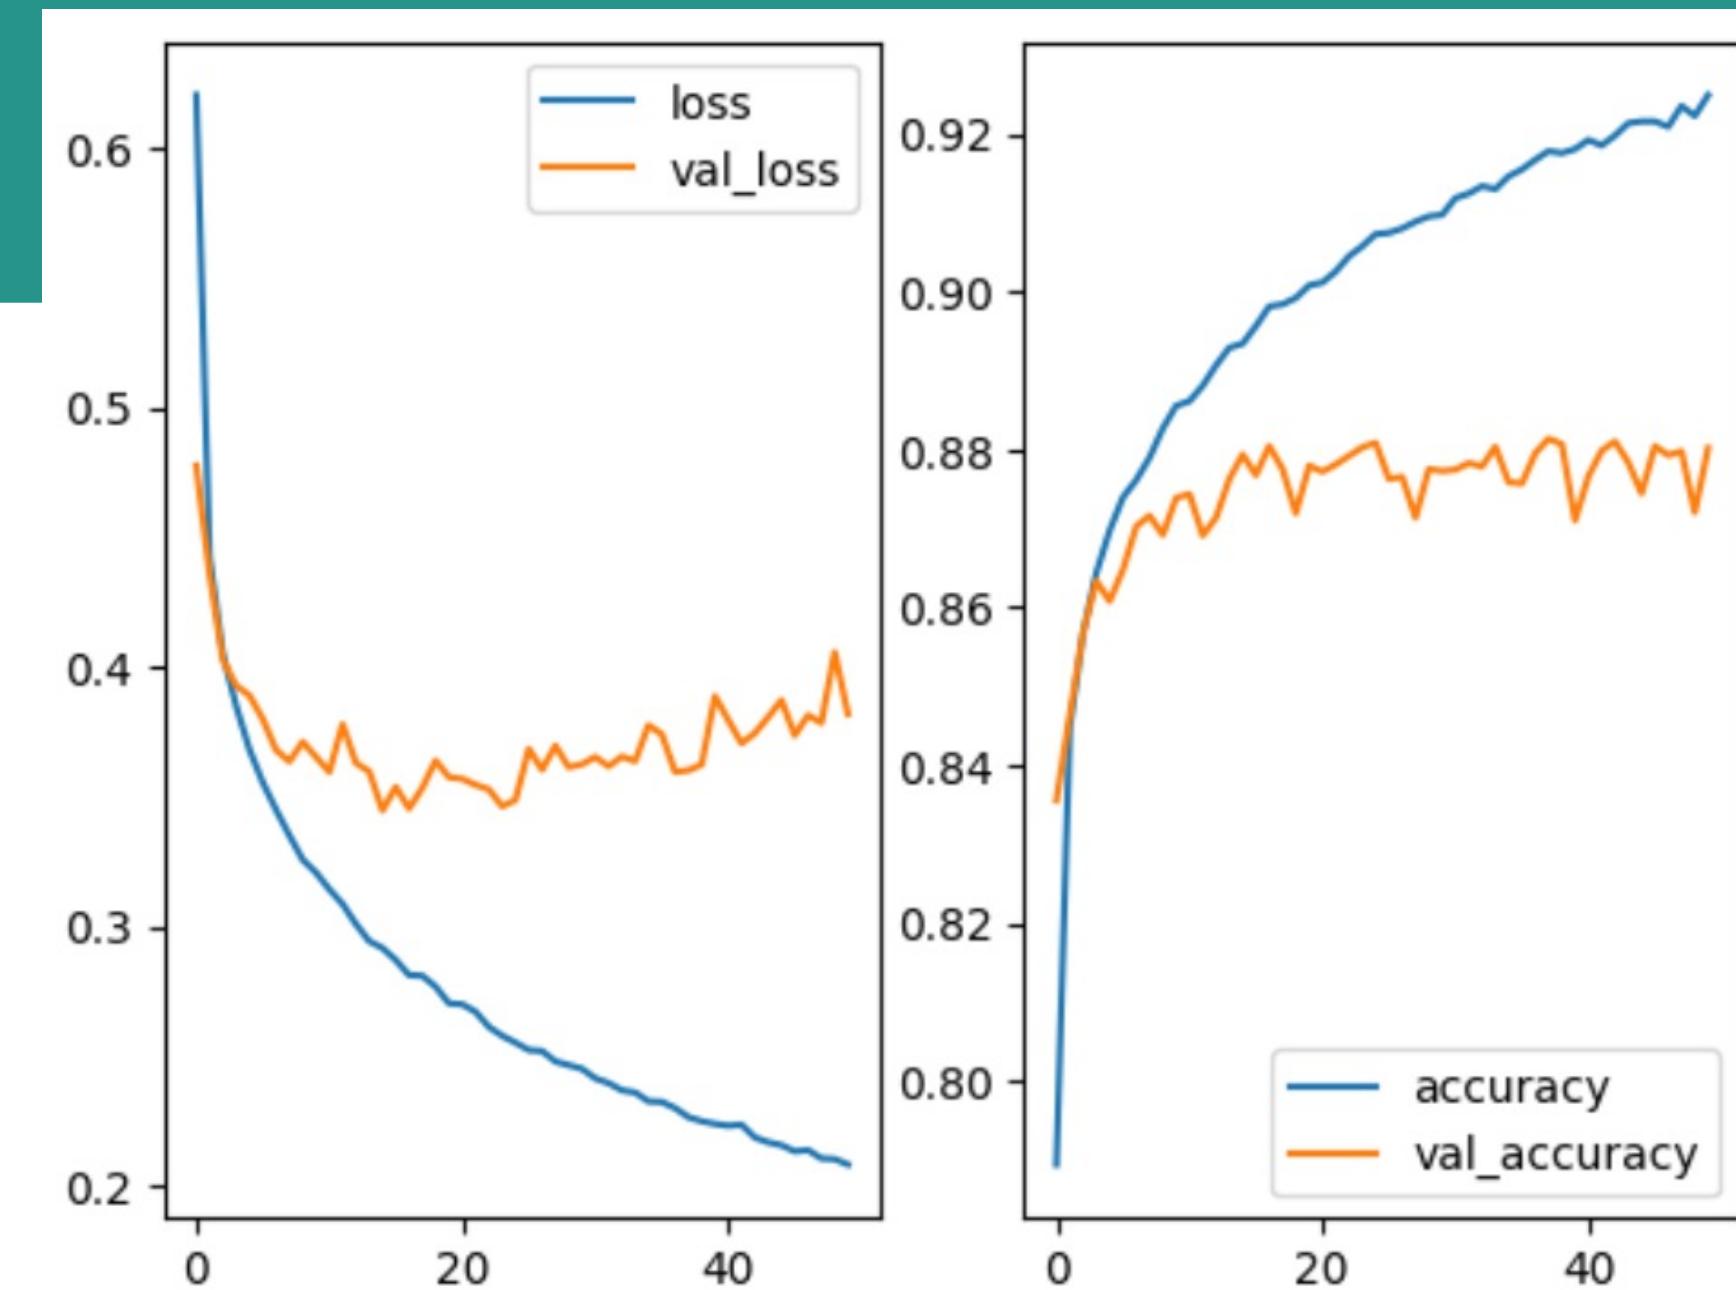
↓
12000枚の画像で検証

この作業を
50回繰り返す

結果の作図

```
import matplotlib.pyplot as plt
```

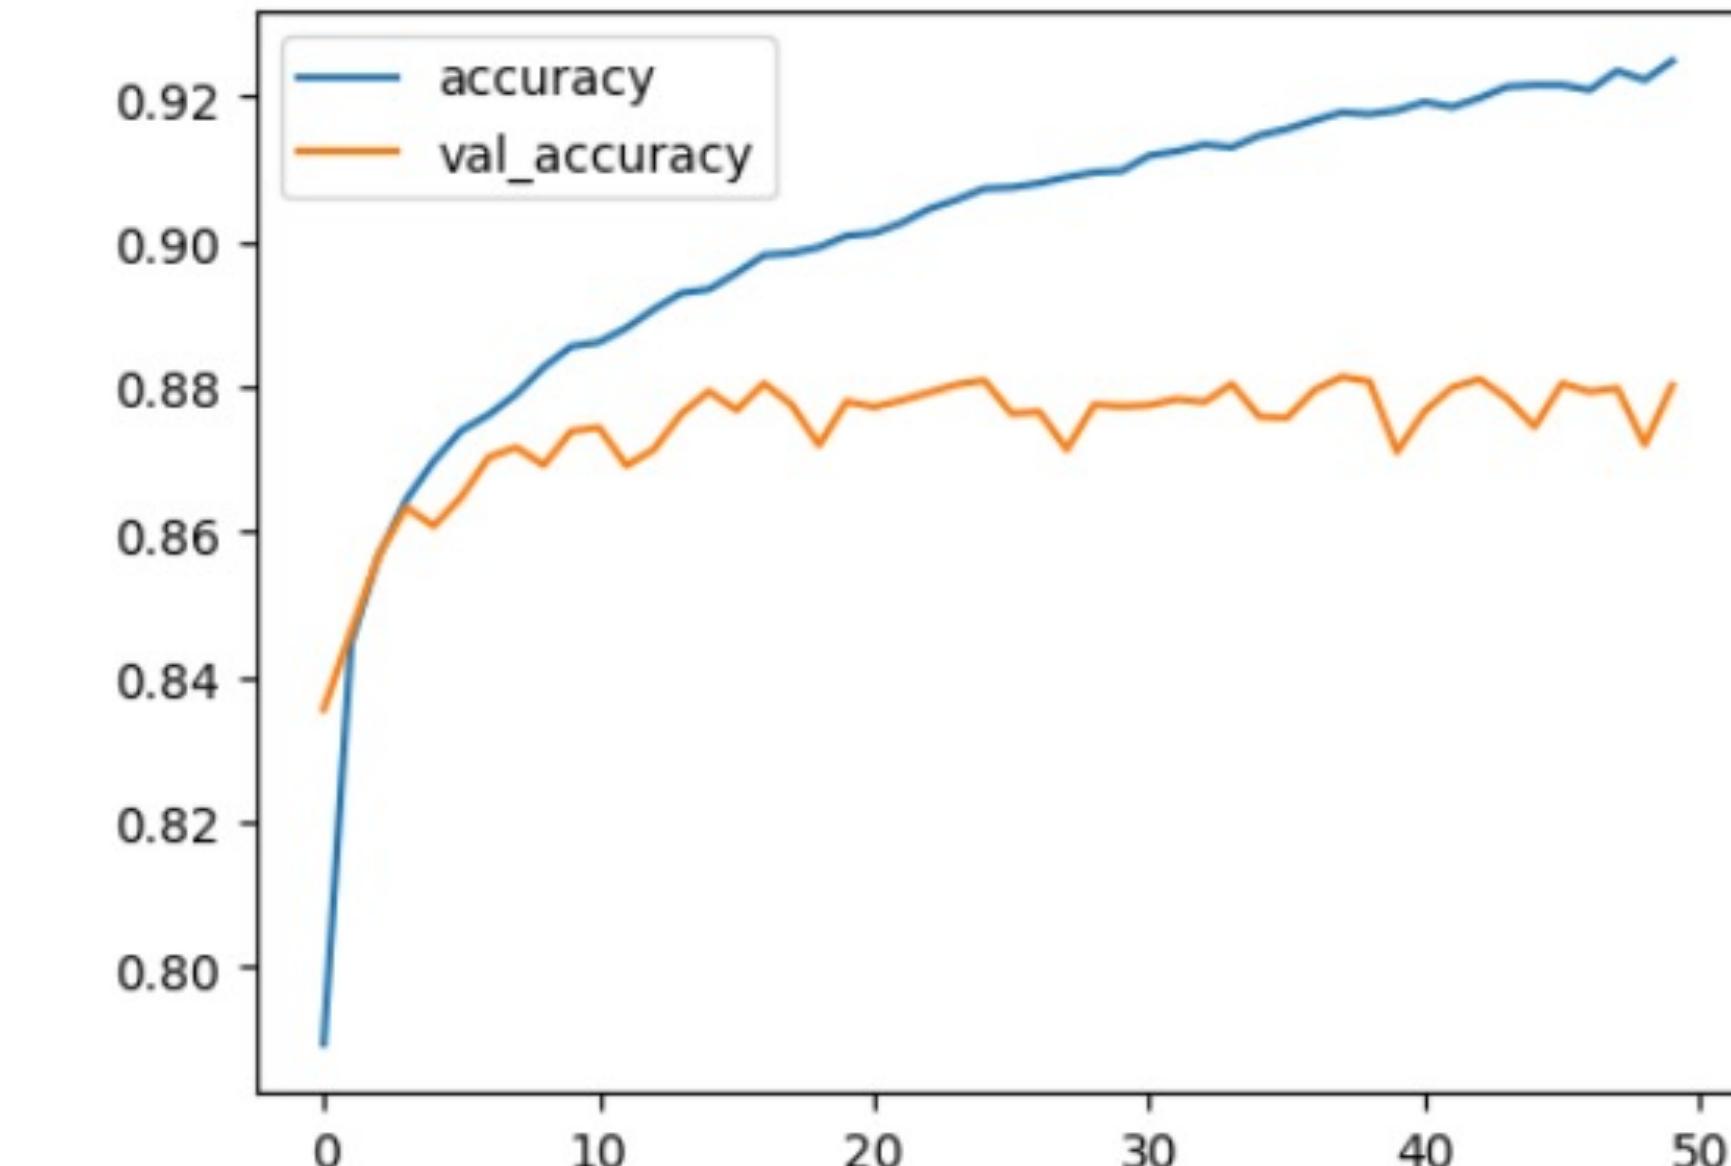
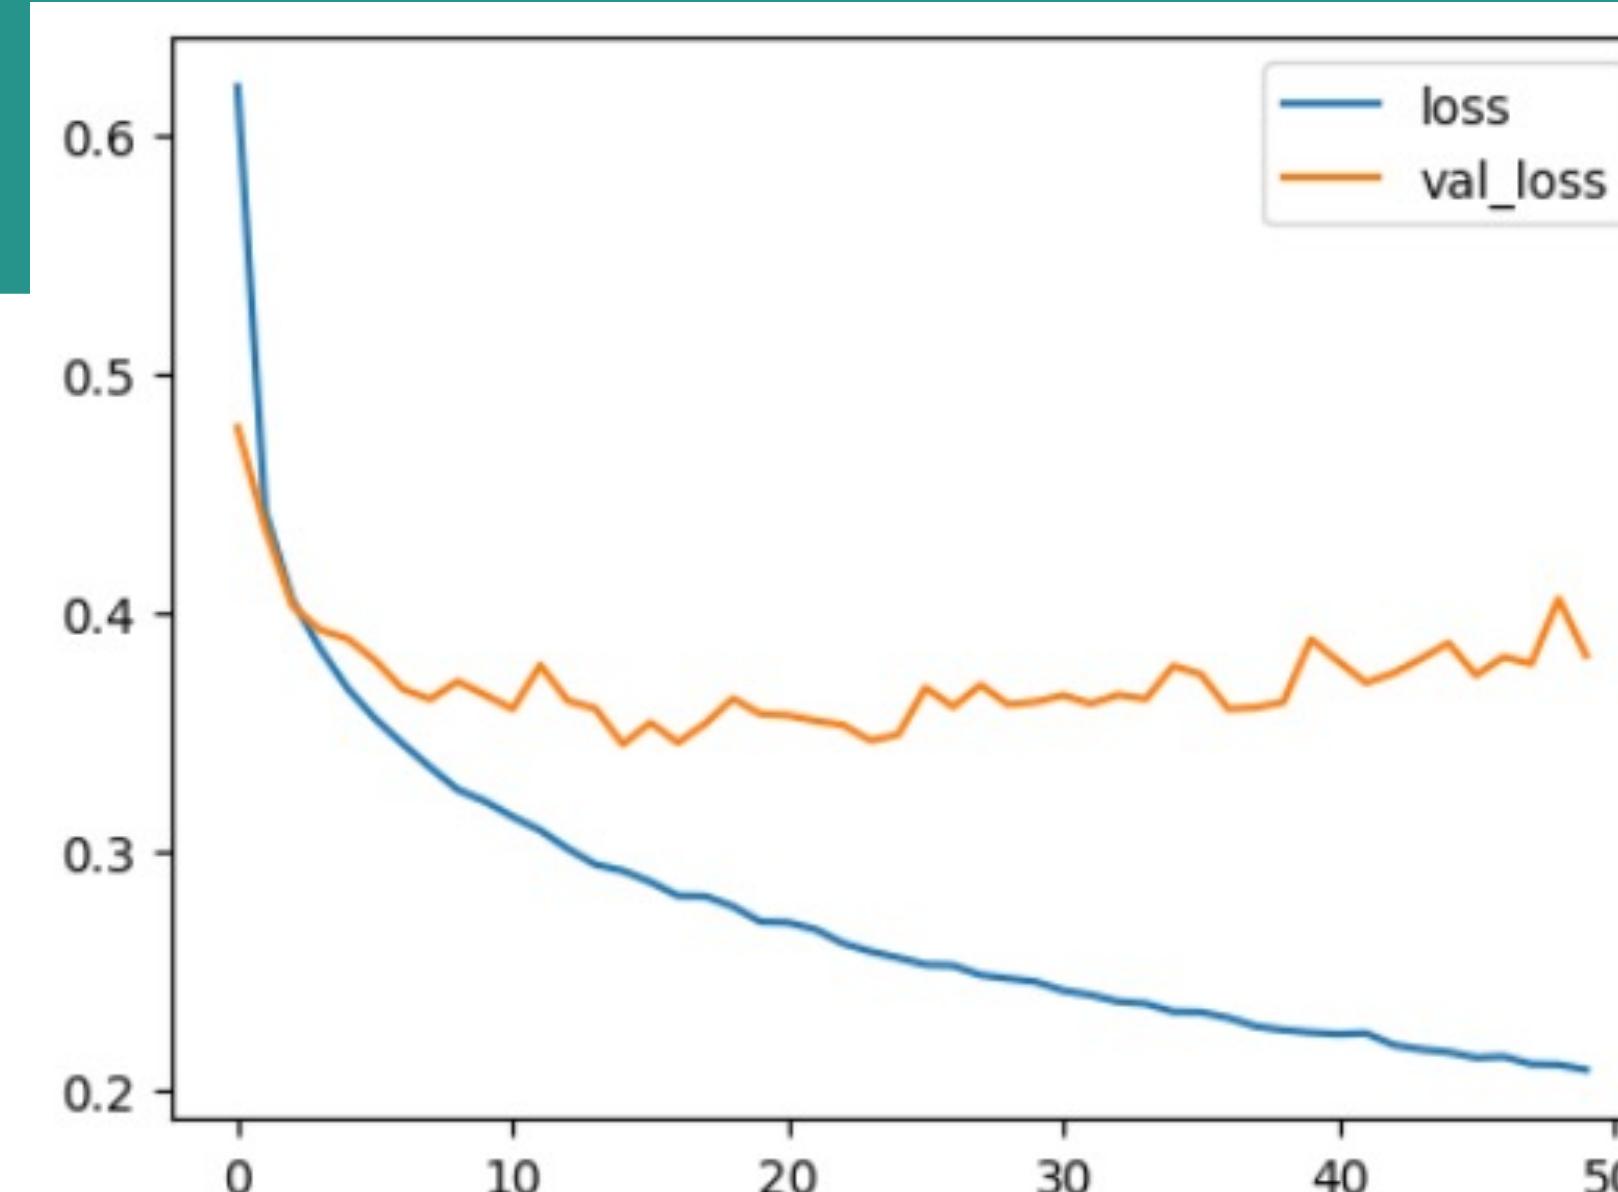
```
plt.subplot(1,2,1)
plt.plot(result.history['loss'],label='loss')
plt.plot(result.history['val_loss'],label='val_loss')
plt.legend()
plt.subplot(1,2,2)
plt.plot(result.history['accuracy'],label='accuracy')
plt.plot(result.history['val_accuracy'],label='val_accuracy')
plt.legend()
plt.show()
```



- 縦1, 横2の1つ目
誤差(loss)の折れ線グラフ
- 縦1, 横2の2つ目
正解率(accuracy)の折れ線グラフ

結果の作図

```
import matplotlib.pyplot as plt
plt.figure(figsize=(12,4))
plt.subplot(1,2,1)
plt.plot(result.history['loss'],label='loss')
plt.plot(result.history['val_loss'],label='val_loss')
plt.legend()
plt.subplot(1,2,2)
plt.plot(result.history['accuracy'],label='accuracy')
plt.plot(result.history['val_accuracy'],label='val_accuracy')
plt.legend()
plt.show()
```



result.historyの中身について

print(result.history)

```
{'loss': [0.6204796433448792, 0.4424095153808594, 0.4049777686595917, 0.38482892513275146, 0.3680422008037567, 0.3553660809993744, 0.34484514594078064, 0.3349671959877014, 0.32561713457107544, 0.3206530511379242, 0.3141988515853882, 0.30852627754211426, 0.3008130192756653, 0.29420095682144165, 0.29154443740844727, 0.28692877292633057, 0.28109729290008545, 0.28085023164749146, 0.27662160992622375, 0.2701963186264038, 0.26984351873397827, 0.26697129011154175, 0.26113253831863403, 0.25769904255867004, 0.2550542652606964, 0.2521992623806, 0.2518135905265808, 0.24781620502471924, 0.24636663496494293, 0.24498197436332703, 0.2412831038236618, 0.23945355415344238, 0.23669078946113586, 0.2358267456293106, 0.23242957890033722, 0.23221394419670105, 0.2298291176557541, 0.22631986439228058, 0.2247573286294937, 0.22372491657733917, 0.22302721440792084, 0.22342391312122345, 0.2184654176235199, 0.21663862466812134, 0.21550878882408142, 0.21314330399036407, 0.2136351317167282, 0.2104269564151764, 0.2101719230413437, 0.2080526500940323],  
  
'accuracy': [0.789354145526886, 0.8447291851043701, 0.8566874861717224, 0.8643541932106018, 0.8697083592414856, 0.8739166855812073, 0.8761041760444641, 0.8789583444595337, 0.8826666474342346, 0.8855208158493042, 0.886104166507721, 0.888062477118164, 0.8906458616256714, 0.8928750157356262, 0.8933958411216736, 0.8956249952316284, 0.898104190826416, 0.8983749747276306, 0.8991875052452087, 0.9007708430290222, 0.9011458158493042, 0.9025416374206543, 0.9044791460037231, 0.9057499766349792, 0.9072708487510681, 0.9074375033378601, 0.9079999923706055, 0.9088541865348816, 0.9095208048820496, 0.9097291827201843, 0.9118333458900452, 0.9124166369438171, 0.9133541584014893, 0.9129791855812073, 0.9146041870117188, 0.9154791831970215, 0.9166874885559082, 0.9177916646003723, 0.9175416827201843, 0.9180625081062317, 0.9192083477973938, 0.9185208082199097, 0.9197708368301392, 0.9213333129882812, 0.9215624928474426, 0.9215624928474426, 0.9208750128746033, 0.9235208630561829, 0.922249972820282, 0.9248958230018616],  
  
'val_loss': [0.4776163697242737, 0.4357101321220398, 0.40258854627609253, 0.39271479845046997, 0.3889164924621582, 0.3798101842403412, 0.3678809702396393, 0.36349910497665405, 0.37104806303977966, 0.3652504086494446, 0.35947203636169434, 0.37782320380210876, 0.3629121482372284, 0.3596421778202057, 0.34462788701057434, 0.35367244482040405, 0.3453534245491028, 0.35335132479667664, 0.36383312940597534, 0.35738077759742737, 0.35678377747535706, 0.3544683754441223, 0.3527243733406067, 0.34618350863456726, 0.3486511112594604, 0.3683689832687378, 0.3603420555591583, 0.36953479051589966, 0.36129820346832275, 0.3623996675014496, 0.36520129442214966, 0.36162319779396057, 0.36536312103271484, 0.3636190593242645, 0.37748828530311584, 0.37399259209632874, 0.35947826504707336, 0.36005476117134094, 0.3623170256614685, 0.3886697292327881, 0.37945523858070374, 0.37049585580825806, 0.3743937611579895, 0.3805387318134308, 0.38715872168540955, 0.3735528290271759, 0.38132739067077637, 0.37841248512268066, 0.4056456685066223, 0.3818448781967163],  
  
'val_accuracy': [0.8355000019073486, 0.8462499976158142, 0.8567500114440918, 0.863333444595337, 0.8607500195503235, 0.8647500276565552, 0.8702499866485596, 0.8715833425521851, 0.8691666722297668, 0.8738333582878113, 0.874333220481873, 0.8690833449363708, 0.8713333606719971, 0.8762500286102295, 0.8793333172798157, 0.8767499923706055, 0.8804166913032532, 0.8774999976158142, 0.871916651725769, 0.877916693687439, 0.8771666884422302, 0.878083348274231, 0.8791666626930237, 0.8802499771118164, 0.880833327702332, 0.8762500286102295, 0.8765000104904175, 0.8713333606719971, 0.8774999976158142, 0.8772500157356262, 0.8774166703224182, 0.87825002861023, 0.8778333067893982, 0.8803333044052124, 0.875833325386047, 0.8756666779518127, 0.8794999718666077, 0.8813333511352539, 0.8806666731834412, 0.8709999918937683, 0.8765833377838135, 0.8798333406448364, 0.8809999823570251, 0.87833330154419, 0.8744166493415833, 0.8804166913032532, 0.8792499899864197, 0.8797500133514404, 0.871999979019165, 0.8801666498184204]}
```

`print(result.history)`

result.historyの中身について

エポック50回分の誤差と正解率

```
{'loss': [0.6204796433448792, 0.4424095153808594, 0.4049777686595917, 0.38482892513275146, 0.3680422008037567, 0.3553660809993744, 0.34484514594078064, 0.3349671959877014, 0.32561713457107544, 0.3206530511379242, 0.3141988515853882, 0.30852627754211426, 0.3008130192756653, 0.29420095682144165, 0.29154443740844727, 0.28692877292633057, 0.28109729290008545, 0.28085023164749146, 0.27662160992622375, 0.2701963186264038, 0.26984351873397827, 0.26697129011154175, 0.26113253831863403, 0.25769904255867004, 0.2550542652606964, 0.2521992623806, 0.2518135905265808, 0.24781620502471924, 0.24636663496494293, 0.24498197436332703, 0.2412831038236618, 0.23945355415344238, 0.23669078946113586, 0.2358267456293106, 0.23242957890033722, 0.23221394419670105, 0.2298291176557541, 0.22631986439228058, 0.2247573286294937, 0.22372491657733917, 0.22302721440792084, 0.22342391312122345, 0.2184654176235199, 0.21663862466812134, 0.21550878882408142, 0.21314330399036407, 0.2136351317167282, 0.2104269564151764, 0.2101719230413437, 0.2080526500940323], 'accuracy': [0.789354145526886, 0.8447291851043701, 0.8566874861717224, 0.8643541932106018, 0.8697083592414856, 0.8739166855812073, 0.8761041760444641, 0.8789583444595337, 0.8826666474342346, 0.8855208158493042, 0.886104166507721, 0.8880624771118164, 0.8906458616256714, 0.8928750157356262, 0.8933958411216736, 0.8956249952316284, 0.898104190826416, 0.8983749747276306, 0.8991875052452087, 0.9007708430290222, 0.9011458158493042, 0.9025416374206543, 0.9044791460037231, 0.9057499766349792, 0.9072708487510681, 0.9074375033378601, 0.9079999923706055, 0.9088541865348816, 0.9095208048820496, 0.9097291827201843, 0.9118333458900452, 0.9124166369438171, 0.9133541584014893, 0.9129791855812073, 0.9146041870117188, 0.9154791831970215, 0.9166874885559082, 0.9177916646003723, 0.9175416827201843, 0.9180625081062317, 0.9192083477973938, 0.9185208082199097, 0.9197708368301392, 0.9213333129882812, 0.9215624928474426, 0.9215624928474426, 0.9208750128746033, 0.9235208630561829, 0.922249972820282, 0.9248958230018616], 'val_loss': [0.4776163697242737, 0.4357101321220398, 0.40258854627609253, 0.39271479845046997, 0.3889164924621582, 0.3798101842403412, 0.3678809702396393, 0.36349910497665405, 0.37104806303977966, 0.3652504086494446, 0.35947203636169434, 0.37782320380210876, 0.3629121482372284, 0.3596421778202057, 0.34462788701057434, 0.35367244482040405, 0.3453534245491028, 0.35335132479667664, 0.36383312940597534, 0.35738077759742737, 0.35678377747535706, 0.3544683754441223, 0.3527243733406067, 0.34618350863456726, 0.3486511112594604, 0.3683689832687378, 0.3603420555591583, 0.36953479051589966, 0.36129820346832275, 0.3623996675014496, 0.36520129442214966, 0.36162319779396057, 0.36536312103271484, 0.3636190593242645, 0.37748828530311584, 0.37399259209632874, 0.35947826504707336, 0.36005476117134094, 0.3623170256614685, 0.3886697292327881, 0.37945523858070374, 0.37049585580825806, 0.3743937611579895, 0.3805387318134308, 0.38715872168540955, 0.3735528290271759, 0.38132739067077637, 0.37841248512268066, 0.4056456685066223, 0.3818448781967163], 'val_accuracy': [0.8355000019073486, 0.8462499976158142, 0.8567500114440918, 0.863333444595337, 0.8607500195503235, 0.8647500276565552, 0.8702499866485596, 0.8715833425521851, 0.8691666722297668, 0.8738333582878113, 0.874333220481873, 0.8690833449363708, 0.8713333606719971, 0.8762500286102295, 0.8793333172798157, 0.8767499923706055, 0.8804166913032532, 0.8774999976158142, 0.871916651725769, 0.877916693687439, 0.8771666884422302, 0.878083348274231, 0.8791666626930237, 0.8802499771118164, 0.880833327702332, 0.8762500286102295, 0.8765000104904175, 0.8713333606719971, 0.8774999976158142, 0.8772500157356262, 0.8774166703224182, 0.87825002861023, 0.8778333067893982, 0.8803333044052124, 0.875833325386047, 0.8756666779518127, 0.8794999718666077, 0.8813333511352539, 0.8806666731834412, 0.8709999918937683, 0.8765833377838135, 0.8798333406448364, 0.8809999823570251, 0.87833330154419, 0.8744166493415833, 0.8804166913032532, 0.8792499899864197, 0.8797500133514404, 0.871999979019165, 0.8801666498184204]}]
```

{'loss':[1回目の学習用データの損失,2回目の学習用データの損失,...,50回目の学習用データの損失],
'accuracy':[1回目の学習用データの正解率,2回目の学習用データの正解率,...,50回目の学習用データの正解率],
'val_loss':[1回目の検証用データの損失,2回目の検証用データの損失,...,50回目の検証用データの損失],
'val_accuracy':[1回目の検証用データの正解率,2回目の検証用データの正解率,...,50回目の検証用データの正解率]}

辞書型のデータの取得方法

```
print(result.history['loss'])
```

```
[0.6204796433448792, 0.4424095153808594, 0.4049777686595917, 0.38482892513275146, 0.3680422008037567, 0.3553660809993744, 0.34484514594078064, 0.3349671959877014, 0.32561713457107544, 0.3206530511379242, 0.3141988515853882, 0.30852627754211426, 0.3008130192756653, 0.29420095682144165, 0.29154443740844727, 0.28692877292633057, 0.28109729290008545, 0.28085023164749146, 0.27662160992622375, 0.2701963186264038, 0.26984351873397827, 0.26697129011154175, 0.26113253831863403, 0.25769904255867004, 0.2550542652606964, 0.2521992623806, 0.2518135905265808, 0.24781620502471924, 0.24636663496494293, 0.24498197436332703, 0.2412831038236618, 0.23945355415344238, 0.23669078946113586, 0.2358267456293106, 0.23242957890033722, 0.23221394419670105, 0.2298291176557541, 0.22631986439228058, 0.2247573286294937, 0.22372491657733917, 0.22302721440792084, 0.22342391312122345, 0.2184654176235199, 0.21663862466812134, 0.21550878882408142, 0.21314330399036407, 0.2136351317167282, 0.2104269564151764, 0.2101719230413437, 0.2080526500940323]
```

出力結果は各エポックの誤差がリストになっている

x = [要素,要素,...,要素]

a = [1,1,3,3,3]
これはリスト型

x = {key:value,key:value,...,key:value}

b = {'name':'sudo','age':36}
これは辞書型

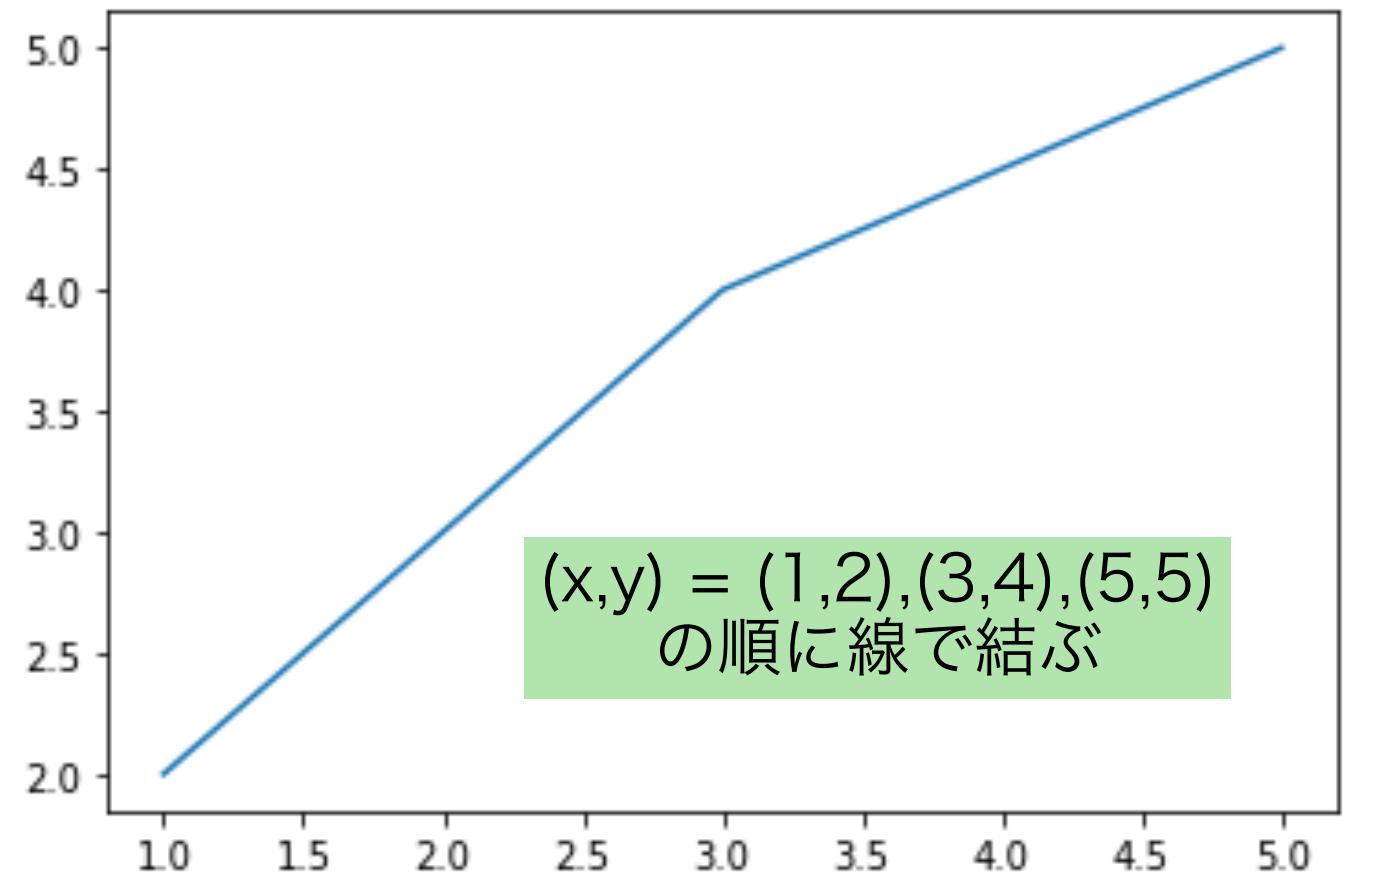
```
b = {'name':'sudo','age':36}
print(type(b))
print(b['name'])
print(b['age'])
```

<class 'dict'>
sudo
36

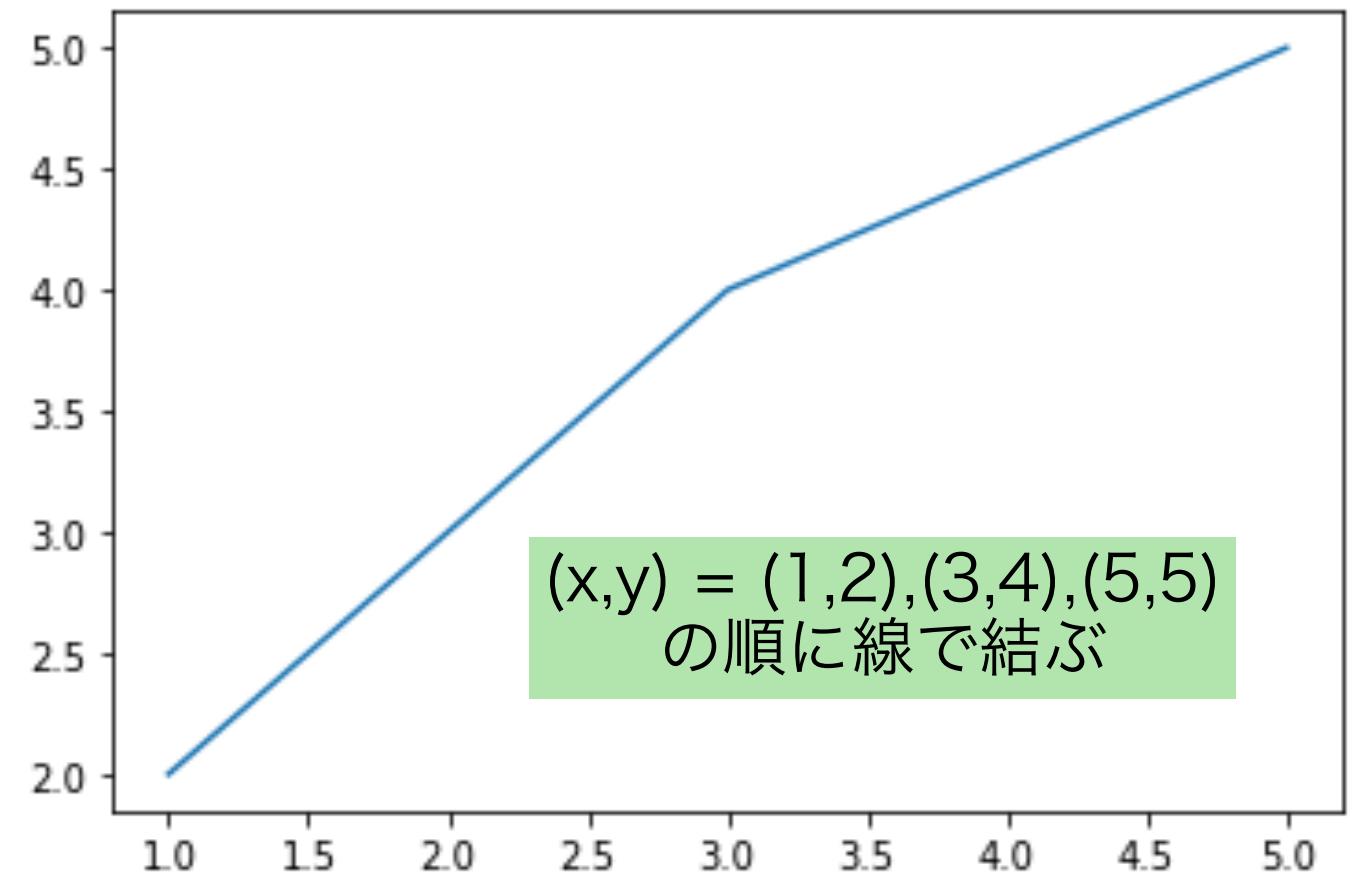
辞書型は変数名[key]で
valueを取り出せる!

result.history['loss']で{'loss':[~~~], ...}の[~~~]を取り出している

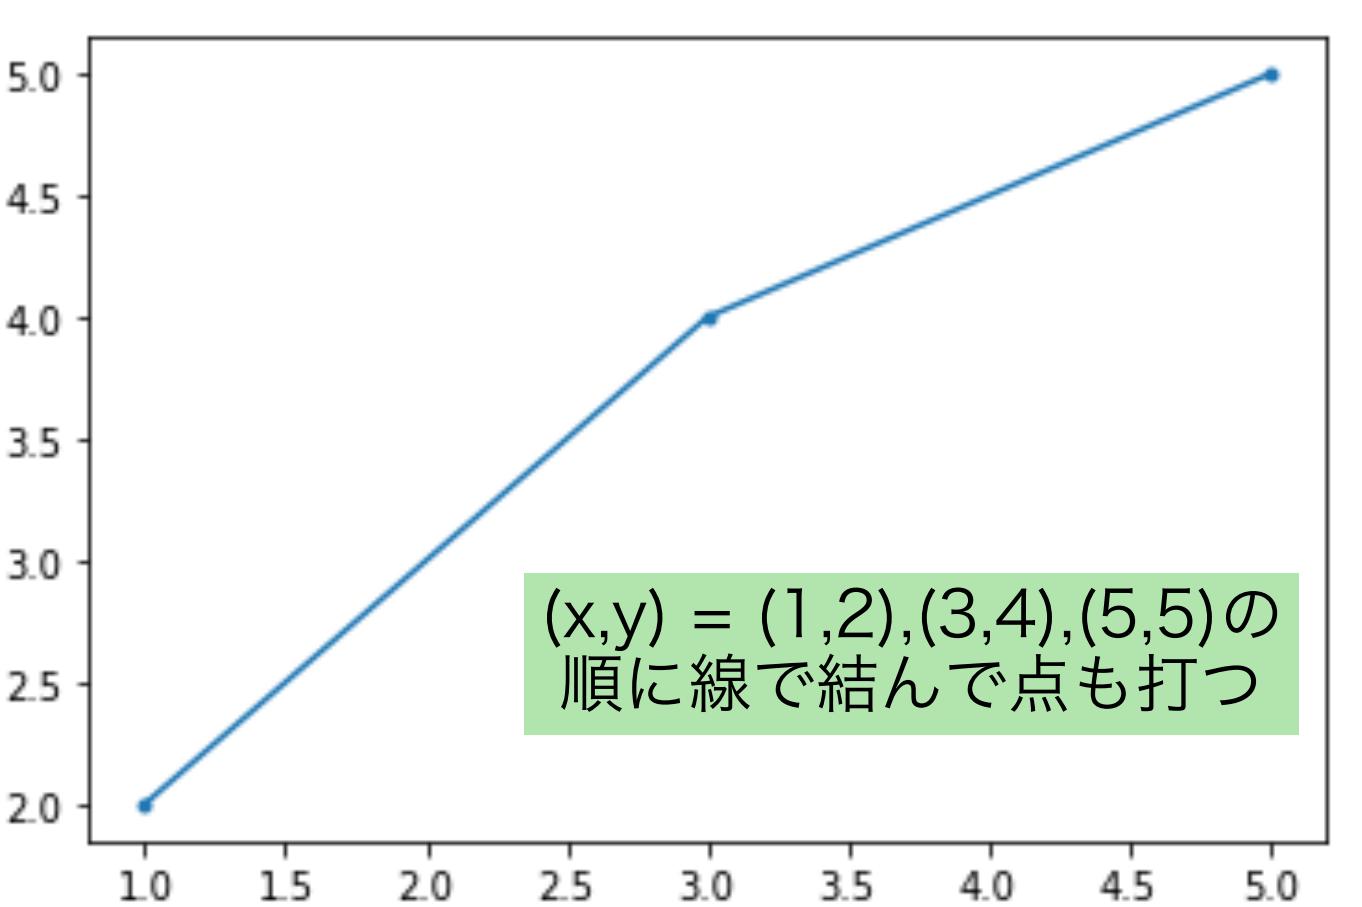
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y)  
plt.show()
```



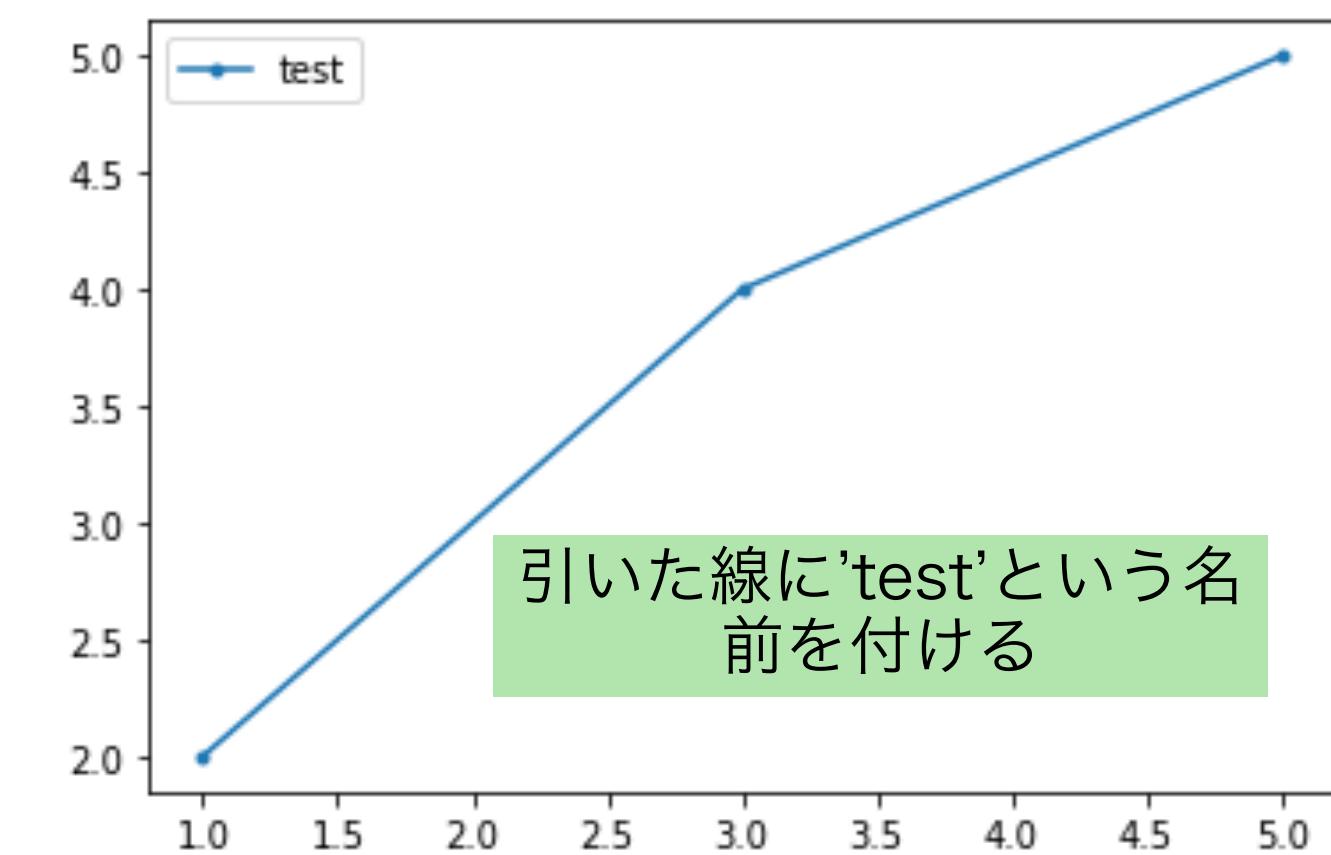
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y)  
plt.show()
```



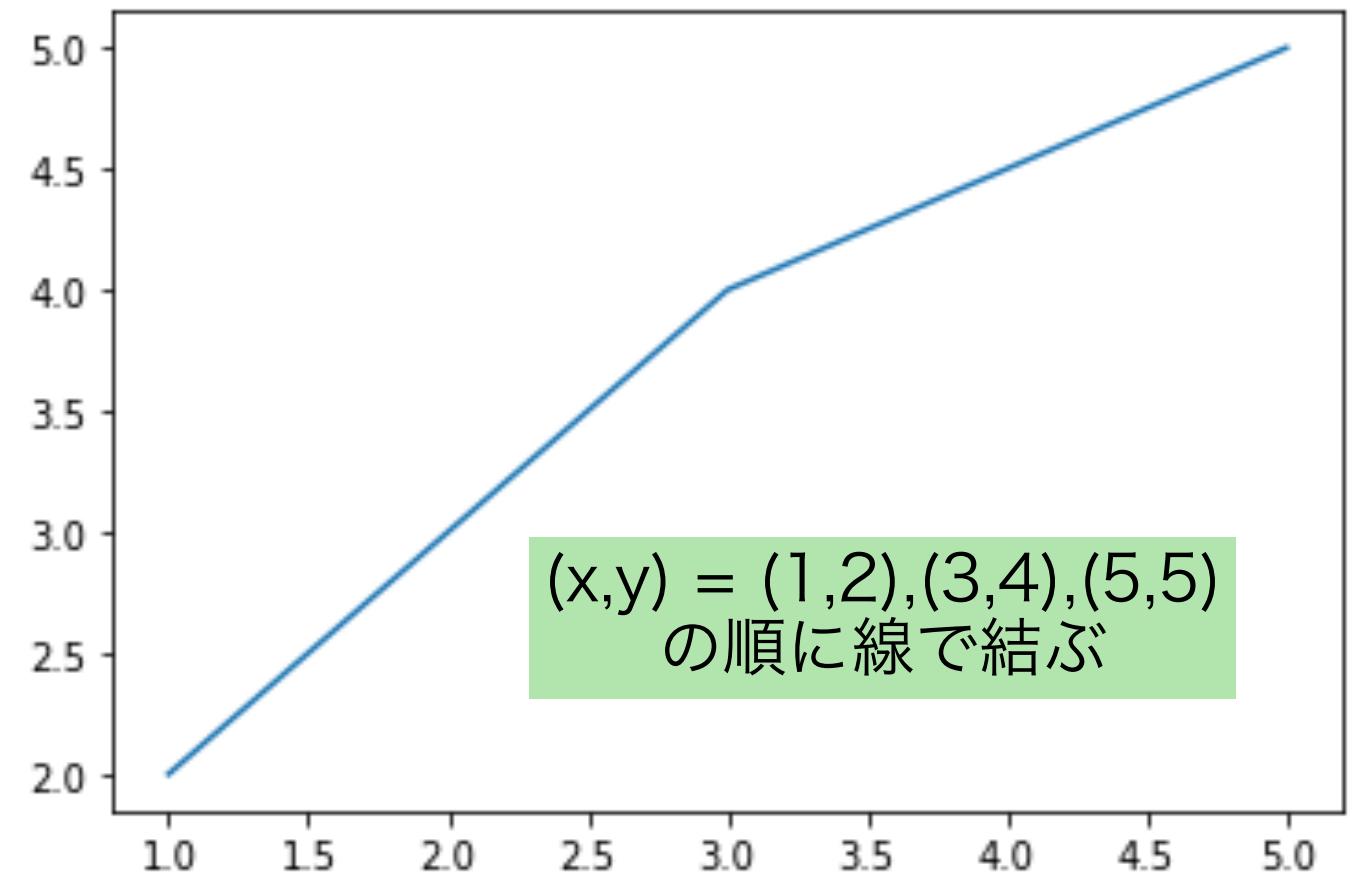
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y,marker='.',)  
plt.show()
```



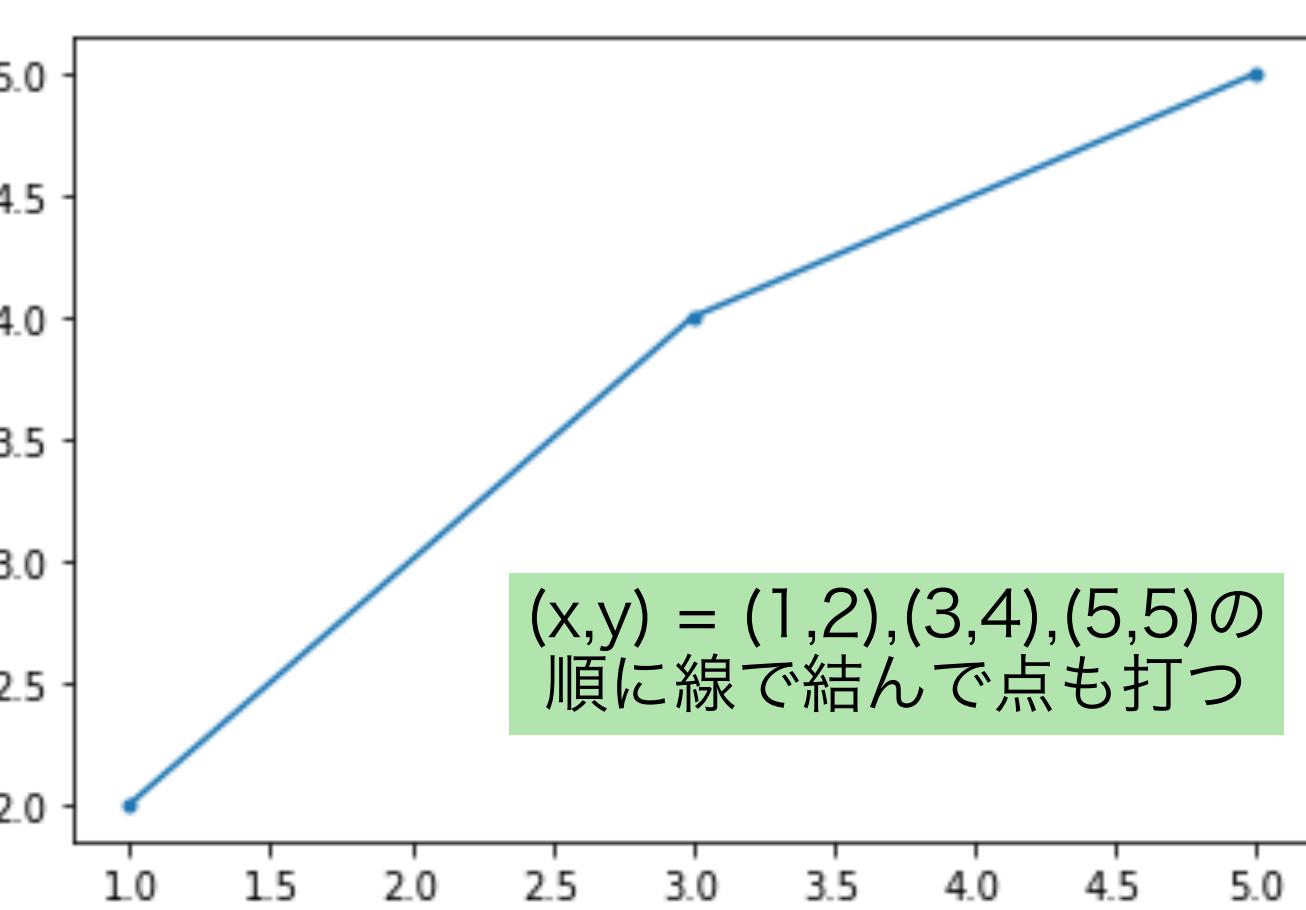
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y,marker='.',label='test')  
plt.legend()  
plt.show()
```



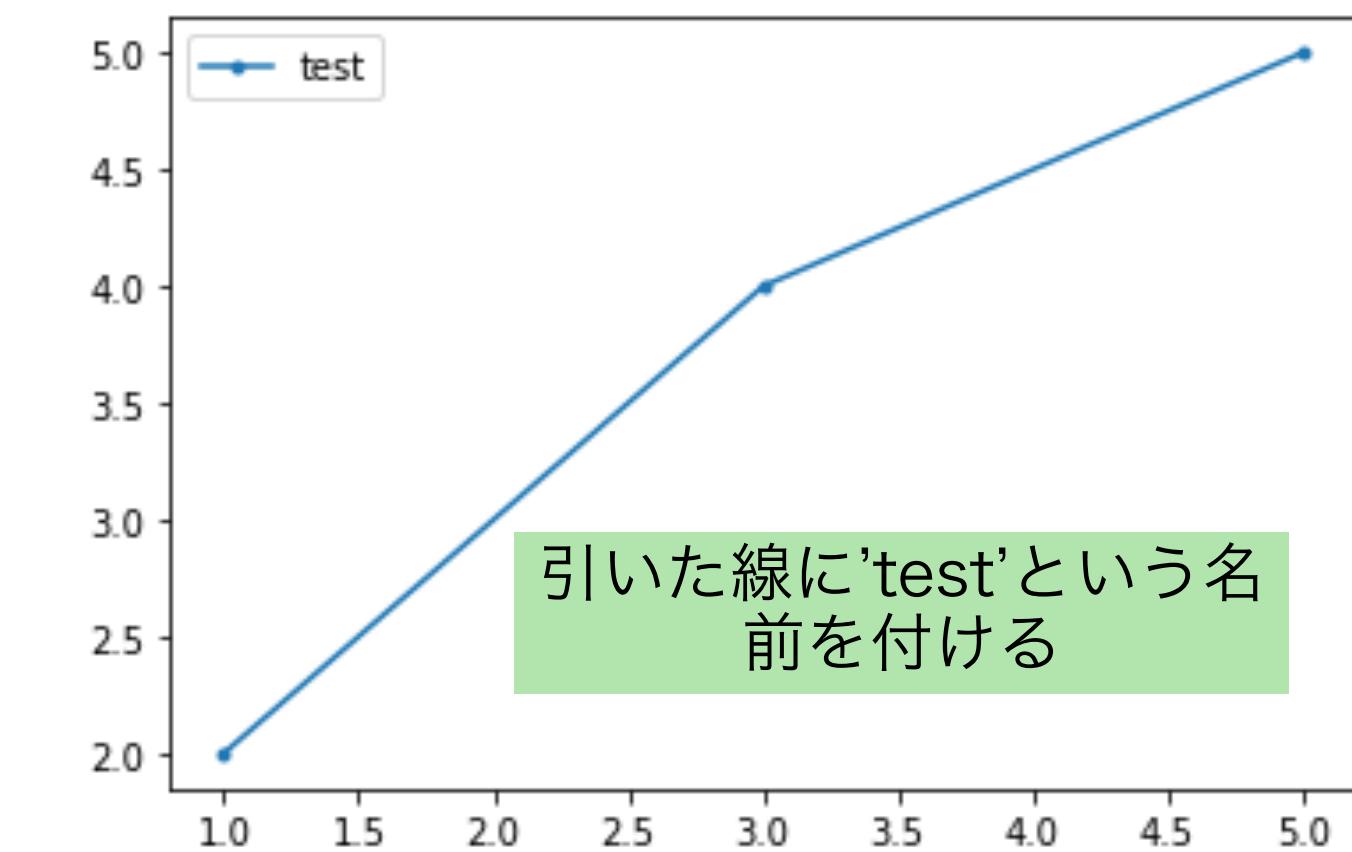
```
x = [1,3,5]
y = [2,4,5]
plt.plot(x,y)
plt.show()
```



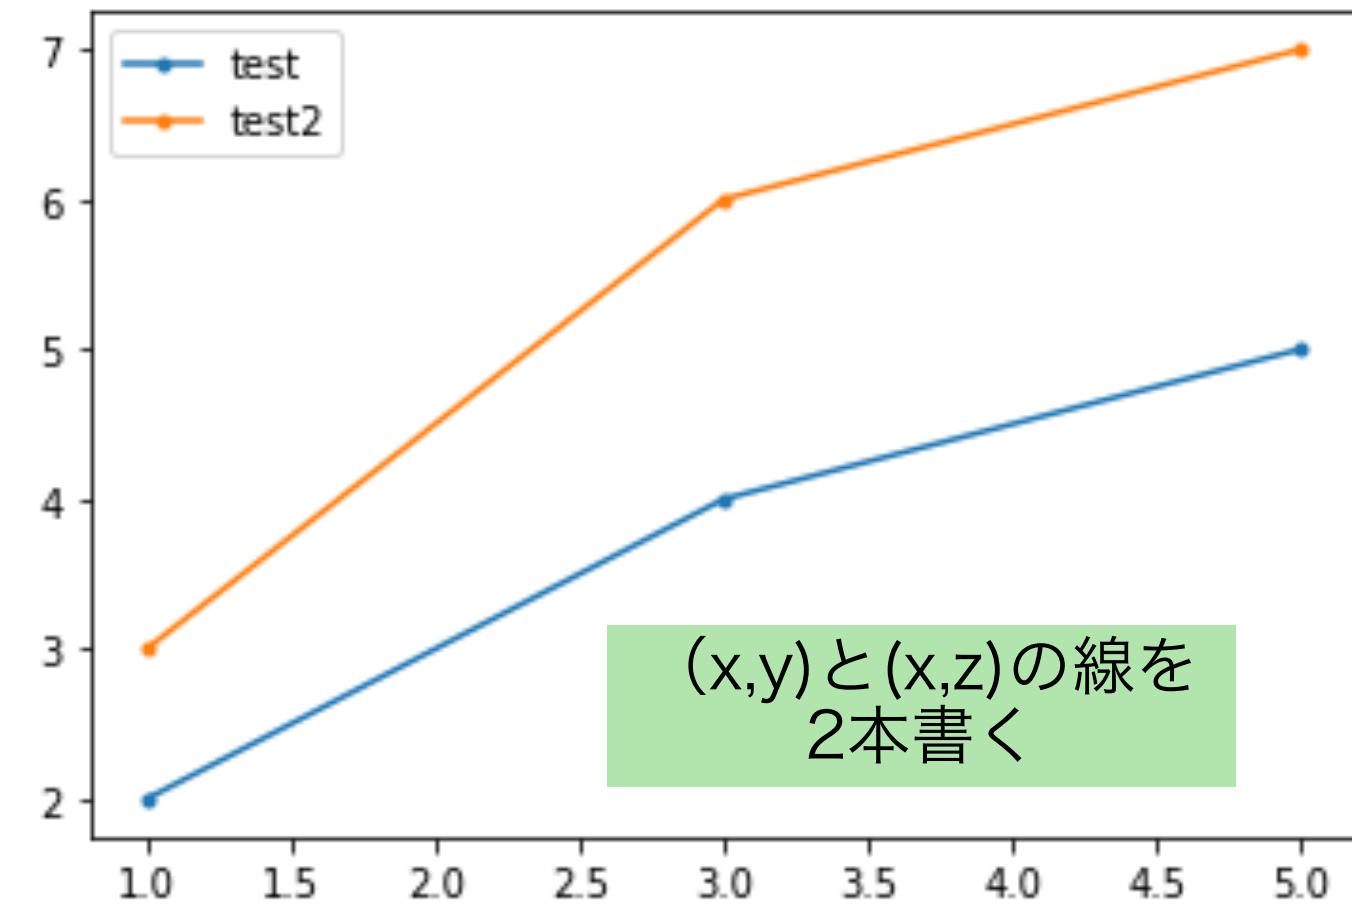
```
x = [1,3,5]
y = [2,4,5]
plt.plot(x,y,marker='.')
plt.show()
```



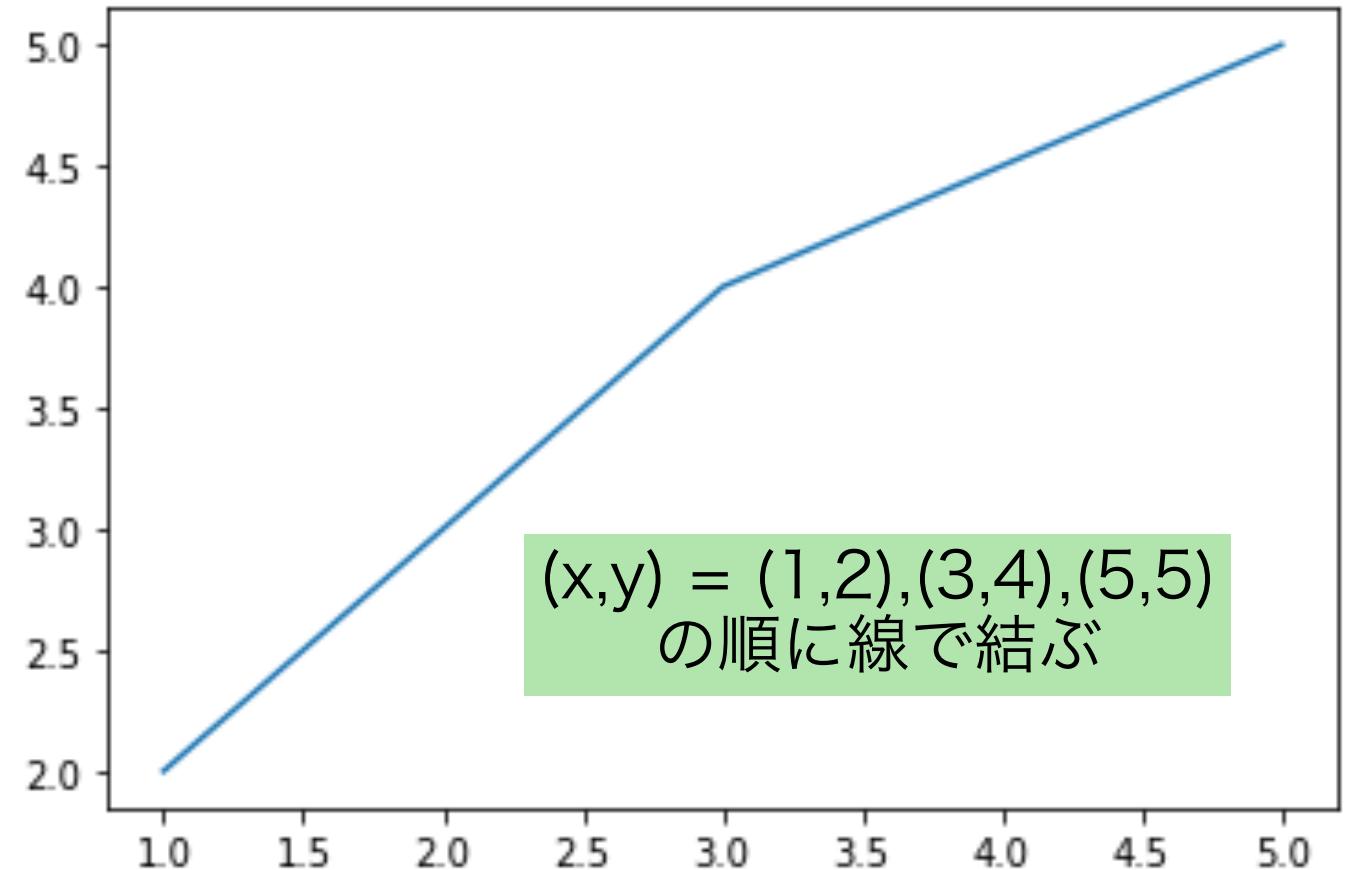
```
x = [1,3,5]
y = [2,4,5]
plt.plot(x,y,marker='.',label='test')
plt.legend()
plt.show()
```



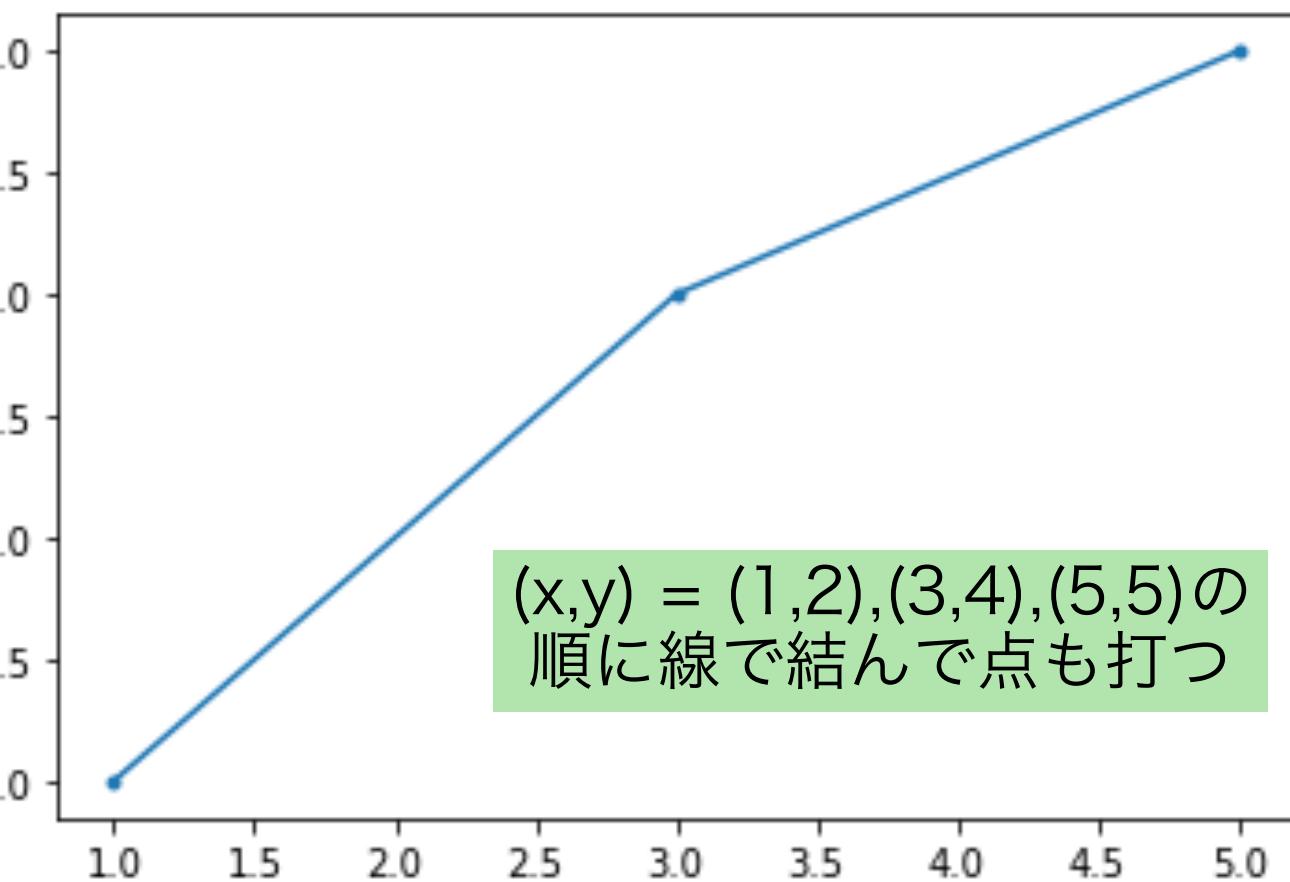
```
x = [1,3,5]
y = [2,4,5]
z = [3,6,7]
plt.plot(x,y,marker='.',label='test')
plt.plot(x,z,marker='.',label='test2')
plt.legend()
plt.show()
```



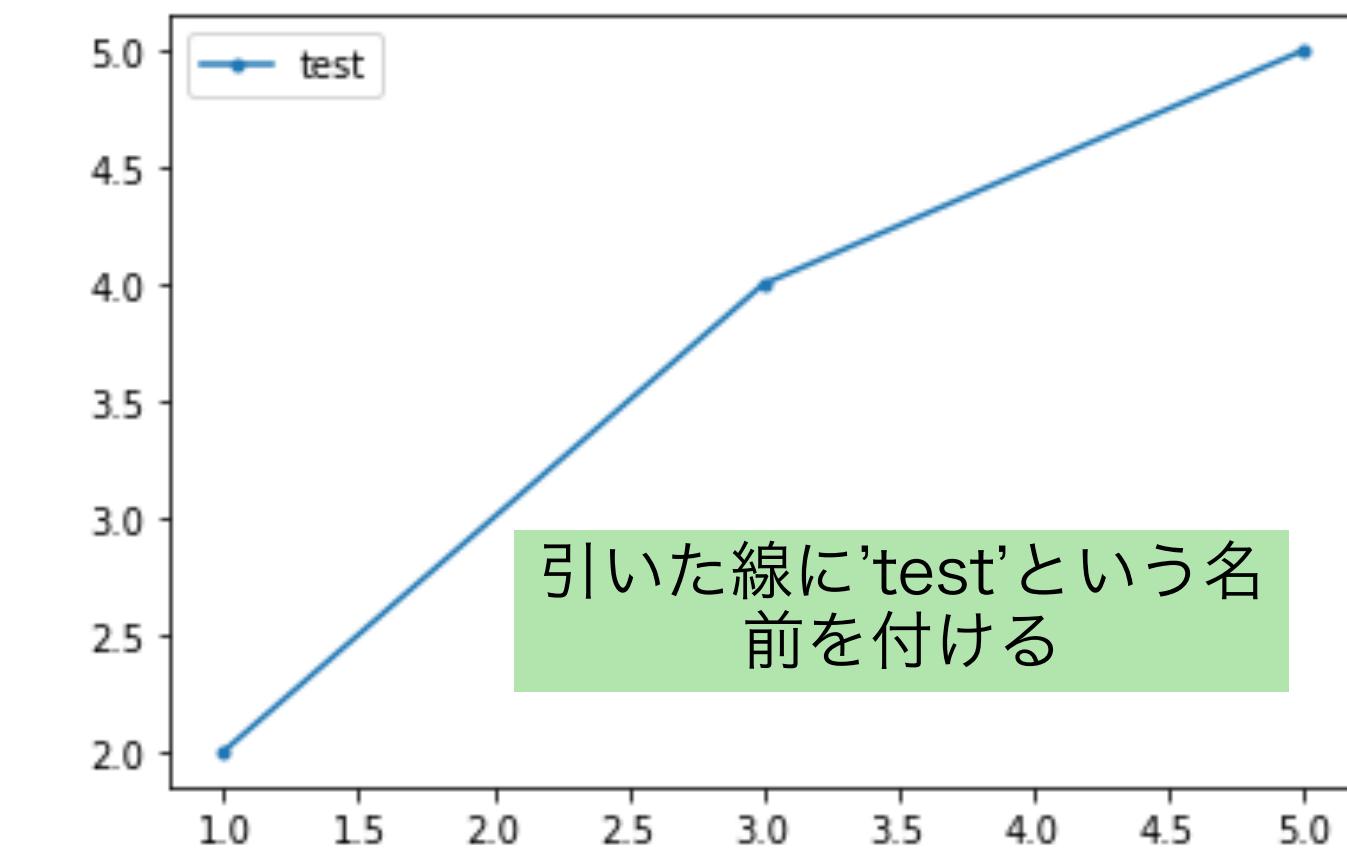
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y)  
plt.show()
```



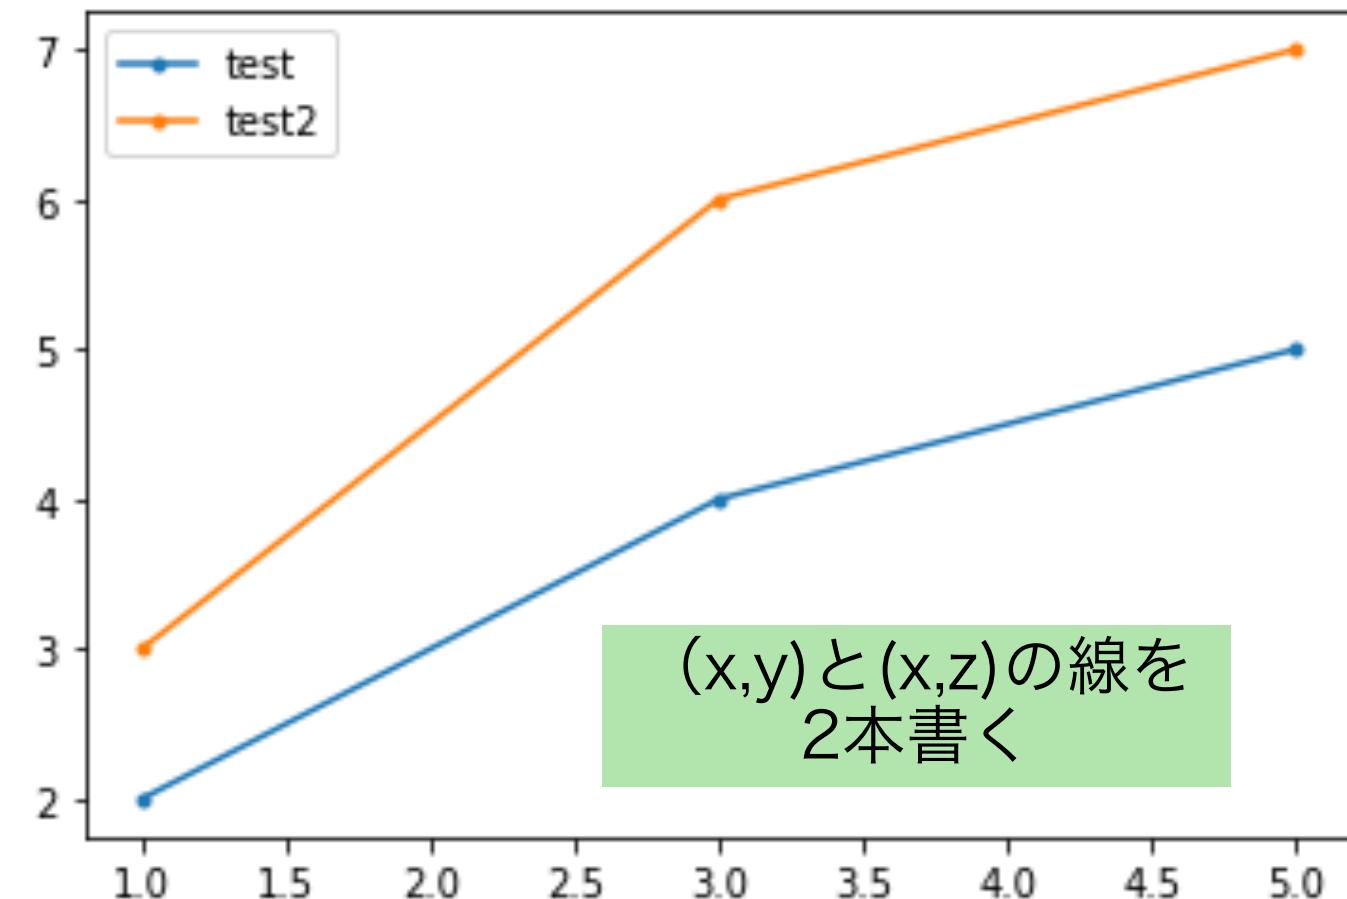
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y,marker='.',)  
plt.show()
```



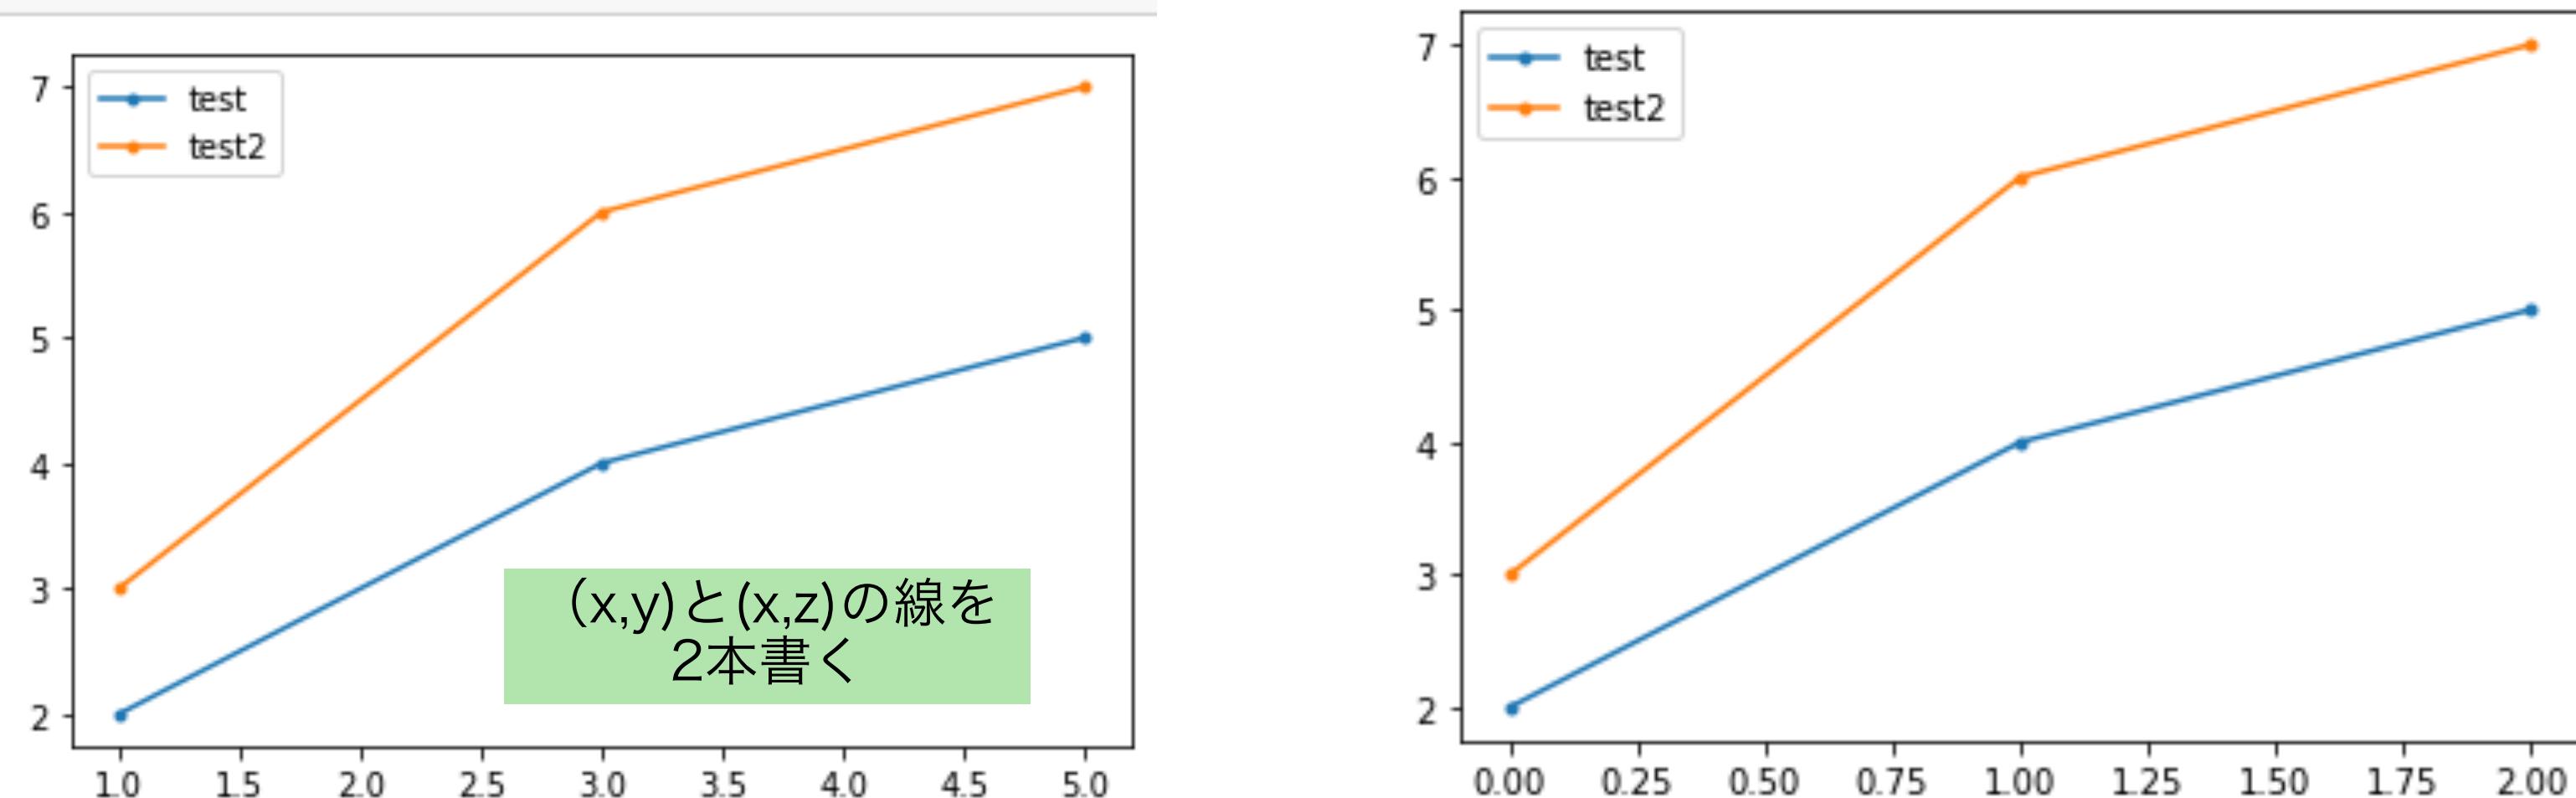
```
x = [1,3,5]  
y = [2,4,5]  
plt.plot(x,y,marker='.',label='test')  
plt.legend()  
plt.show()
```



```
x = [1,3,5]  
y = [2,4,5]  
z = [3,6,7]  
plt.plot(x,y,marker='.',label='test')  
plt.plot(x,z,marker='.',label='test2')  
plt.legend()  
plt.show()
```



```
y = [2,4,5]  
z = [3,6,7]  
plt.plot(y,marker='.',label='test')  
plt.plot(z,marker='.',label='test2')  
plt.legend()  
plt.show()
```

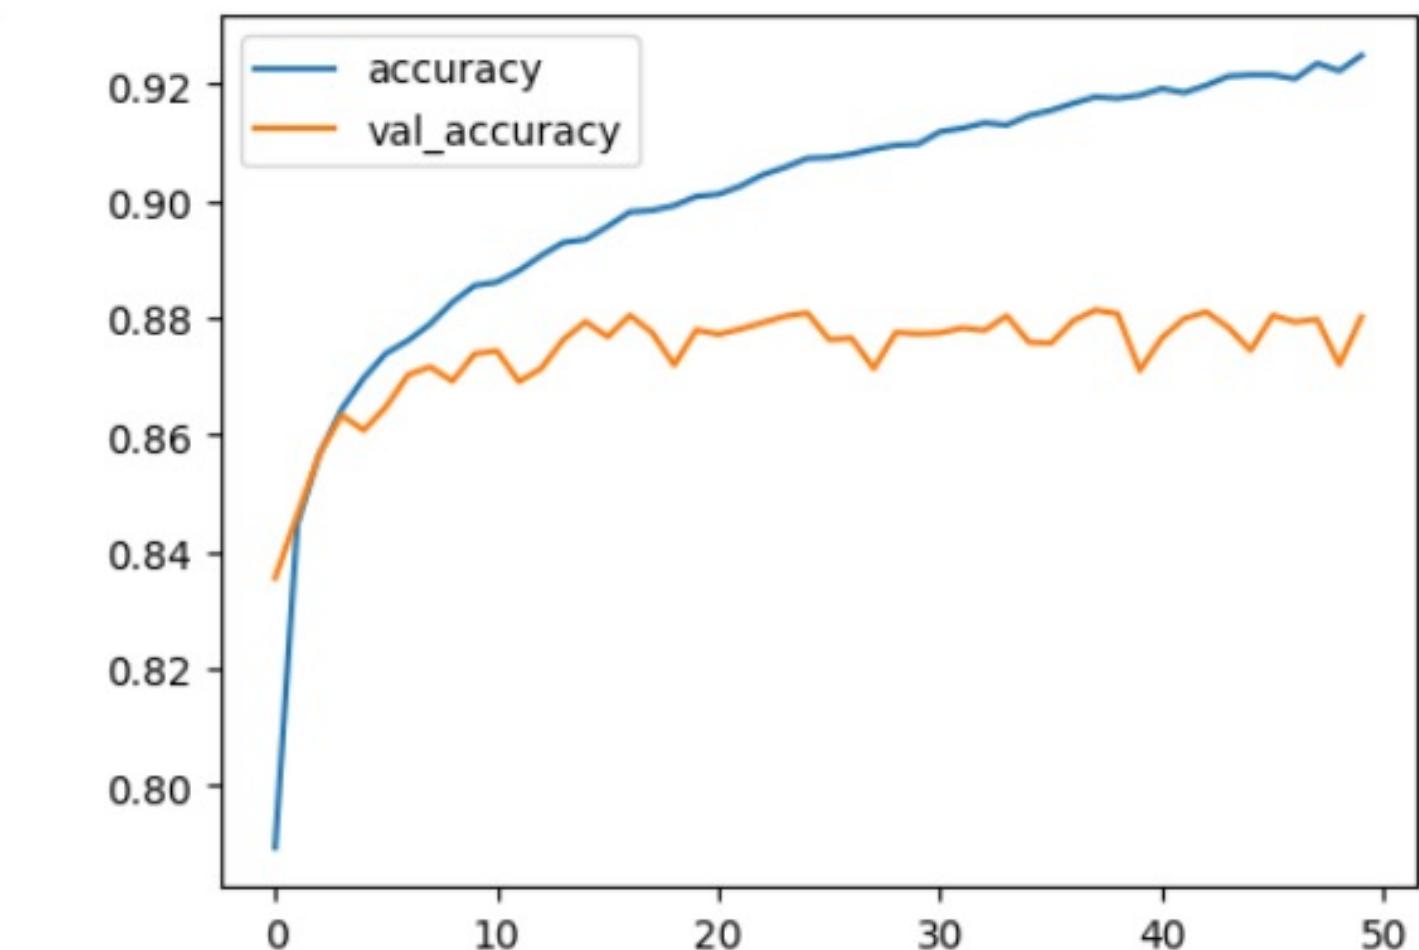
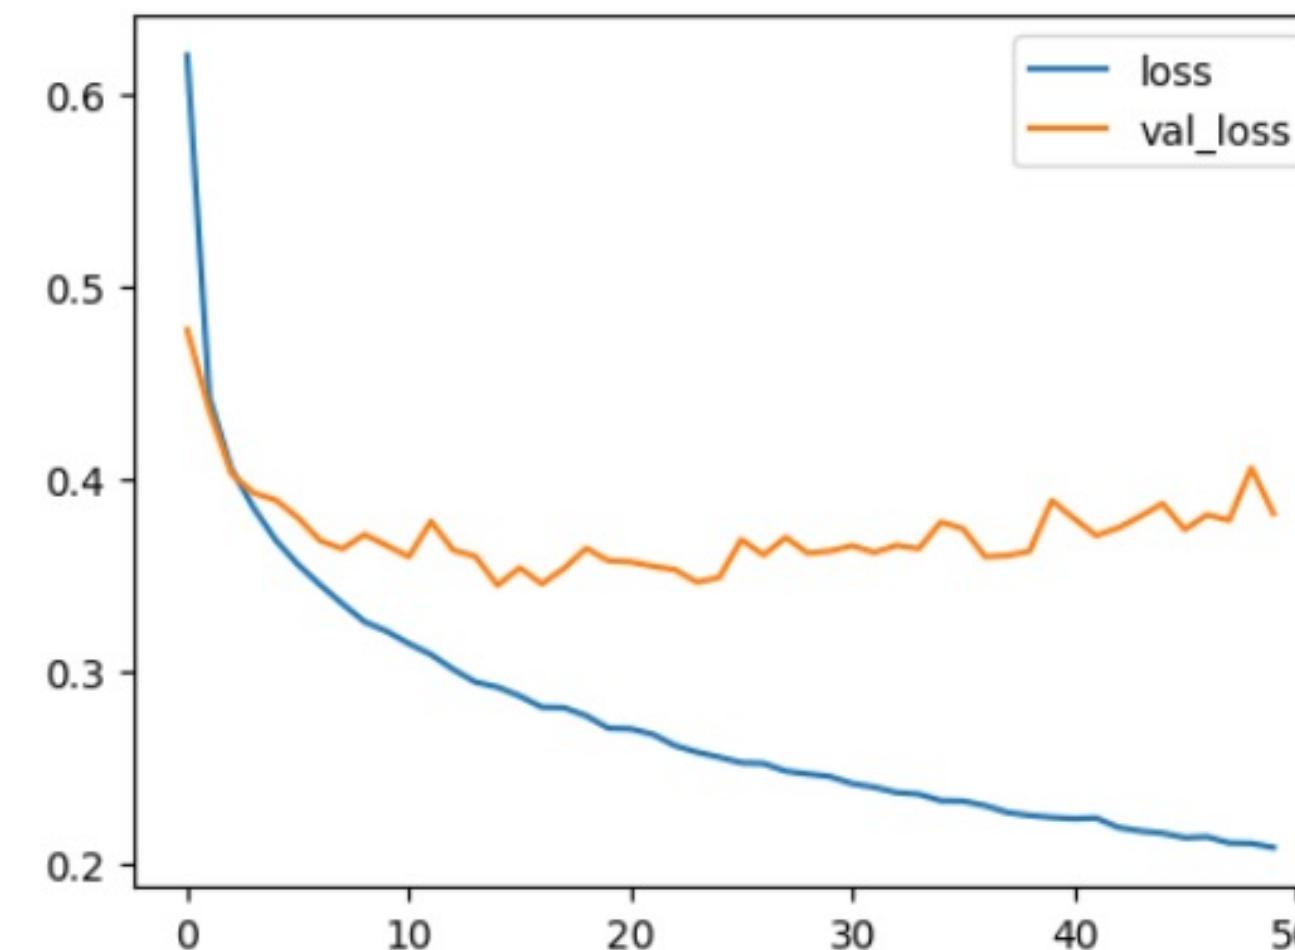


x軸の変数が与えられない時はy軸の個数だけ順に0,1,2,3,..と与えられる。

```
plt.plot(result.history['loss'],label='loss')
plt.plot(result.history['val_loss'],label='val_loss')
```

```
'loss': [0.6204796433448792, 0.4424095153808594, 0.4049777686595917, 0.38482892513275146, 0.3680422008037567,
0.3553660809993744, 0.34484514594078064, 0.3349671959877014, 0.32561713457107544, 0.3206530511379242, 0.3141988515853882,
0.30852627754211426, 0.3008130192756653, 0.29420095682144165, 0.29154443740844727, 0.28692877292633057,
0.28109729290008545, 0.28085023164749146, 0.27662160992622375, 0.2701963186264038, 0.26984351873397827,
0.26697129011154175, 0.26113253831863403, 0.25769904255867004, 0.2550542652606964, 0.2521992623806, 0.2518135905265808,
0.24781620502471924, 0.24636663496494293, 0.24498197436332703, 0.2412831038236618, 0.23945355415344238,
0.23669078946113586, 0.2358267456293106, 0.23242957890033722, 0.23221394419670105, 0.2298291176557541, 0.22631986439228058,
0.2247573286294937, 0.22372491657733917, 0.22302721440792084, 0.22342391312122345, 0.2184654176235199, 0.21663862466812134,
0.21550878882408142, 0.21314330399036407, 0.2136351317167282, 0.2104269564151764, 0.2101719230413437, 0.2080526500940323],
'val_loss': [0.4776163697242737, 0.4357101321220398, 0.40258854627609253, 0.39271479845046997, 0.3889164924621582,
0.3798101842403412, 0.3678809702396393, 0.36349910497665405, 0.37104806303977966, 0.3652504086494446, 0.35947203636169434,
0.37782320380210876, 0.3629121482372284, 0.3596421778202057, 0.34462788701057434, 0.35367244482040405, 0.3453534245491028,
0.35335132479667664, 0.36383312940597534, 0.35738077759742737, 0.35678377747535706, 0.35446837544441223,
0.3527243733406067, 0.34618350863456726, 0.34865111112594604, 0.3683689832687378, 0.3603420555591583, 0.36953479051589966,
0.36129820346832275, 0.3623996675014496, 0.36520129442214966, 0.36162319779396057, 0.36536312103271484, 0.3636190593242645,
0.37748828530311584, 0.37399259209632874, 0.35947826504707336, 0.36005476117134094, 0.3623170256614685, 0.3886697292327881,
0.37945523858070374, 0.37049585580825806, 0.3743937611579895, 0.3805387318134308, 0.38715872168540955, 0.3735528290271759,
0.38132739067077637, 0.37841248512268066, 0.4056456685066223, 0.3818448781967163],
```

どちらも要素の数が50個のリスト
xは[0,1,2,...,49]が省略されている



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

model.evaluate()で評価

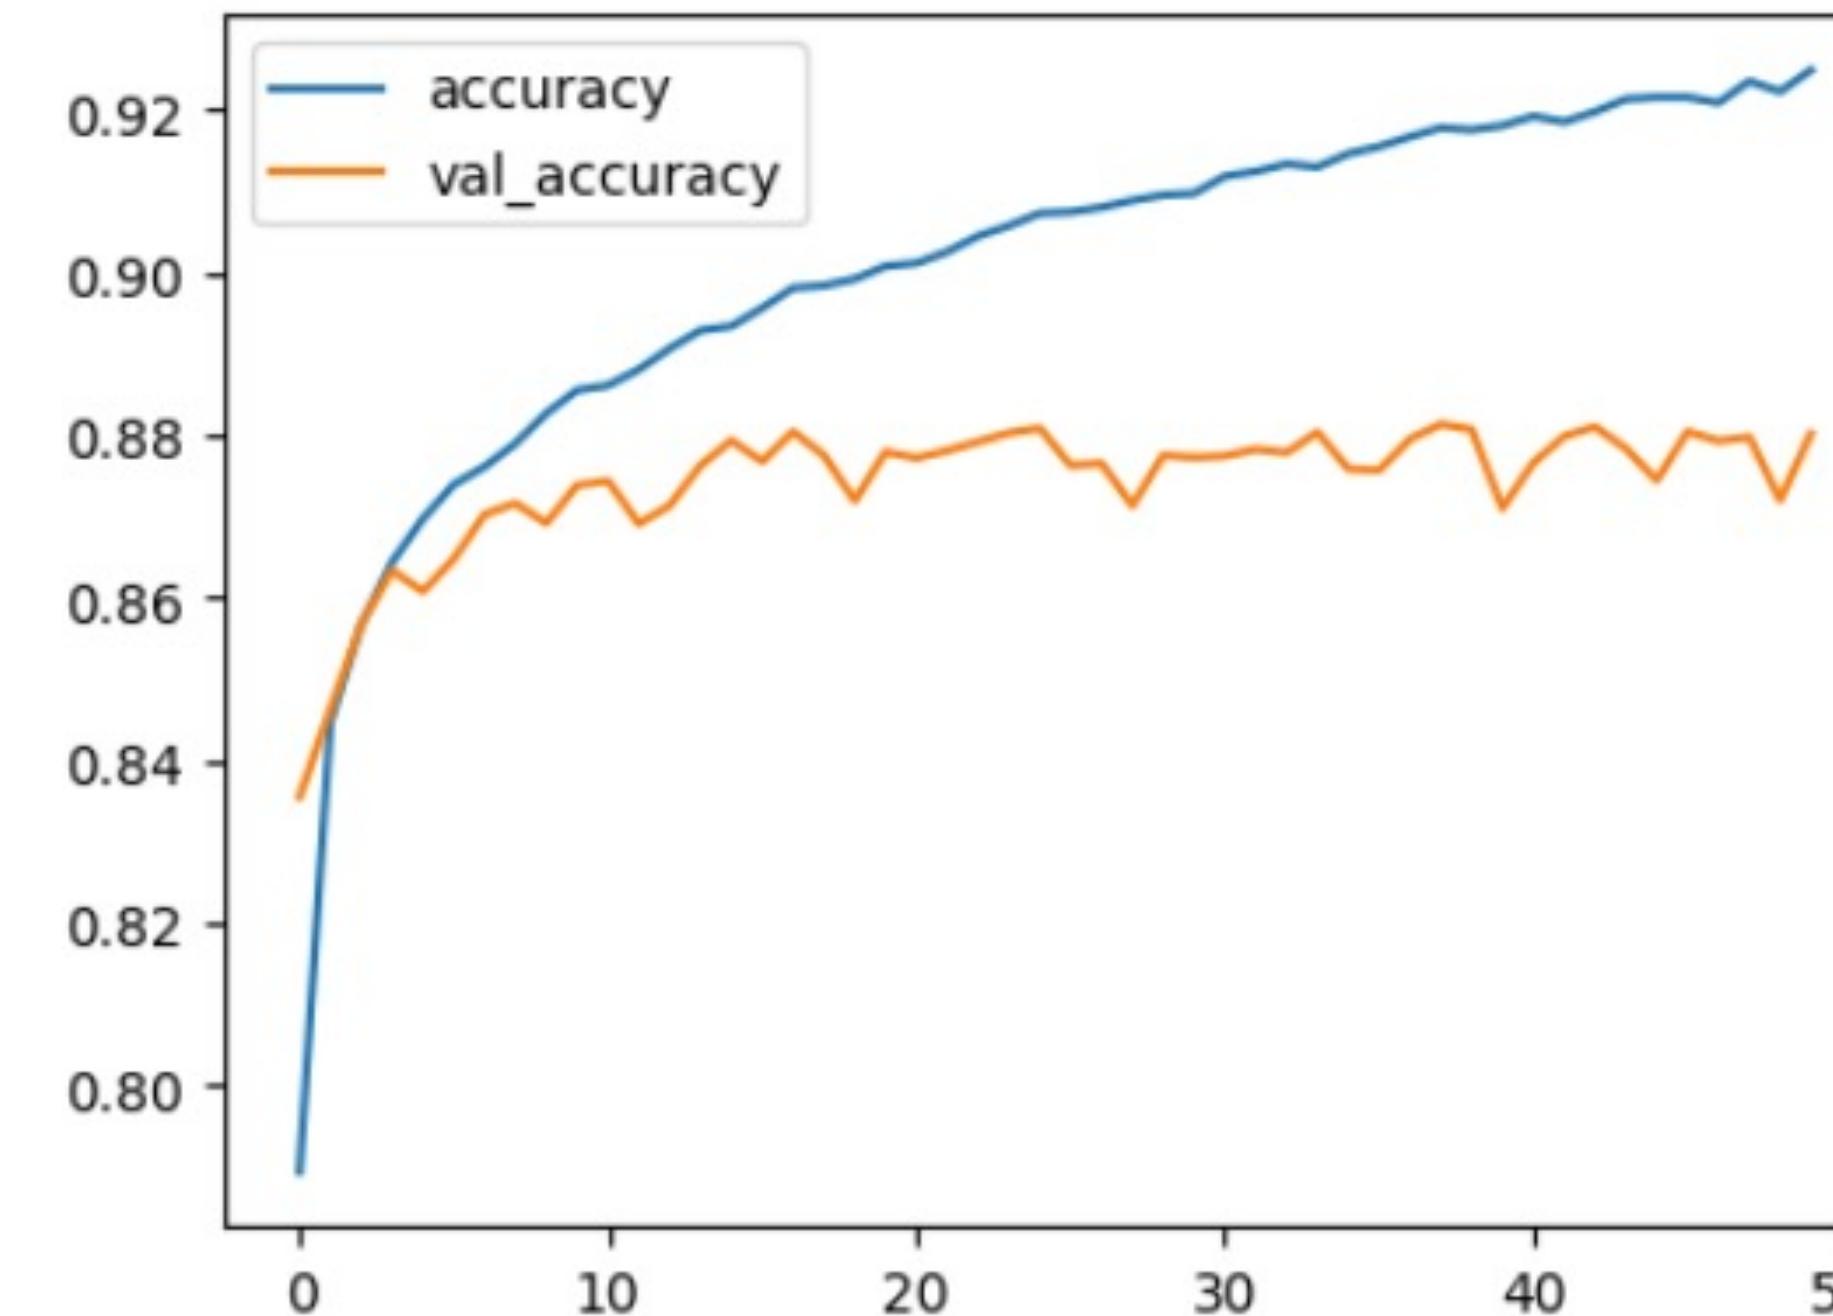
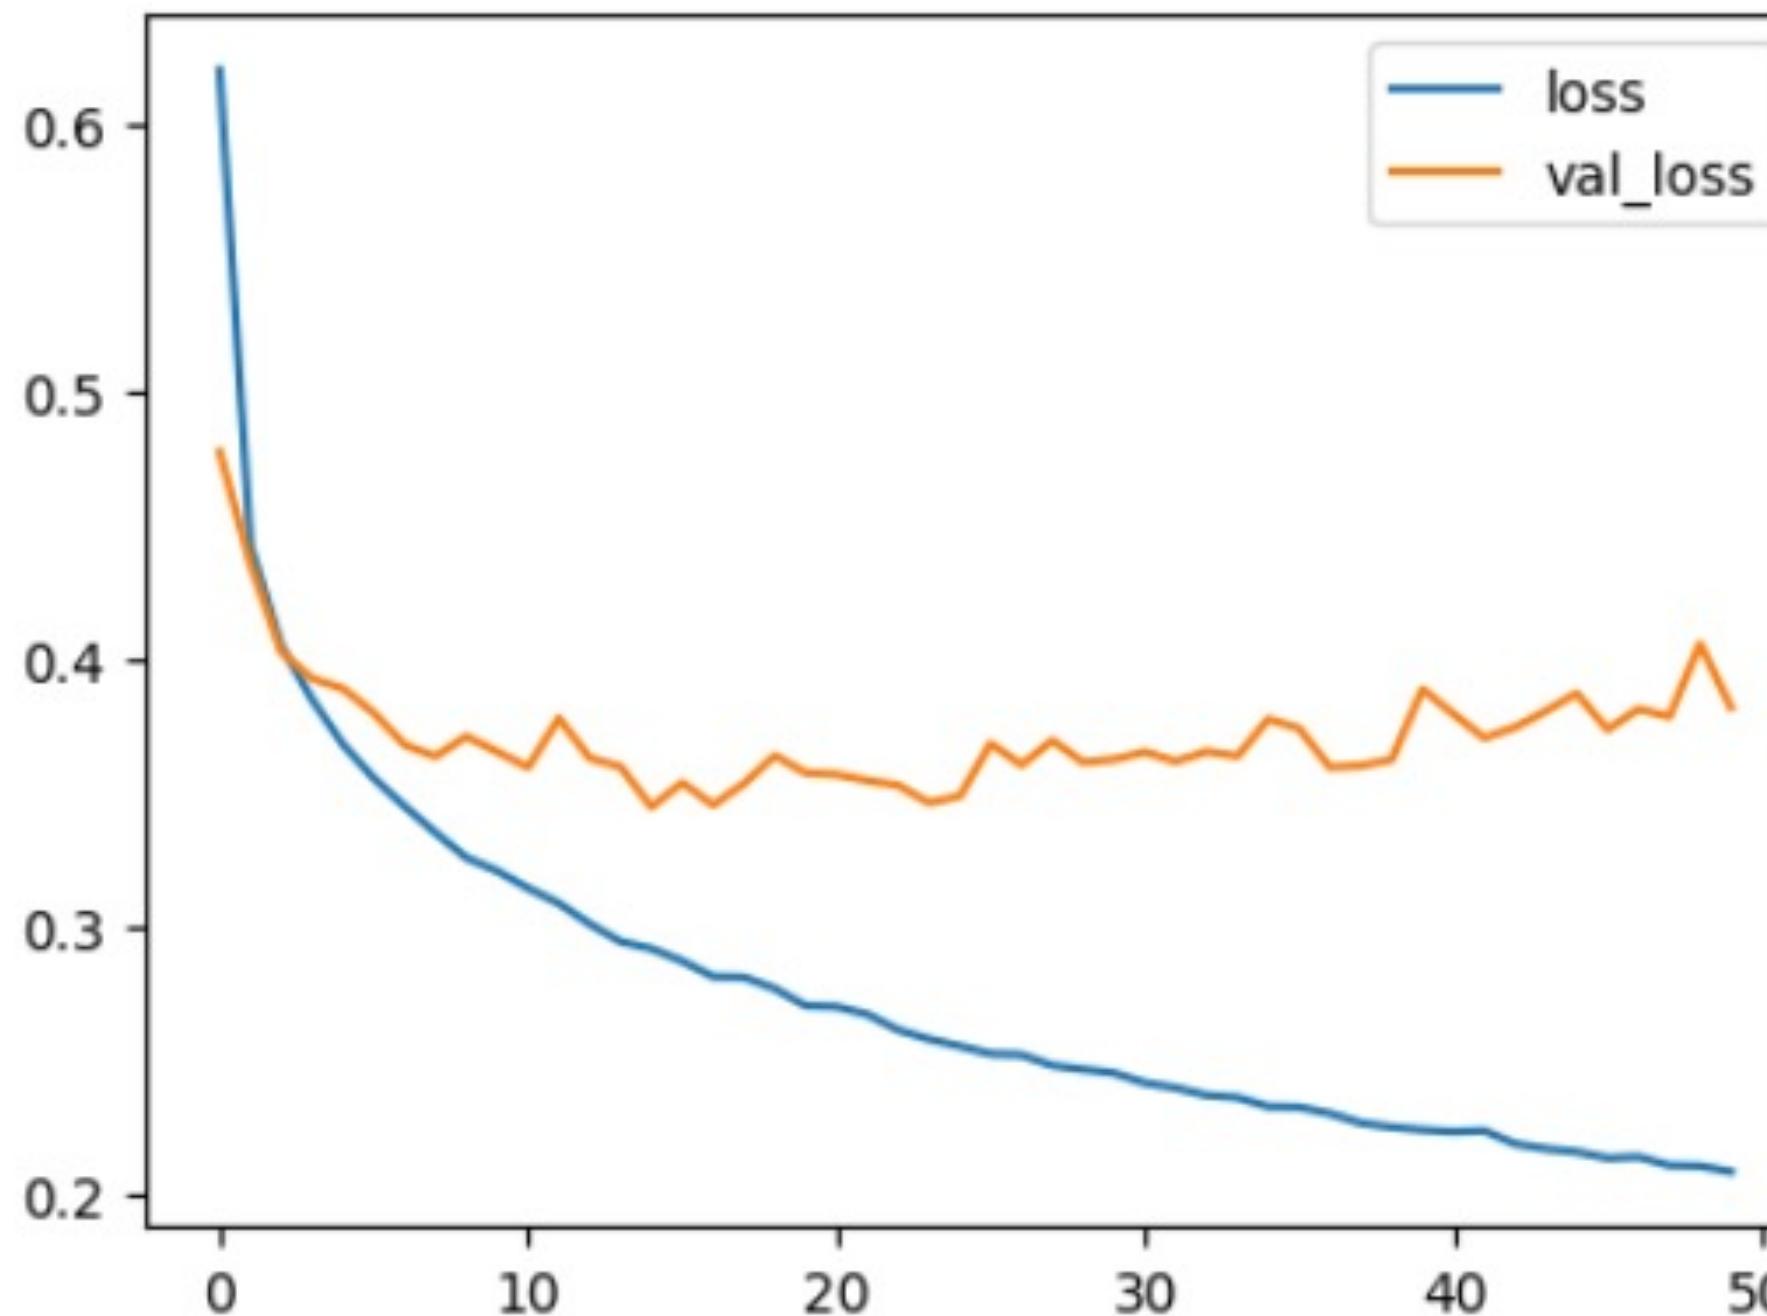
出来上がったモデルを別で用意している10000枚の画像で評価する

Test loss: 0.40565115213394165
Test accuracy: 0.8694000244140625

score = model.evaluate(特徴量,正解)で、scoreにはmodelを用いた予測結果の損失と正解率が代入される
score[0]で損失、score[1]で正解率が得られる。

a = 5	出力 5
print(a)	出力 aは
print('aは')	出力 aは
print('aは',a)	出力 aは5

今回のモデルで学習した結果



Test loss: 0.40565115213394165

Test accuracy: 0.8694000244140625

もっと精度をあげたい

ニューロンの数を増やす

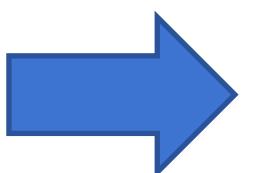
```
model = Sequential()  
model.add(Dense(32,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

Layer (type)	Output Shape	Param #

dense_12 (Dense)	(None, 32)	25120

dense_13 (Dense)	(None, 10)	330

Total params: 25,450		
Trainable params: 25,450		
Non-trainable params: 0		



```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

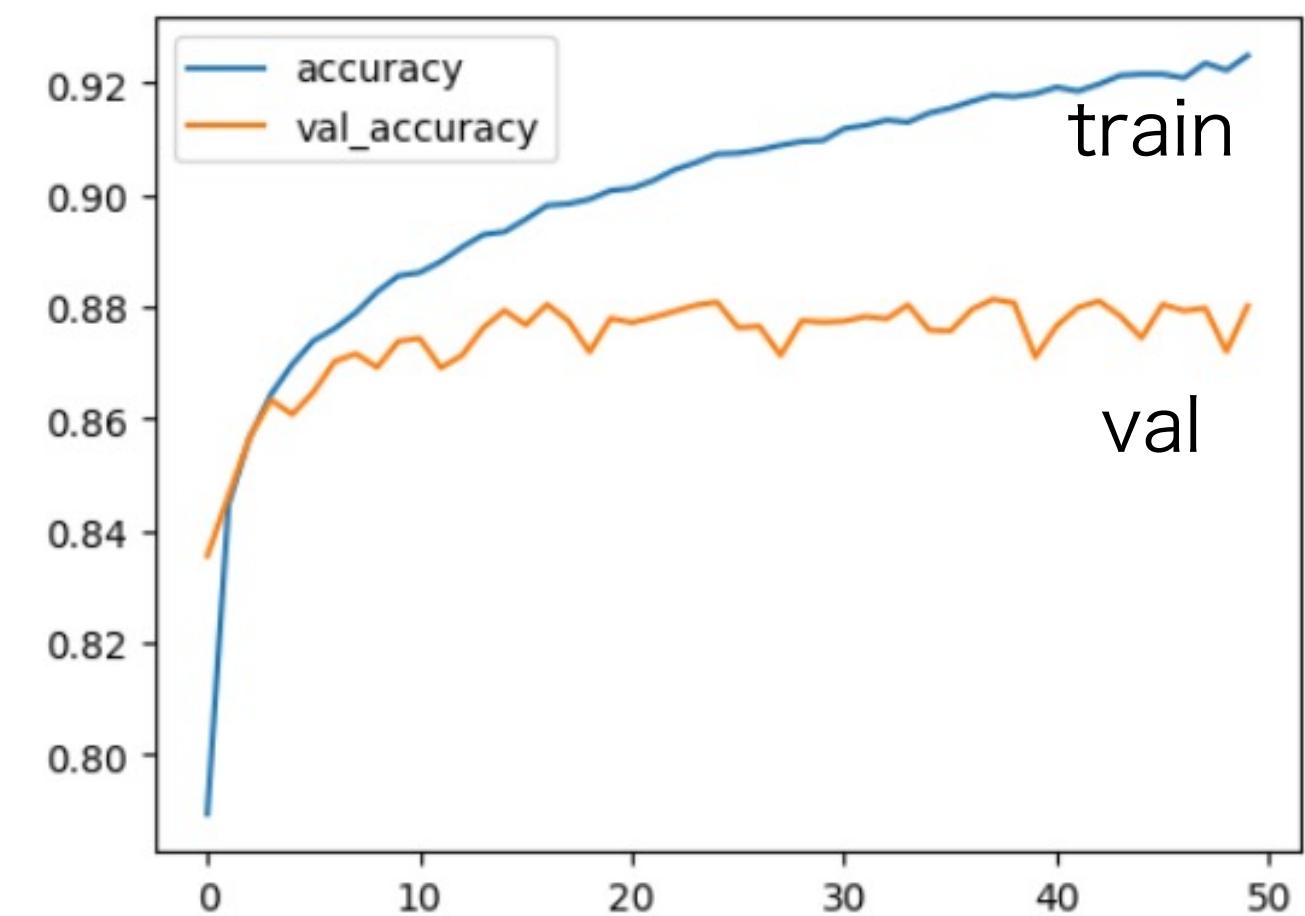
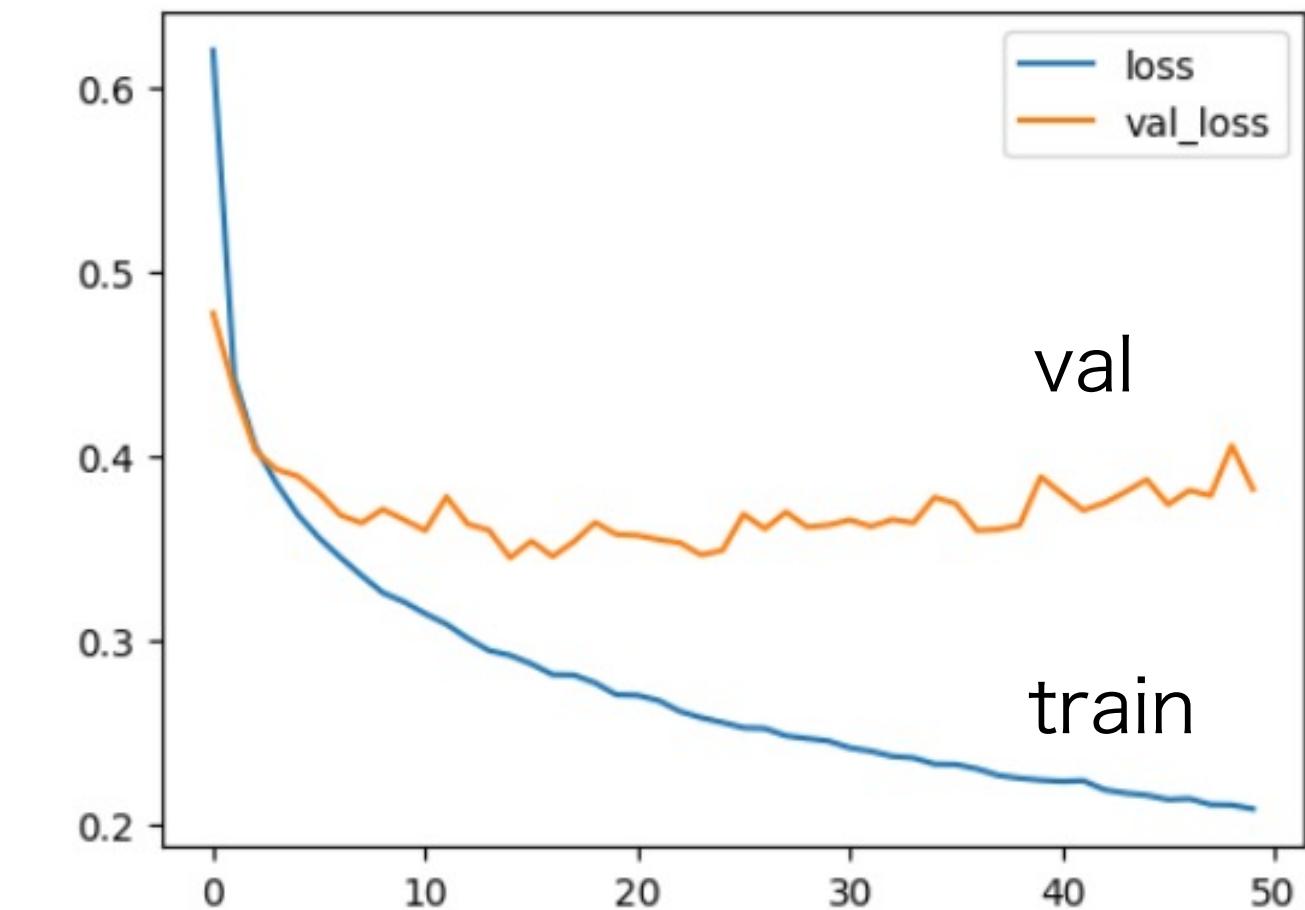
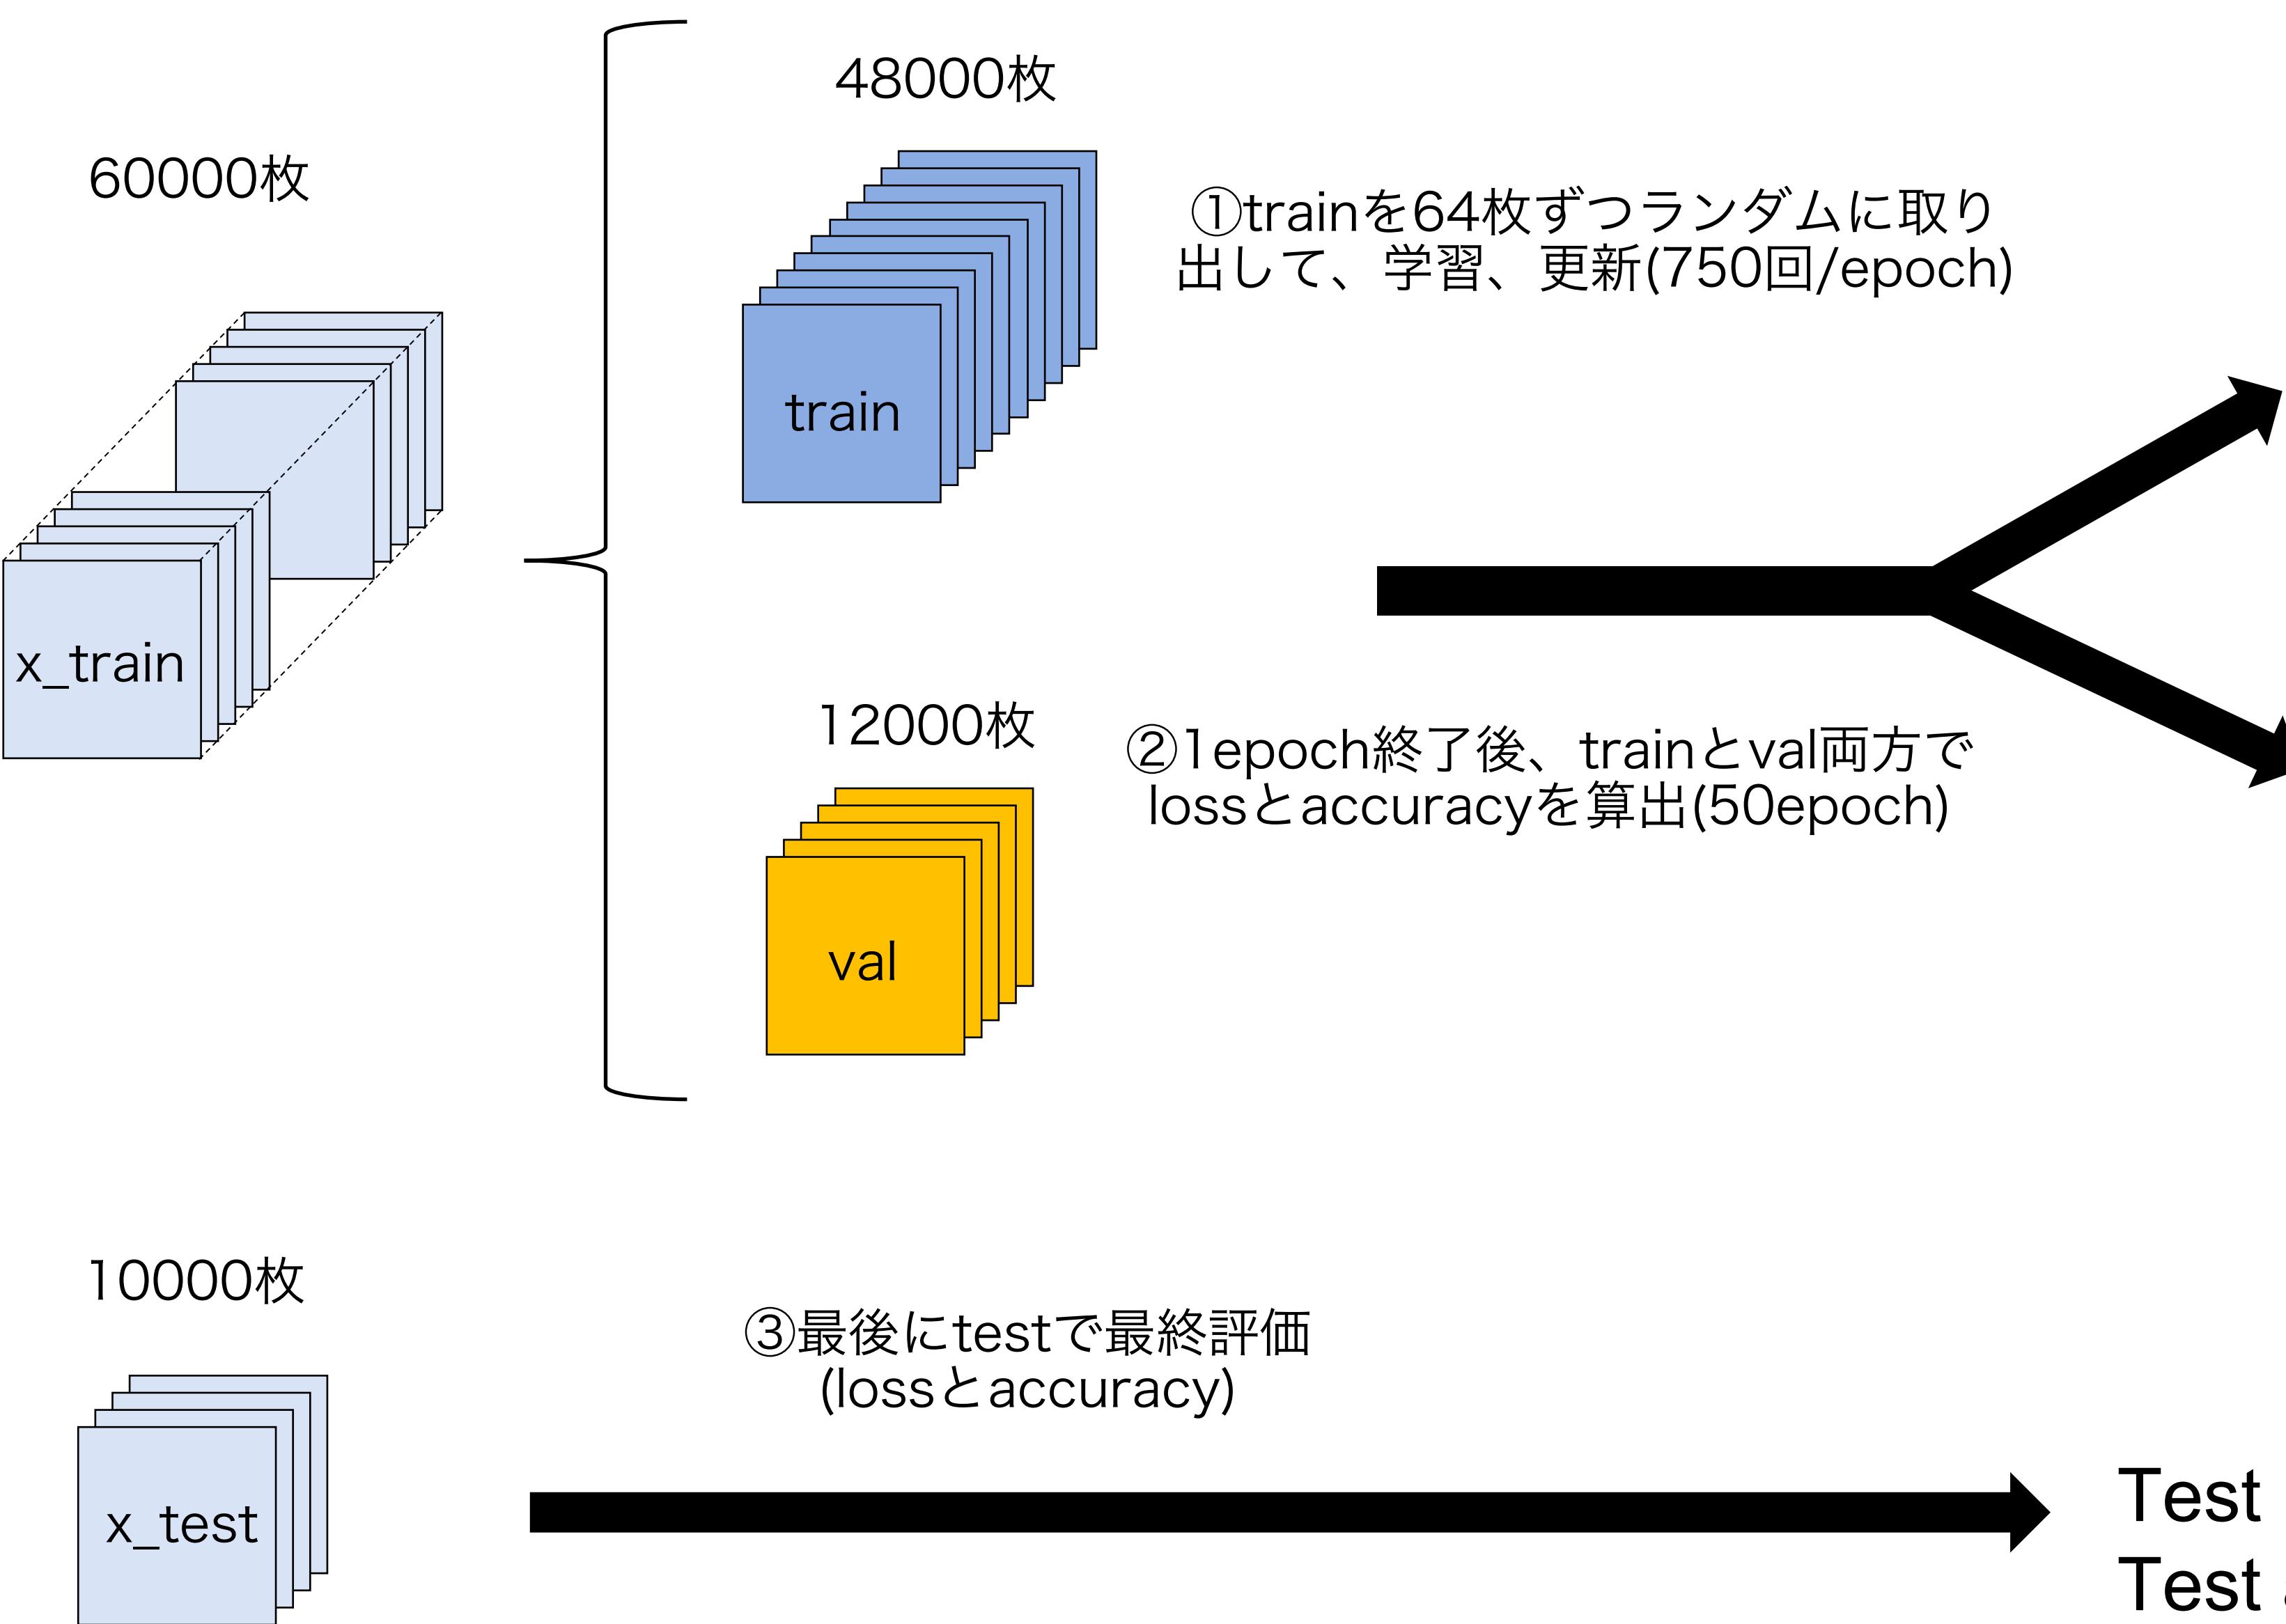
Layer (type)	Output Shape	Param #

dense_8 (Dense)	(None, 128)	100480

dense_9 (Dense)	(None, 10)	1290

Total params: 101,770		
Trainable params: 101,770		
Non-trainable params: 0		

結果の分析



Test loss: 0.40565115213394165
Test accuracy: 0.8694000244140625

result.historyの中身について

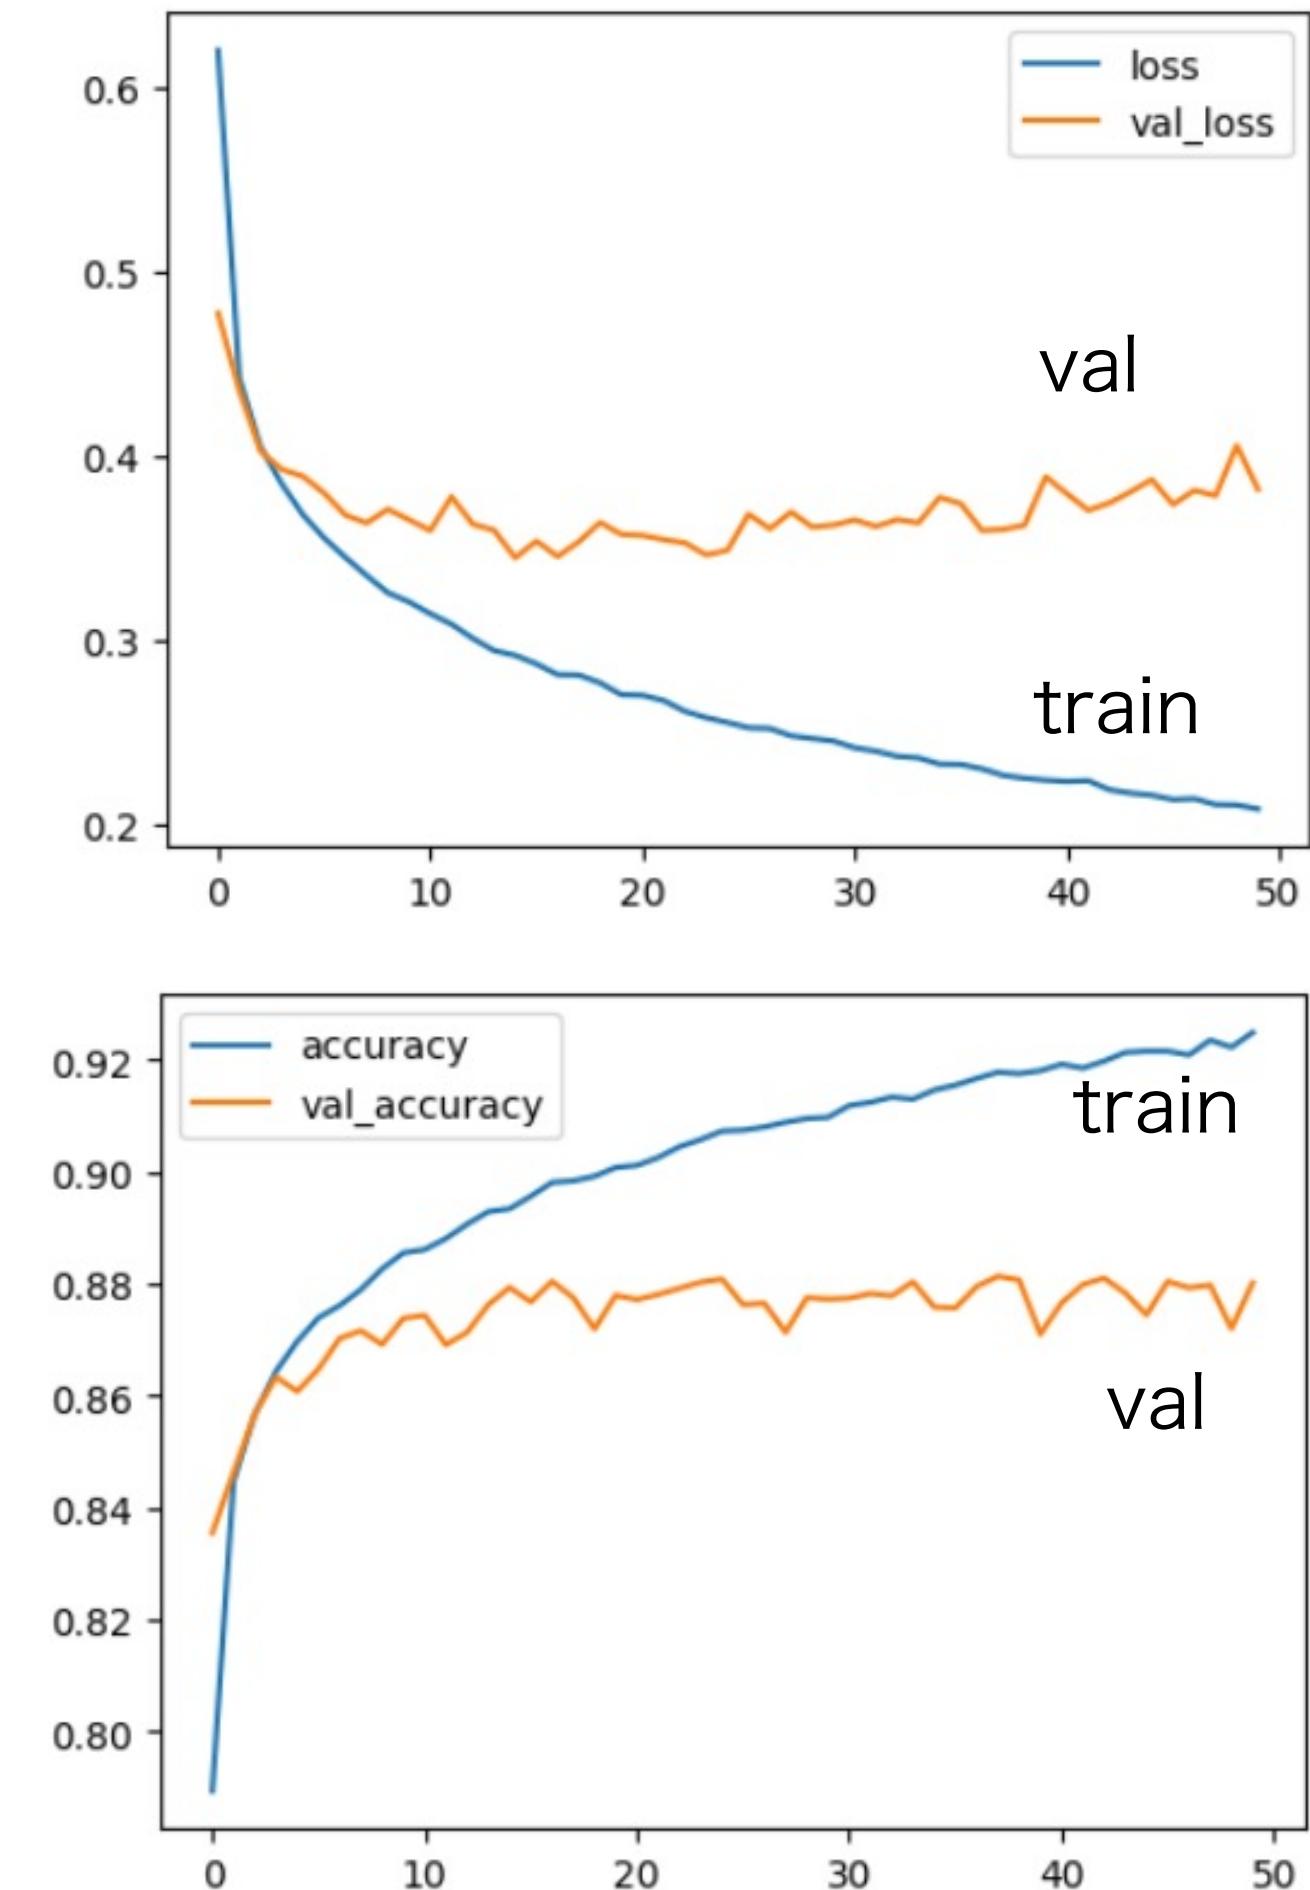
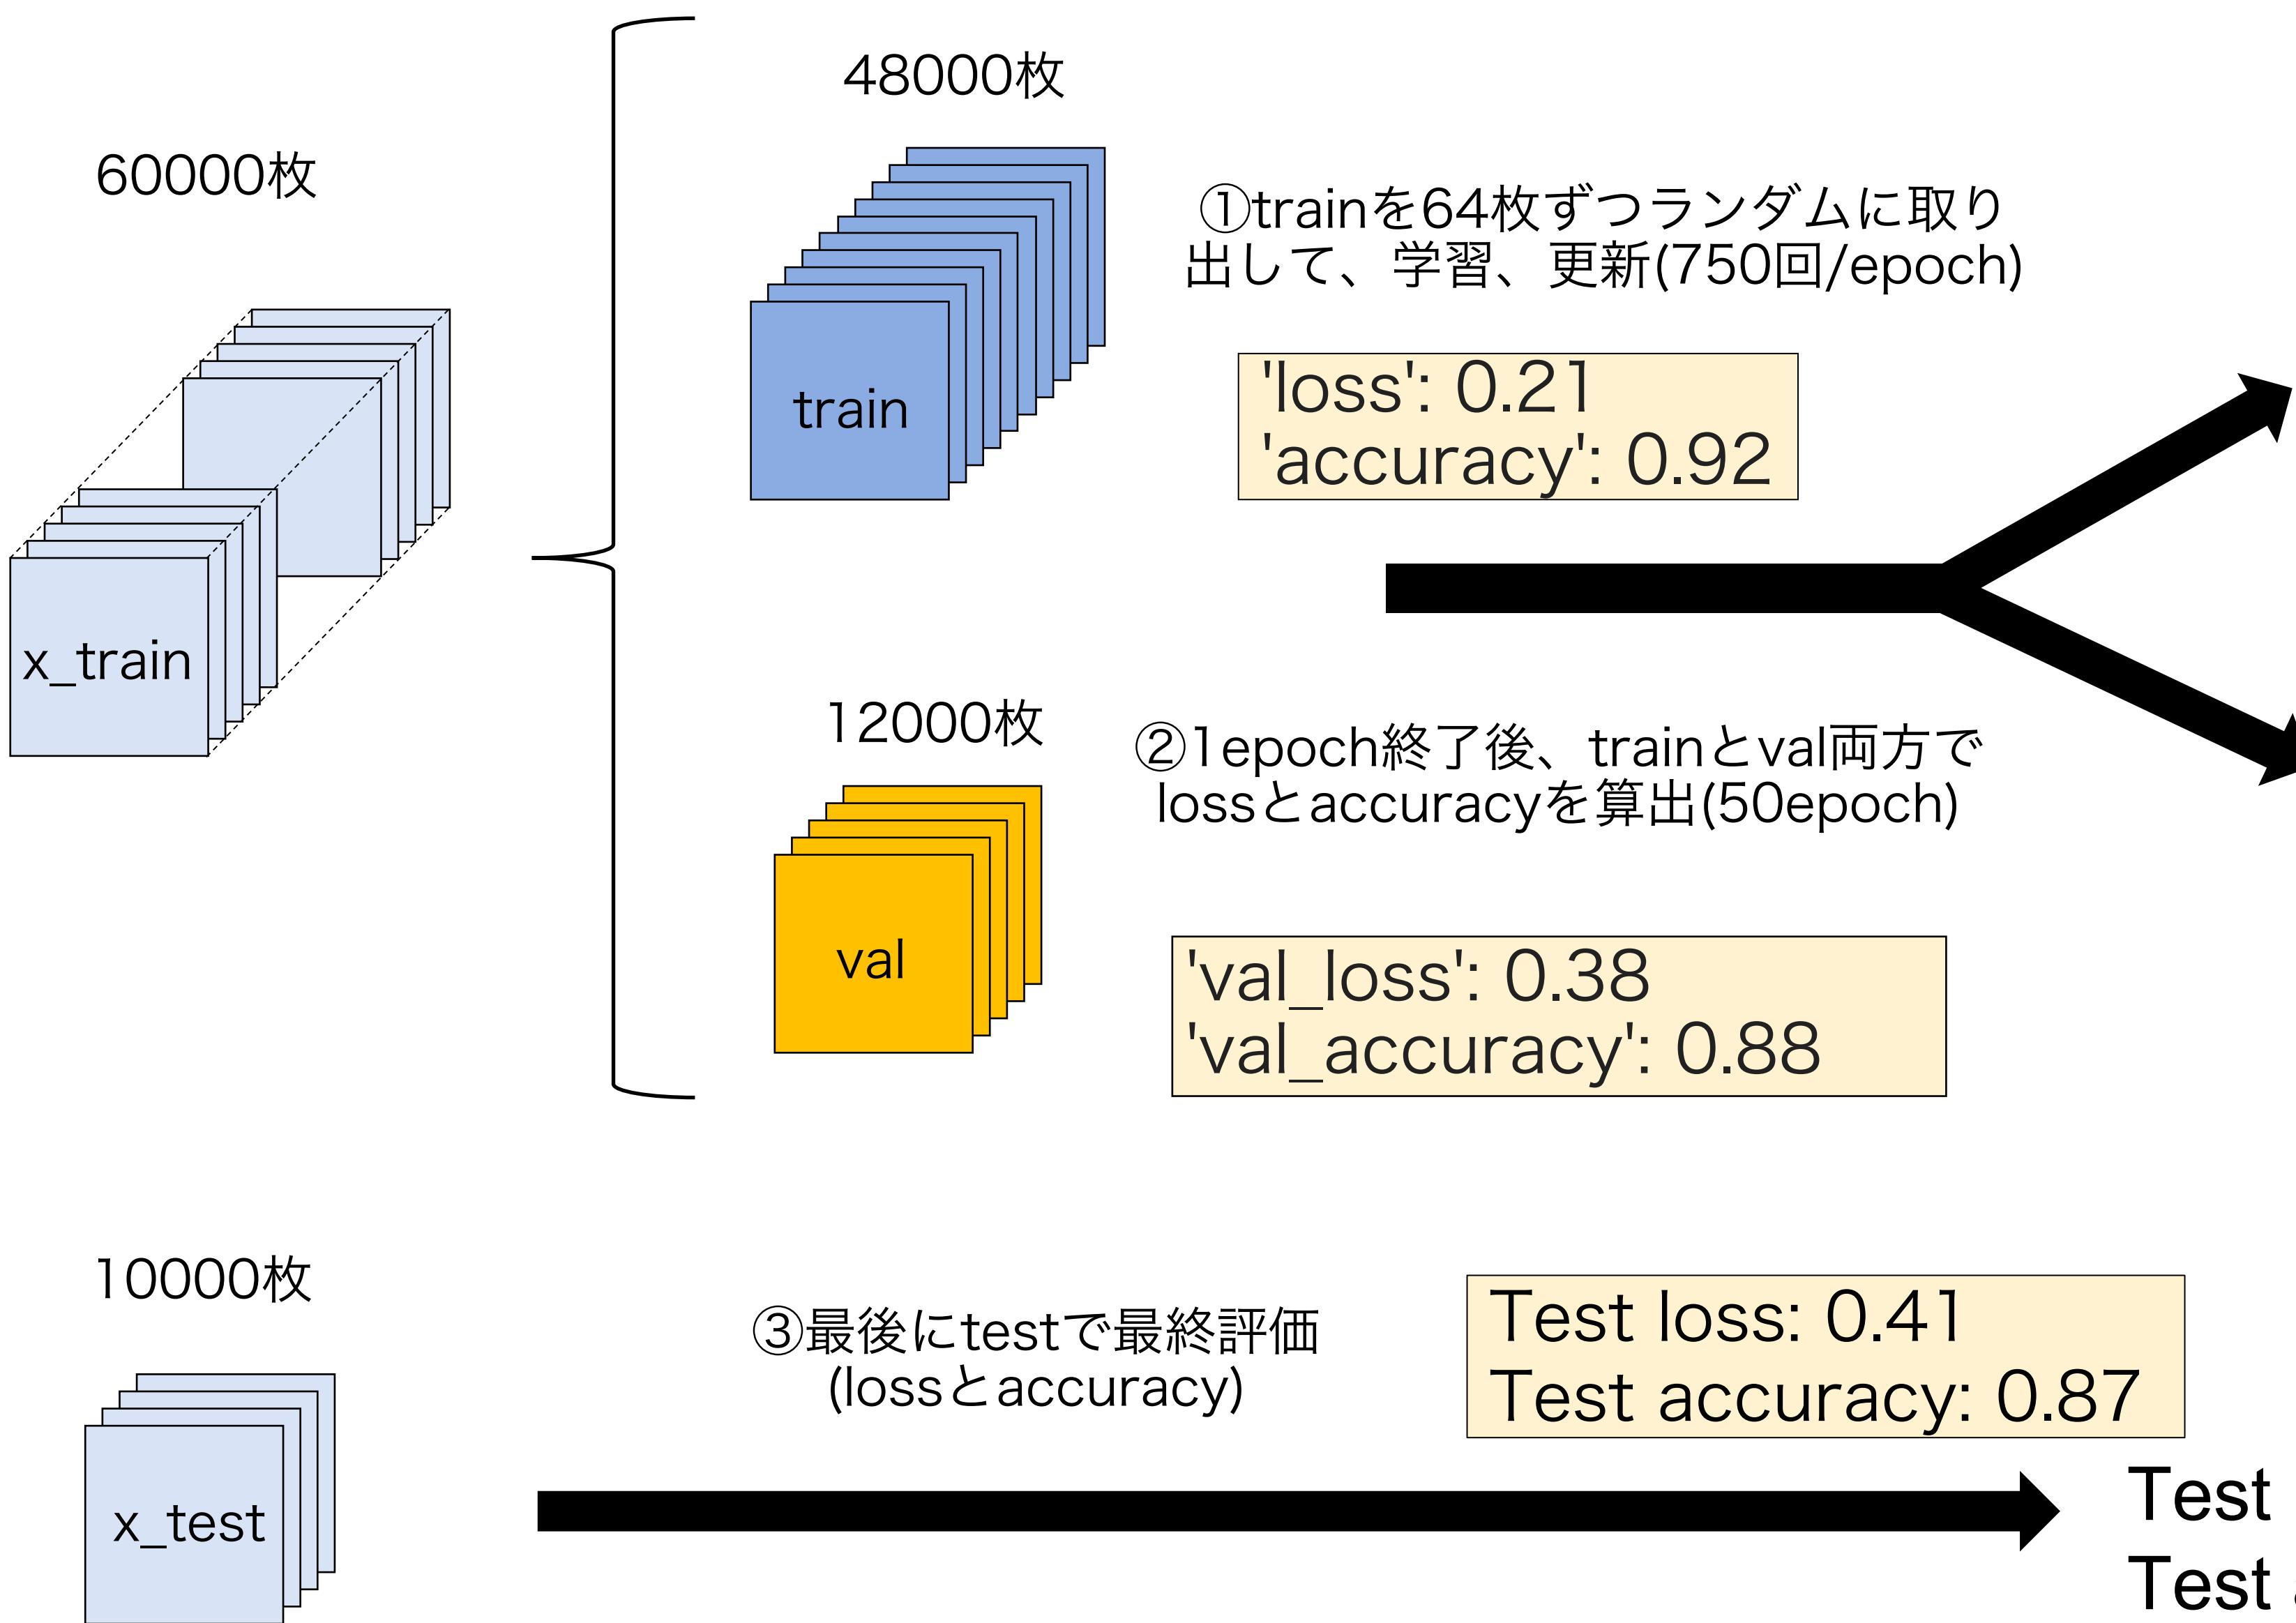
print(result.history)

```
{'loss': [0.6204796433448792, 0.4424095153808594, 0.4049777686595917, 0.38482892513275146, 0.3680422008037567, 0.3553660809993744, 0.34484514594078064, 0.3349671959877014, 0.32561713457107544, 0.3206530511379242, 0.3141988515853882, 0.30852627754211426, 0.3008130192756653, 0.29420095682144165, 0.29154443740844727, 0.28692877292633057, 0.28109729290008545, 0.28085023164749146, 0.27662160992622375, 0.2701963186264038, 0.26984351873397827, 0.26697129011154175, 0.26113253831863403, 0.25769904255867004, 0.2550542652606964, 0.2521992623806, 0.2518135905265808, 0.24781620502471924, 0.24636663496494293, 0.24498197436332703, 0.2412831038236618, 0.23945355415344238, 0.23669078946113586, 0.2358267456293106, 0.23242957890033722, 0.23221394419670105, 0.2298291176557541, 0.22631986439228058, 0.2247573286294937, 0.22372491657733917, 0.22302721440792084, 0.22342391312122345, 0.2184654176235199, 0.21663862466812134, 0.21550878882408142, 0.21314330399036407, 0.2136351317167282, 0.2104269564151764, 0.2101719230413437, 0.2080526500940323],  
  
'accuracy': [0.789354145526886, 0.8447291851043701, 0.8566874861717224, 0.8643541932106018, 0.8697083592414856, 0.8739166855812073, 0.8761041760444641, 0.8789583444595337, 0.8826666474342346, 0.8855208158493042, 0.886104166507721, 0.888062477118164, 0.8906458616256714, 0.8928750157356262, 0.8933958411216736, 0.8956249952316284, 0.898104190826416, 0.8983749747276306, 0.8991875052452087, 0.9007708430290222, 0.9011458158493042, 0.9025416374206543, 0.9044791460037231, 0.9057499766349792, 0.9072708487510681, 0.9074375033378601, 0.9079999923706055, 0.9088541865348816, 0.9095208048820496, 0.9097291827201843, 0.9118333458900452, 0.9124166369438171, 0.9133541584014893, 0.9129791855812073, 0.9146041870117188, 0.9154791831970215, 0.9166874885559082, 0.9177916646003723, 0.9175416827201843, 0.9180625081062317, 0.9192083477973938, 0.9185208082199097, 0.9197708368301392, 0.9213333129882812, 0.9215624928474426, 0.9215624928474426, 0.9208750128746033, 0.9235208630561829, 0.922249972820282, 0.9248958230018616],  
  
'val_loss': [0.4776163697242737, 0.4357101321220398, 0.40258854627609253, 0.39271479845046997, 0.3889164924621582, 0.3798101842403412, 0.3678809702396393, 0.36349910497665405, 0.37104806303977966, 0.3652504086494446, 0.35947203636169434, 0.37782320380210876, 0.3629121482372284, 0.3596421778202057, 0.34462788701057434, 0.35367244482040405, 0.3453534245491028, 0.35335132479667664, 0.36383312940597534, 0.35738077759742737, 0.35678377747535706, 0.3544683754441223, 0.3527243733406067, 0.34618350863456726, 0.3486511112594604, 0.3683689832687378, 0.3603420555591583, 0.36953479051589966, 0.36129820346832275, 0.3623996675014496, 0.36520129442214966, 0.36162319779396057, 0.36536312103271484, 0.3636190593242645, 0.37748828530311584, 0.37399259209632874, 0.35947826504707336, 0.36005476117134094, 0.3623170256614685, 0.3886697292327881, 0.37945523858070374, 0.37049585580825806, 0.3743937611579895, 0.3805387318134308, 0.38715872168540955, 0.3735528290271759, 0.38132739067077637, 0.37841248512268066, 0.4056456685066223, 0.3818448781967163],  
  
'val_accuracy': [0.8355000019073486, 0.8462499976158142, 0.8567500114440918, 0.863333444595337, 0.8607500195503235, 0.8647500276565552, 0.8702499866485596, 0.8715833425521851, 0.8691666722297668, 0.8738333582878113, 0.874333220481873, 0.8690833449363708, 0.8713333606719971, 0.8762500286102295, 0.8793333172798157, 0.8767499923706055, 0.8804166913032532, 0.8774999976158142, 0.871916651725769, 0.877916693687439, 0.8771666884422302, 0.878083348274231, 0.8791666626930237, 0.8802499771118164, 0.880833327702332, 0.8762500286102295, 0.8765000104904175, 0.8713333606719971, 0.8774999976158142, 0.8772500157356262, 0.8774166703224182, 0.87825002861023, 0.8778333067893982, 0.8803333044052124, 0.875833325386047, 0.8756666779518127, 0.8794999718666077, 0.8813333511352539, 0.8806666731834412, 0.8709999918937683, 0.8765833377838135, 0.8798333406448364, 0.8809999823570251, 0.87833330154419, 0.8744166493415833, 0.8804166913032532, 0.8792499899864197, 0.8797500133514404, 0.871999979019165, 0.8801666498184204]}
```

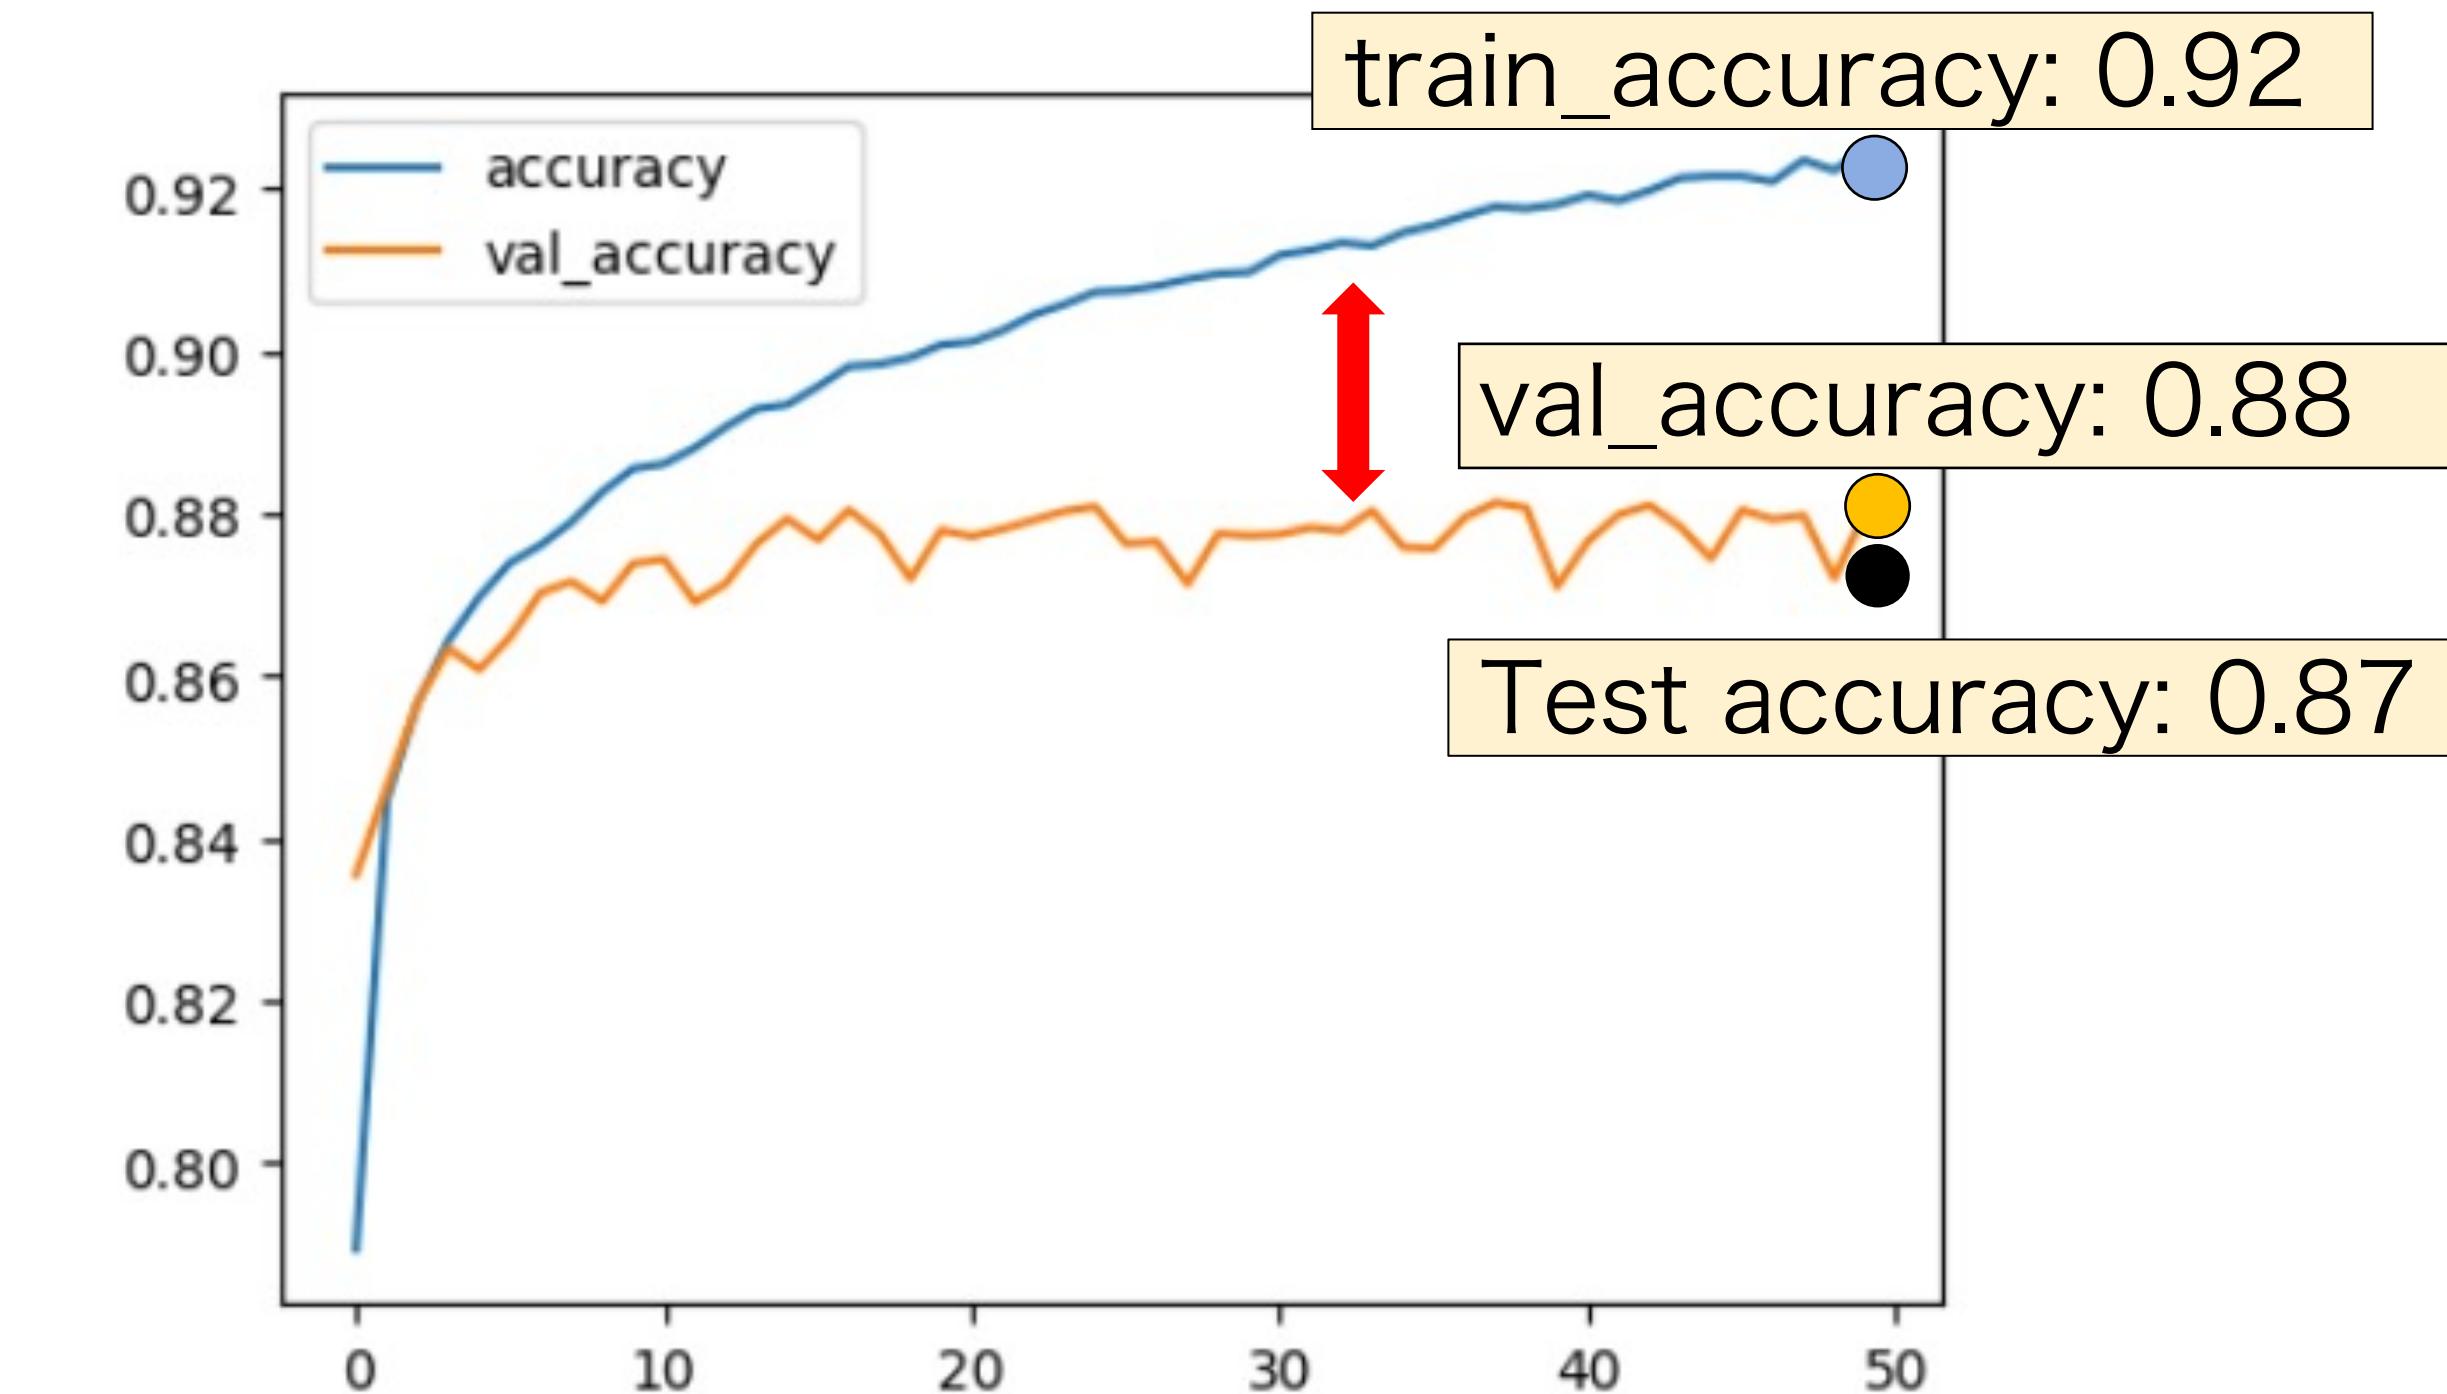
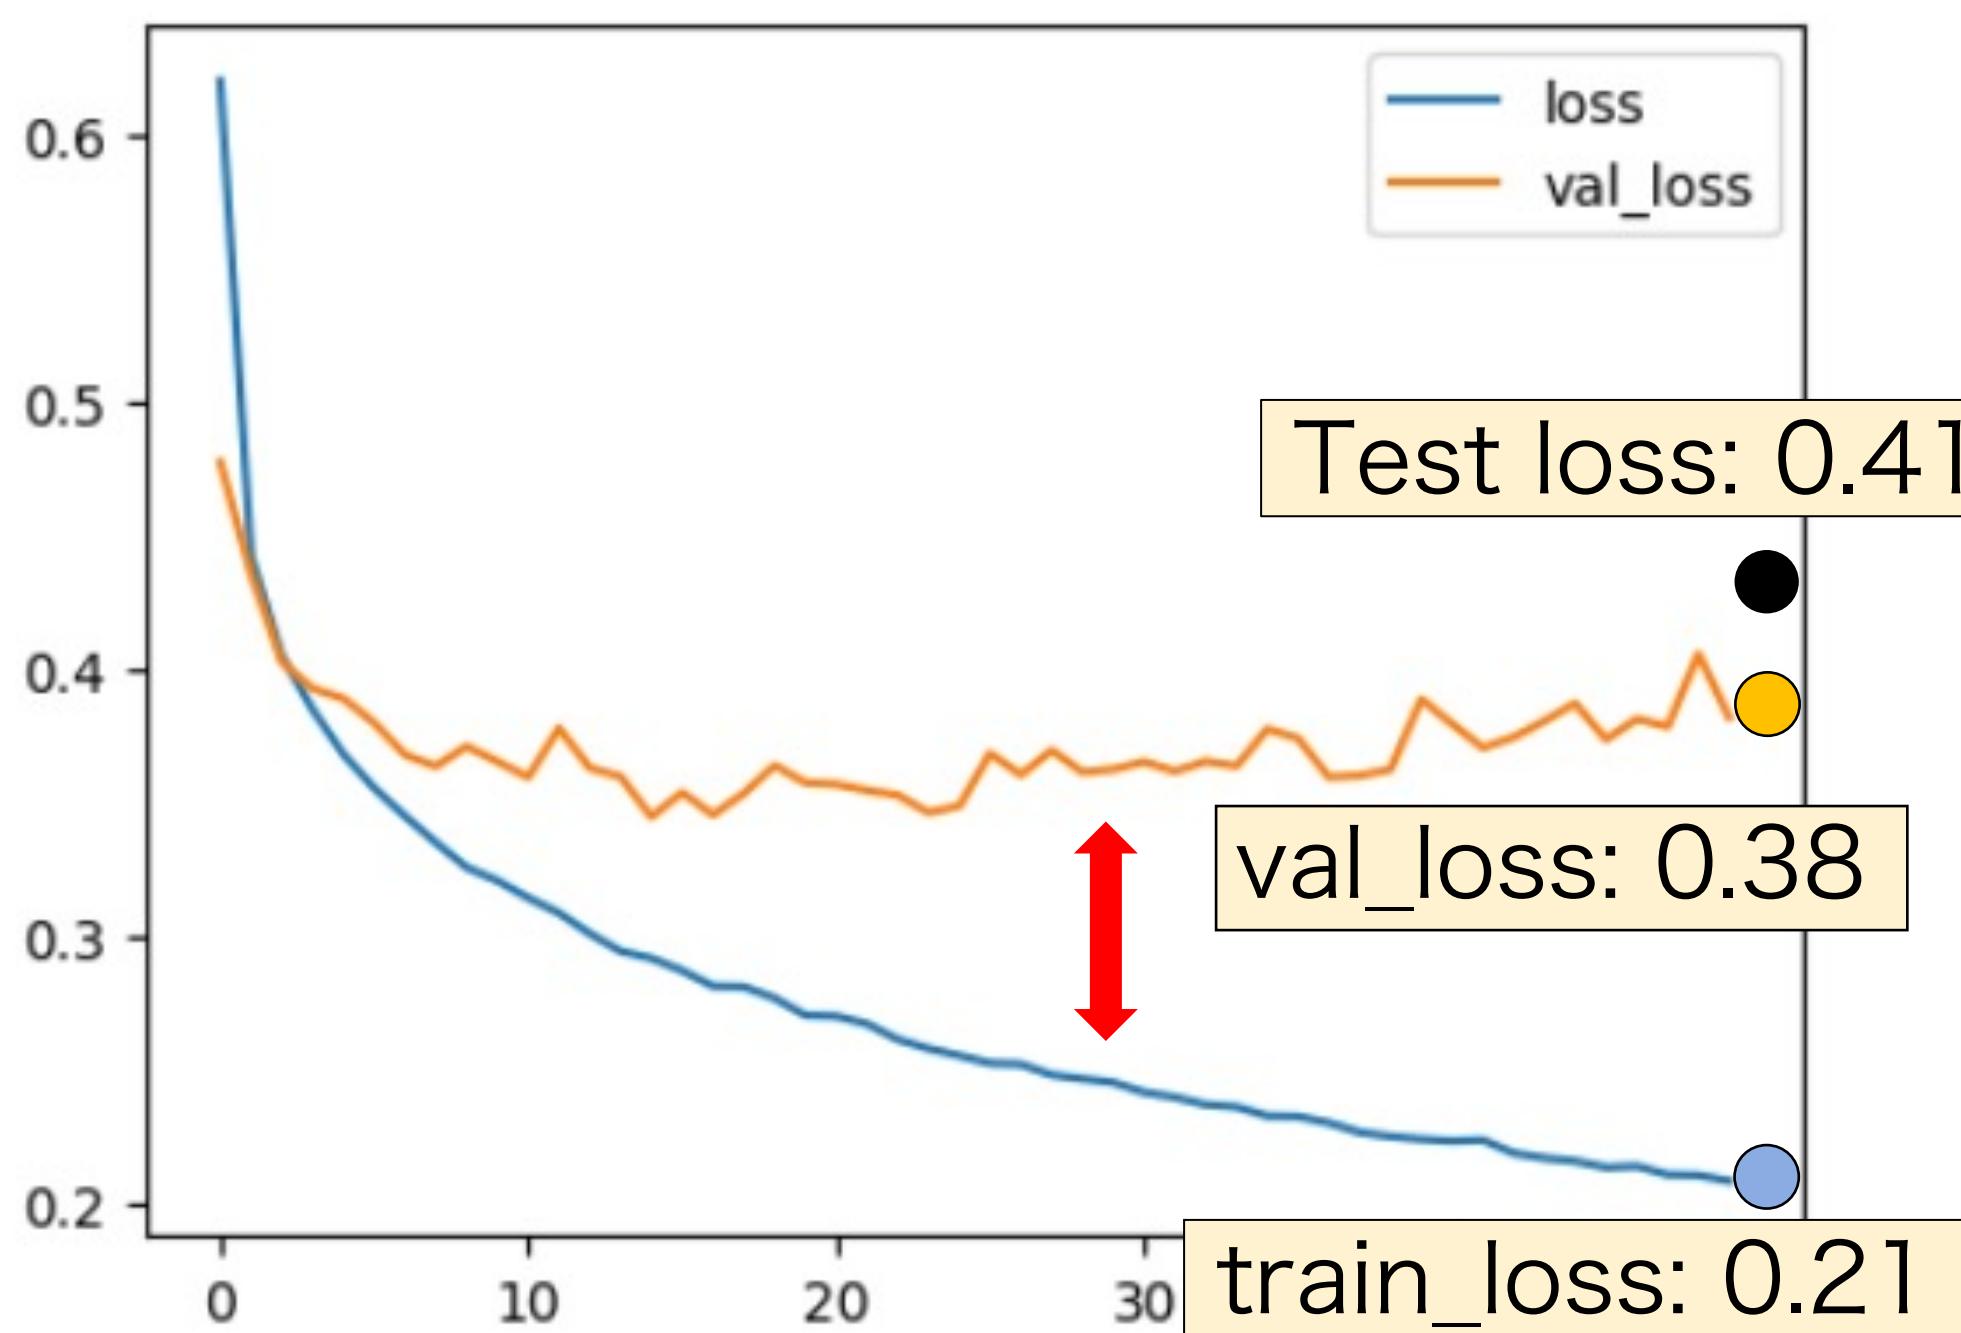
'loss': 0.2080526500940323,
'accuracy': 0.9248958230018616,

'val_loss': 0.3818448781967163,
'val_accuracy': 0.8801666498184204

結果の分析



trainはlossも小さくaccuracyも高いのに、valは精度が悪い (testも悪い)

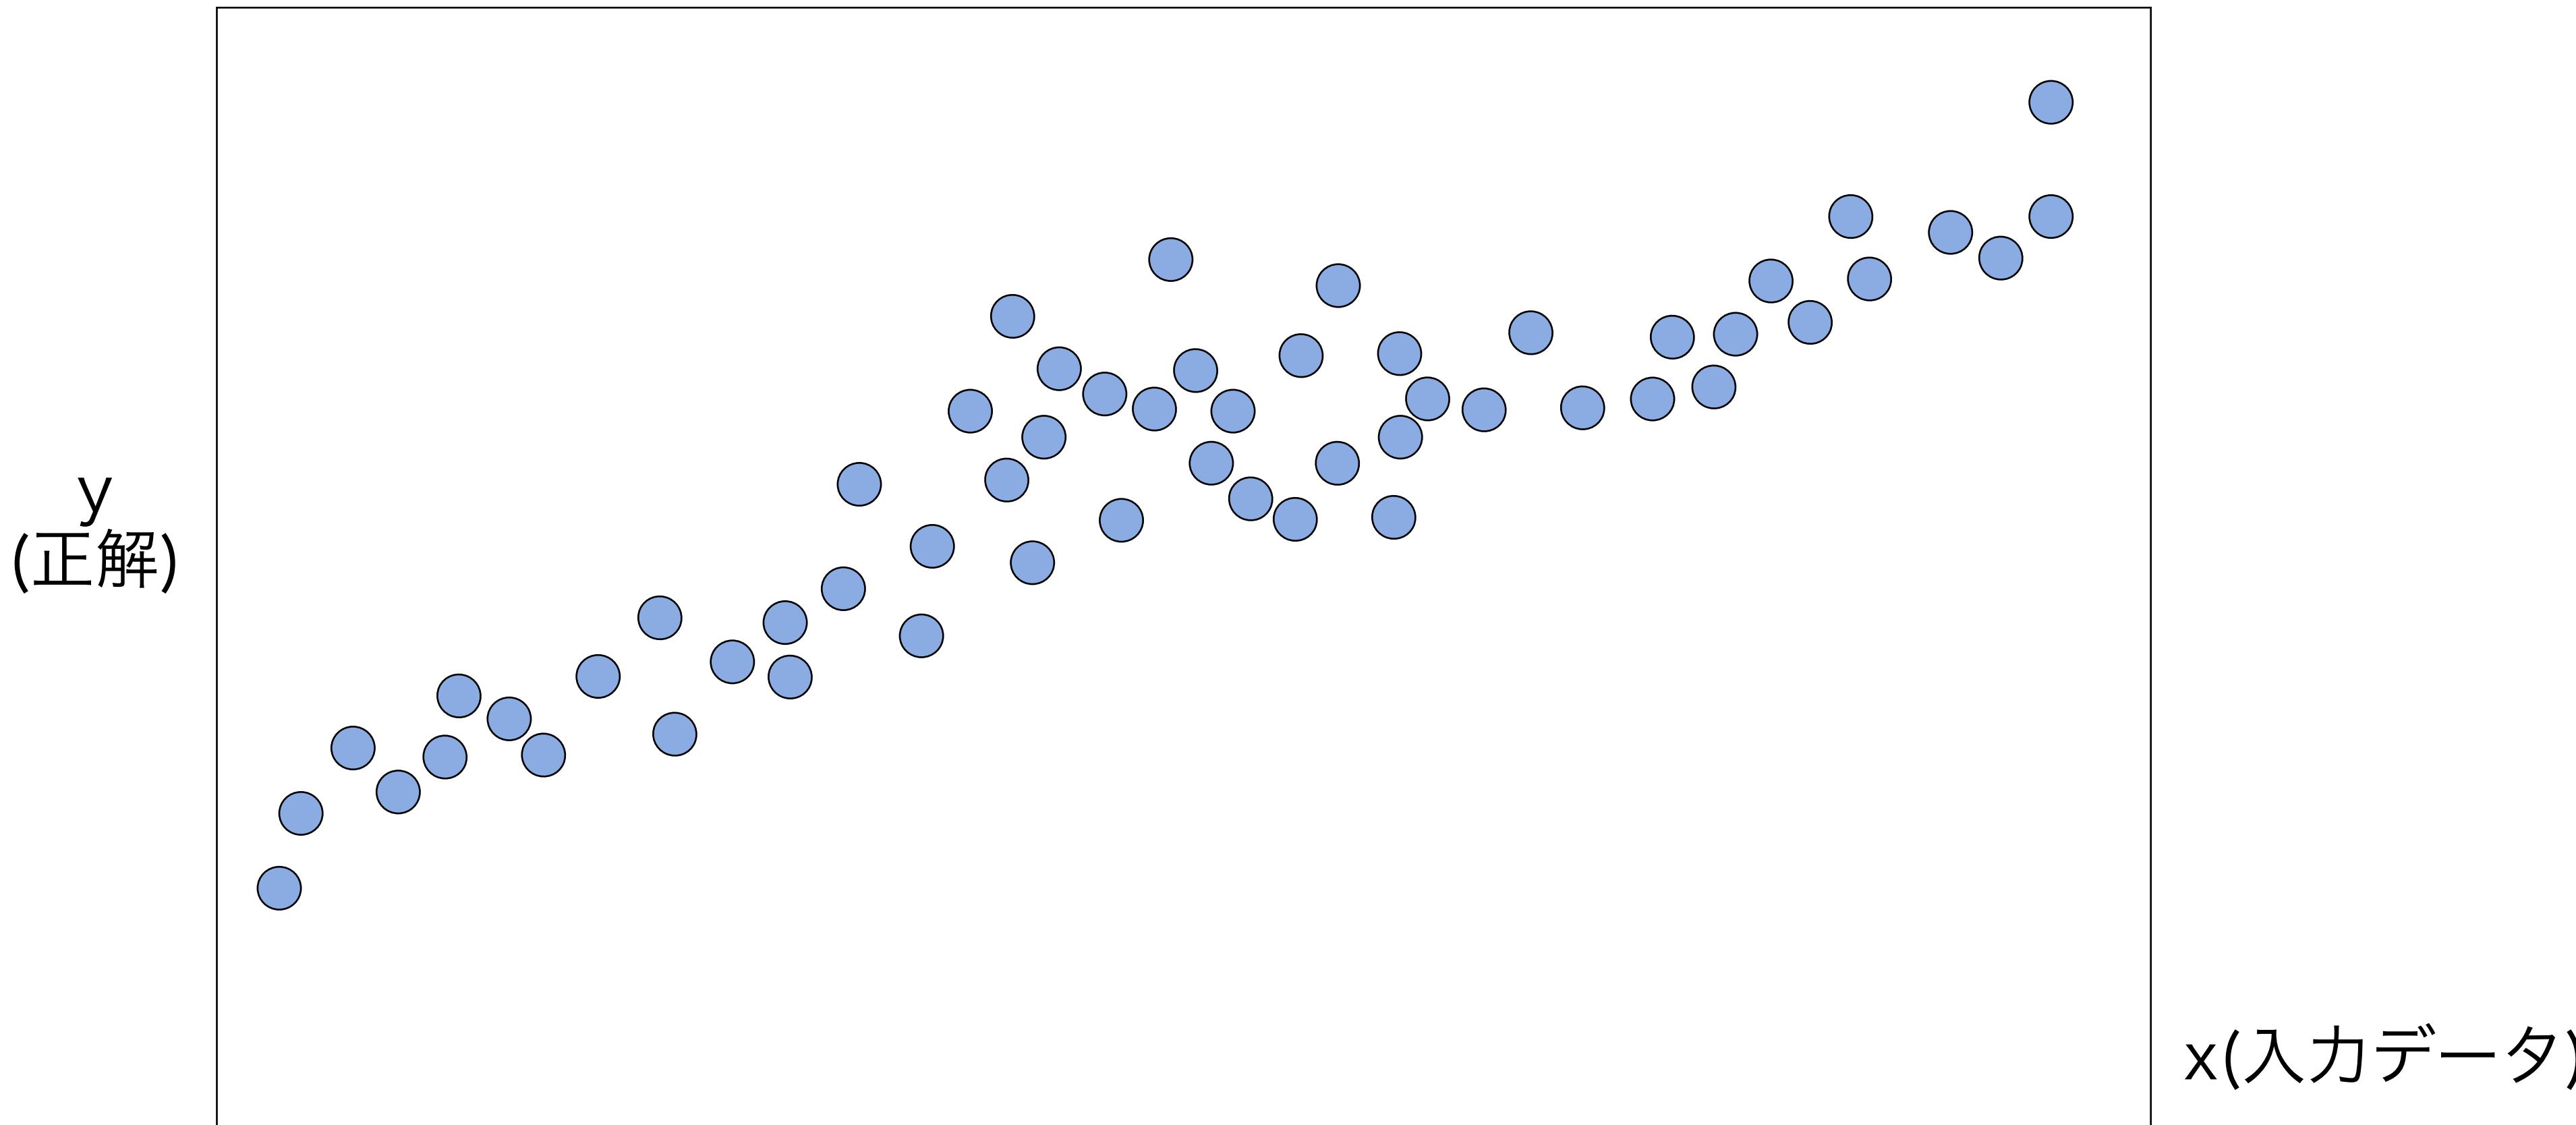


→ trainはうまく学習出来ているのに、valは出来ていない
→ trainのデータに合わせて学習し過ぎ

この状態を過学習と言う

学習のイメージ

学習はデータから当てはまりの良い関数(係数)を導く作業です



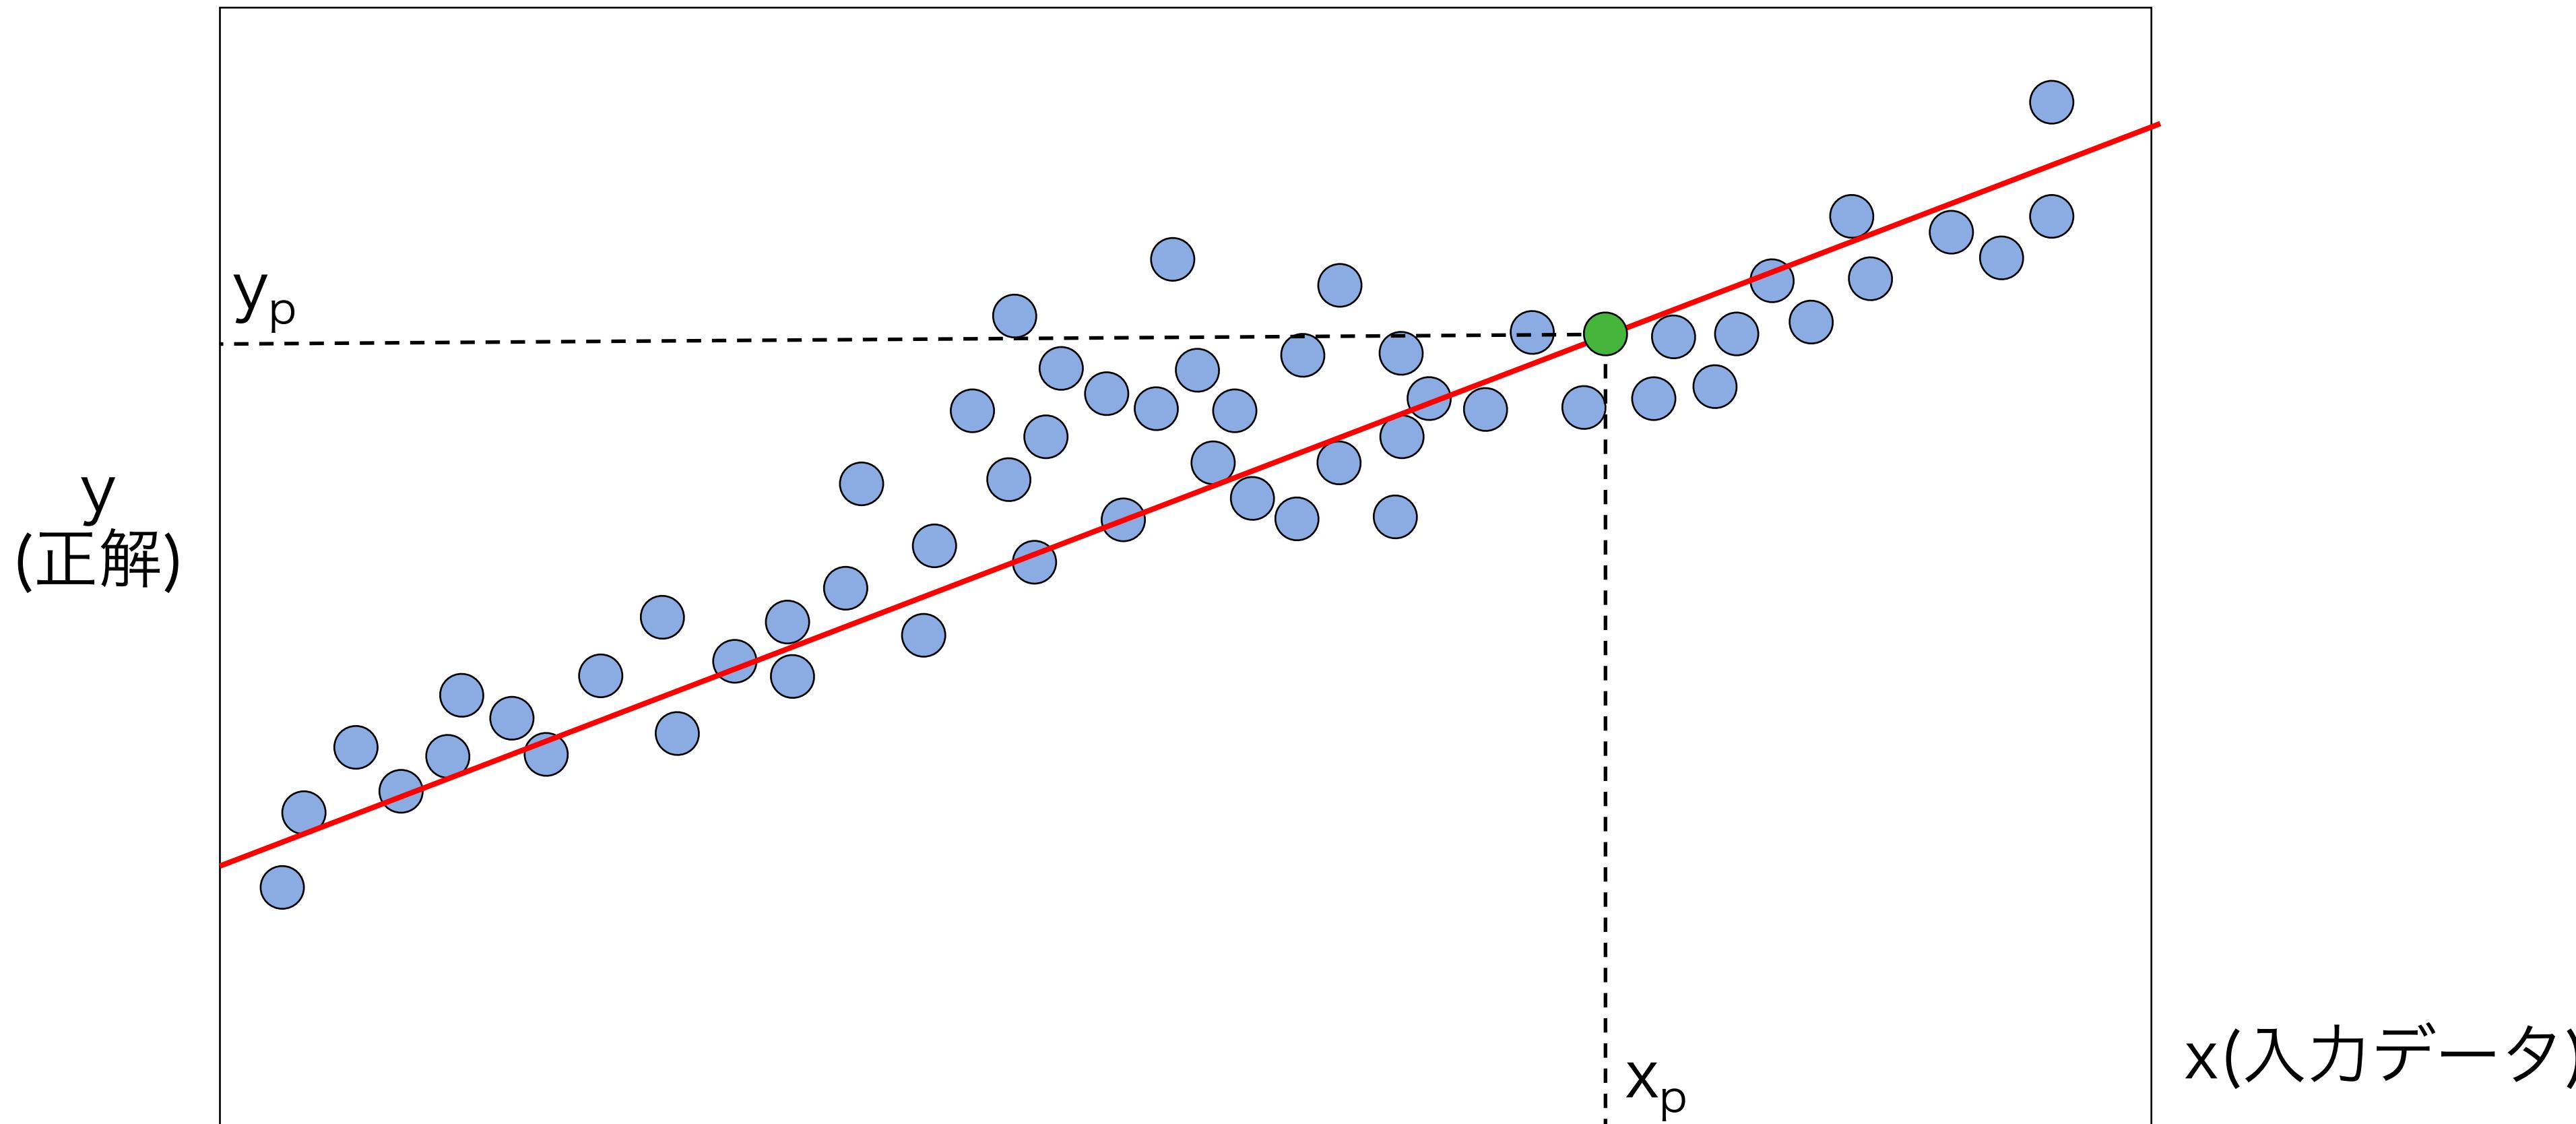
一番シンプルな線形回帰 $f_1(x)$ を想定します(x が増えると y が一定の割合で増える)

$$y = f_1(x) = a_1 x + a_2 \quad \text{となり、この } a_1 \text{ と } a_2 \text{を探します}$$

深層学習の w が a_1 、 b が a_2 に相当します

学習のイメージ

学習はデータから当てはまりの良い関数(係数)を導く作業です



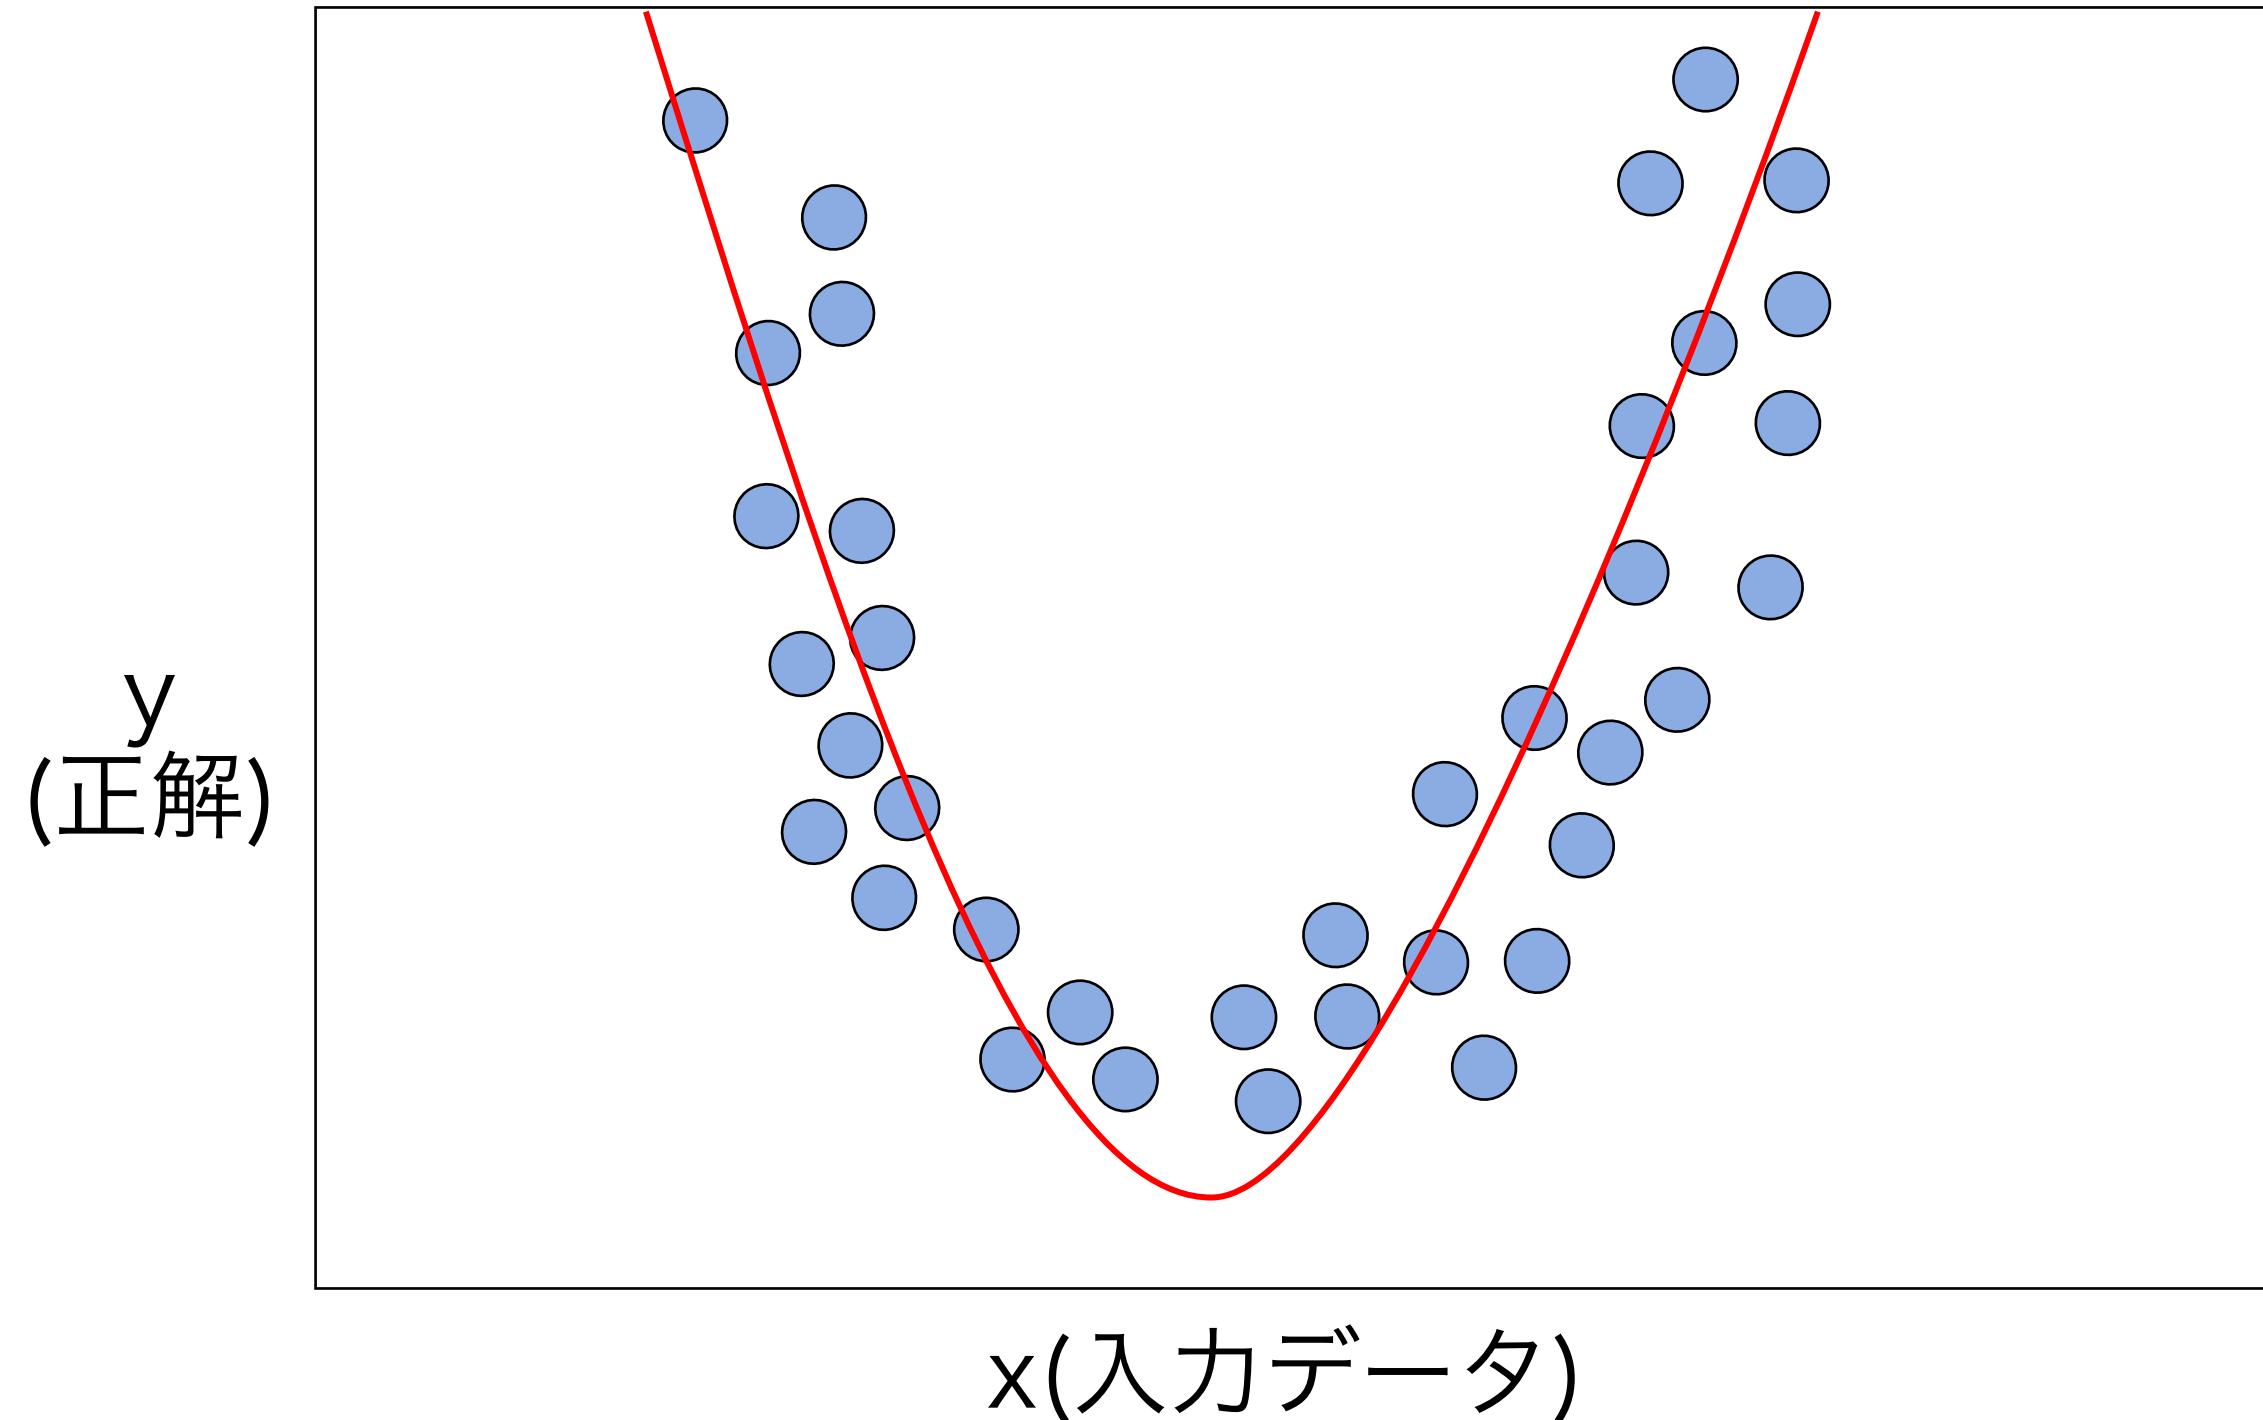
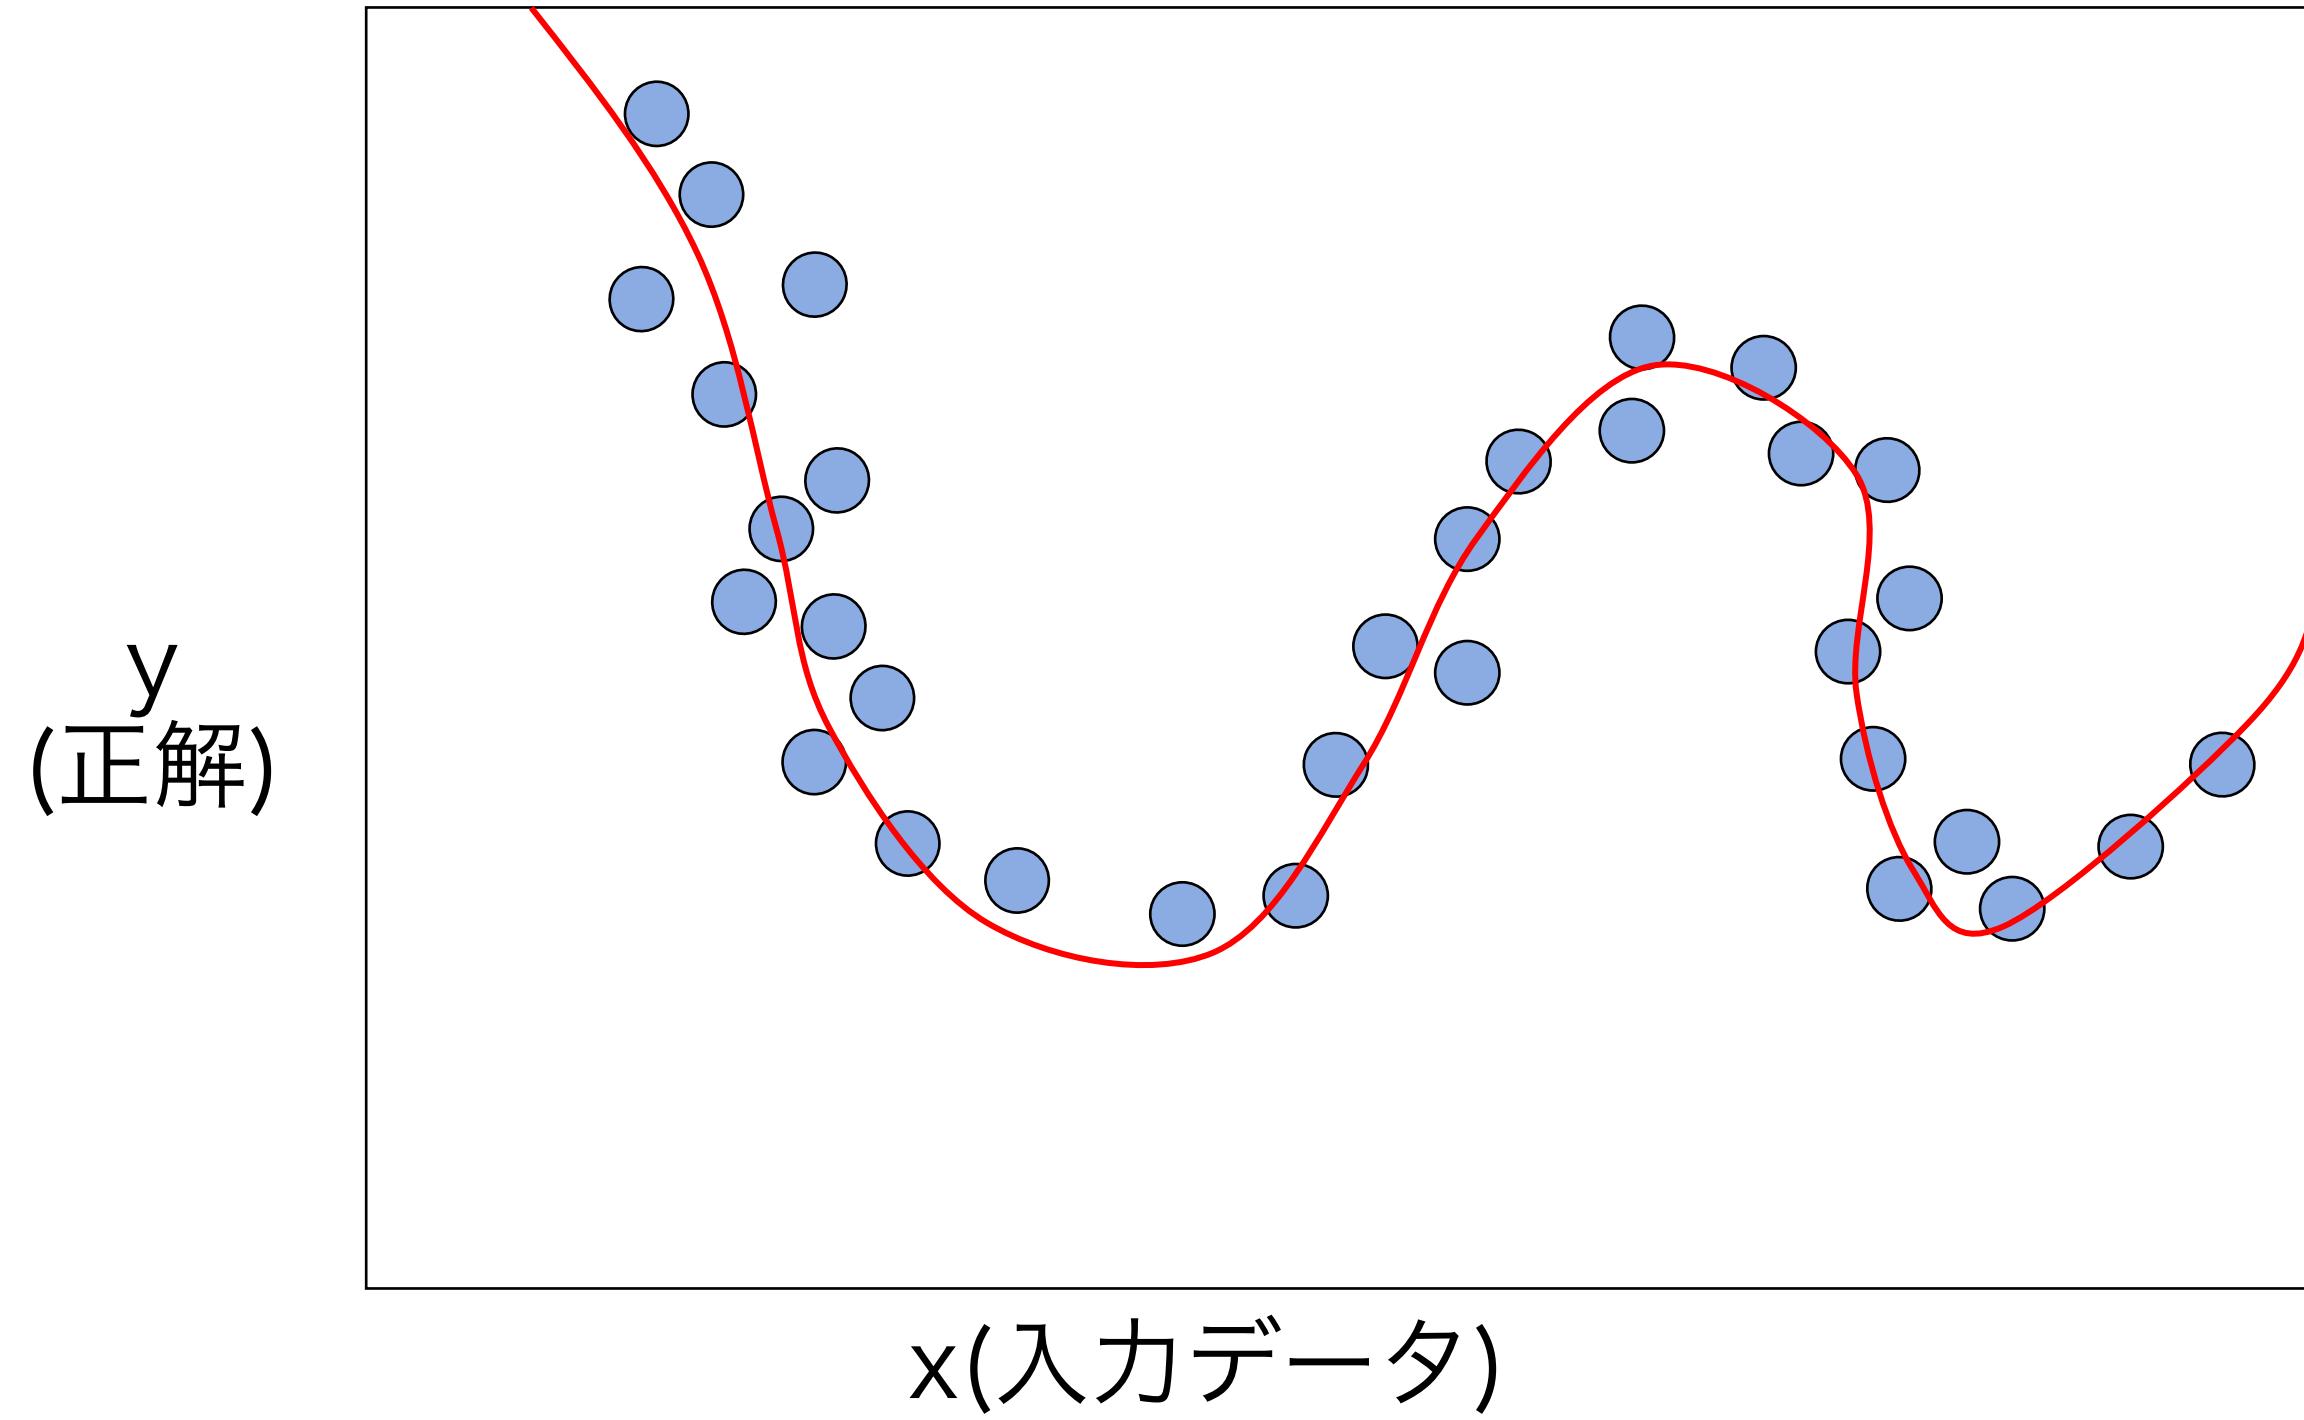
a_1 と a_2 が求まると、図のような直線が求まるので、

例えば x_p の時の予測結果 y_p は、

$$y_p = f(x_p) = a_1 x_p + a_2 \text{ で予測することができます}$$

学習のイメージ

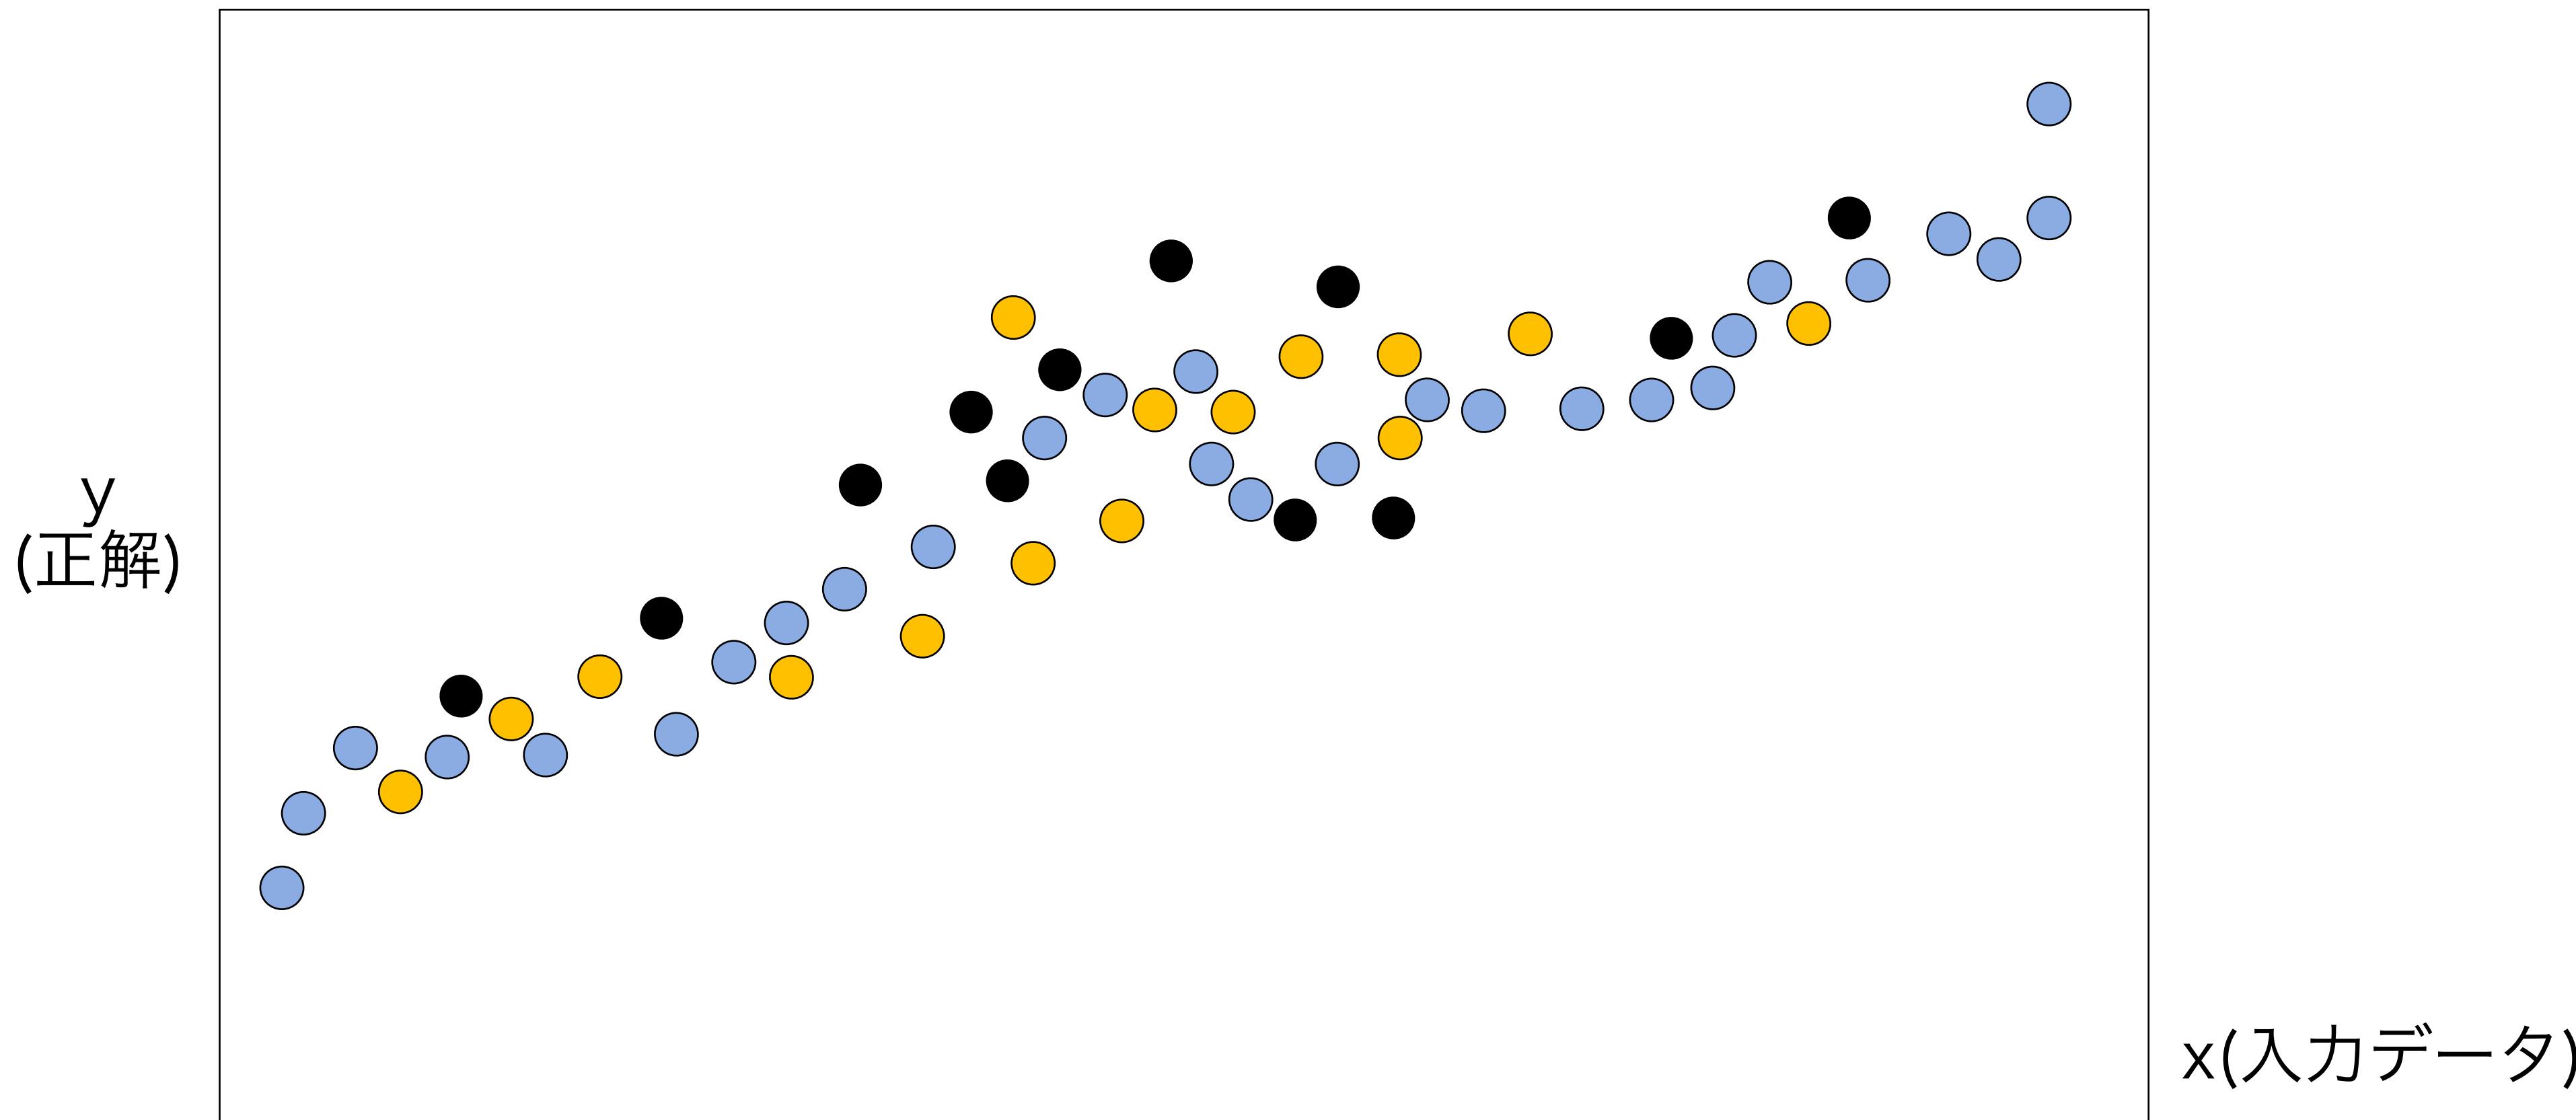
学習はデータから当てはまりの良い関数(係数)を導く作業です



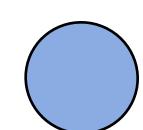
$y = a_1x + a_2$ では(どんな a_1 、 a_2 を与えても)直線にしかならない

曲線や3次元空間、4次元以上で表現出来るデータも適切な関数を設定すれば学習出来る

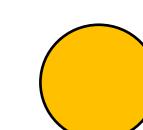
過学習のイメージ



仮に深層学習のデータをまとめて2次元で表したとする
(本当は高次元で作図が難しい)



学習用データ



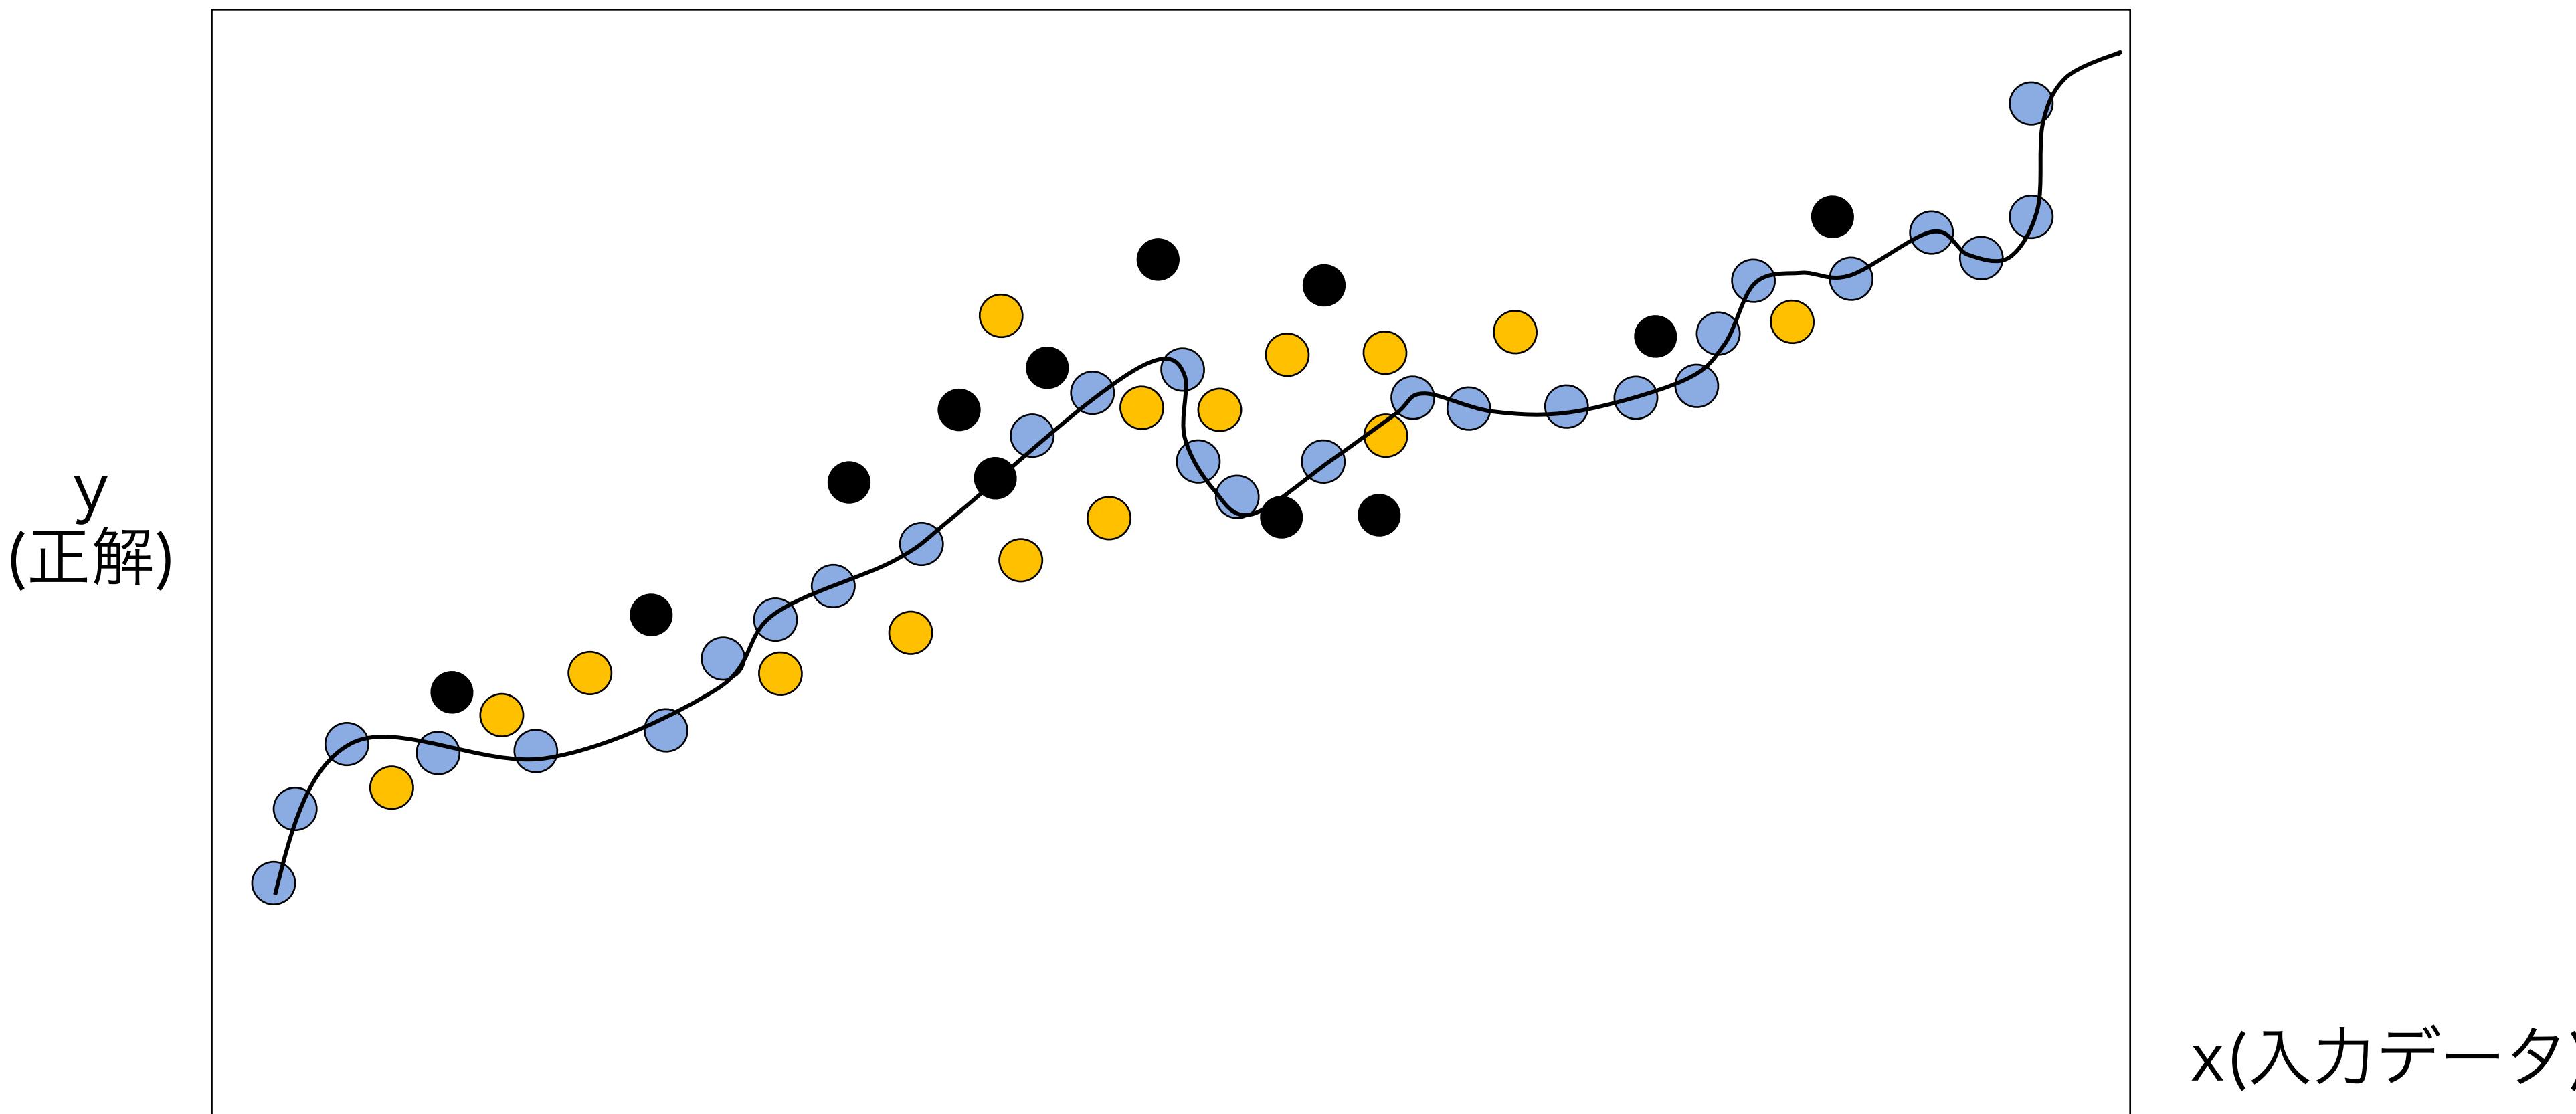
検証用データ



テスト用データ

過学習のイメージ

trainはlossも小さくaccuracyも高いのに、valは精度が悪い (testも悪い)



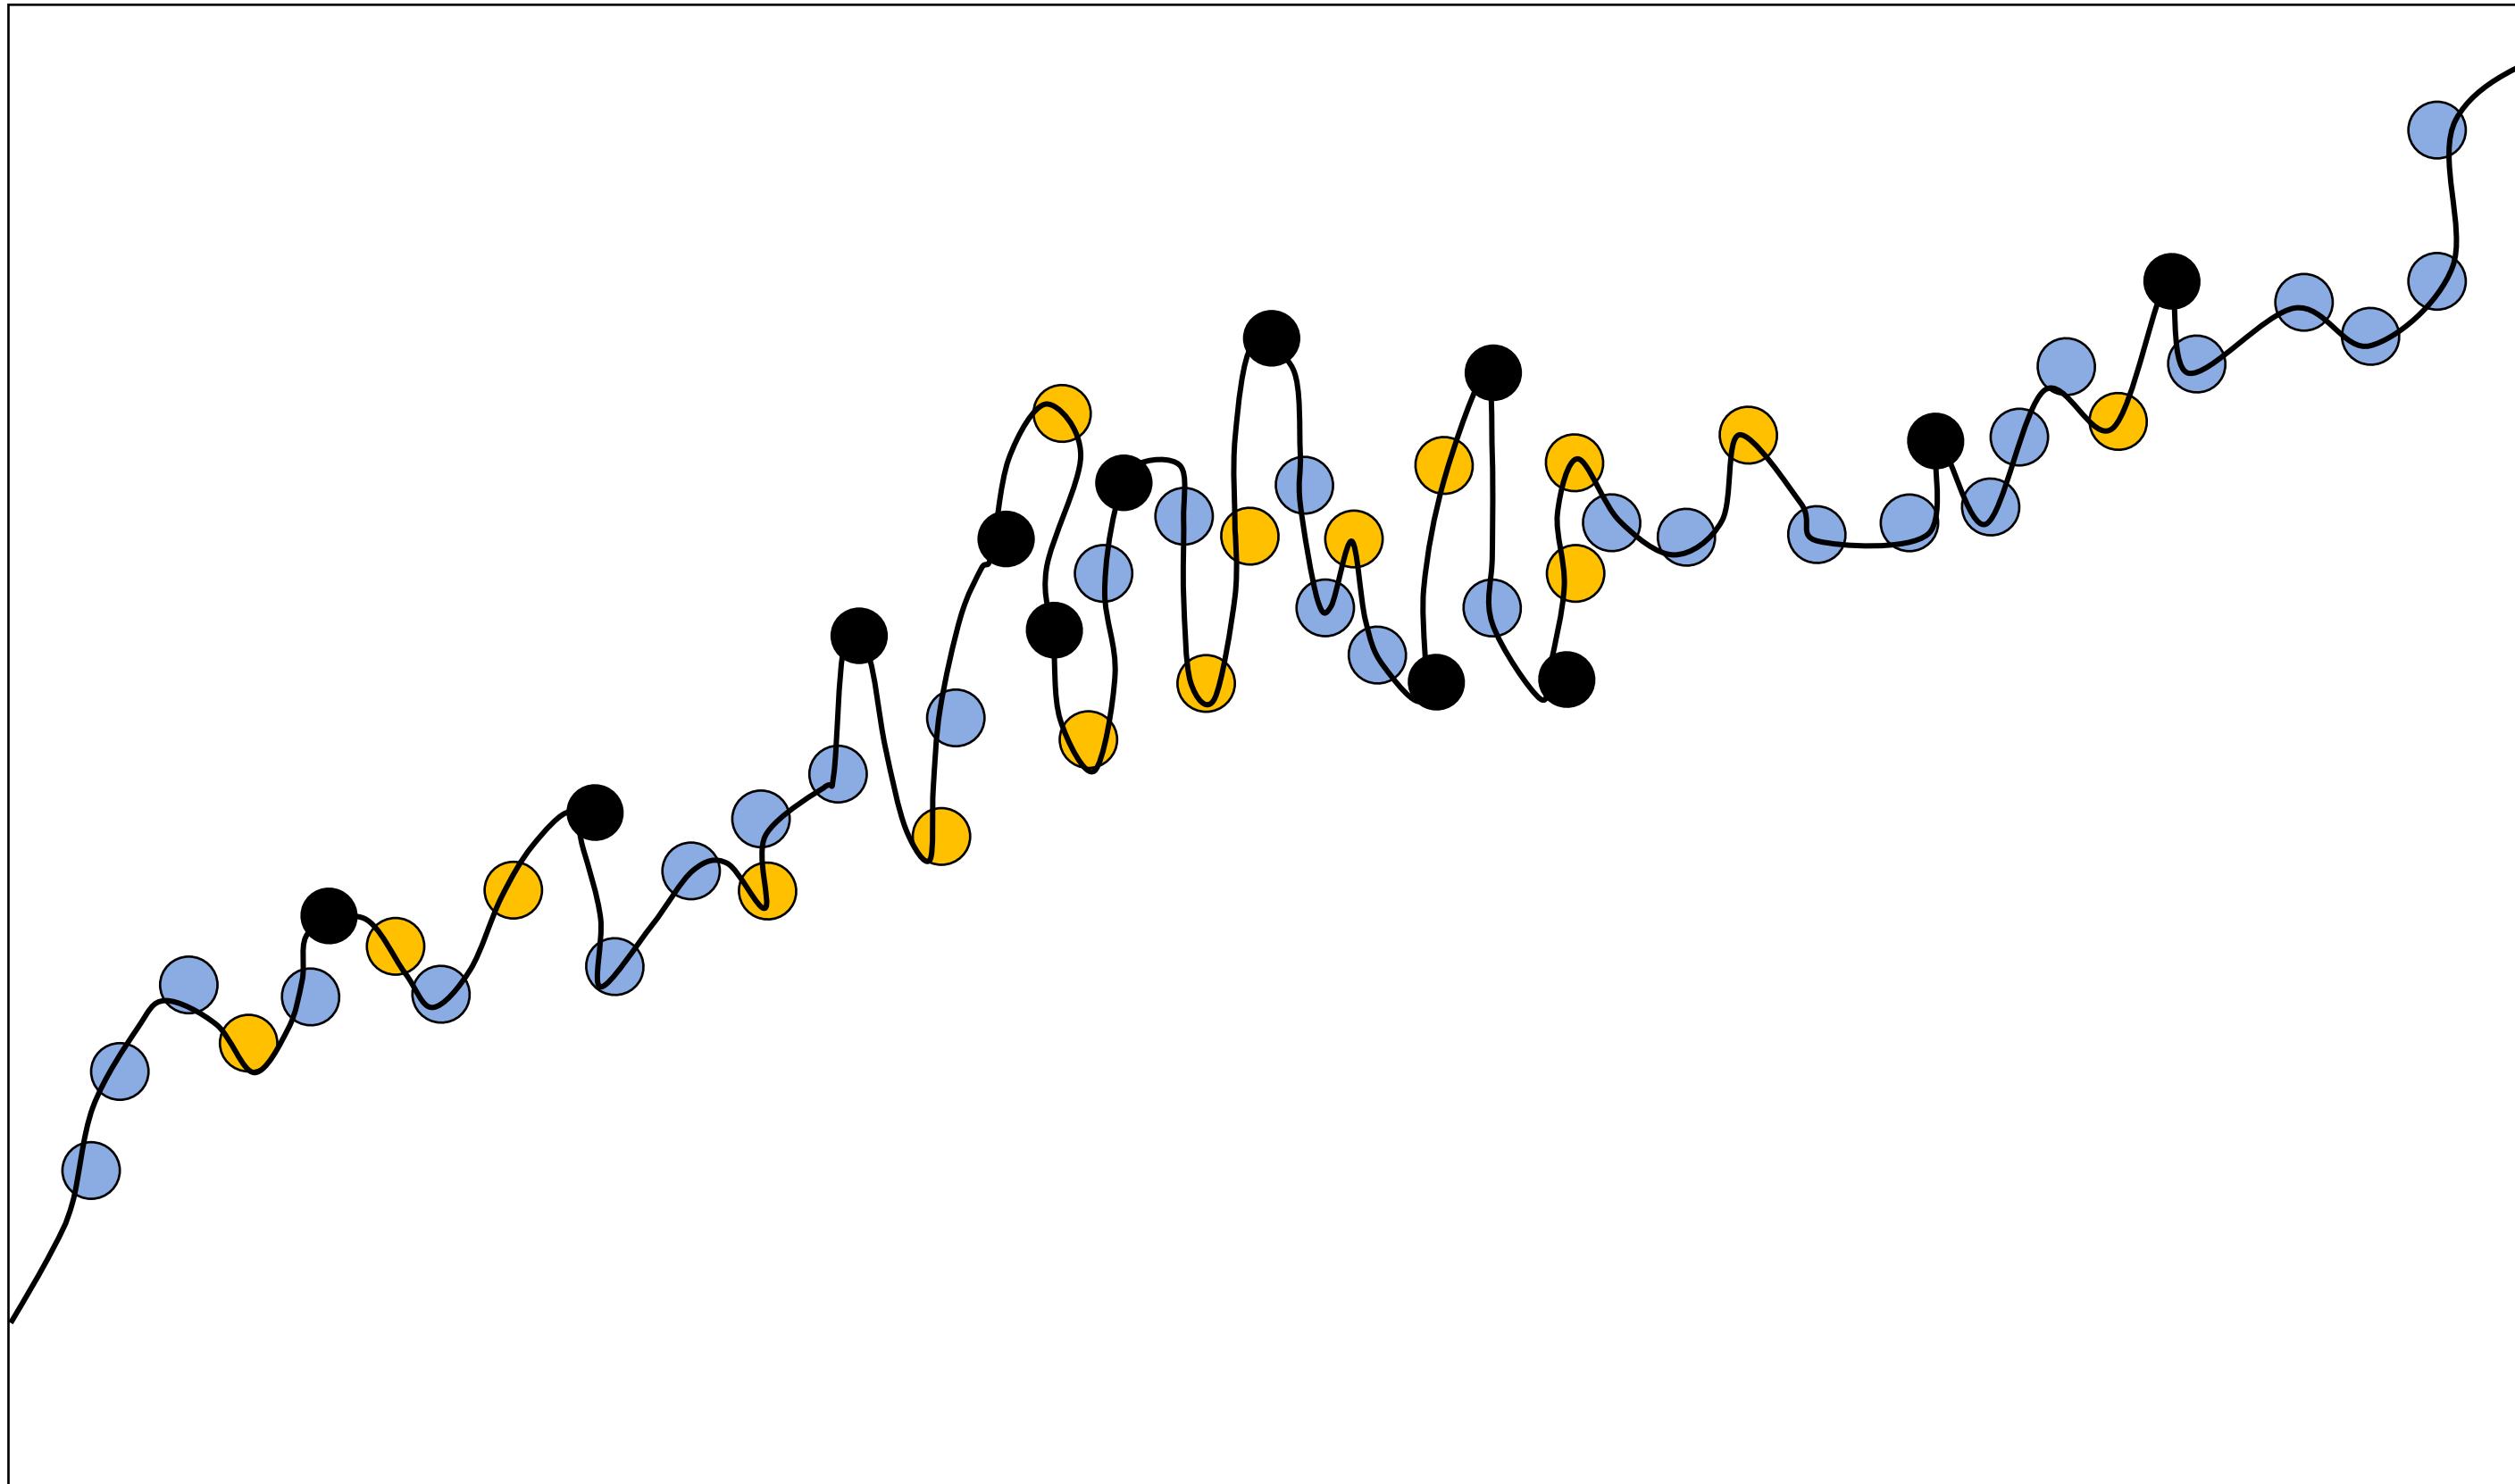
過学習はtrainのデータに合わせて学習し過ぎてしまった状態
この図だとtrainでは精度100%近いが、valやtestでは精度が落ちる

● 学習用データ

● 検証用データ

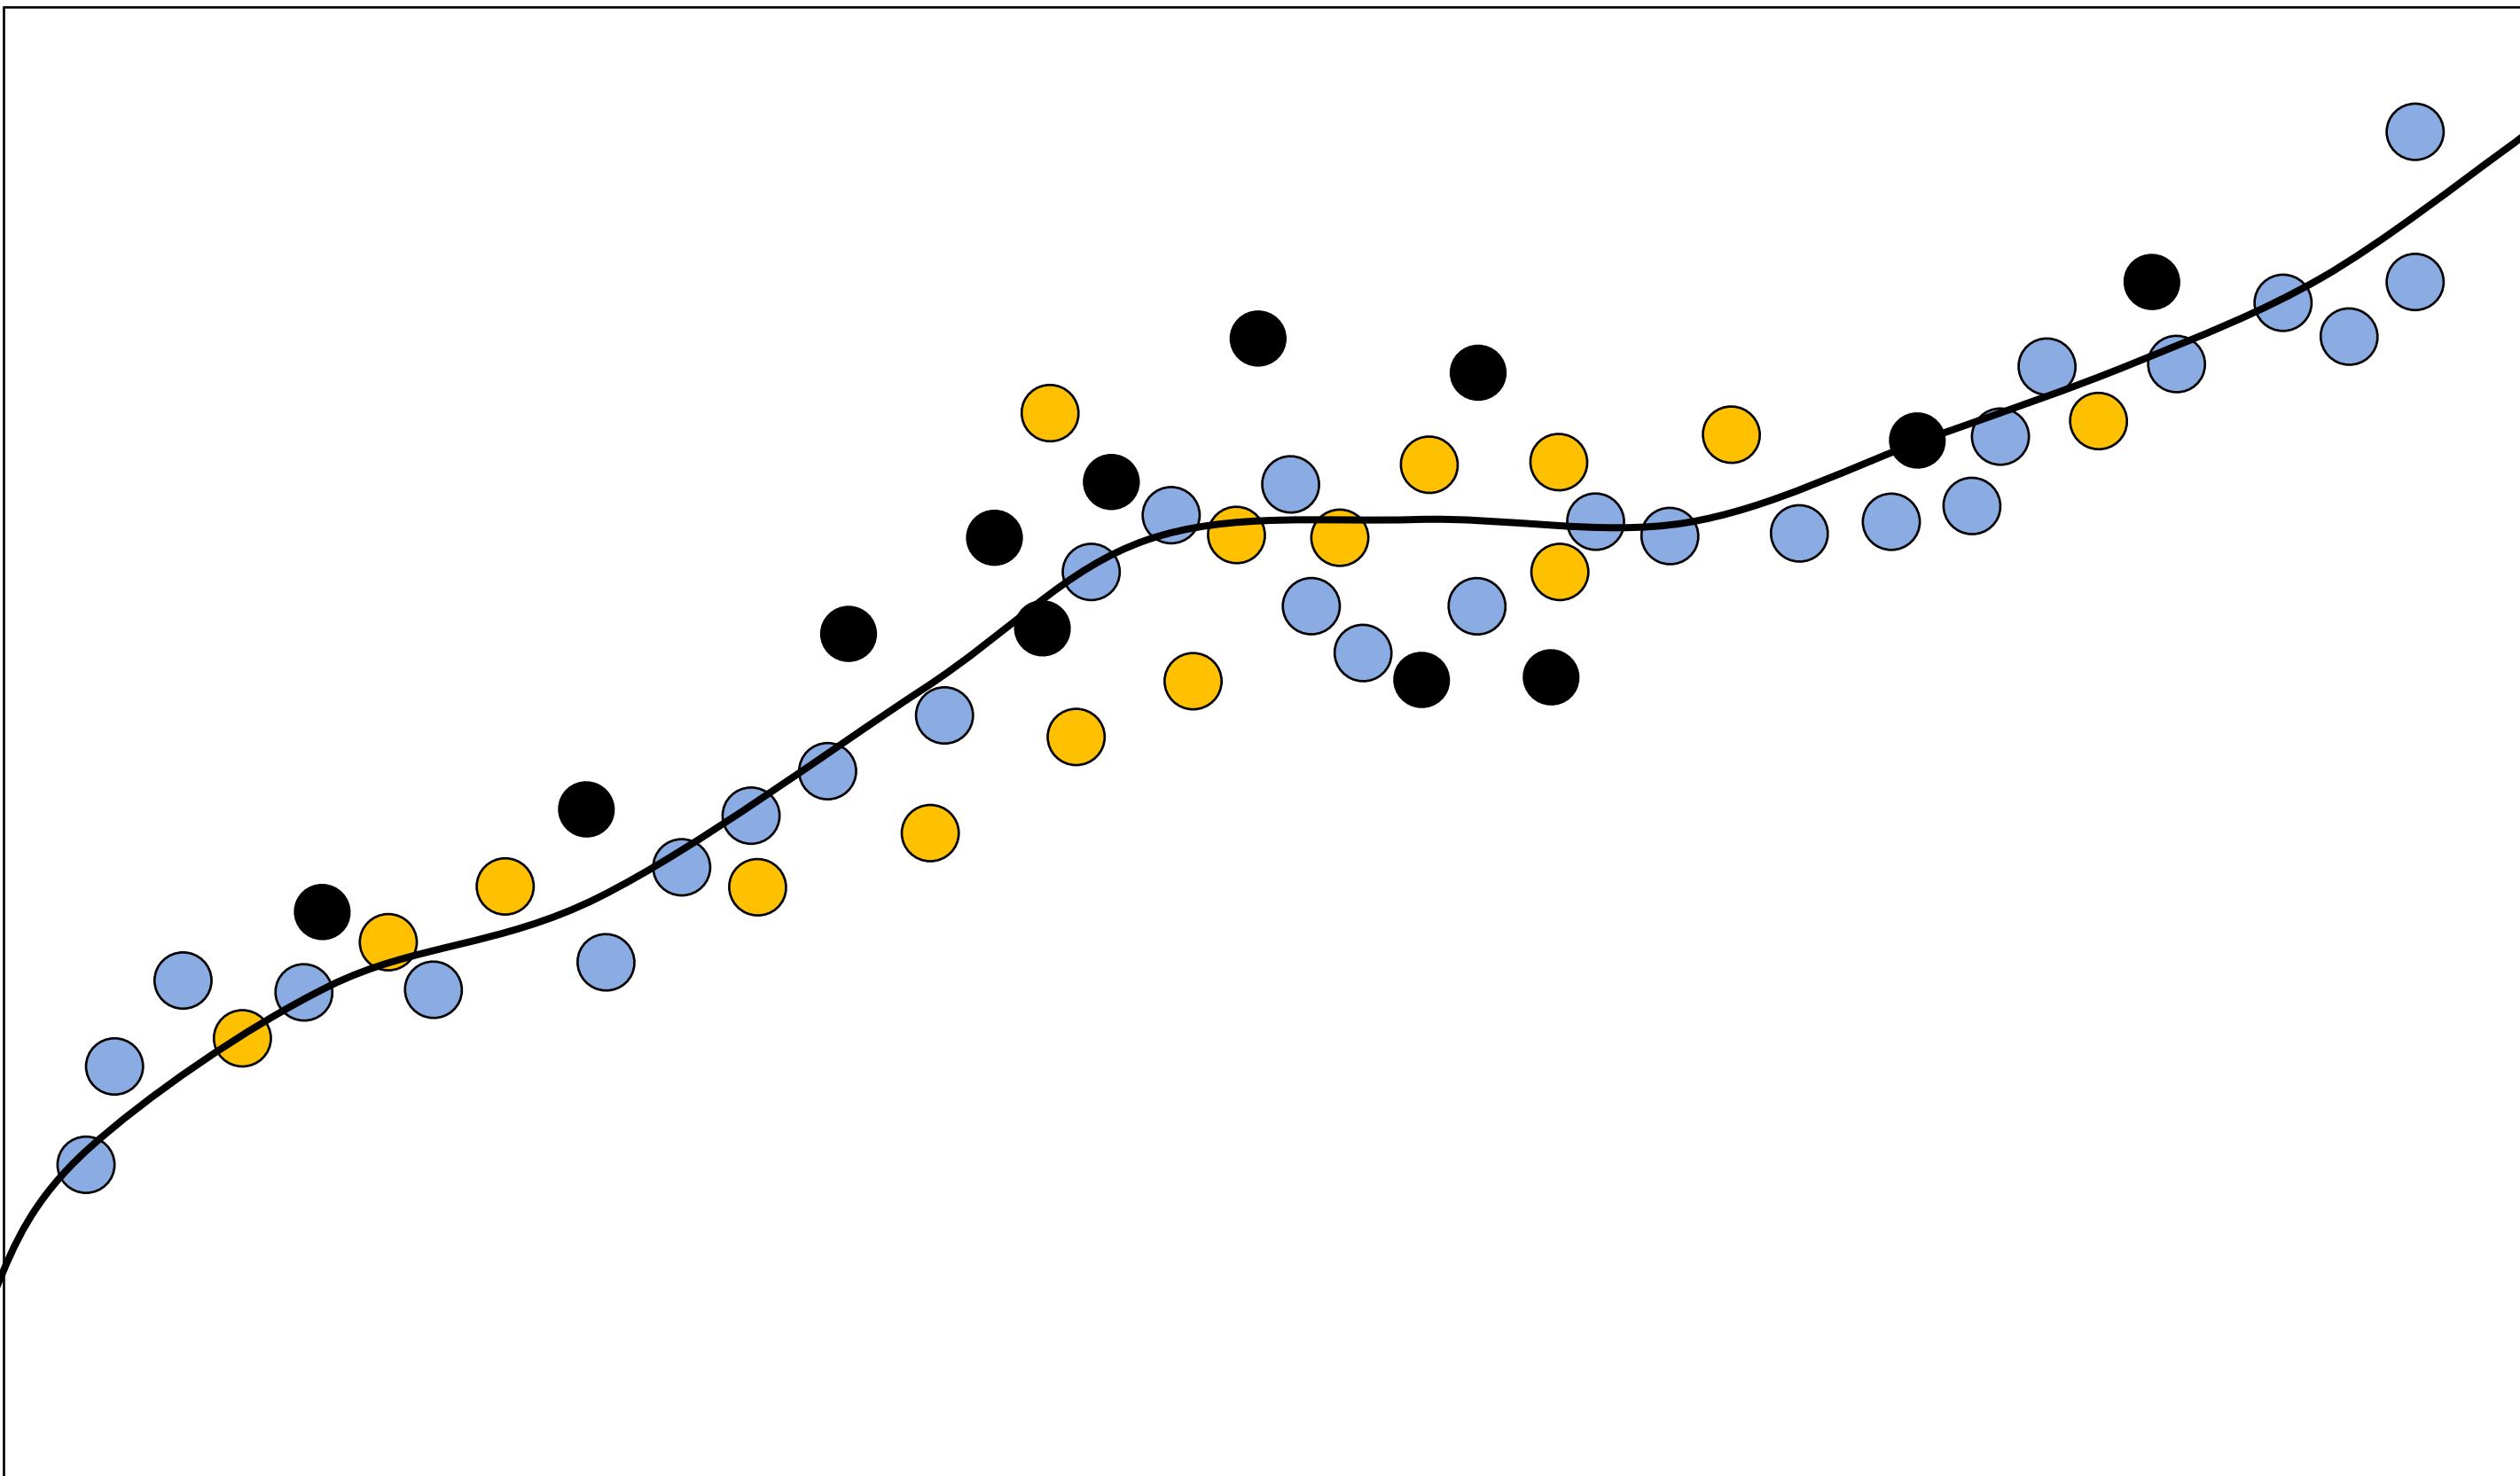
● テスト用データ

完全に適合しているイメージ



実際はこのようにはなりません

過学習のイメージ



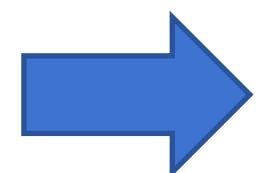
未知のデータでも精度が高くなるようなパラメータを探す作業

モデルの改変や学習用データに偏りがないかなど

ニューロンの数を増やす

```
model = Sequential()  
model.add(Dense(32,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

Layer (type)	Output Shape	Param #
dense_12 (Dense)	(None, 32)	25120
dense_13 (Dense)	(None, 10)	330
Total params: 25,450		
Trainable params: 25,450		
Non-trainable params: 0		



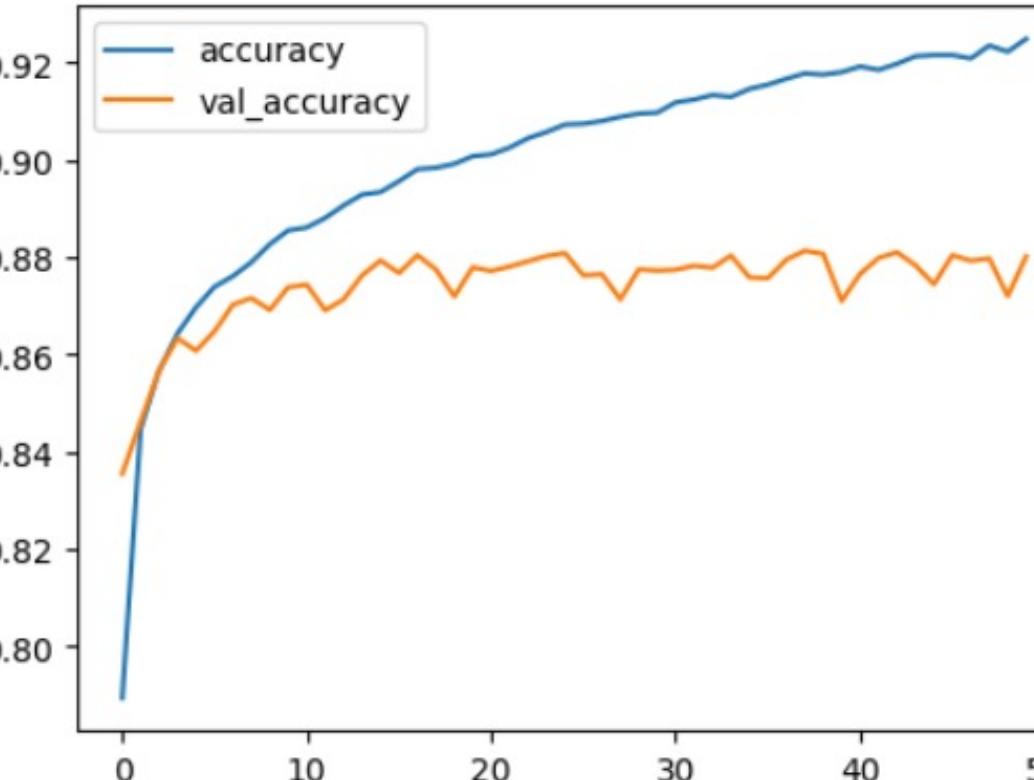
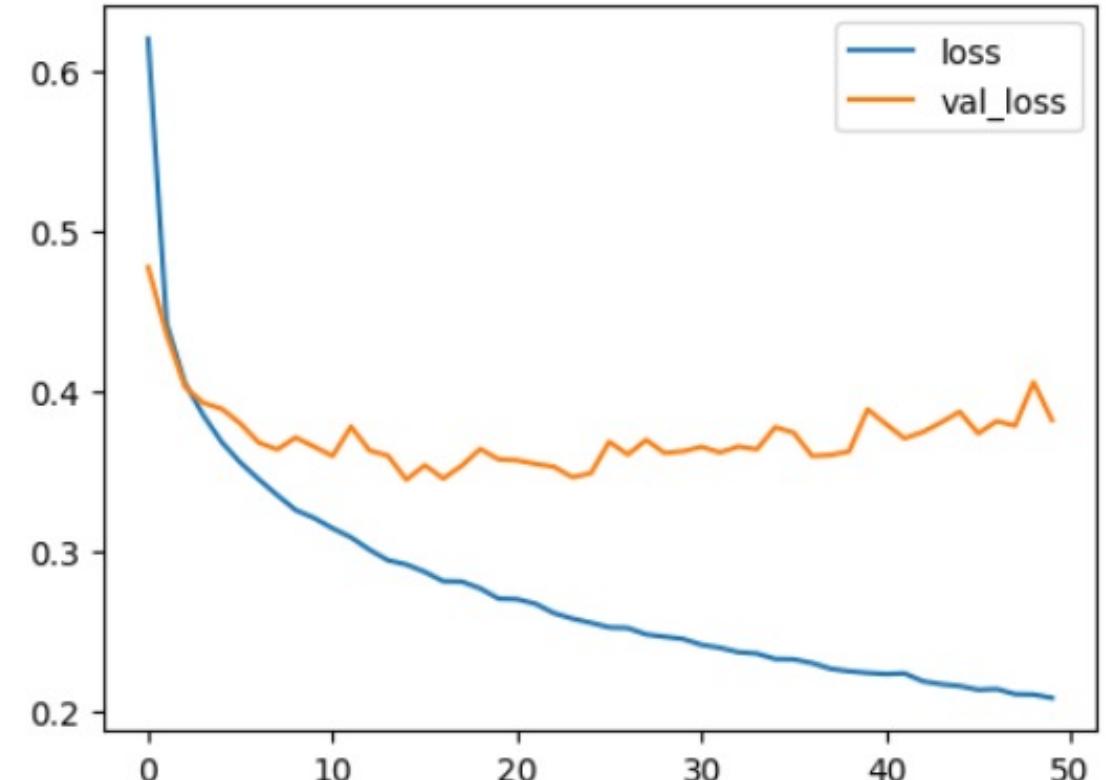
```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

Layer (type)	Output Shape	Param #
dense_8 (Dense)	(None, 128)	100480
dense_9 (Dense)	(None, 10)	1290
Total params: 101,770		
Trainable params: 101,770		
Non-trainable params: 0		

ニューロンの数を増やす

```
model = Sequential()  
model.add(Dense(32,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

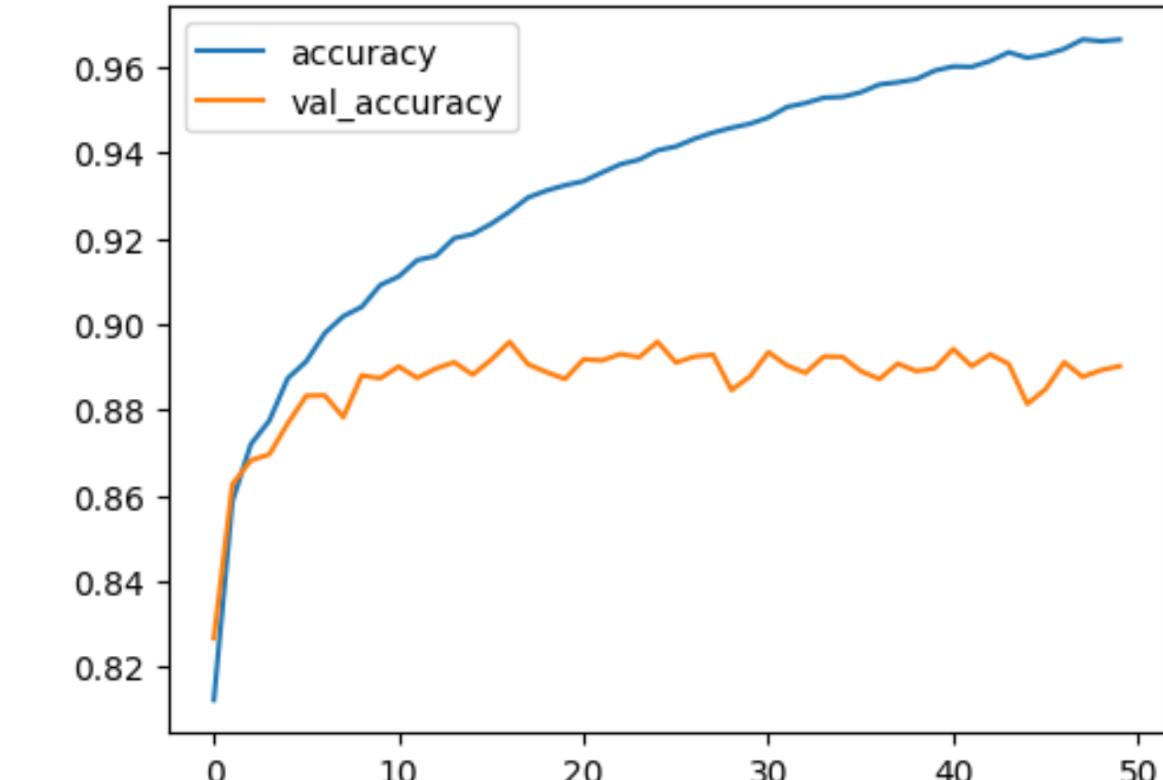
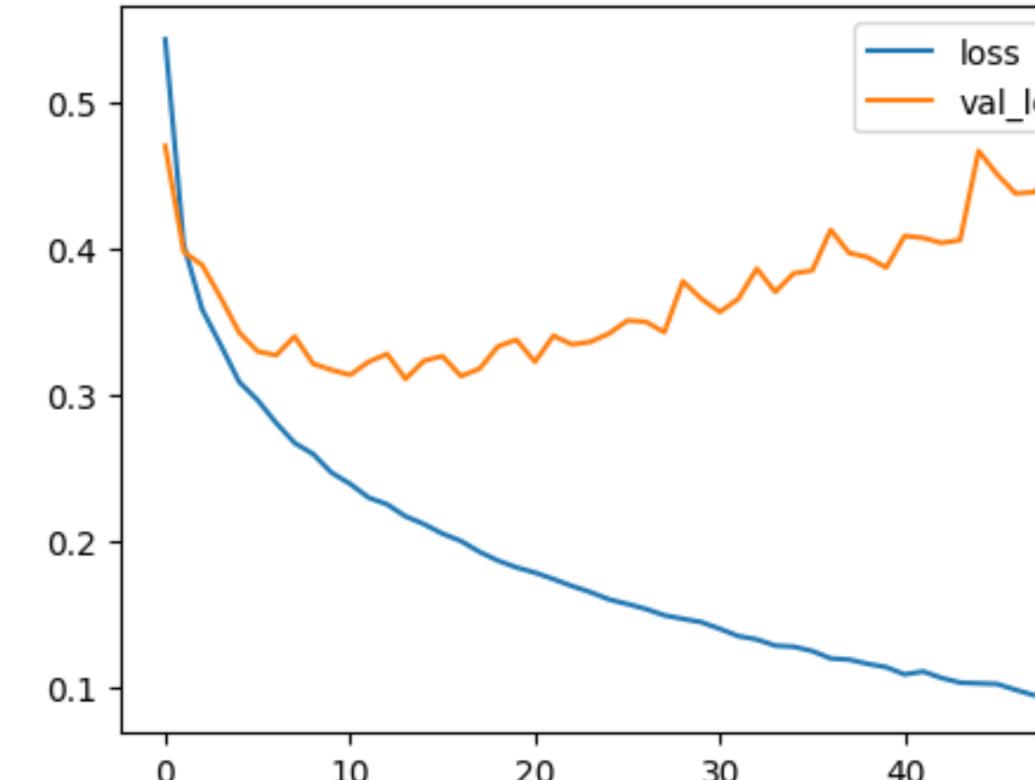
Layer (type)	Output Shape	Param #
dense_12 (Dense)	(None, 32)	25120
dense_13 (Dense)	(None, 10)	330
Total params:	25,450	
Trainable params:	25,450	
Non-trainable params:	0	



Test loss: 0.40565115213394165
Test accuracy: 0.8694000244140625

```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

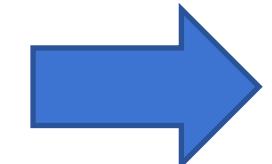
Layer (type)	Output Shape	Param #
dense_8 (Dense)	(None, 128)	100480
dense_9 (Dense)	(None, 10)	1290
Total params:	101,770	
Trainable params:	101,770	
Non-trainable params:	0	



Test loss: 0.4939178228378296
Test accuracy: 0.885200023651123

層を追加してみよう

```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

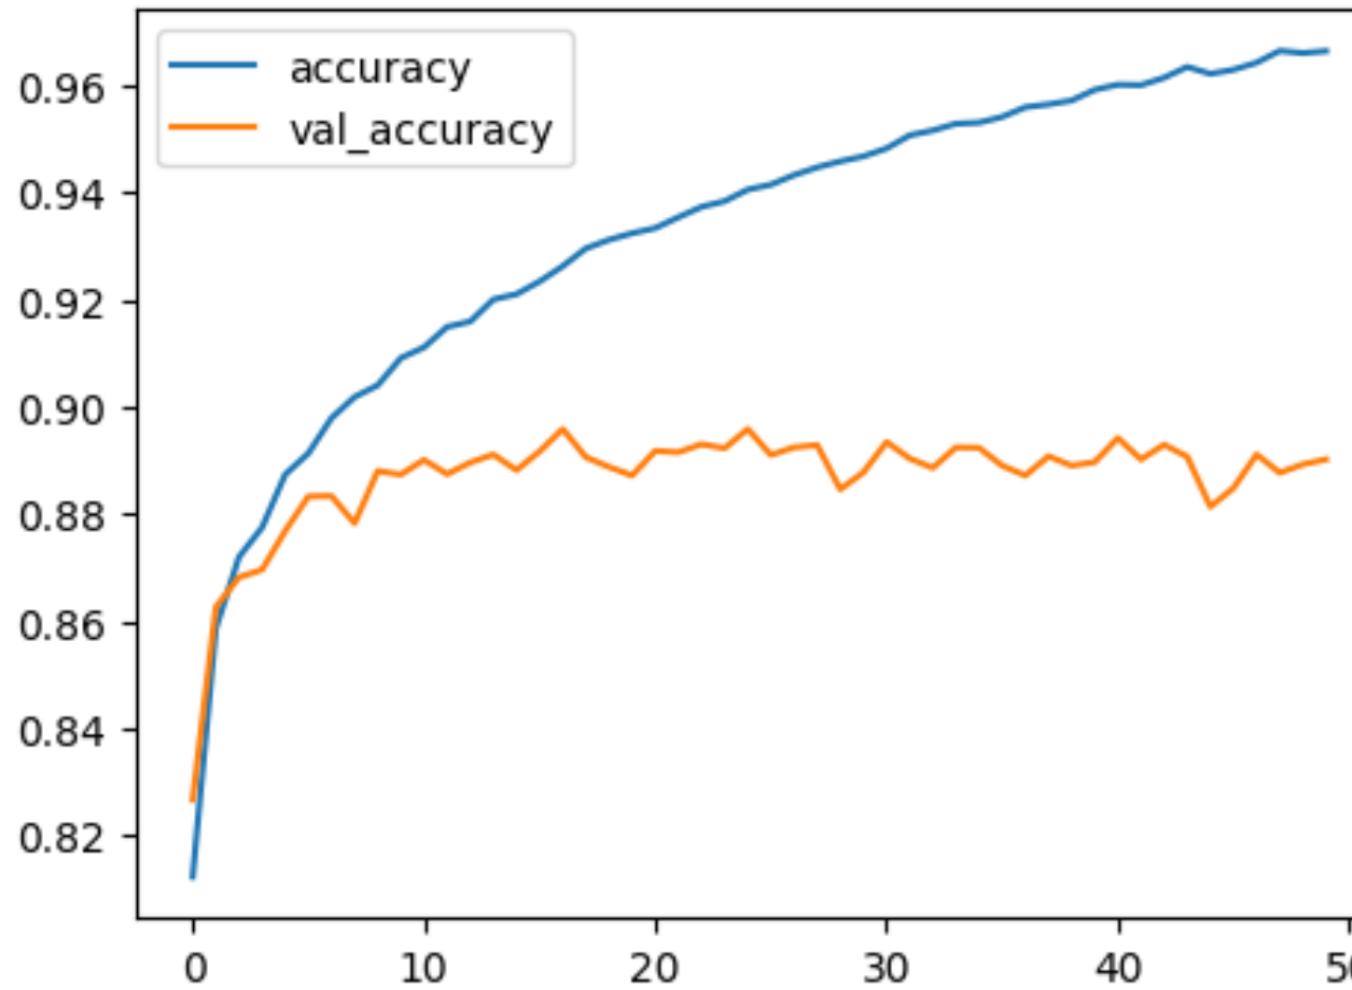
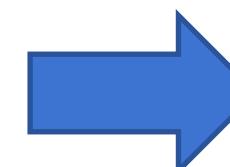
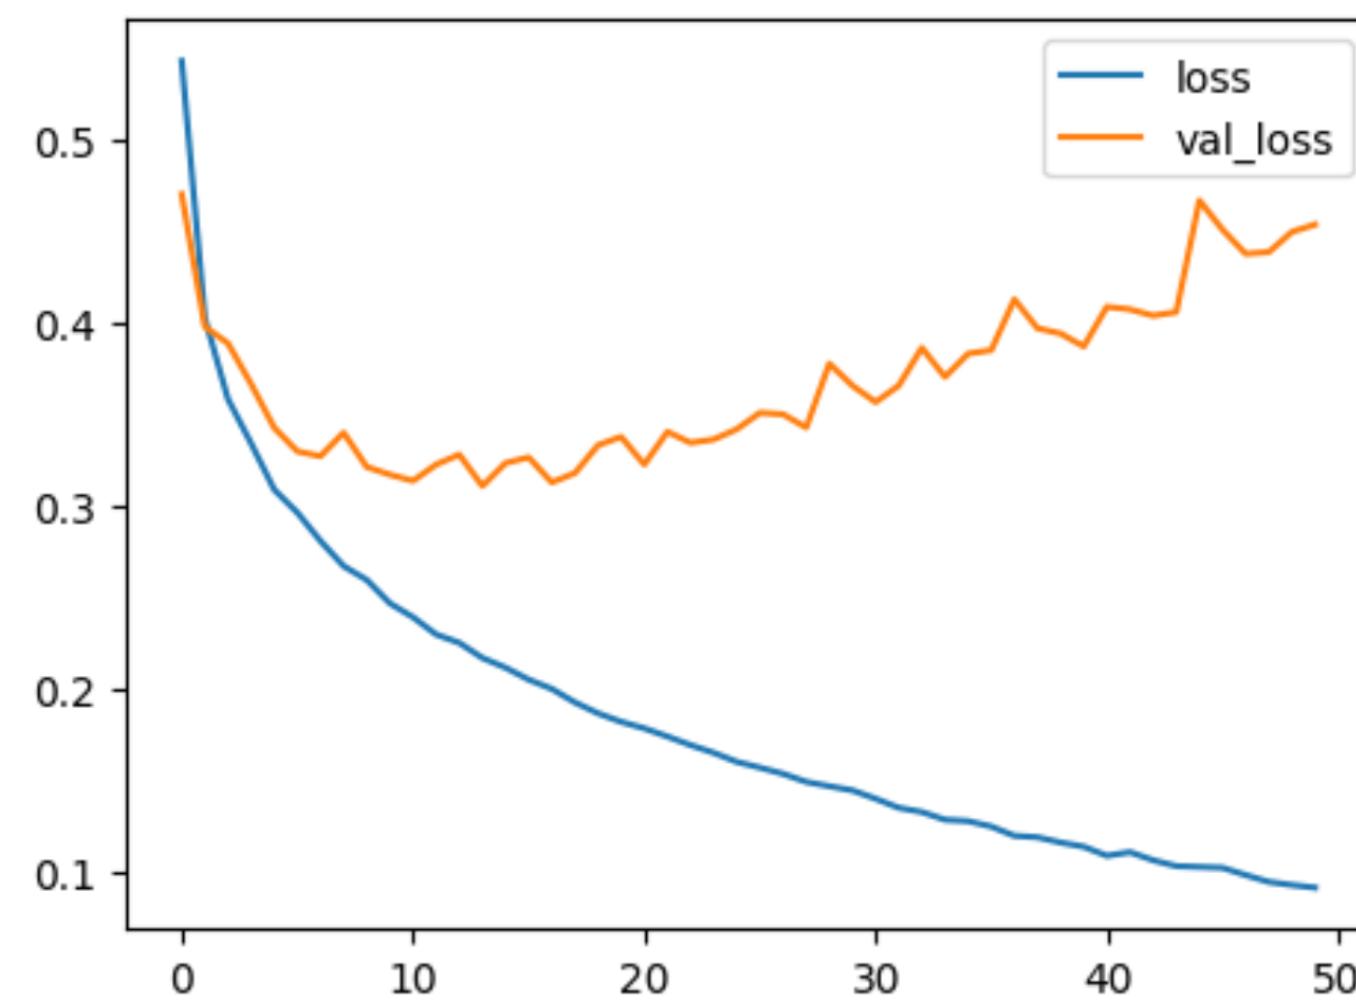


```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(64,activation='relu'))  
model.add(Dense(32,activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

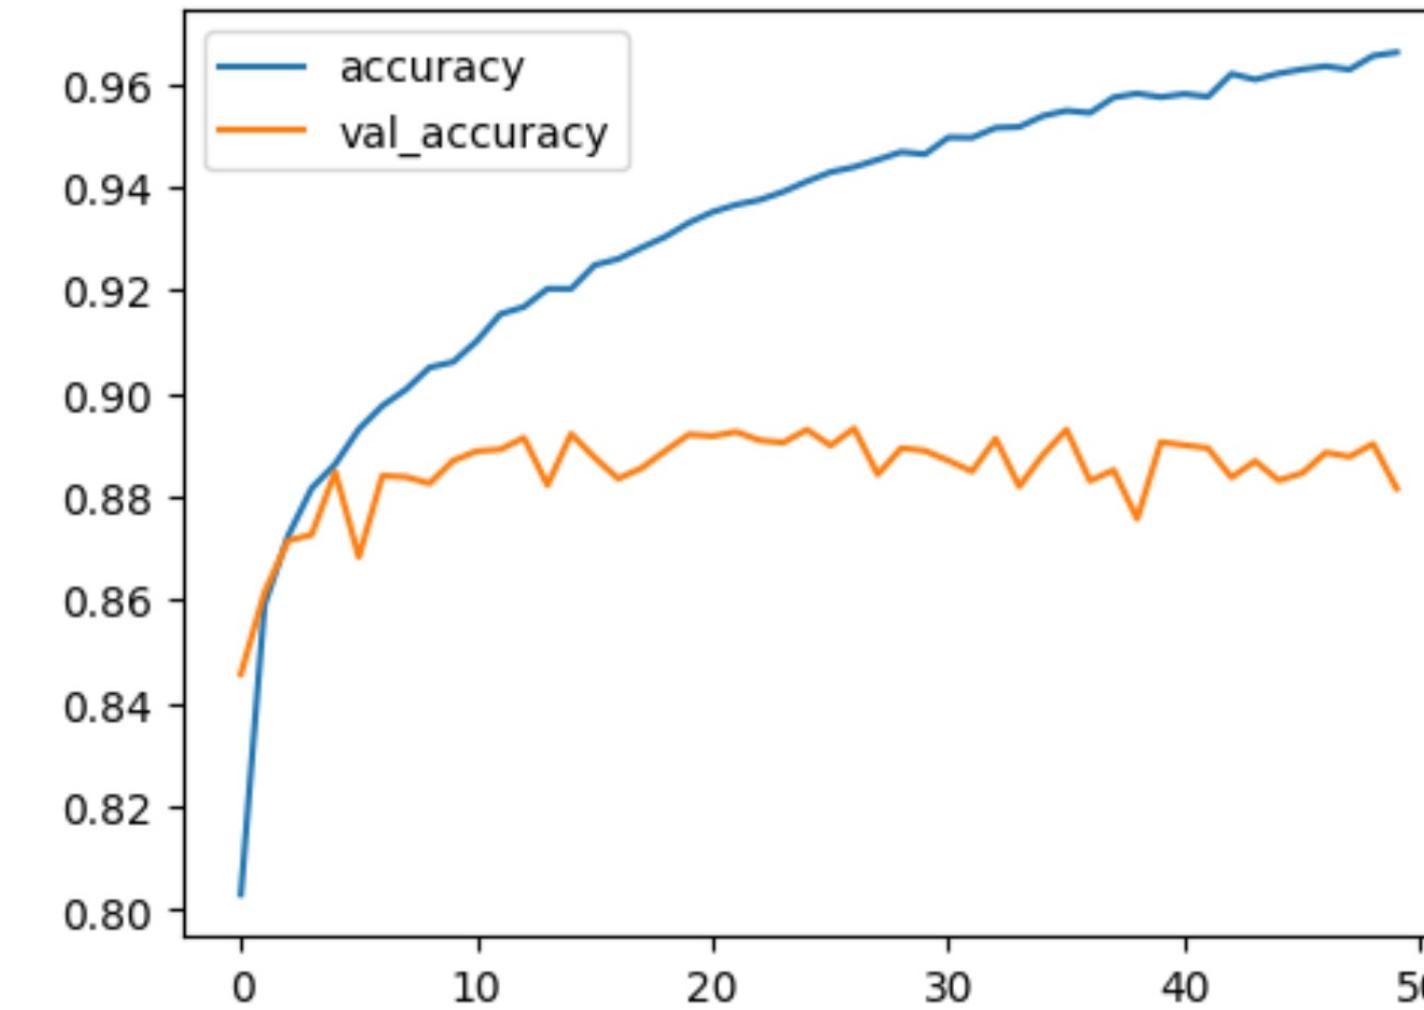
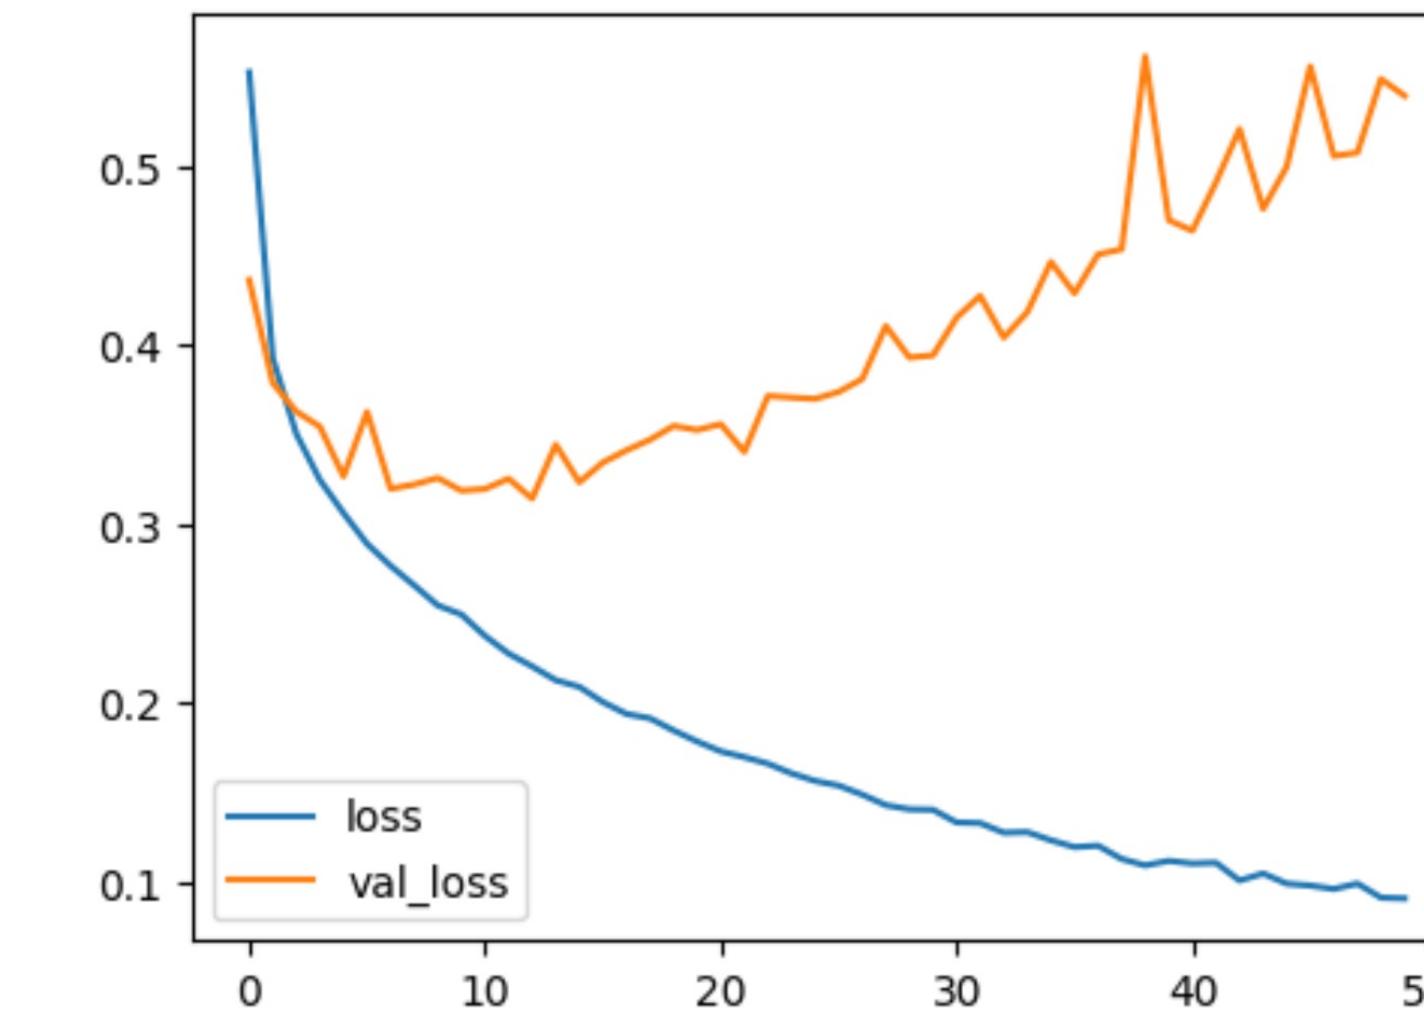
Layer (type)	Output Shape	Param #
=====		
dense_8 (Dense)	(None, 128)	100480
dense_9 (Dense)	(None, 10)	1290
=====		
Total params: 101,770		
Trainable params: 101,770		
Non-trainable params: 0		
=====		

Layer (type)	Output Shape	Param #
=====		
dense_4 (Dense)	(None, 128)	100480
dense_5 (Dense)	(None, 64)	8256
dense_6 (Dense)	(None, 32)	2080
dense_7 (Dense)	(None, 10)	330
=====		
Total params: 111,146		
Trainable params: 111,146		
Non-trainable params: 0		
=====		

層を増やしても今回のデータでは精度あまり上がっていない



Test loss: 0.4939178228378296
Test accuracy: 0.885200023651123



Test loss: 0.5994181036949158
Test accuracy 0.8773999810218811

なぜ過学習が起きるのか

モデルの複雑さ： モデルが非常に複雑である場合（例えば、パラメータが多すぎる）、そのモデルは訓練データのノイズまで学習してしまう。モデルがデータの真のパターンよりも、データに含まれるランダムな誤差や無関係な特徴を学習してしまう。

データの不足： 訓練データが不十分である場合、モデルは利用可能なデータに過剰に適合してしまう。十分なバリエーションのデータがなければ、モデルが一般化するための「良い」パターンを学ぶことができない。

トレーニングの長さ： トレーニングを長く続けすぎると、モデルが訓練データセットの特異性を学習し、新しいデータに対してうまく一般化できなくなる。

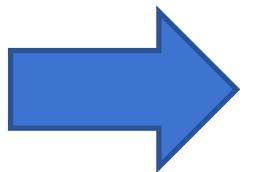
データの品質： データに偏りがあったり、誤った情報が含まれていたりすると、モデルが誤ったパターンを学習する原因となる。

Dropoutを加えてみよう

```
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dense(64,activation='relu'))  
model.add(Dense(32,activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

```
from keras.layers import Dropout  
  
model = Sequential()  
model.add(Dense(128,input_shape=(784,),activation='relu'))  
model.add(Dropout(0.5))  
model.add(Dense(64,activation='relu'))  
model.add(Dense(32,activation='relu'))  
model.add(Dense(10,activation='softmax'))  
model.compile(loss='categorical_crossentropy',  
              optimizer='Adam',metrics=['accuracy'])  
model.summary()
```

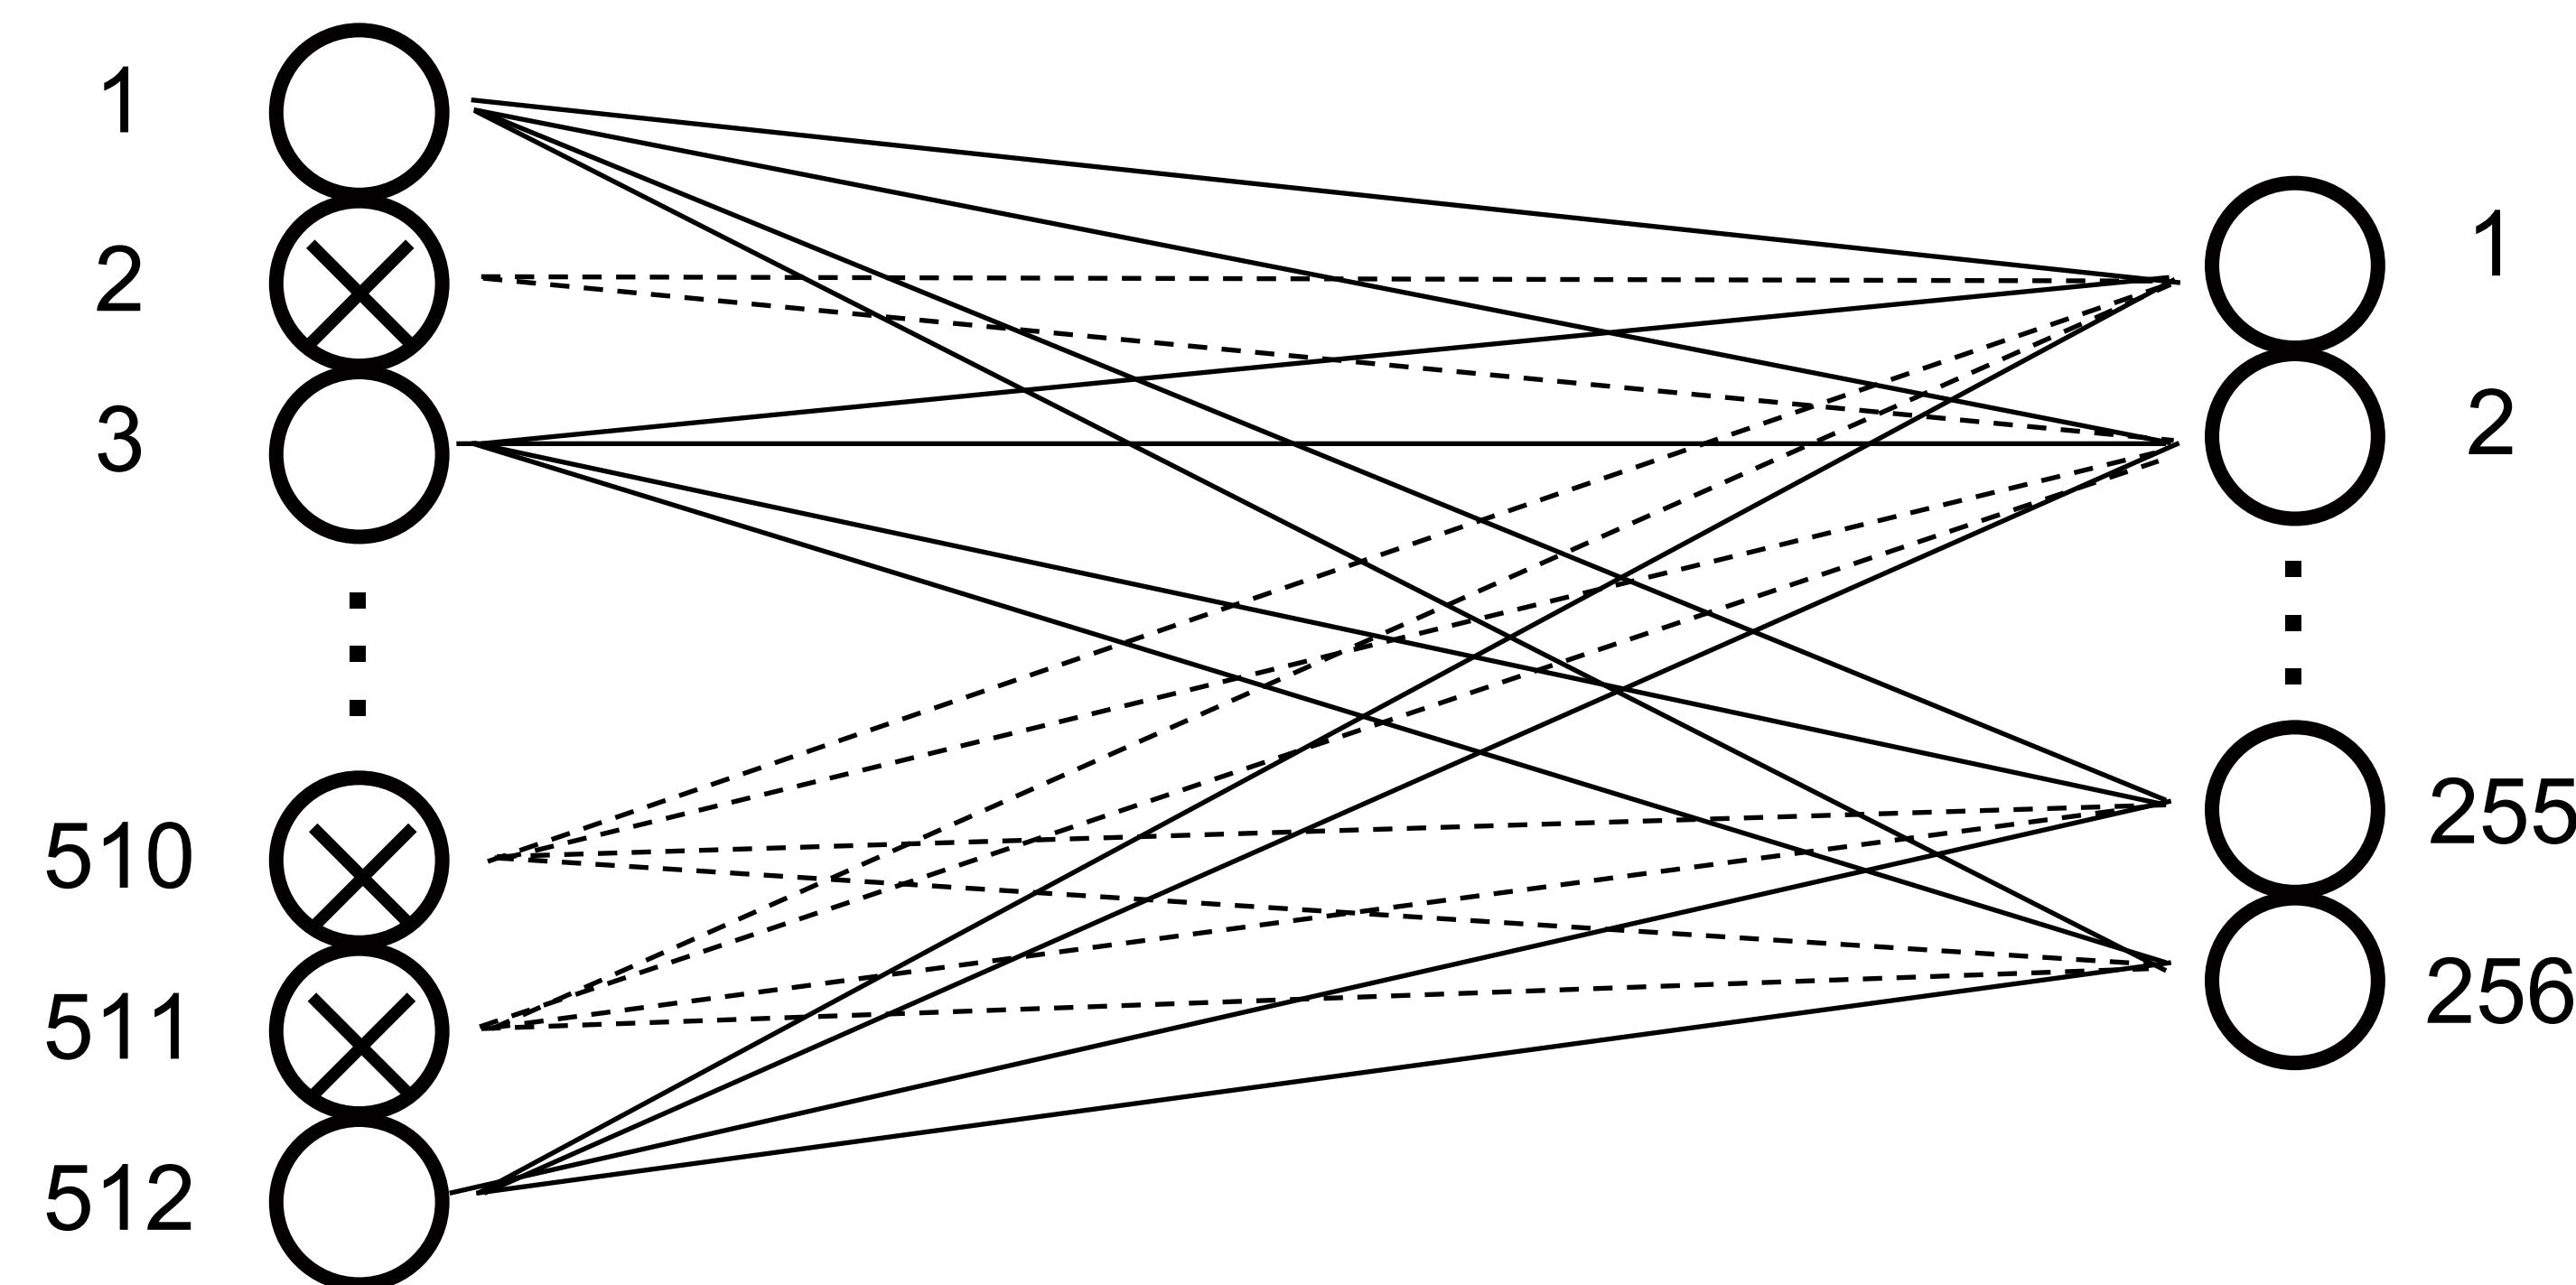
Layer (type)	Output Shape	Param #
dense_4 (Dense)	(None, 128)	100480
dense_5 (Dense)	(None, 64)	8256
dense_6 (Dense)	(None, 32)	2080
dense_7 (Dense)	(None, 10)	330
<hr/>		
Total params:	111,146	
Trainable params:	111,146	
Non-trainable params:	0	



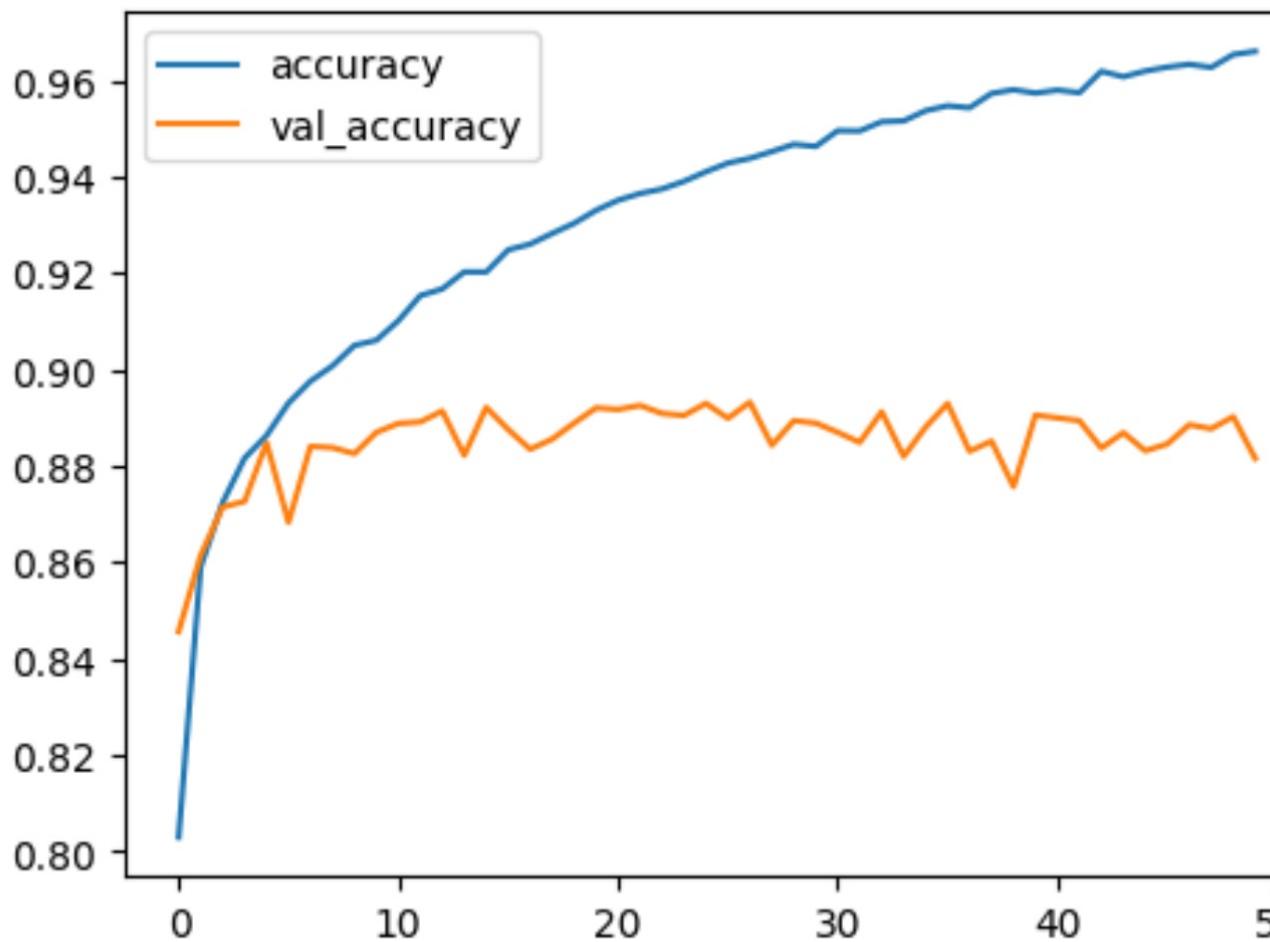
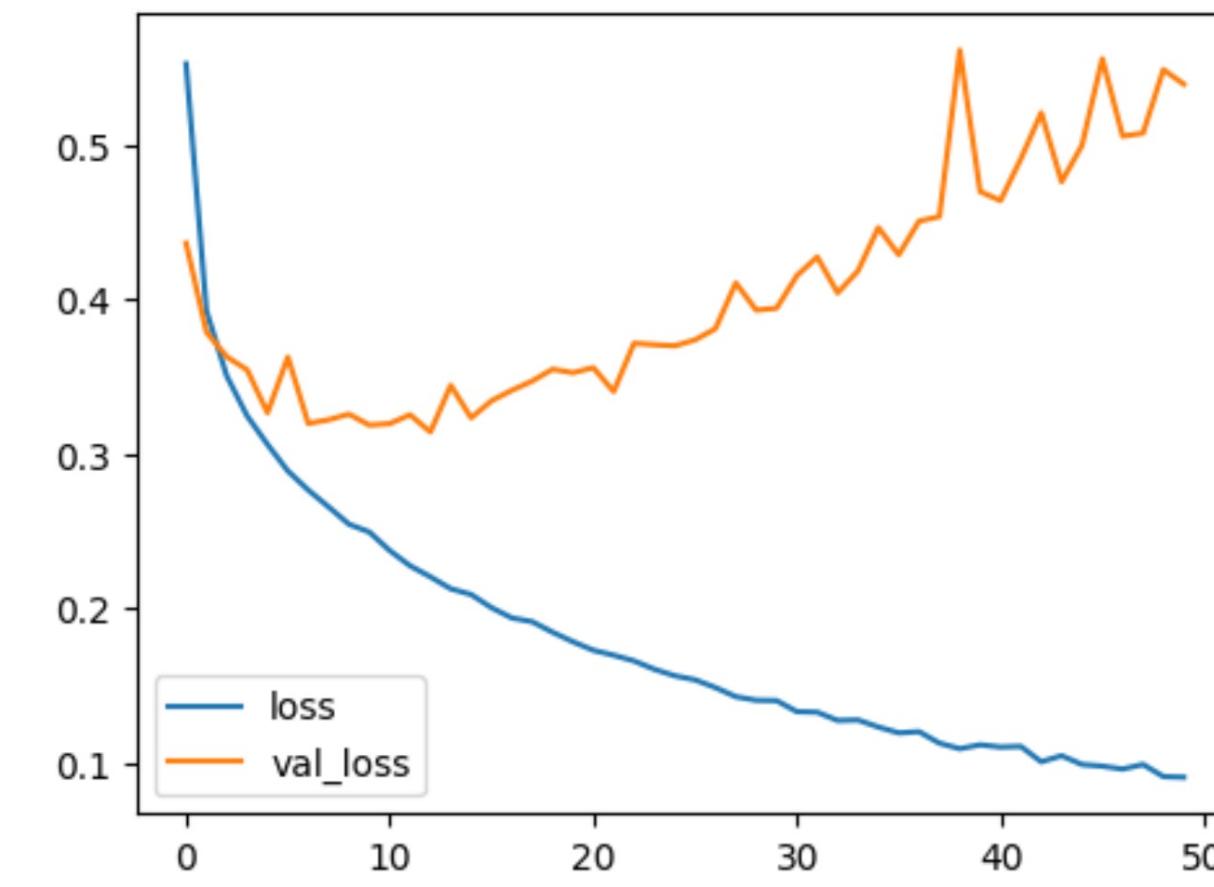
Layer (type)	Output Shape	Param #
dense_8 (Dense)	(None, 128)	100480
dropout (Dropout)	(None, 128)	0
dense_9 (Dense)	(None, 64)	8256
dense_10 (Dense)	(None, 32)	2080
dense_11 (Dense)	(None, 10)	330
<hr/>		
Total params:	111,146	
Trainable params:	111,146	
Non-trainable params:	0	

Dropout

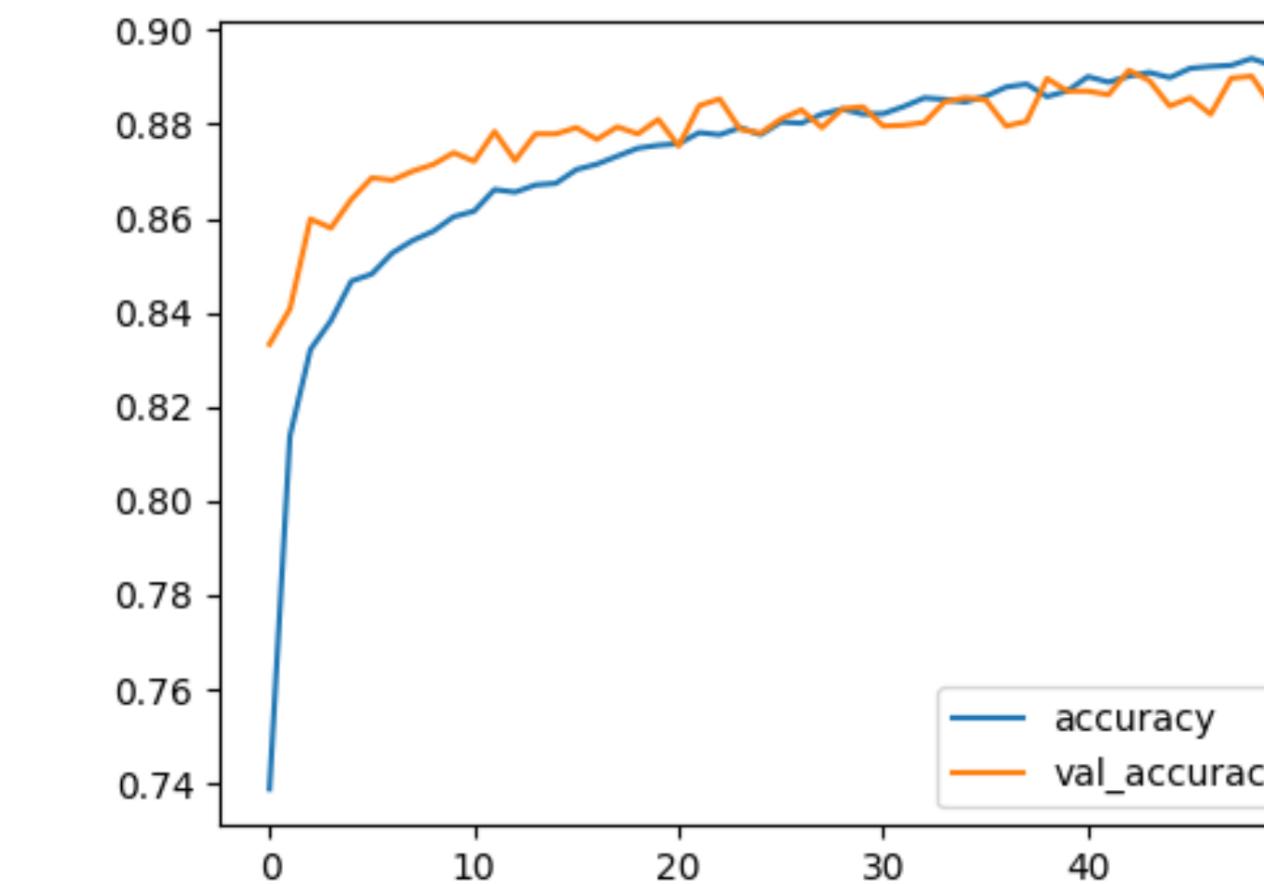
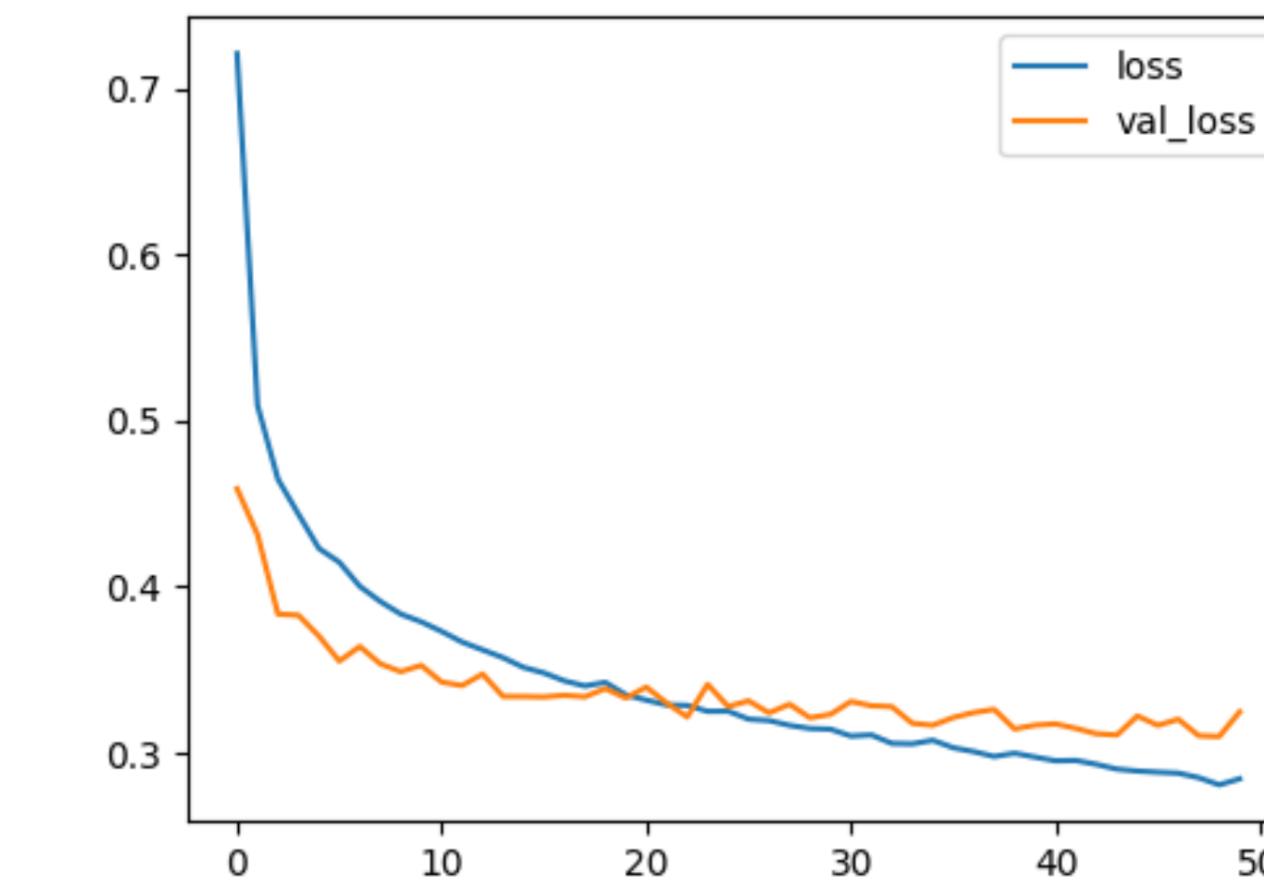
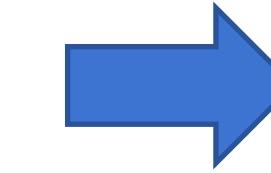
過学習を防ぐための対策の1つで、学習時に設定した確率で出力を0にする手法。推論時には何も行わず、学習時にのみ行われる。これにより、特定のニューロンの評価だけに依存し過ぎることを避けて、より頑健な(=データの本質的な構造を捉えた)特徴を学習することを促す。



Dropoutを加えると過学習を抑制できる



Test loss: 0.5994181036949158
Test accuracy 0.8773999810218811



Test loss: 0.3330557644367218
Test accuracy: 0.8855000138282776

実際は過学習を抑えつつ精度をどれだけ上げられるかを検討する

層はいくらでも増やすことが出来ます。
色々試してみましょう。

Layer (type)	Output Shape	Param #
dense_12 (Dense)	(None, 256)	200960
dropout_1 (Dropout)	(None, 256)	0
dense_13 (Dense)	(None, 64)	16448
dense_14 (Dense)	(None, 128)	8320
dropout_2 (Dropout)	(None, 128)	0
dense_15 (Dense)	(None, 64)	8256
dense_16 (Dense)	(None, 32)	2080
dense_17 (Dense)	(None, 10)	330
Total params:	236,394	
Trainable params:	236,394	
Non-trainable params:	0	

Test loss:
0.3416001796722412
Test accuracy:
0.8855000138282776

今回のデータの量、質だと
MLPではパラメータを増やし
ても90%以上の精度は
なかなか出にくいようです。

課題

- ・WebClassにある"kadai5.ipynb"をやってみましょう
- ・実行したら"学籍番号_名前_5.ipynb"という名前で保存して提出して下さい。

締め切りは2週間後の11/23の23:59です。

締め切りを過ぎた課題は受け取らないので注意して下さい