# at-3.ニューラルネットワークによる分類，未来予測

（ディープラーニングのシステムとプログラミング）

（全１２回）

https://www.kkaneko.jp/ai/at/index.html

金子邦彦

1. 教師あり学習の概要、Irisデータセットを用いた分類の実践を解説。
2. 時系列データの特性（例：Facebookイベント数の分析事例）。
3. リカレントニューラルネットワークの特徴、応用。
4. 太陽黒点数のデータを用いたLSTMによる未来予測の事例を解説。
5. 基本から実践的な演習、応用事例までを網羅。

# アウトライン

１．教師有り学習

２．Irisデータセット

３．分類

４．時系列データ

５．リカレントニューラルネットワークと LSTM

６．未来予測

# 11-1 教師有り学習

# 教師あり学習

**訓練データ (x, y) を使用.**

(x, y) ・・・ **入力 x** に対する**正解 y**

両方を学習に使用.

# 教師あり学習の主な用途

- **分類**：何種類かに分類すること
- **判別**：２種類への分類
- **回帰**：ある量から，別の量を予測するためのもの

# 分類

訓練データ

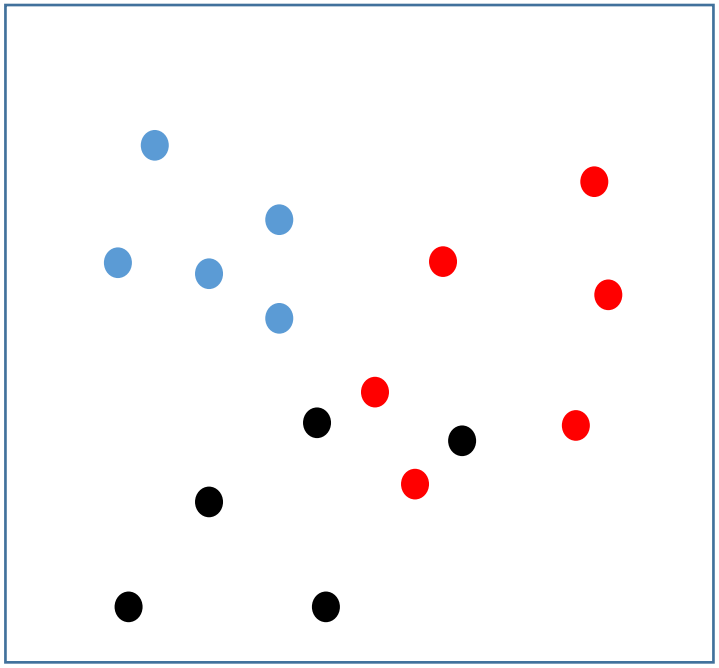

それぞれの範囲を得る

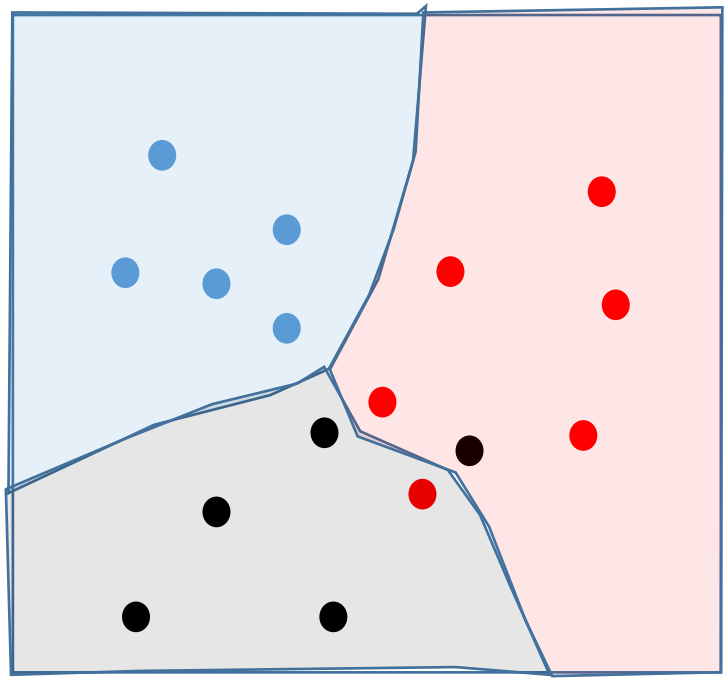

**分類**：何種類かに分類すること

# 判別

訓練データ

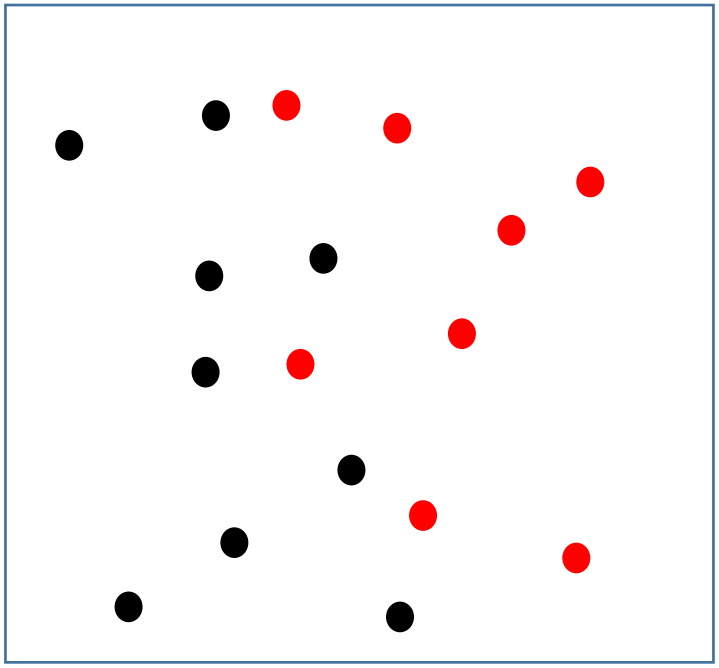

それぞれの範囲を得る

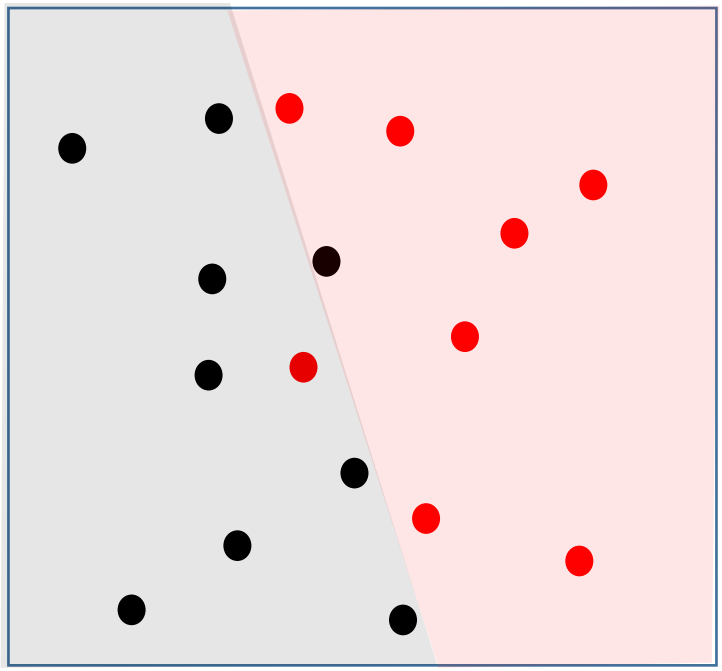

**判別**：２種類への分類

# 回帰

訓練データ

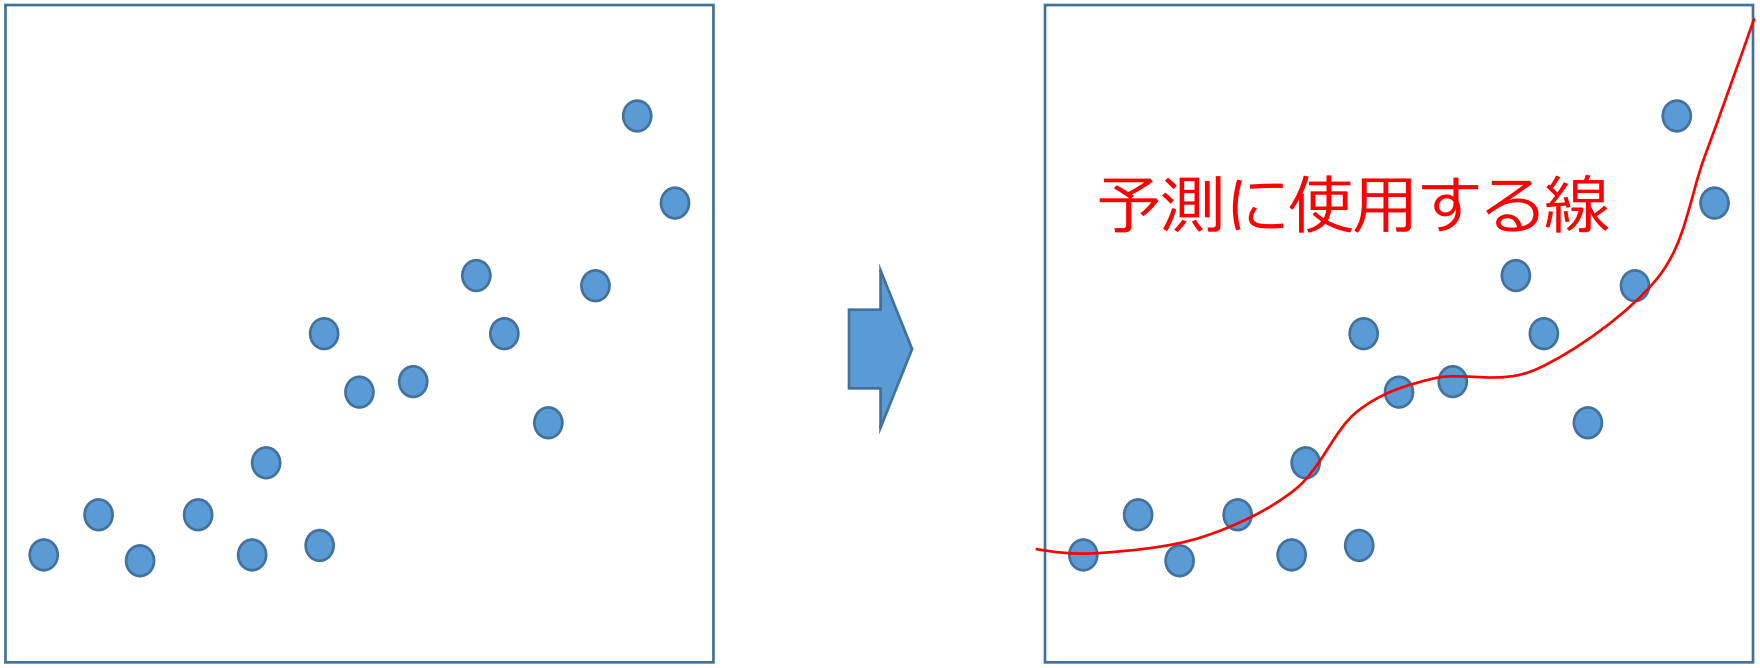


**回帰**：ある量から，別の量を予測するためのもの
（例）身長と体重の関係，年齢と収入の関係

# 11-2 Iris データセット

# アヤメ属 (Iris)

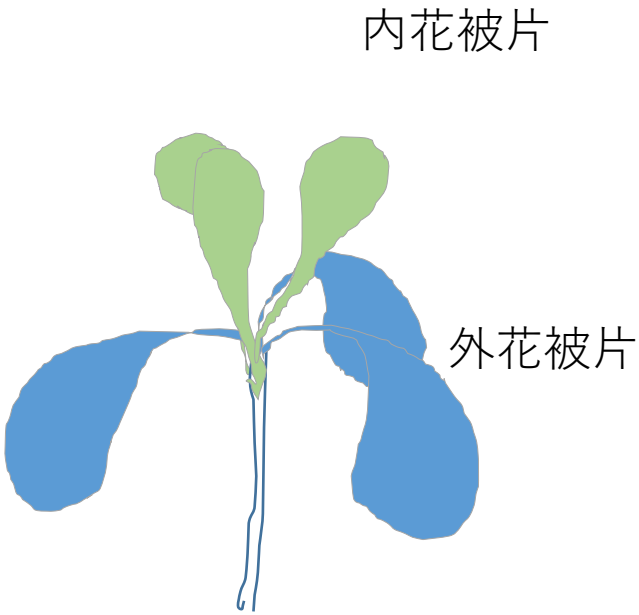


- 多年草
- 世界に 150種. 日本に 9種.
- 花被片は 6個
- **外花被片**（がいかひへん） Sepal
  3個（大型で下に垂れる）
- **内花被片**（ないかひへん） Petal
  3個（直立する）

# Iris データセット

**Iris データセット**（データ数は 50 × 3）
のうち、先頭 10 行

| sepal_length | sepal_width | petal_length | petal_width | species |
|---|---|---|---|---|
| 5.1 | 3.5 | 1.4 | 0.2 | setosa |
| 4.9 | 3 | 1.4 | 0.2 | setosa |
| 4.7 | 3.2 | 1.3 | 0.2 | setosa |
| 4.6 | 3.1 | 1.5 | 0.2 | setosa |
| 5 | 3.6 | 1.4 | 0.2 | setosa |
| 5.4 | 3.9 | 1.7 | 0.4 | setosa |
| 4.6 | 3.4 | 1.4 | 0.3 | setosa |
| 5 | 3.4 | 1.5 | 0.2 | setosa |
| 4.4 | 2.9 | 1.4 | 0.2 | setosa |

**外花被片**(**Sepal**)の長さと幅　**内花被片**(**Petal**)の長さと幅　**種類**

**特徴量**　**ラベル**

- **3種**のアヤメの**外花被辺**、**内花被片**を計測
- 種類も記録
  - **setosa**
  - **versicolor**
  - **virginica**
- データ数は **50** × **3**

作成者：Ronald Fisher

作成年：1936

# Iris データセットの散布図

## アヤメ属 (Iris)

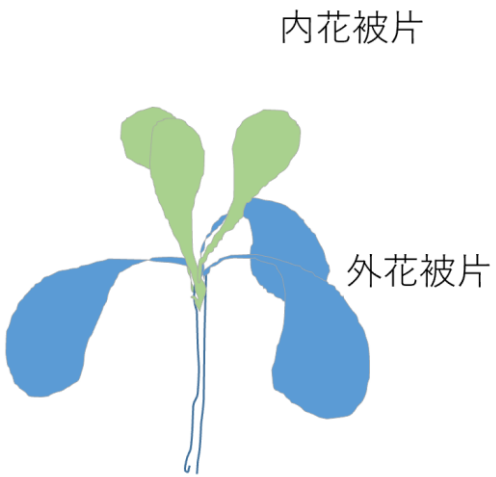


縦軸：内花被片の**幅**

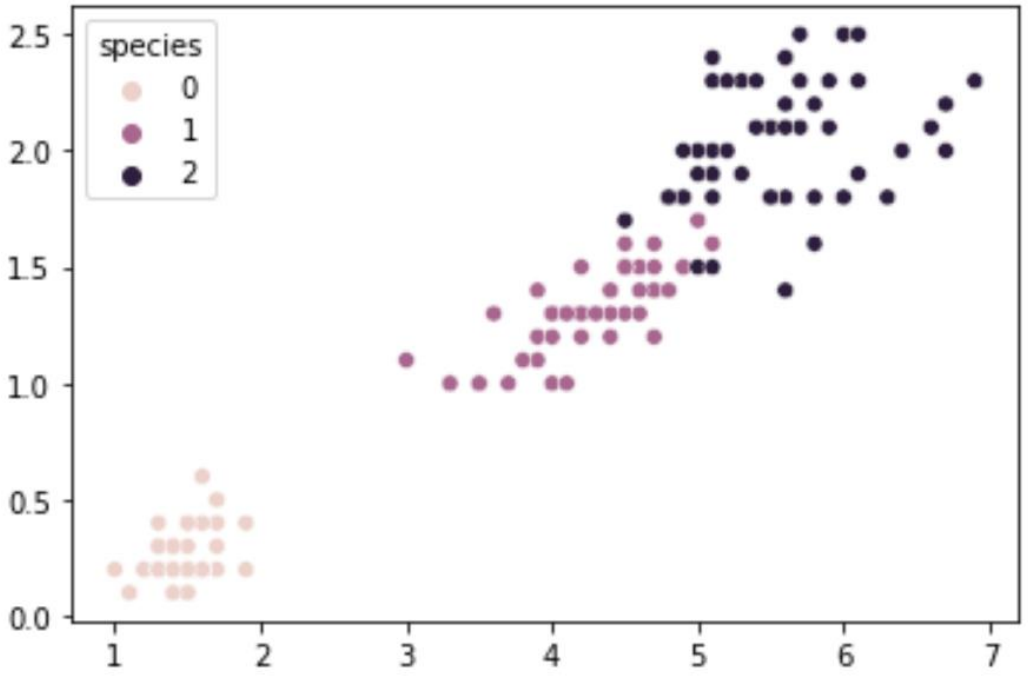


横軸：内花被片の**長さ**

次の**3種類**の分類済みのデータ

0: **setosa**
1: **versicolor**
2: **virginica**

# Iris データセットと配列（アレイ）

Iris データセット

| sepal_length | sepal_width | petal_length | petal_width | species |
|---|---|---|---|---|
| 5.1 | 3.5 | 1.4 | 0.2 | setosa |
| 4.9 | 3 | 1.4 | 0.2 | setosa |
| 4.7 | 3.2 | 1.3 | 0.2 | setosa |
| 4.6 | 3.1 | 1.5 | 0.2 | setosa |
| 5 | 3.6 | 1.4 | 0.2 | setosa |
| 5.4 | 3.9 | 1.7 | 0.4 | setosa |
| 4.6 | 3.4 | 1.4 | 0.3 | setosa |
| 5 | 3.4 | 1.5 | 0.2 | setosa |
| 4.4 | 2.9 | 1.4 | 0.2 | setosa |

```
[[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]
```

**特徴量**（数値）
サイズ：**150 × 4**

```
[0
0
0
0
0
0
0
0
0
0
```

**ラベル**（数値）
サイズ：**150**

setosa → 0
versicolor → 1
virginia → 2

**ラベルの数値化**

# 演習

Iris データセットをロードし，特徴量とラベルを表示

ページ１５～１７

【トピックス】

- Google Colaboratory でのプログラム実行
- Iris データセット

# Google Colaboratory の使い方概要 ①

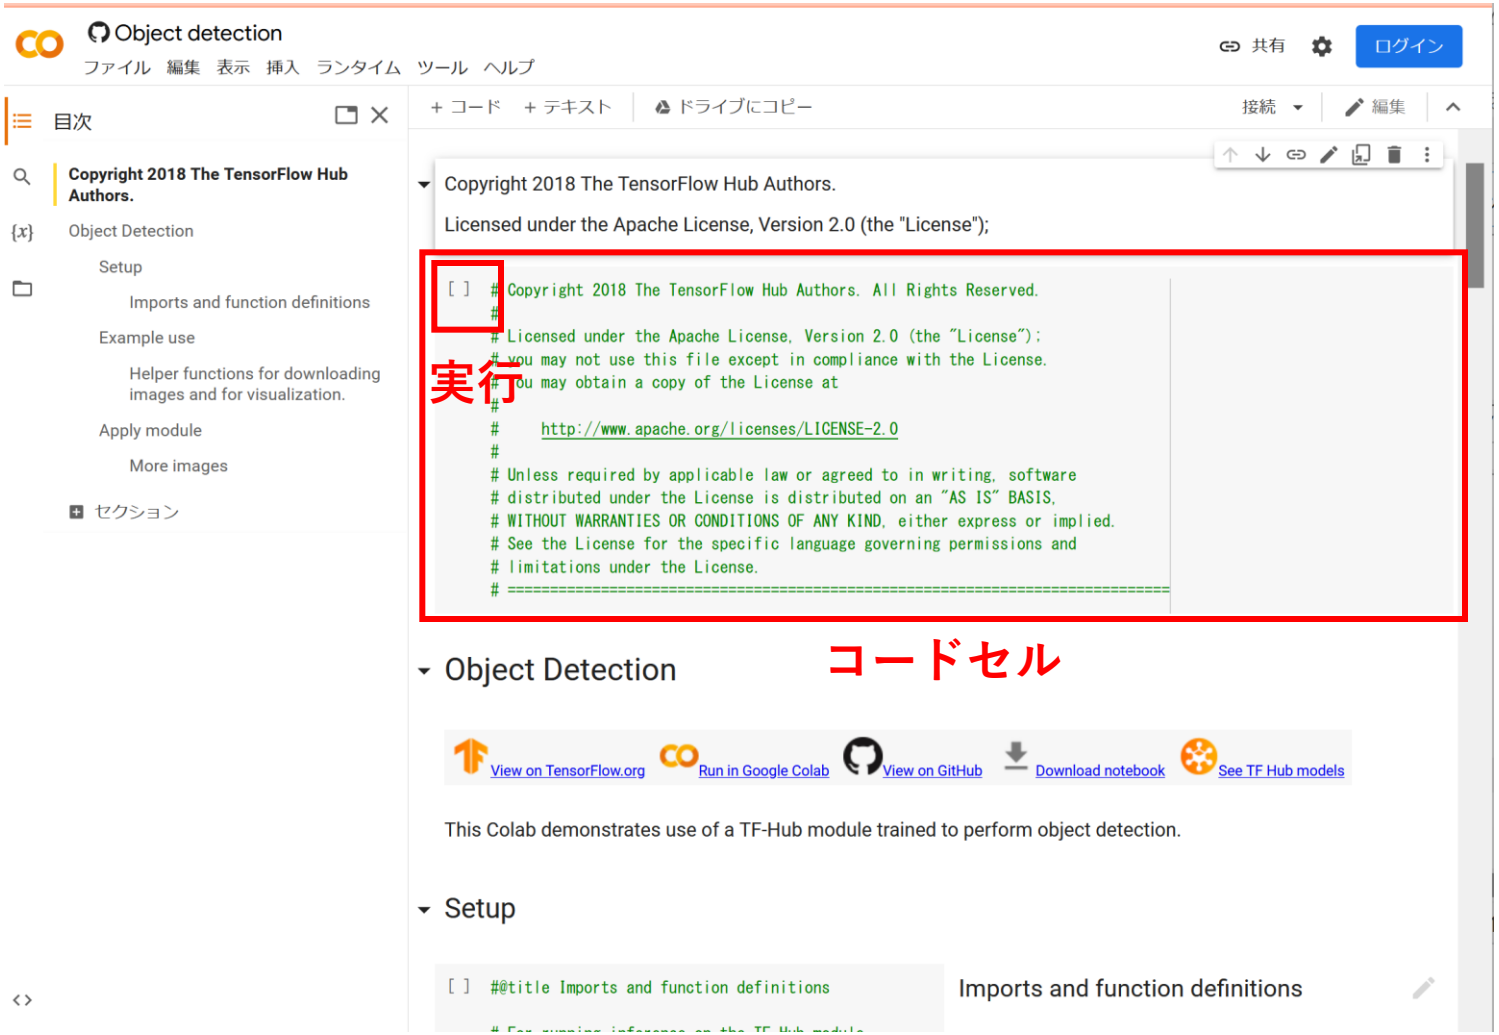


Google Colaboratory ノートブック
コードセルの再実行や変更には,
Google アカウントでのログインが必要

# Google Colaboratory の使い方概要 ②

実行

```
[ ] files = ['a.png', 'b.png','c.png', '126.png', '127.png']
```

## 6．顔検出

顔検出は，**写真やビデオの中の顔を検出すること**．顔とそれ以外のオブジェクトを区別することも行う．顔検出の結果は，バウンディングボックスで得られるのが普通である．

次のプログラムは，Dlib を用いて，画像からの顔検出を行う。

- 「**dets = cnn_face_detector(img, 6)**」・・・**顔検出**の実行
- 「**cv2.rectangle(disp, (d.rect.left(), d.rect.top()), (d.rect.right(), d.rect.bottom()), (255, 0, 0), 1)**」・・・**顔検出の結果**を**四角形で表示**

結果は，赤い四角で表示される．１，３，４，５番目の画像（a.png, c.png, 126.png, 127.png）からは，顔が検出される．２番目の画像（b.png, 手で顔を覆い隠したもの）からは顔が検出されない．**少し隠れていたり，顔が傾いていても顔検出ができる**が，**大きく隠れていると顔検出できない**．

実行結果が長いので，スクロールして**全体を確認**すること．

謝辞: ここの Python プログラムは，Dlib に付属の cnn_face_detector.py を書き換えて使用している

実行

```
import sys
import dlib
import os
import urllib.request
import cv2
import matplotlib.pyplot as plt

cnn_face_detector = dlib.cnn_face_detection_model_v1('mmod_human_face_detector.dat')

for f in files:
    print("*** file: {} ***".format(f))
    img = dlib.load_rgb_image(f)
    dets = cnn_face_detector(img, 1)
    print("Number of faces detected: {}".format(len(dets)))
    for i, d in enumerate(dets):
        print("Detection {}: Left: {} Top: {} Right: {} Bottom: {} Confidence: {}".format(
            i, d.rect.left(), d.rect.top(), d.rect.right(), d.rect.bottom(), d.confidence))
    disp = img.copy()
    for i, d in enumerate(dets):
        cv2.rectangle(disp, (d.rect.left(), d.rect.top()), (d.rect.right(), d.rect.bottom()), (255, 0, 0), 8)
    plt.figure(figsize=(10,10))
    plt.imshow(disp)
    plt.show()
```

```
*** file: a.png ***
Number of faces detected: 1
Detection 0: Left: 614 Top: 319 Right: 1121 Bottom: 827 Confidence: 0.20801100134849548
```

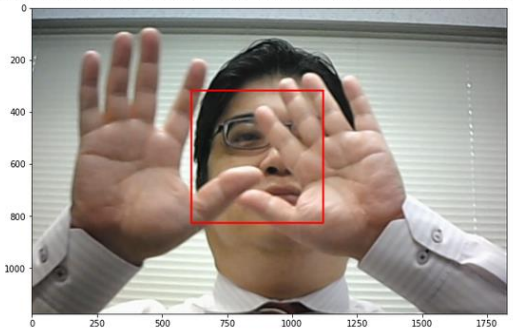


```
*** file: b.png ***
Number of faces detected: 0
```

一番上のコードセルから順々に実行

コードセル

テキストセル

コードセル

- **WEBブラウザでアクセス**
- **コードセル**は **Python プログラム**．
  各自の Google アカウントでログインすれば，
  変更，再実行可能

# Iris データセットは Python でも利用可能

ソースコード

```
from sklearn.datasets import load_iris
iris = load_iris()
x, y = iris.data, iris.target
print(x)
print(y)
```

x に**特徴量**を，yに**ラベル**を格納

```
from sklearn.datasets import load_iris
iris = load_iris()
x, y = iris.data, iris.target
print(x)
print(y)
```

```
[6.2 2.9 4.3 1.3]
[5.1 2.5 3.  1.1]
[5.7 2.8 4.1 1.3]
[6.3 3.3 6.  2.5]
[5.8 2.7 5.1 1.9]
[7.1 3.  5.9 2.1]
[6.3 2.9 5.6 1.8]
[6.5 3.  5.8 2.2]
[7.6 3.  6.6 2.1]
[4.9 2.5 4.5 1.7]
[7.3 2.9 6.3 1.8]
[6.7 2.5 5.8 1.8]
[7.2 3.6 6.1 2.5]
[6.5 3.2 5.1 2. ]
[6.4 2.7 5.3 1.9]
[6.8 3.  5.5 2.1]
[5.7 2.5 5.  2. ]
[5.8 2.8 5.1 2.4]
[6.4 3.2 5.3 2.3]
[6.5 3.  5.5 1.8]
[7.7 3.8 6.7 2.2]
[7.7 2.6 6.9 2.3]
[6.  2.2 5.  1.5]
```

実行結果

```
[[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]
 [4.3 3.  1.1 0.1]
 [5.8 4.  1.2 0.2]
 [5.7 4.4 1.5 0.4]
 [5.4 3.9 1.3 0.4]
 [5.1 3.5 1.4 0.3]
 [5.7 3.8 1.7 0.3]
 [5.1 3.8 1.5 0.3]
 [5.4 3.4 1.7 0.2]
 [5.1 3.7 1.5 0.4]
 [4.6 3.6 1.  0.2]
 [5.1 3.3 1.7 0.5]
 [4.8 3.4 1.9 0.2]
 [5.  3.  1.6 0.2]
 [5.  3.4 1.6 0.4]
 [5.2 3.5 1.5 0.2]
 [5.2 3.4 1.4 0.2]
 [4.7 3.2 1.6 0.2]
 [4.8 3.1 1.6 0.2]
 [5.4 3.4 1.5 0.4]
 [5.2 4.1 1.5 0.1]
 [5.5 4.2 1.4 0.2]
 [4.9 3.1 1.5 0.2]
 [5.  3.2 1.2 0.2]
```

x を表示している部分

```
[0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2
 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 2 2]
```

y を表示している部分

# 11-3 分類

# Iris データセットの分類

- **花びらの長さと幅**から，**花の種類**を予測

**花びら4つの数値**（長さと幅の2つによる計4つの値）に基づいて、**3種類の花**（アイリスセトーサ、アイリスバーシクル、アイリスバージニカ）の**一つを予測**する

- **利用可能なデータを分割**

150個を，120個と 30個のように分割

120個：**訓練データ**

30個：**検証データ**（過学習や学習不足の可能性を評価）

# 演習

Iris データセットを１２０個と３０個に分割

ページ２１

【トピックス】

- Google Colaboratory でのプログラム実行
- Irisデータセットの分割

# Iris データセットの利用可能なデータを分割

ソースコード

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from tensorflow.keras.utils import to_categorical

iris = load_iris()
x, y = iris.data, iris.target

# データの正規化（特徴量間のスケールの違いをなくす処理）
scaler = StandardScaler()
x = scaler.fit_transform(x)

# データセットを訓練データとテストデータに分割（ランダムシードを設定）
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.2, random_state=42)

# ターゲットをカテゴリカル変数に変換（ニューラルネットワークで使用するため）
y_train = to_categorical(y_train, num_classes=3)
y_test = to_categorical(y_test, num_classes=3)

#確認表示
print(x_train)
print(x_test)
print(y_train)
print(y_test)
```

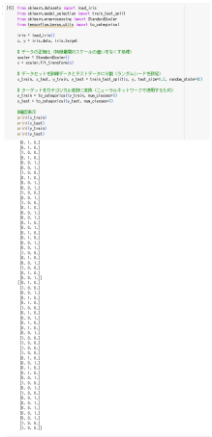

実行結果

# 分類

- **学習により、「未知のデータを分類できる能力を獲得」と考えることもできる**

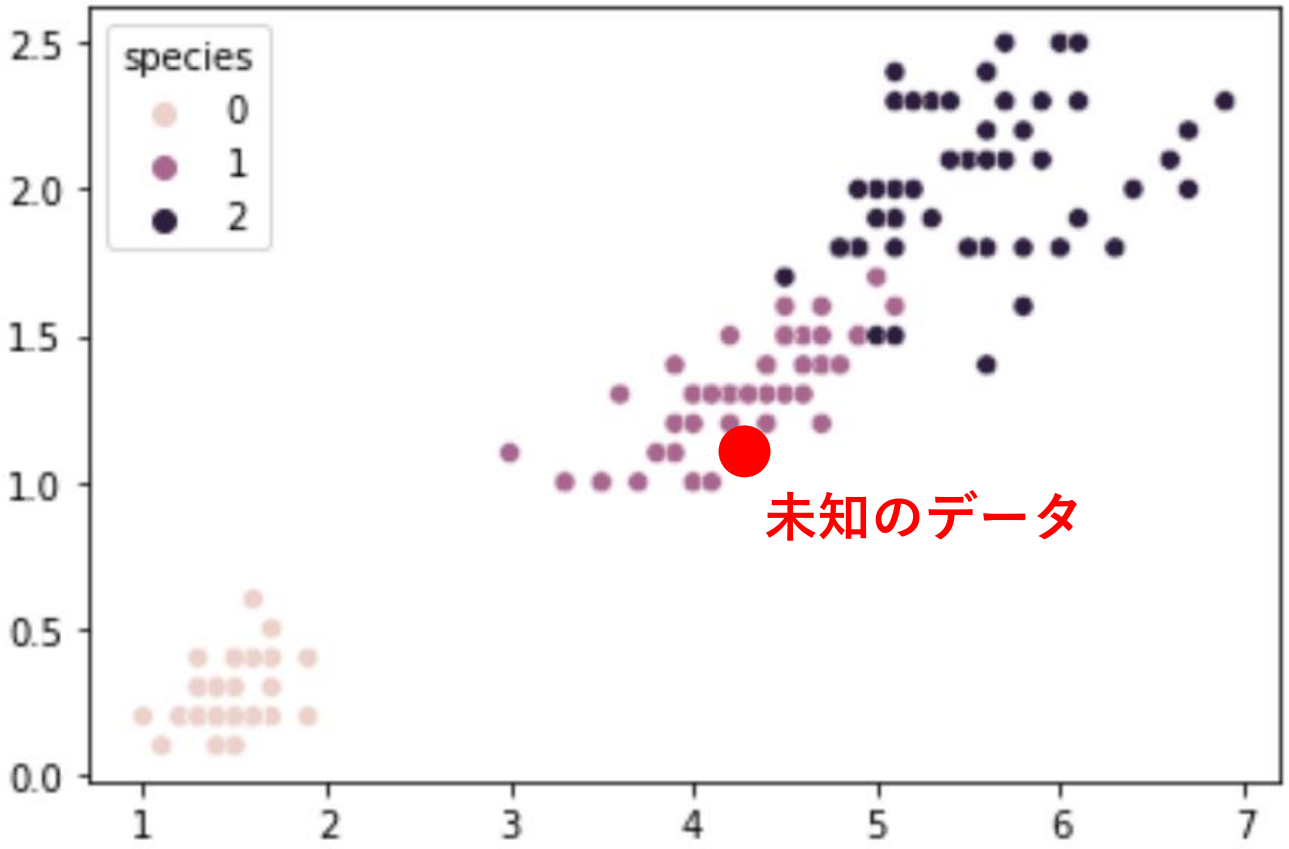

# 分類を行うニューラルネットワークの例

- **1層目：ユニット数 20, 種類は relu**
- **2層目：ユニット数 3, 種類は softmax**

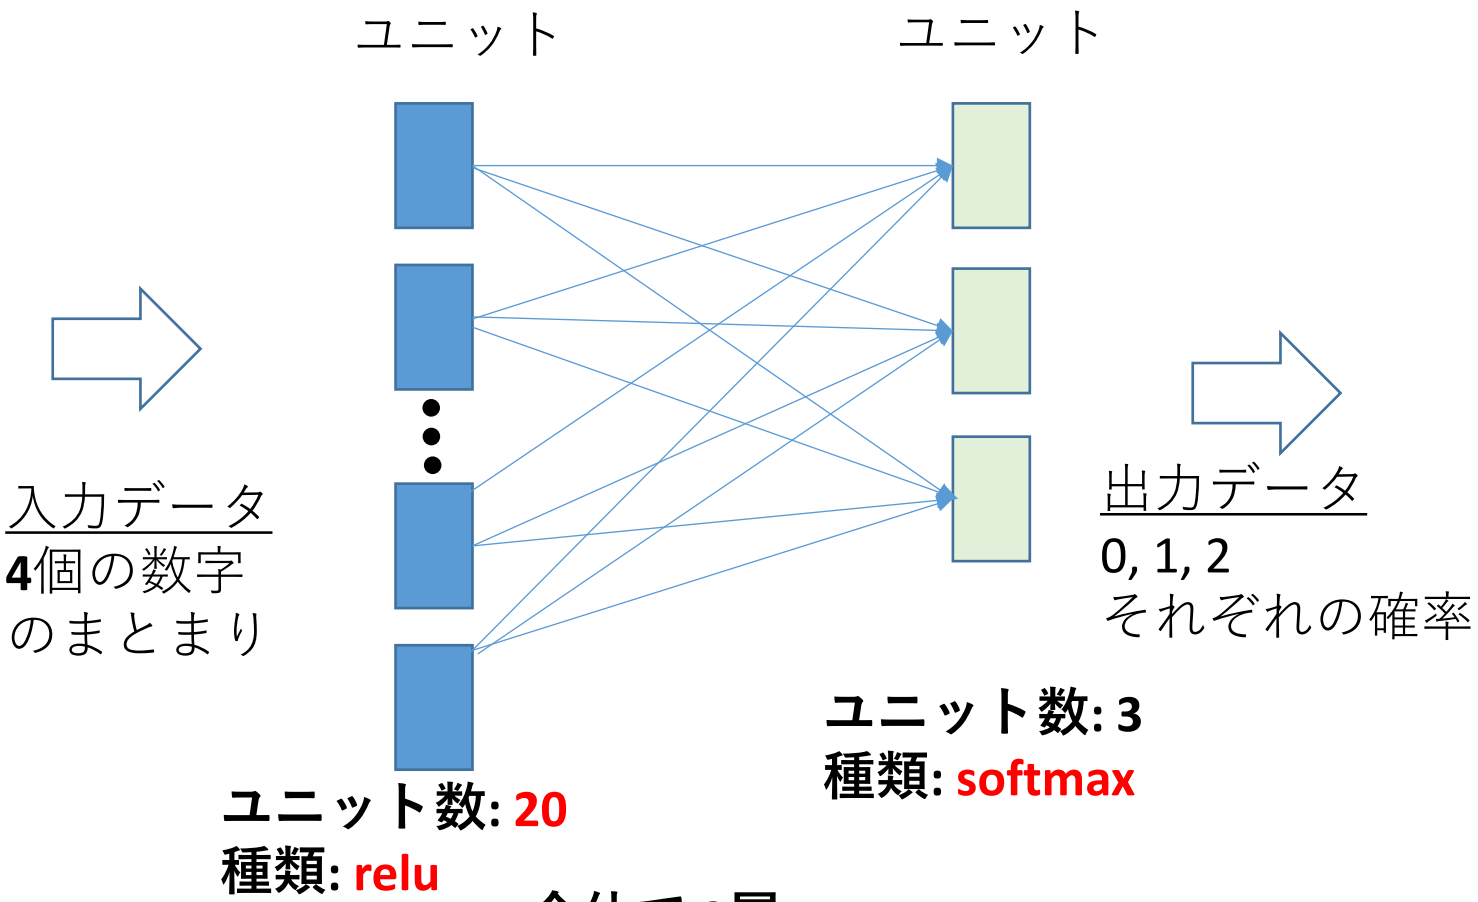

# ニューラルネットワーク作成のプログラム例

プログラムを使用し，
ニューラルネットワークを作成

```
import tensorflow as tf

def create_model():
    return tf.keras.models.Sequential([
        tf.keras.layers.Dense(units=20, input_dim=4, activation='relu'),
        tf.keras.layers.Dropout(0.1),
        tf.keras.layers.Dense(units=3, activation='softmax')
    ])
```

入力データは **4**個の数字

１層目のユニット数は **20**
種類は **relu**

２層目のユニット数は **3**
種類は **softmax**

**ニューラルネットワーク**の作成では，次を設定する

- 入力データでの数値の個数
- **ユニット**の数（**層**ごと）
- **ユニット**の種類（**層**ごと）

# ニューラルネットワークの学習を行うプログラム例

学習の繰り返し回数は **50**

```
EPOCHS=50
history = m.fit(x=x_train,
          y=y_train,
          epochs=EPOCHS,
          validation_data=(x_test, y_test),
          callbacks=[tensorboard_callback],
          verbose=2)
```

**訓練データ**の指定

**検証データ**の指定

# 演習

**Iris データセットを用いた学習，分類の実行**

**ページ２７**

**【トピックス】**

- **Google Colaboratory でのプログラム実行**
- **ニューラルネットワークの作成**
- **学習の実行**
- **分類の実行**

# Irisデータセットによる学習と分類の実行

ソースコード

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
import tensorflow as tf
from tensorflow.keras.utils import to_categorical

iris = load_iris()
x, y = iris.data, iris.target

# データの正規化（特徴量間のスケールの違いをなくす処理）
scaler = StandardScaler()
x = scaler.fit_transform(x)

# データセットを訓練データとテストデータに分割（ランダムシードを設定）
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.2, random_state=42)

# ターゲットをカテゴリカル変数に変換（ニューラルネットワークで使用するため）
y_train = to_categorical(y_train, num_classes=3)
y_test = to_categorical(y_test, num_classes=3)

def create_model():
    return tf.keras.models.Sequential([
        tf.keras.layers.Dense(units=20, input_dim=4, activation='relu'),
        tf.keras.layers.Dropout(0.1),
        tf.keras.layers.Dense(units=3, activation='softmax')
    ])

m = create_model()
m.compile(optimizer='adam',
          loss='categorical_crossentropy',
          metrics=['accuracy'])
EPOCHS = 50
history = m.fit(x = x_train,
                y = y_train,
                epochs = EPOCHS,
                validation_data = (x_test, y_test),
                verbose = 2)

m.evaluate(x_test, y_test)
# 分類を実行
predictions = m.predict(x_test)

# 確率が最大のクラスを選択
predicted_classes = np.argmax(predictions, axis=1)
actual_classes = np.argmax(y_test, axis=1)

# アイリスのクラス名
class_names = iris.target_names

# 予測結果と実際のクラスを表示
for i in range(len(predicted_classes)):
    print(f"分類結果: {class_names[predicted_classes[i]]}, 実際のクラス: {class_names[actual_classes[i]]}")
```

実行結果

```
Epoch 38/50
4/4 - 0s - loss: 0.5121 - accuracy: 0.8167 - val_loss: 0.4648 - val_accuracy: 0.8333 - 34ms/epoch - 9ms/step
Epoch 39/50
4/4 - 0s - loss: 0.4910 - accuracy: 0.8167 - val_loss: 0.4580 - val_accuracy: 0.8333 - 36ms/epoch - 9ms/step
Epoch 40/50
4/4 - 0s - loss: 0.4794 - accuracy: 0.8333 - val_loss: 0.4514 - val_accuracy: 0.8667 - 39ms/epoch - 10ms/step
Epoch 41/50
4/4 - 0s - loss: 0.4656 - accuracy: 0.8250 - val_loss: 0.4450 - val_accuracy: 0.8667 - 56ms/epoch - 14ms/step
Epoch 42/50
4/4 - 0s - loss: 0.4851 - accuracy: 0.8083 - val_loss: 0.4388 - val_accuracy: 0.8667 - 38ms/epoch - 10ms/step
Epoch 43/50
4/4 - 0s - loss: 0.4755 - accuracy: 0.8333 - val_loss: 0.4328 - val_accuracy: 0.8667 - 37ms/epoch - 9ms/step
Epoch 44/50
4/4 - 0s - loss: 0.4801 - accuracy: 0.8000 - val_loss: 0.4271 - val_accuracy: 0.8667 - 36ms/epoch - 9ms/step
Epoch 45/50
4/4 - 0s - loss: 0.4814 - accuracy: 0.8333 - val_loss: 0.4215 - val_accuracy: 0.8667 - 37ms/epoch - 9ms/step
Epoch 46/50
4/4 - 0s - loss: 0.4594 - accuracy: 0.8250 - val_loss: 0.4160 - val_accuracy: 0.8667 - 39ms/epoch - 10ms/step
Epoch 47/50
4/4 - 0s - loss: 0.4302 - accuracy: 0.8583 - val_loss: 0.4105 - val_accuracy: 0.8667 - 54ms/epoch - 13ms/step
Epoch 48/50
4/4 - 0s - loss: 0.4567 - accuracy: 0.8250 - val_loss: 0.4052 - val_accuracy: 0.8667 - 41ms/epoch - 10ms/step
Epoch 49/50
4/4 - 0s - loss: 0.4552 - accuracy: 0.8333 - val_loss: 0.4001 - val_accuracy: 0.8667 - 36ms/epoch - 9ms/step
Epoch 50/50
4/4 - 0s - loss: 0.4540 - accuracy: 0.8333 - val_loss: 0.3951 - val_accuracy: 0.8667 - 36ms/epoch - 9ms/step
1/1 [==============================] - 0s 25ms/step - loss: 0.3951 - accuracy: 0.8667
1/1 [==============================] - 0s 53ms/step
分類結果: virginica, 実際のクラス: versicolor
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: versicolor
分類結果: setosa, 実際のクラス: setosa
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: versicolor, 実際のクラス: versicolor
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: versicolor, 実際のクラス: versicolor
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
```

# 学習についての表示部分

- 繰り返し学習を行う．訓練データにより，モデルが更新される．
- 各更新後，検証データを用いて，性能を評価（検証データを分類し，正解と比較して，精度を検証）．その結果は，学習不足や過学習の可能性を判断するのに使用

```
Epoch 1/50
4/4 - 1s - loss: 1.0542 - accuracy: 0.4333 - val_loss: 1.0251 - val_accuracy: 0.5000 - 1s/epoch - 301ms/step
Epoch 2/50
4/4 - 0s - loss: 1.0010 - accuracy: 0.6167 - val_loss: 0.9974 - val_accuracy: 0.6667 - 67ms/epoch - 17ms/step
Epoch 3/50
4/4 - 0s - loss: 0.9844 - accuracy: 0.6667 - val_loss: 0.9708 - val_accuracy: 0.7333 - 53ms/epoch - 13ms/step
Epoch 4/50
4/4 - 0s - loss: 0.9589 - accuracy: 0.7083 - val_loss: 0.9452 - val_accuracy: 0.7667 - 53ms/epoch - 13ms/step
Epoch 5/50
4/4 - 0s - loss: 0.9344 - accuracy: 0.7083 - val_loss: 0.9204 - val_accuracy: 0.7667 - 50ms/epoch - 12ms/step
Epoch 6/50
4/4 - 0s - loss: 0.9048 - accuracy: 0.7667 - val_loss: 0.8968 - val_accuracy: 0.7667 - 67ms/epoch - 17ms/step
Epoch 7/50
4/4 - 0s - loss: 0.8733 - accuracy: 0.7750 - val_loss: 0.8739 - val_accuracy: 0.8000 - 68ms/epoch - 17ms/step
Epoch 8/50
4/4 - 0s - loss: 0.8718 - accuracy: 0.7750 - val_loss: 0.8519 - val_accuracy: 0.8000 - 90ms/epoch - 22ms/step
Epoch 9/50
4/4 - 0s - loss: 0.8408 - accuracy: 0.7667 - val_loss: 0.8313 - val_accuracy: 0.8000 - 74ms/epoch - 19ms/step
Epoch 10/50
4/4 - 0s - loss: 0.8318 - accuracy: 0.7667 - val_loss: 0.8112 - val_accuracy: 0.8000 - 59ms/epoch - 15ms/step
Epoch 11/50
4/4 - 0s - loss: 0.8092 - accuracy: 0.8000 - val_loss: 0.7917 - val_accuracy: 0.8000 - 75ms/epoch - 19ms/step
Epoch 12/50
4/4 - 0s - loss: 0.7789 - accuracy: 0.8000 - val_loss: 0.7729 - val_accuracy: 0.8000 - 78ms/epoch - 20ms/step
Epoch 13/50
4/4 - 0s - loss: 0.7654 - accuracy: 0.7917 - val_loss: 0.7547 - val_accuracy: 0.8333 - 53ms/epoch - 13ms/step
```

**検証データ**について，
予測結果と正解を比べての
精度 (accuracy)

# 分類結果についての表示部分

- 検証データを分類した結果と正解と表示

```
1/1 [==============================] - 0s 53ms/step
分類結果: virginica, 実際のクラス: versicolor
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: versicolor
分類結果: setosa, 実際のクラス: setosa
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: versicolor, 実際のクラス: versicolor
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: versicolor, 実際のクラス: versicolor
分類結果: versicolor, 実際のクラス: versicolor
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: virginica, 実際のクラス: virginica
分類結果: setosa, 実際のクラス: setosa
分類結果: setosa, 実際のクラス: setosa
```

# 11-4. 時系列データ

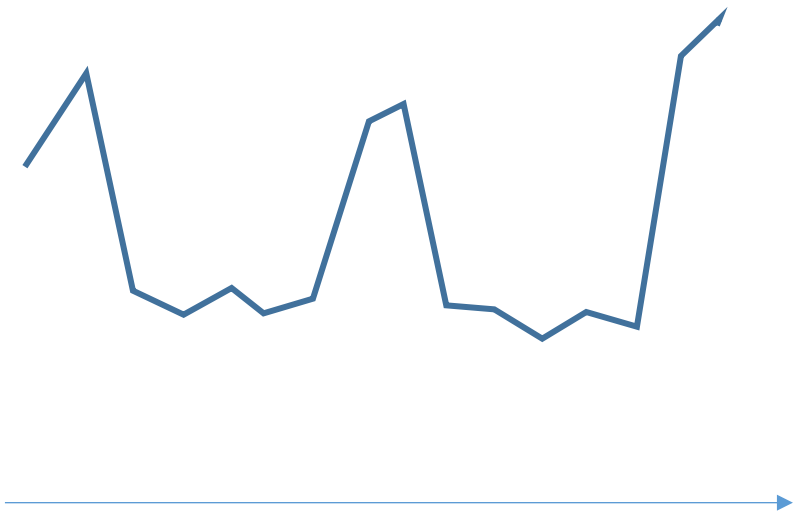

過去の量から，周期性を分析し活用

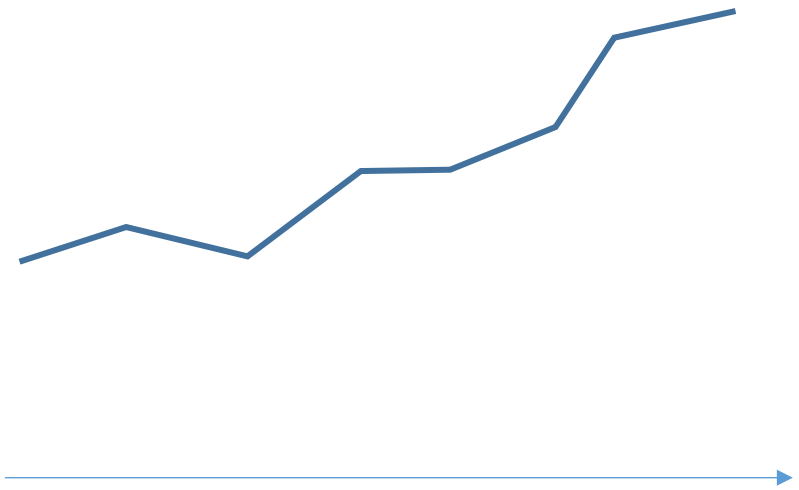

過去の量から，トレンドを分析し活用

# 時系列データ

**時系列データ**は，

**昨日の気温**は**15**度

**今日の気温**が**13**度

のように，**時間とともに，値が変化するデータ**

# 時系列データの例

| year | month | day | sn_value | s |
|---|---|---|---|---|
| 1848 | 12 | 23 | 353 | |
| 1848 | 12 | 24 | 240 | |
| 1848 | 12 | 25 | 275 | |
| 1848 | 12 | 26 | 352 | |
| 1848 | 12 | 27 | 268 | |
| 1848 | 12 | 28 | 285 | |
| 1848 | 12 | 29 | 343 | |
| 1848 | 12 | 30 | 340 | |
| 1848 | 12 | 31 | 238 | |
| 1849 | 1 | 1 | 287 | |

太陽の黒点数の変化

# 時系列データの特性

- **周期性**：　週単位，月単位，年単位
- **イベント**：　正月，クリスマス，４月頭
- **長期的な傾向**：　増加傾向，一定，減少傾向

- **誤差や，突発的な変化・変動**

# Facebook イベント数の分析例

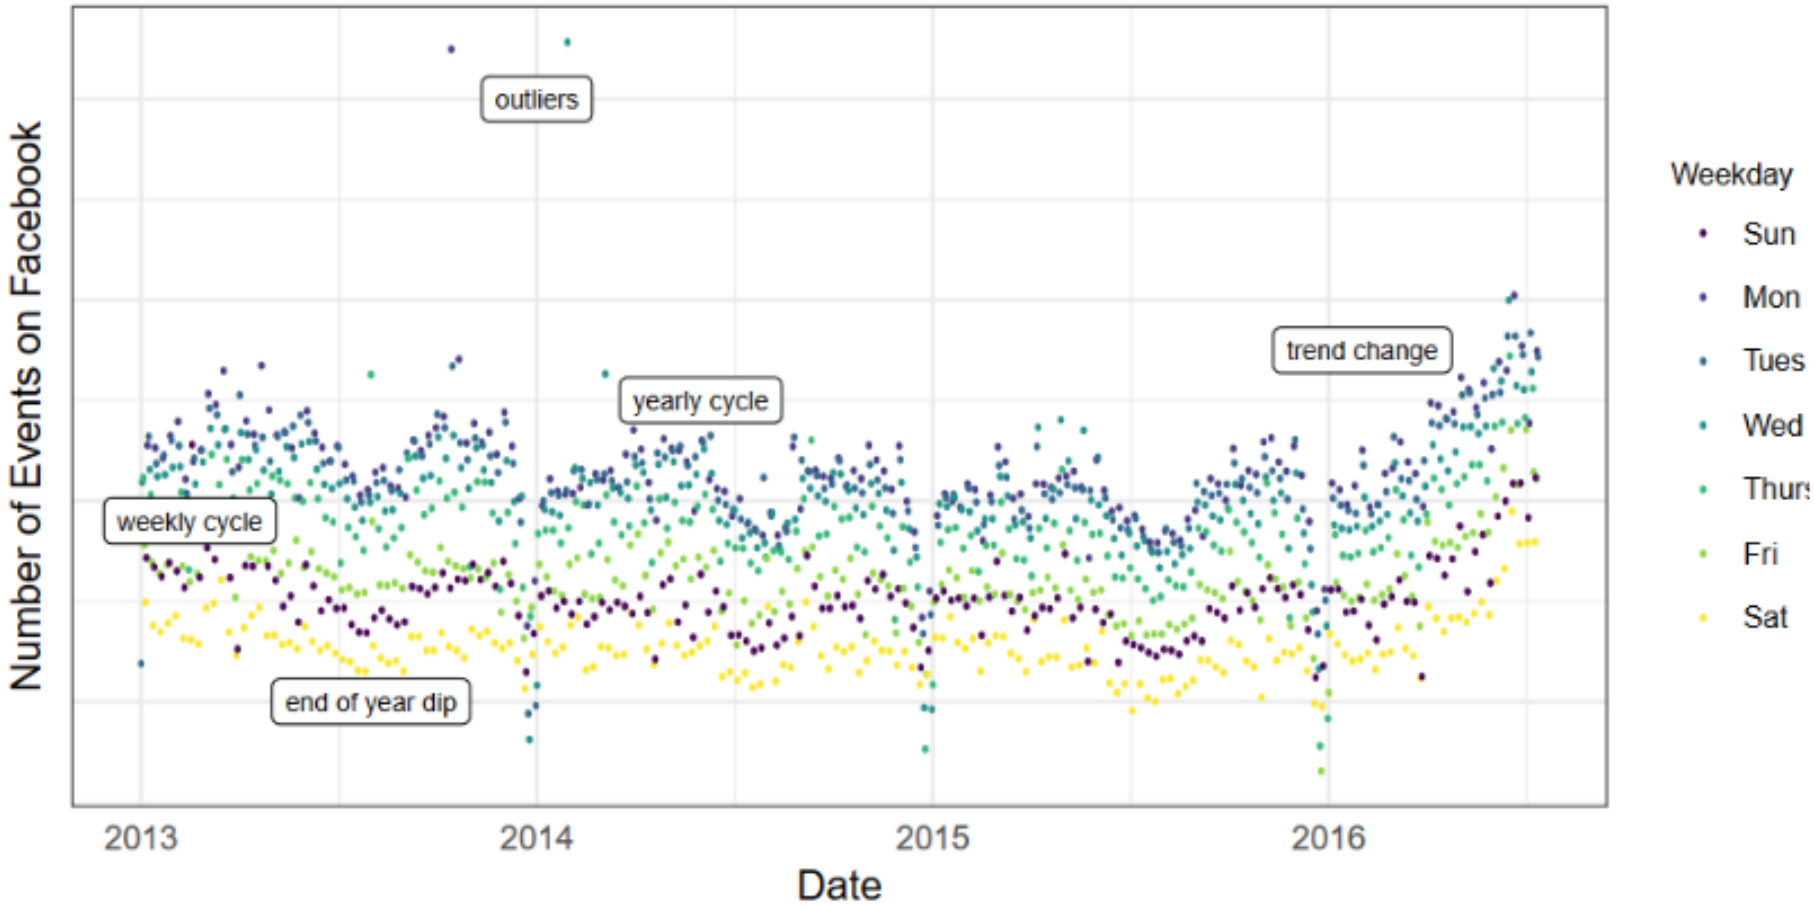


曜日で色を変えて**プロット**　⇒　曜日単の周期性を読み取る

Taylor SJ, Letham B. 2017. Forecasting at scale. PeerJ Preprints 5:e3190v2
https://doi.org/10.7287/peerj.preprints.3190v2

# Facebook イベント数の分析例

## 周期性の分析

元データをProphet で処理した結果

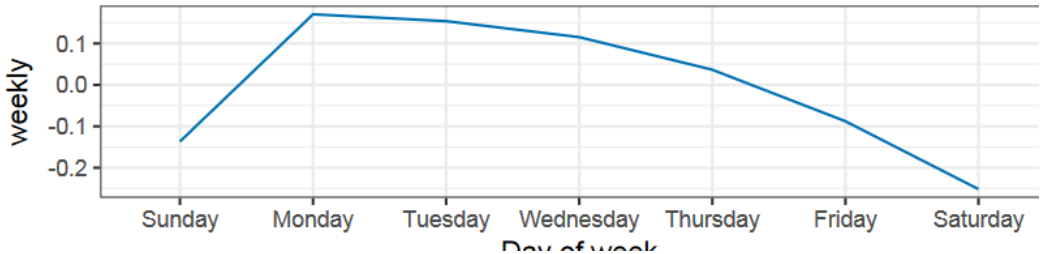


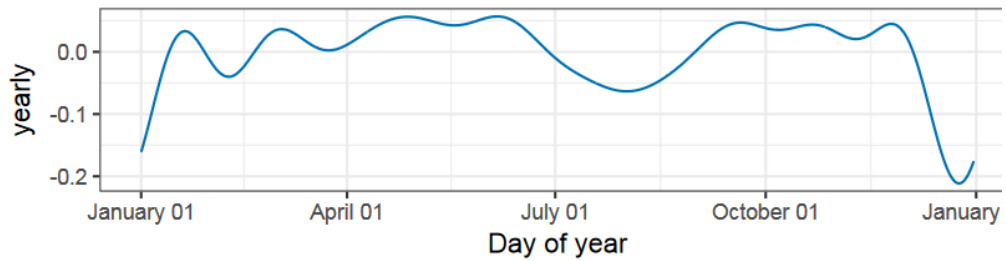


土日は少ない

年末年始は少ない

## トレンドの分析

元データをProphet で処理した結果

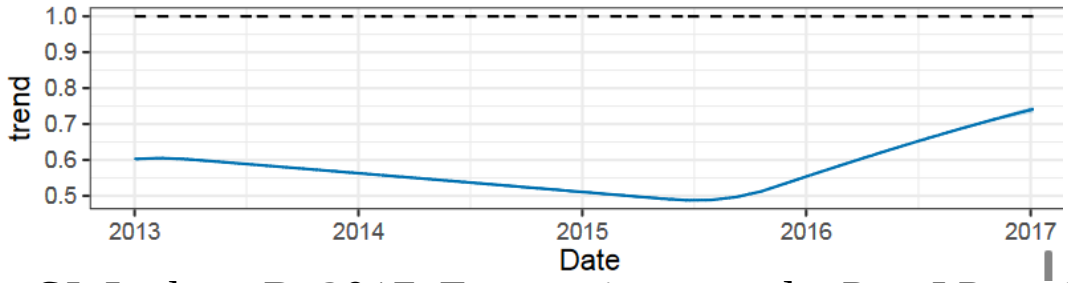


2015年からは増加

Taylor SJ, Letham B. 2017. Forecasting at scale. PeerJ Preprints 5:e3190v2
https://doi.org/10.7287/peerj.preprints.3190v2

# まとめ

- **時系列データ**は，**時間とともに，値が変化するデータ**
- **時系列データ**から，**周期性**や**トレンド**などを読み取ることができる

# 11-5. リカレントニューラルネットワークとLSTM

# リカレントニューラルネットワーク

**リカレントニューラルネットワーク**は
**回帰**により**過去の情報を保持**する
ニューラルネットワーク

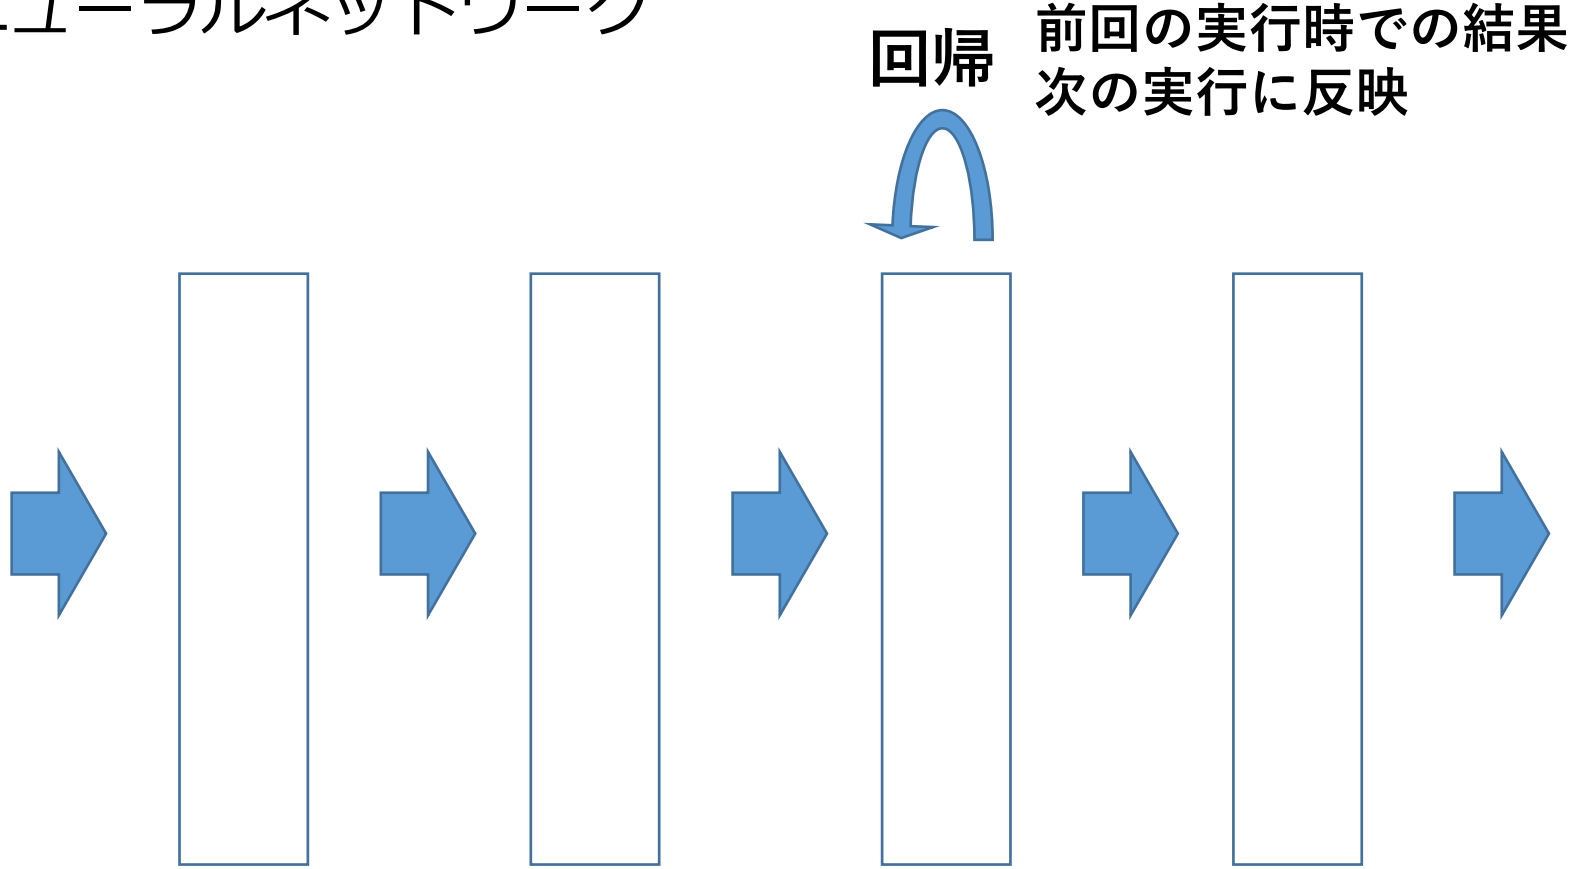

# リカレントニューラルネットワーク

- **回帰**により，**過去の情報を保持**．前回の実行時での結果の一部が，次の実行に反映される

- **時系列データ**など，**データの並びを扱う能力**を持つ

# フィードフォワードとリカレントニューラルネットワーク

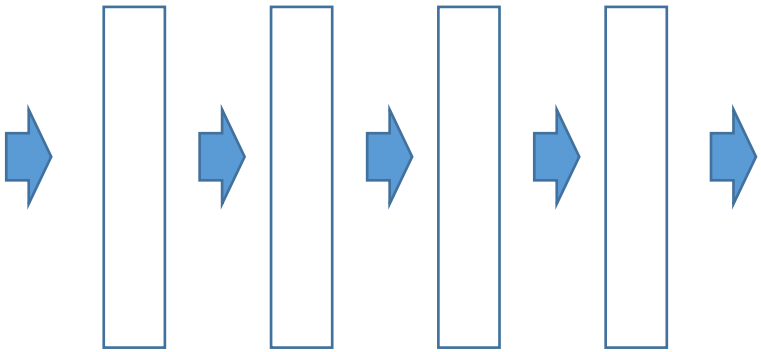

フィードフォワード
ネットワーク

ある層の出力を，次の層が受け取る

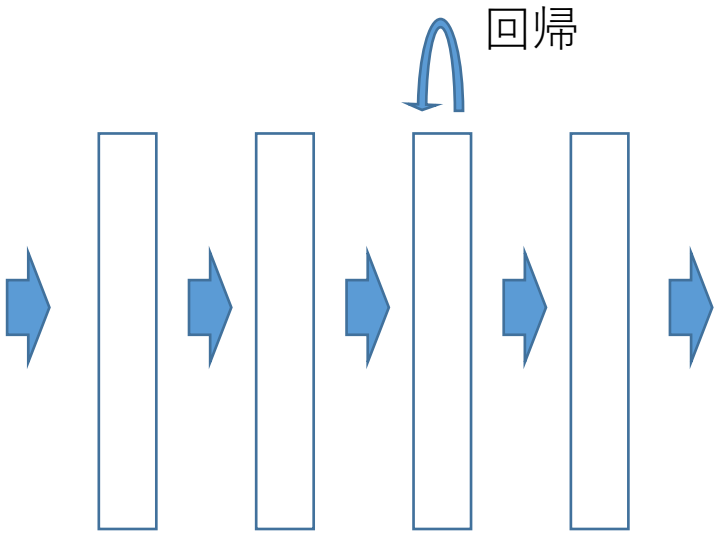


リカレントニューラルネットワーク

**回帰**により，前回の実行時での結果の一部が，次の実行に反映される．

# リカレントニューラルネットワークの動作イメージ ①

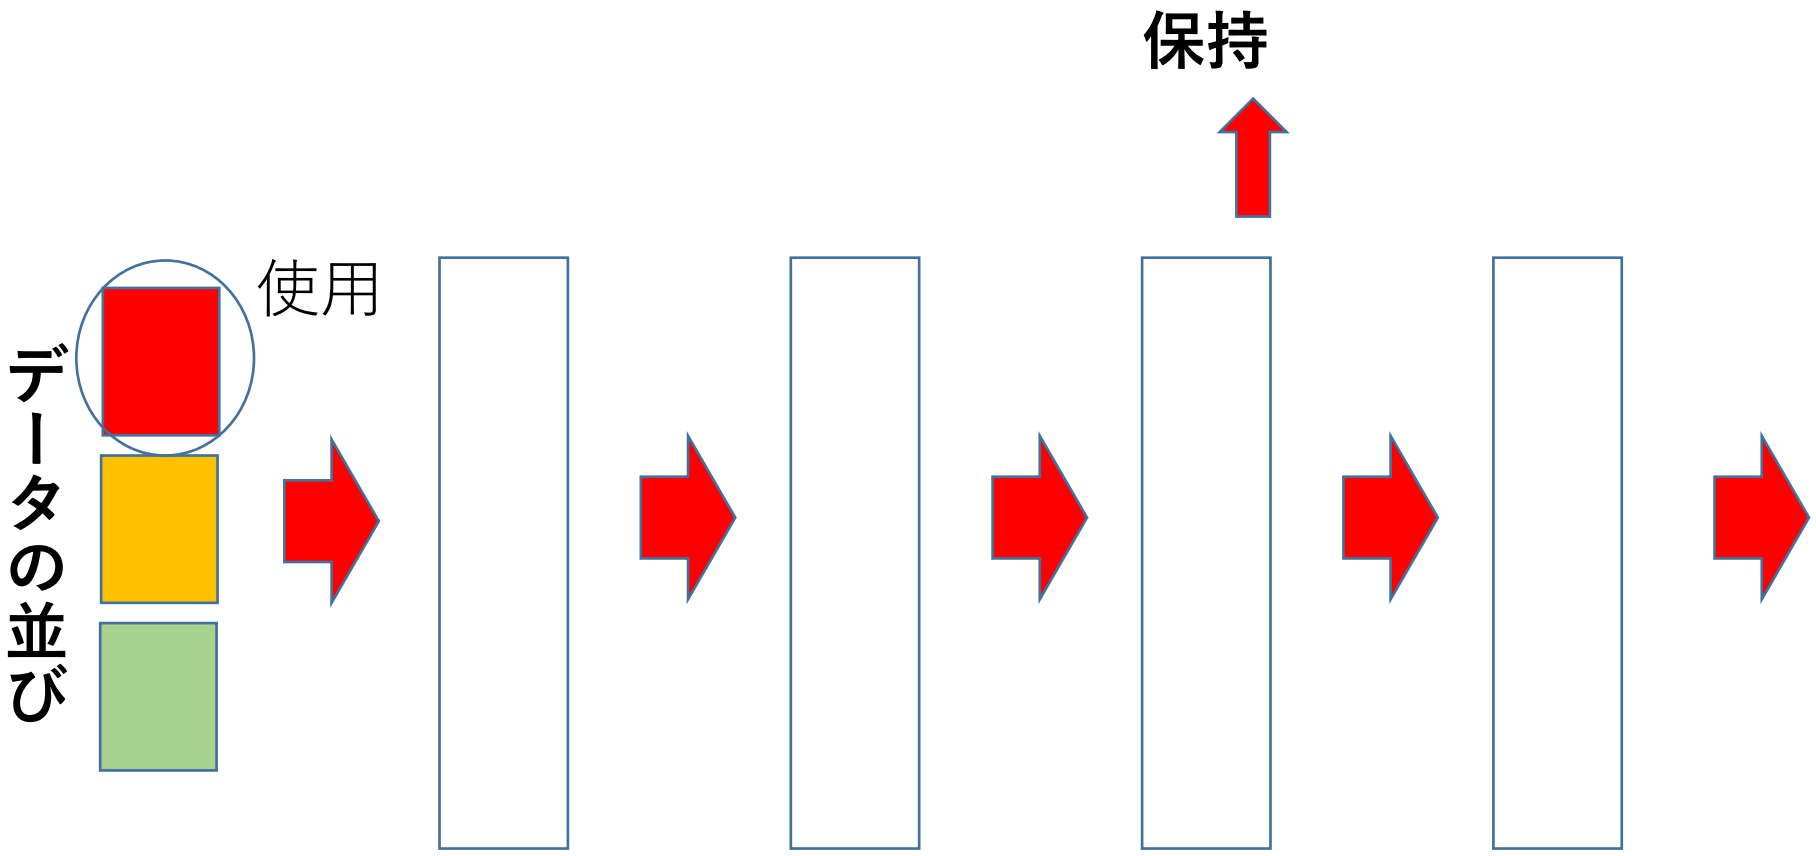

# リカレントニューラルネットワークの動作イメージ ②

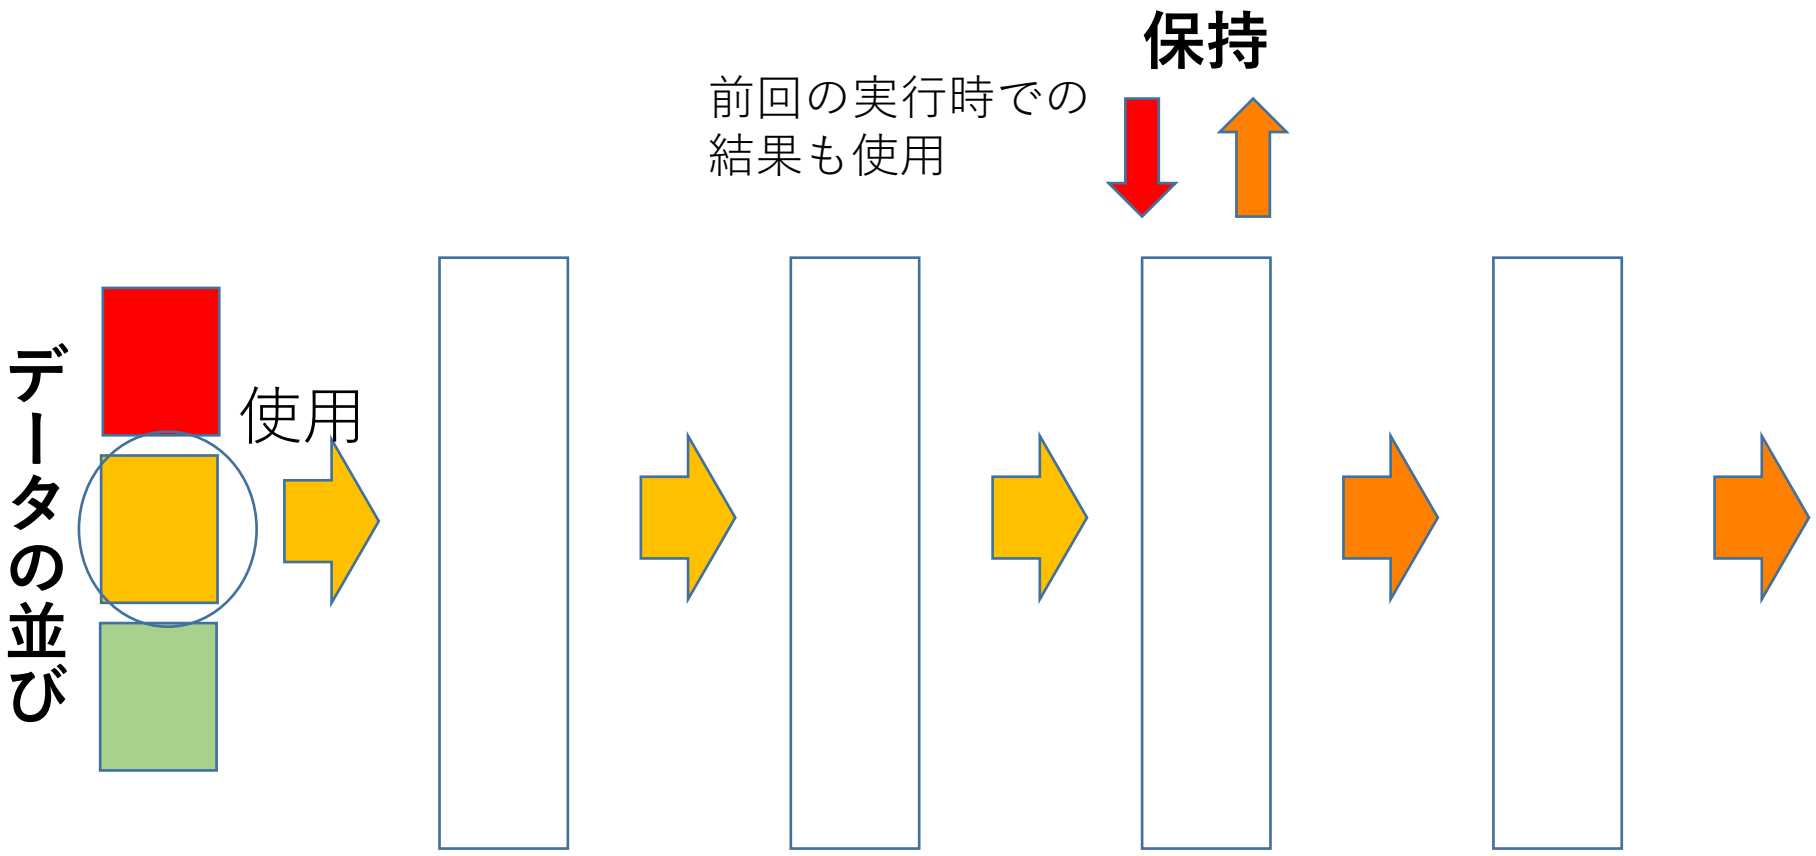

# リカレントニューラルネットワークの動作イメージ ③

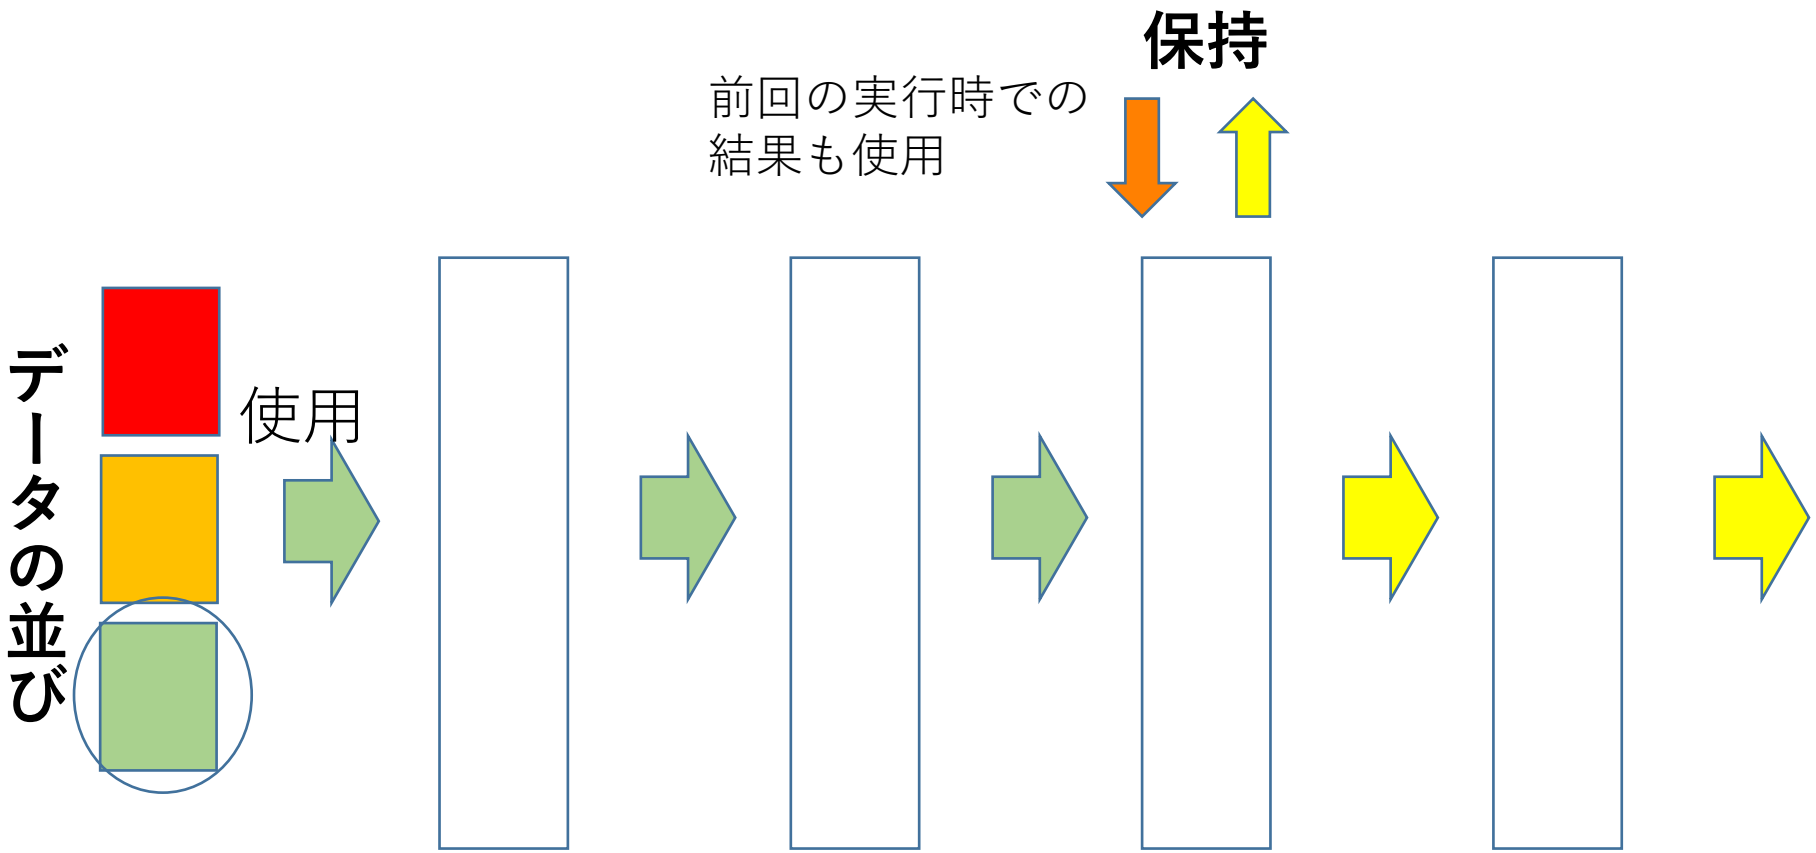

# リカレントニューラルネットワークの応用

- **時系列データを用いた予測**

  データの並びを扱う

- **手書き文字認識**

  筆記の動きを扱う

- **音声認識**

  音の並びを扱う

- **「言葉」の理解，翻訳，テキスト生成，プログラム生成**

  単語の並びを扱う

# LSTM 誕生の背景

- **リカレントニューラルネットワーク**では，**長期に及ぶ**過去の情報の保持が困難 （1991年, 1994年に理論的根拠が示された）

- 長期に及ぶ過去の情報を保持しようとすると，問題が発生（勾配消失や勾配爆発により，学習がうまくいかなくなる）

Y Bengio 1, P Simard, P Frasconi,
Learning long-term dependencies with gradient descent is difficult,
IEEE Trans Neural Netw, 1994;5(2):157-66, doi: 10.1109/72.279181, 1994.

# LSTM の仕組み

LSTM は，リカレント
ニューラルネットワークの一種

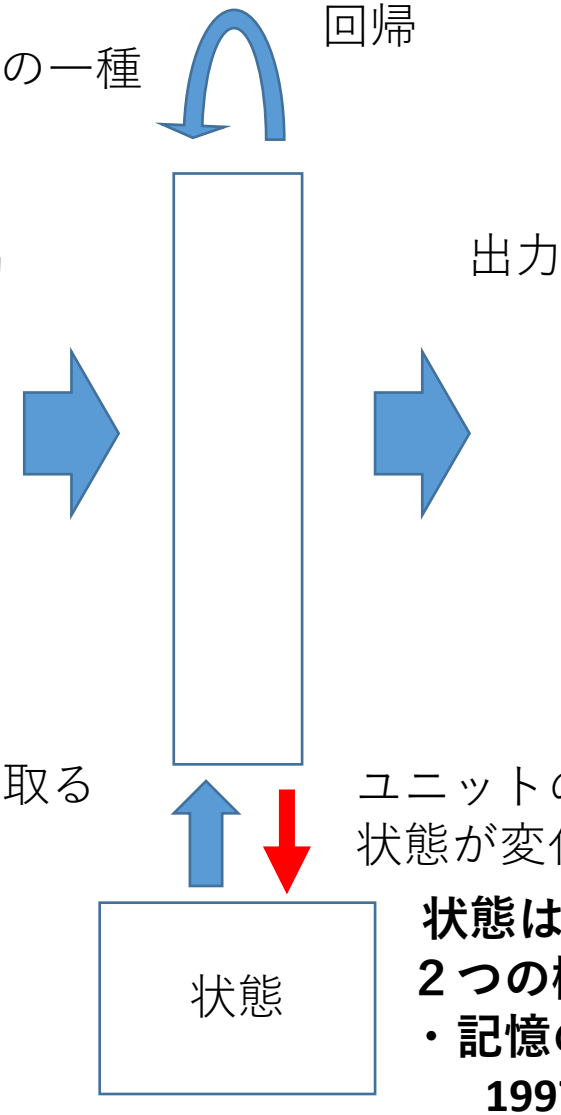


**状態は「メモリセル」に記憶されている**

**2 つの機能**

- **記憶の持続 (constant error carousel)**
  **1997年発表**
- **記憶の忘却 (forget gate)**
  **1999 年発表**

# LSTM の特徴

- **LSTM**は，**リカレントニューラルネットワーク**の一種
- **メモリセル**は，状態として，**同じ値の長期の記憶の保持**を可能とする
- **リカレントニューラルネットワーク**の**弱点**ともいわれる「**長期に及ぶ**過去の情報の保持が困難」であることを**解決**
- 1997, 1999年発表の技術．その後，手書き文字認識，音声認識，自動翻訳など数多くの応用

# まとめ

- **時系列データ**は，**時間とともに，値が変化するデータ**
- **時系列データ**から，**周期性**や**トレンド**などを読み取ることができる
- **リカレントニューラルネットワーク**
  - **回帰**により，**過去の情報を保持**
  - **時系列データ**など**データの並びを扱う能力**を持つ

    予測，手書き文字認識，音声認識，言葉の理解，翻訳，テキスト生成，プログラム生成　など

  - **長期に及ぶ過去の情報の保持**のため，**LSTM** が考案された

# 11-6. 未来予測

# ① LSTM による予測

1. 使用するページ:

https://colab.research.google.com/drive/1qxh5l0iEPUm-QRTuEBSqBLd3V9KvqItK?usp=sharing

2. 必要な事前知識

LSTM もニューラルネットワークの一種であり，学習のさせ方などは，ふつうのニューラルネットワークと同じであること

3. 各自で実行すること

実際に実行し、予測を試す.

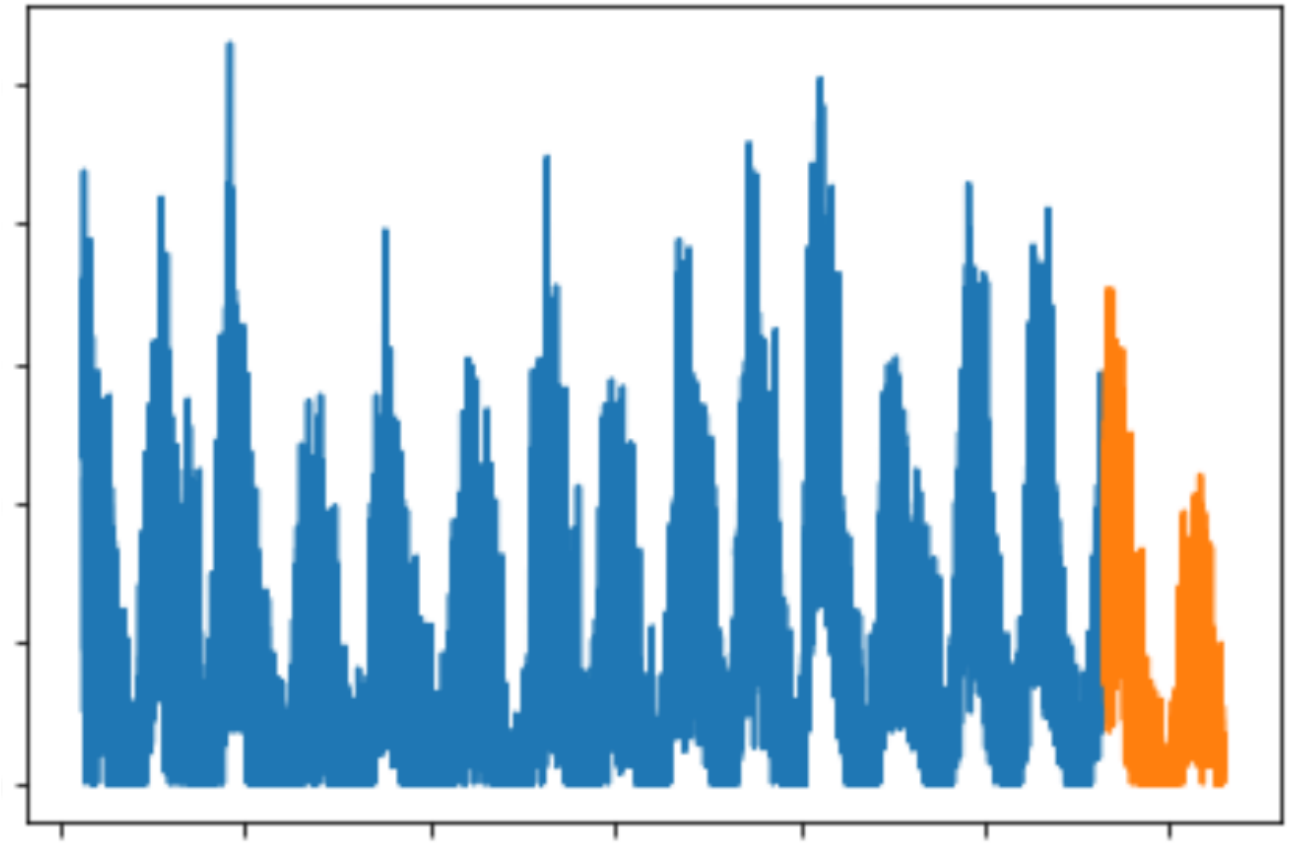

太陽の黒点数の変化　　予測

1848年～1999年のデータを用いて，2000年以降を予測（ディープニューラルネットワークによる予測）

予測では，過去の観測値から「次の日（つまり一日分）の予測」を行うことを繰り返している．

# みどころ

10日分のデータから
11日後を予測

これを
上手く使って

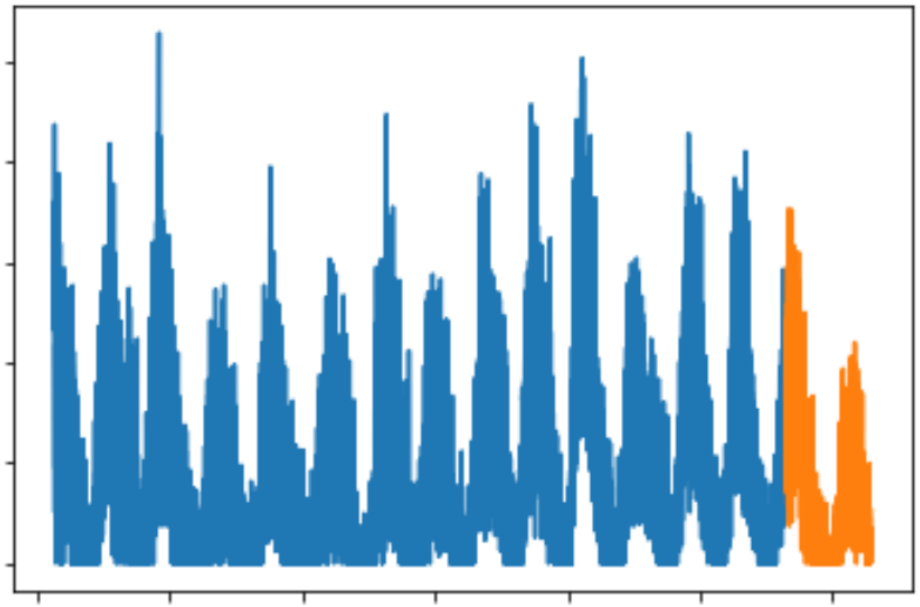

太陽の黒点
数の変化

予測

1848年～1999年のデータを用いて，2000年以降を予測

①

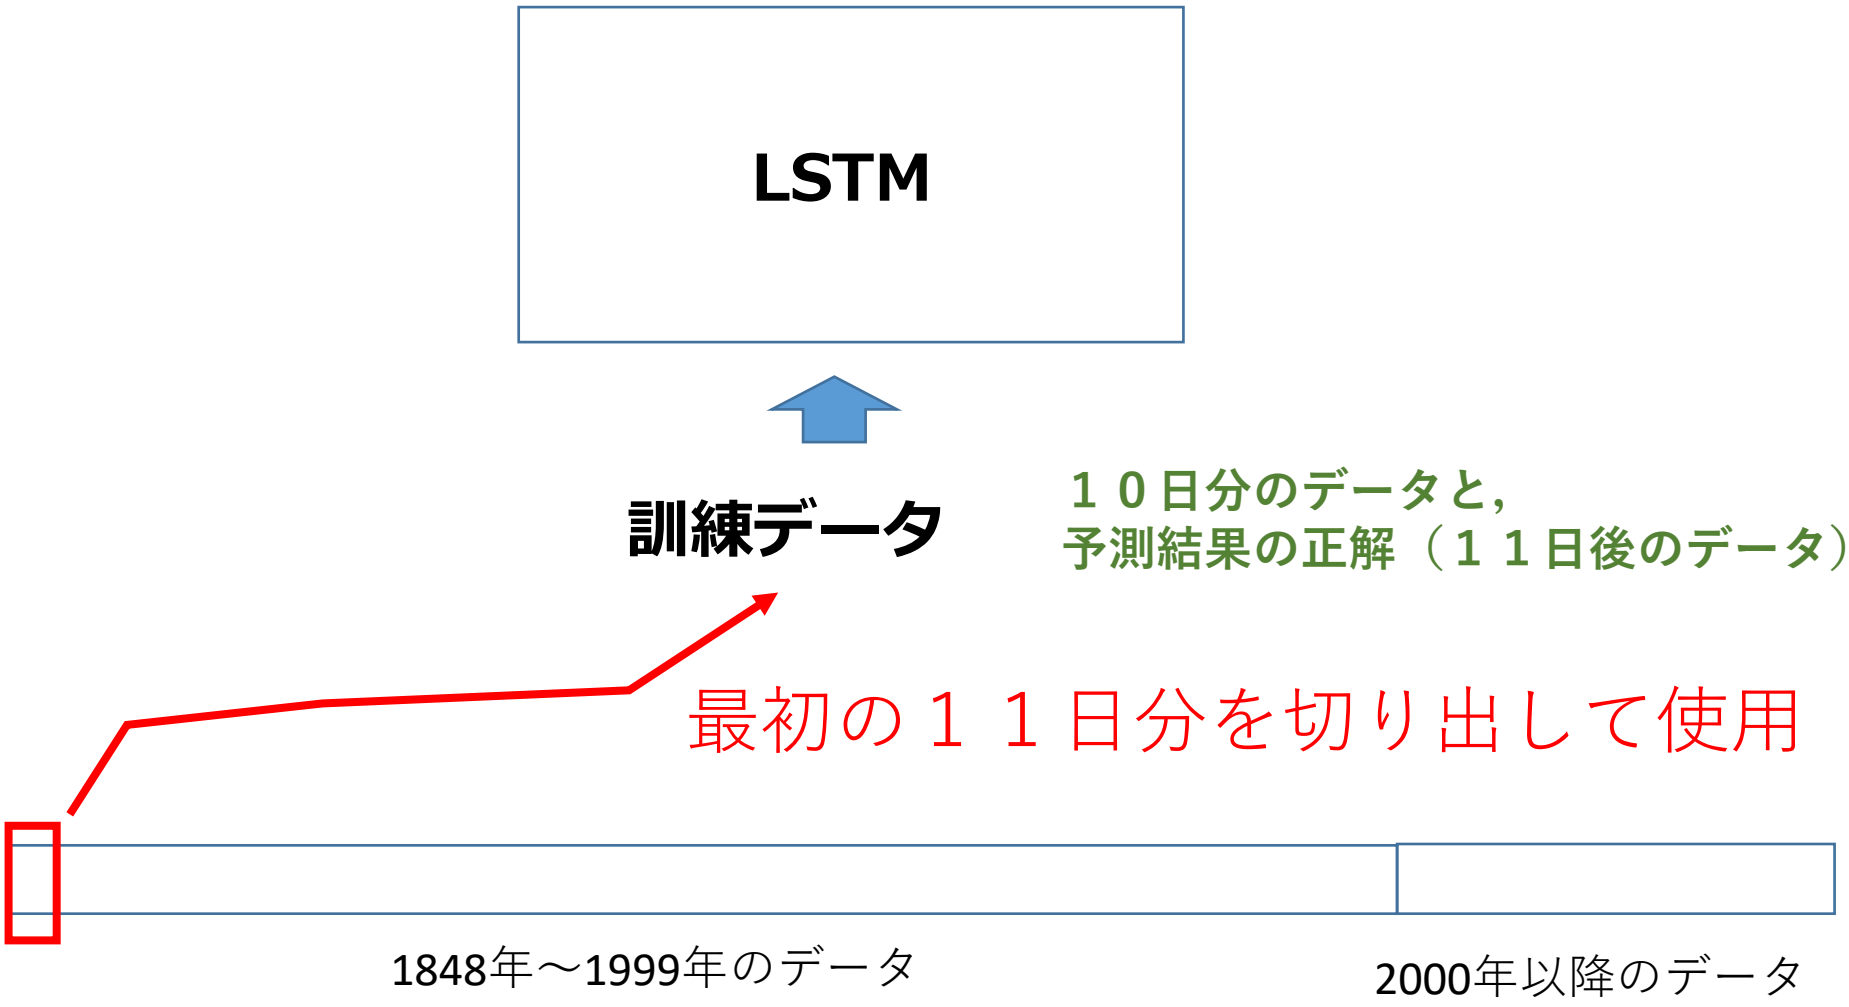


LSTM での学習の繰り返し

②

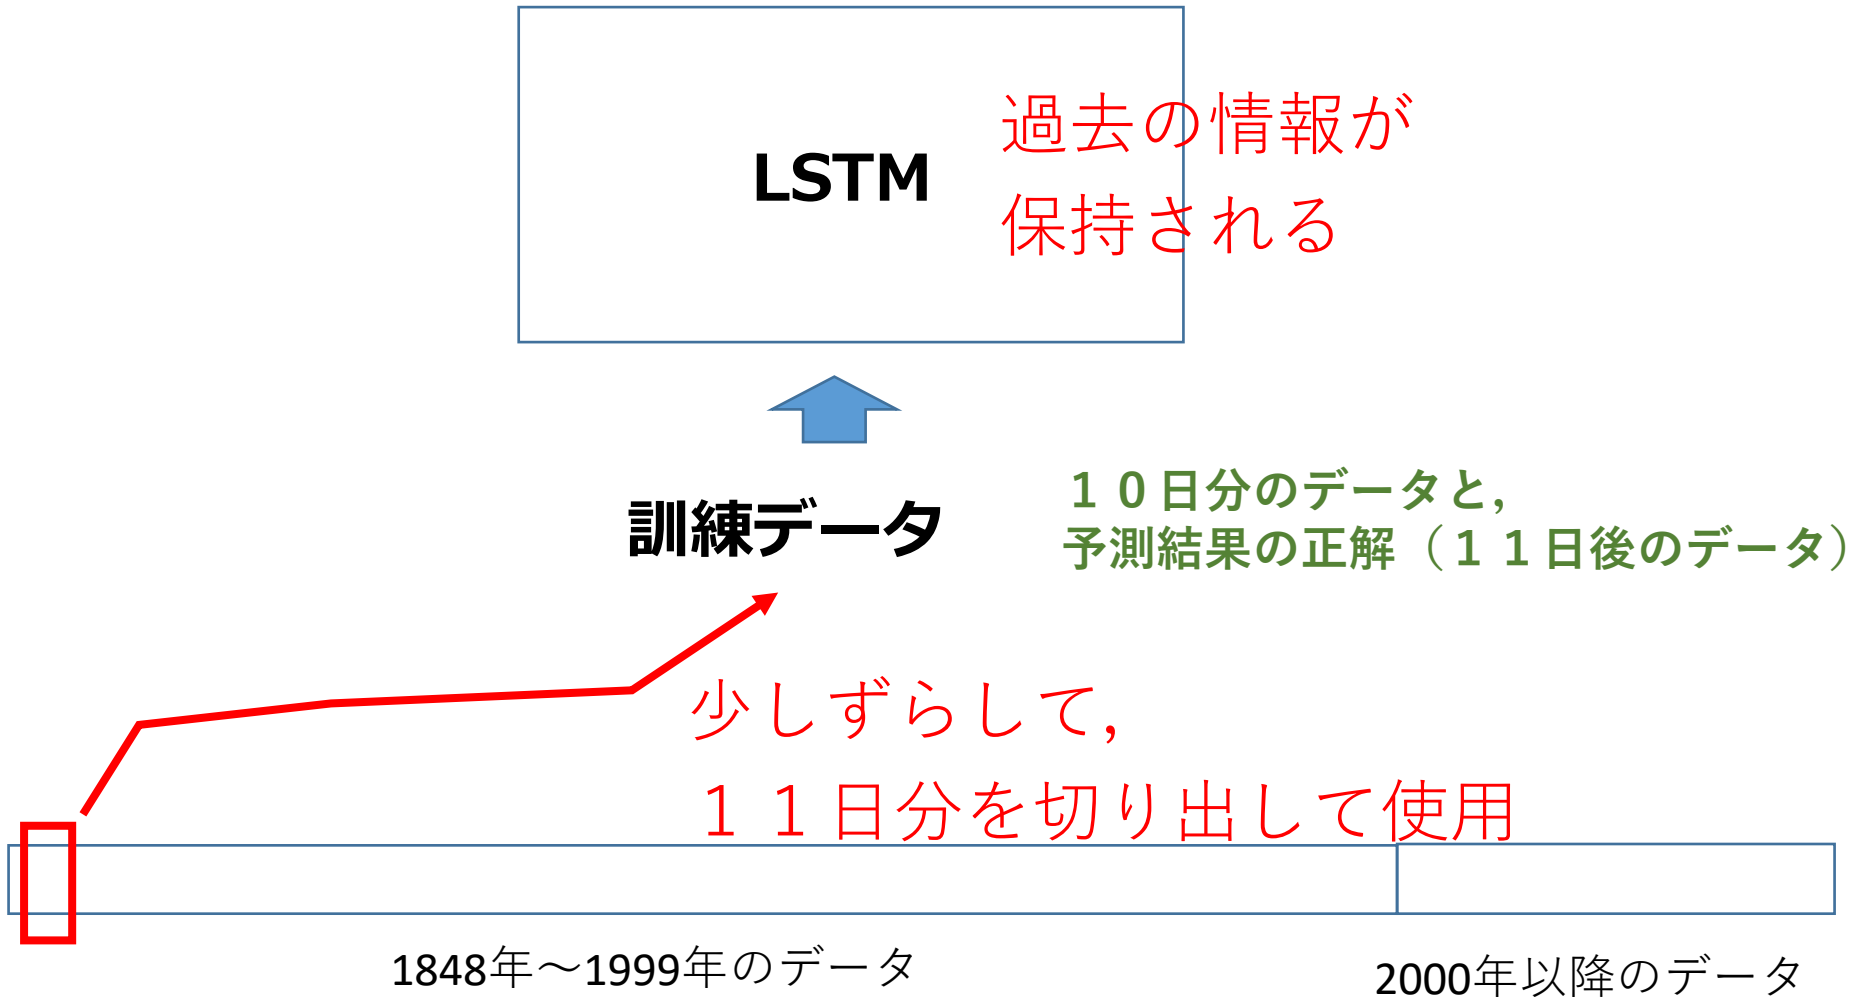


LSTM での学習の繰り返し

③

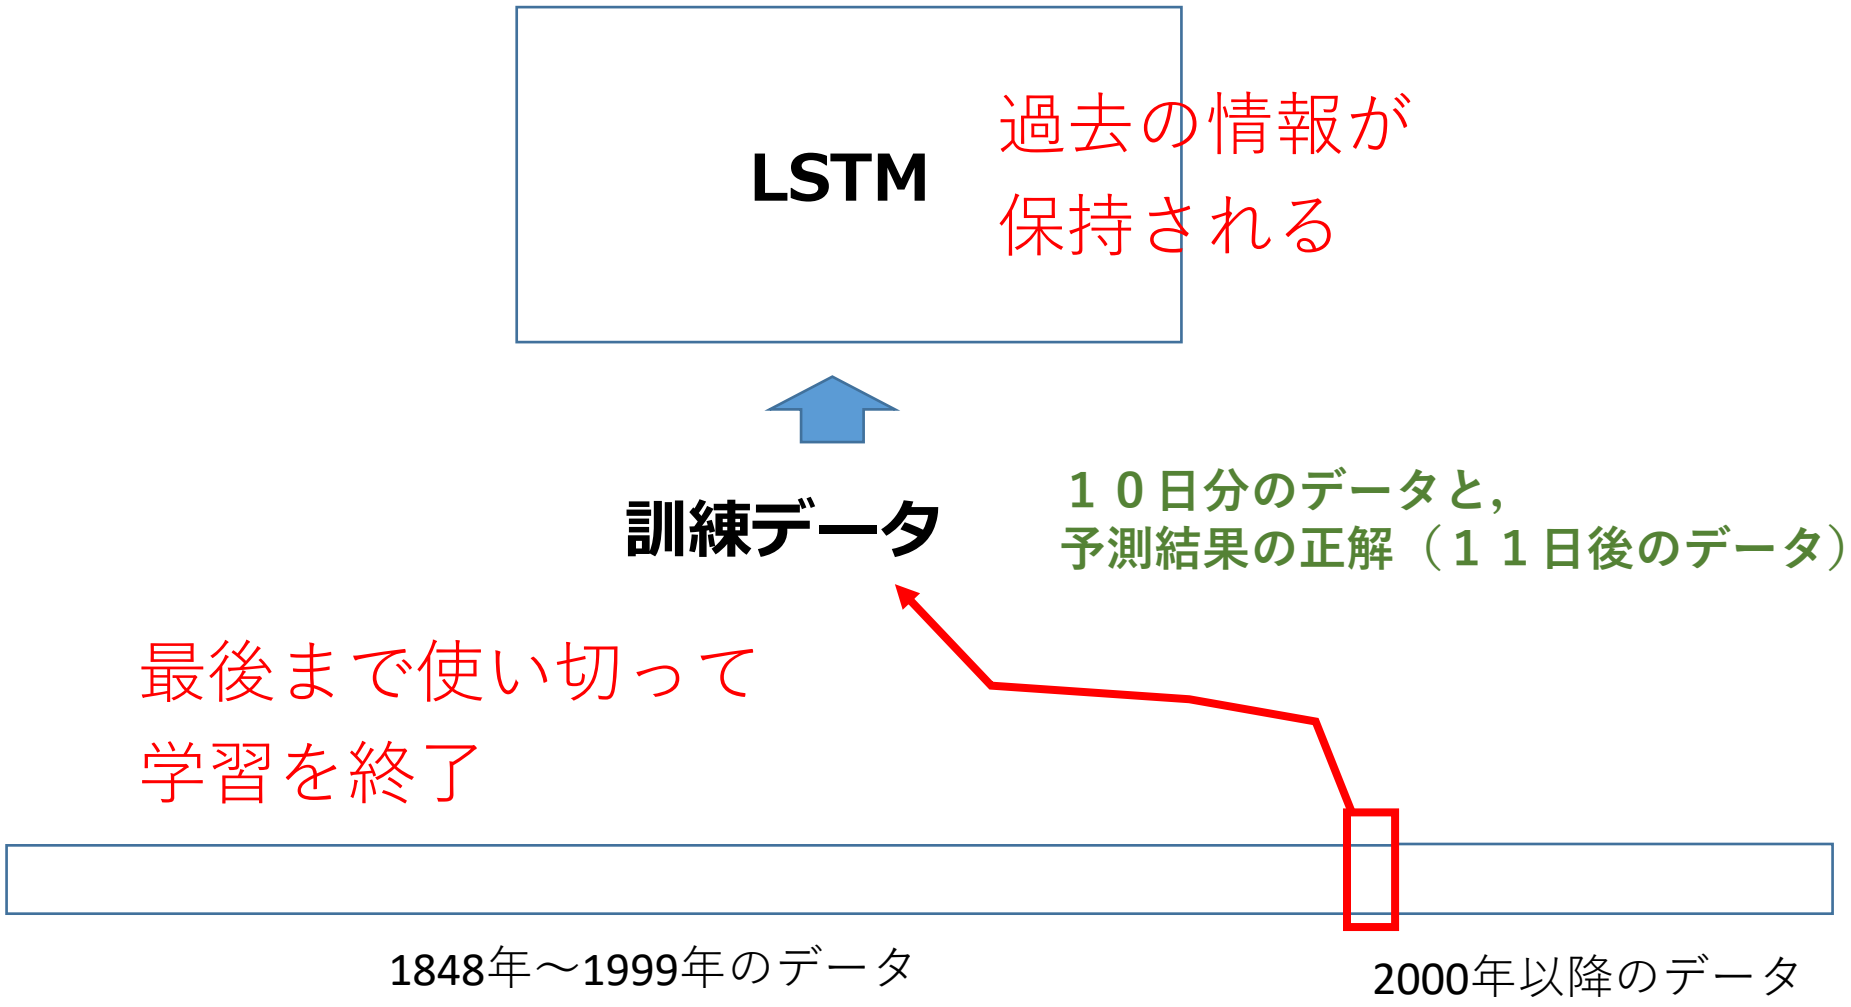


LSTM での学習の繰り返し

④

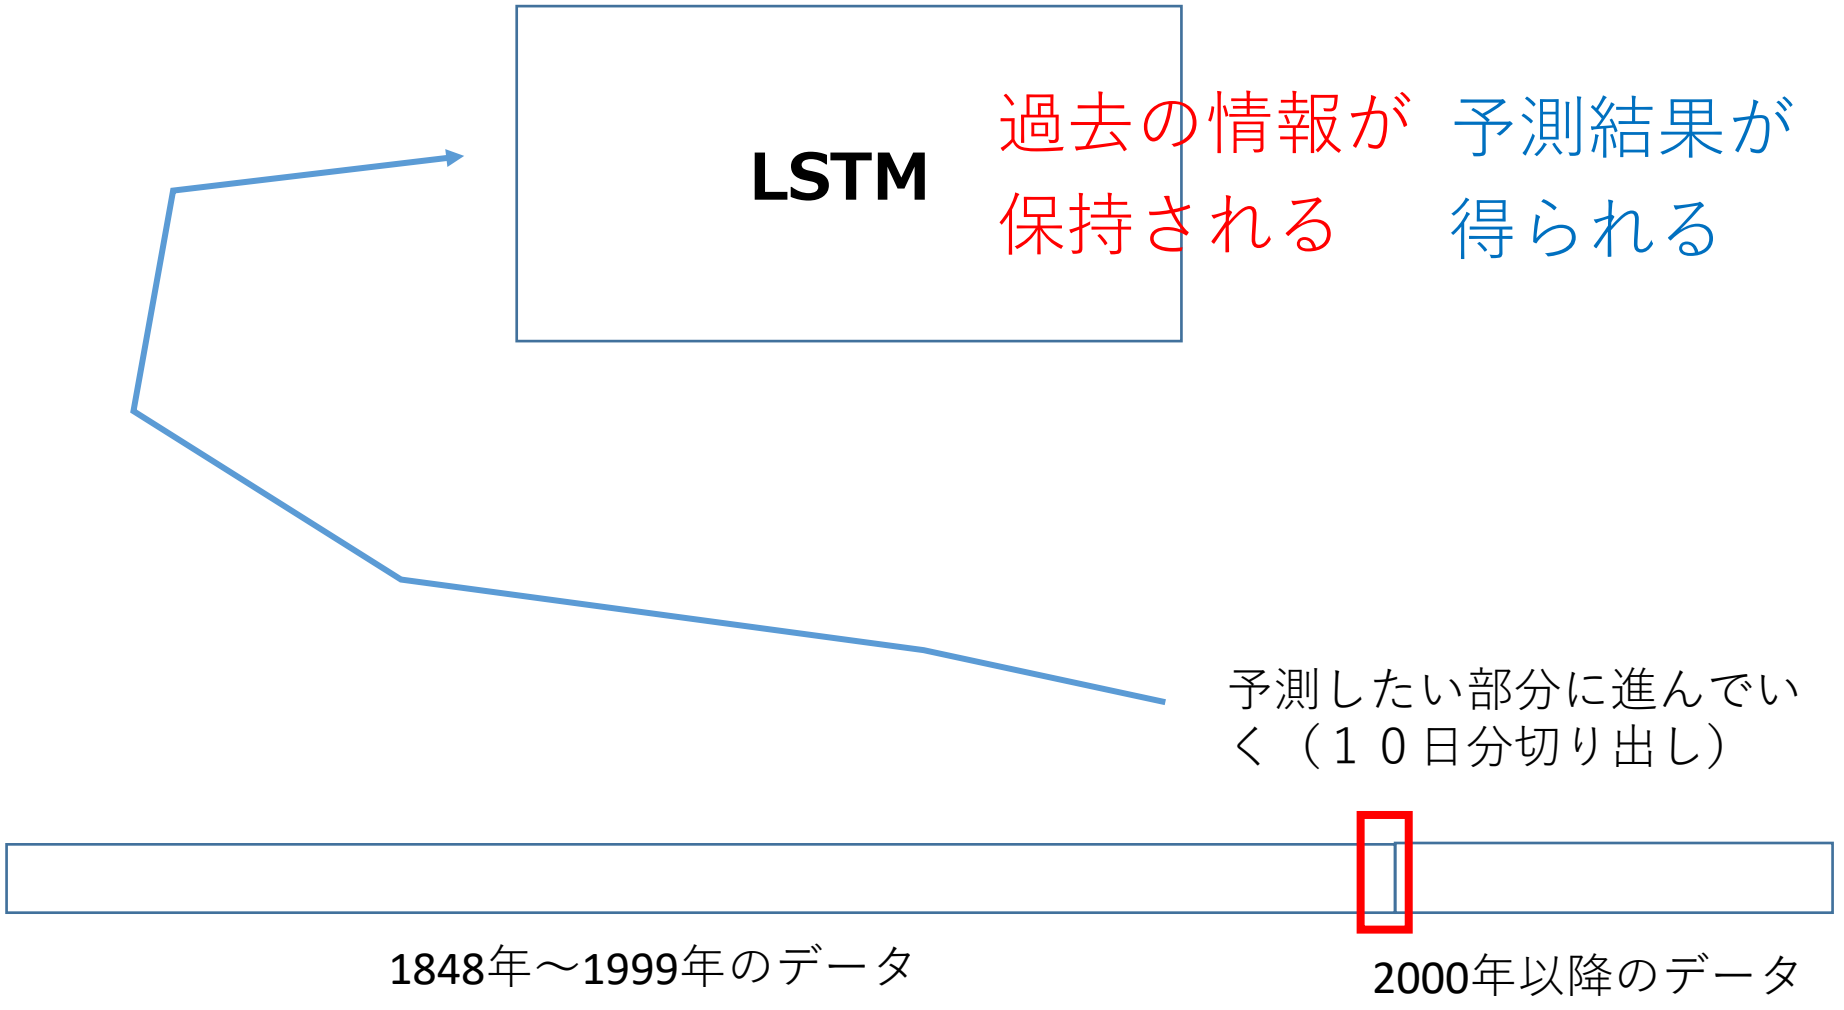
LSTM
過去の情報が保持される
予測結果が得られる
予測したい部分に進んでいく（１０日分切り出し）
1848年～1999年のデータ
2000年以降のデータ

LSTMによる予測

⑤

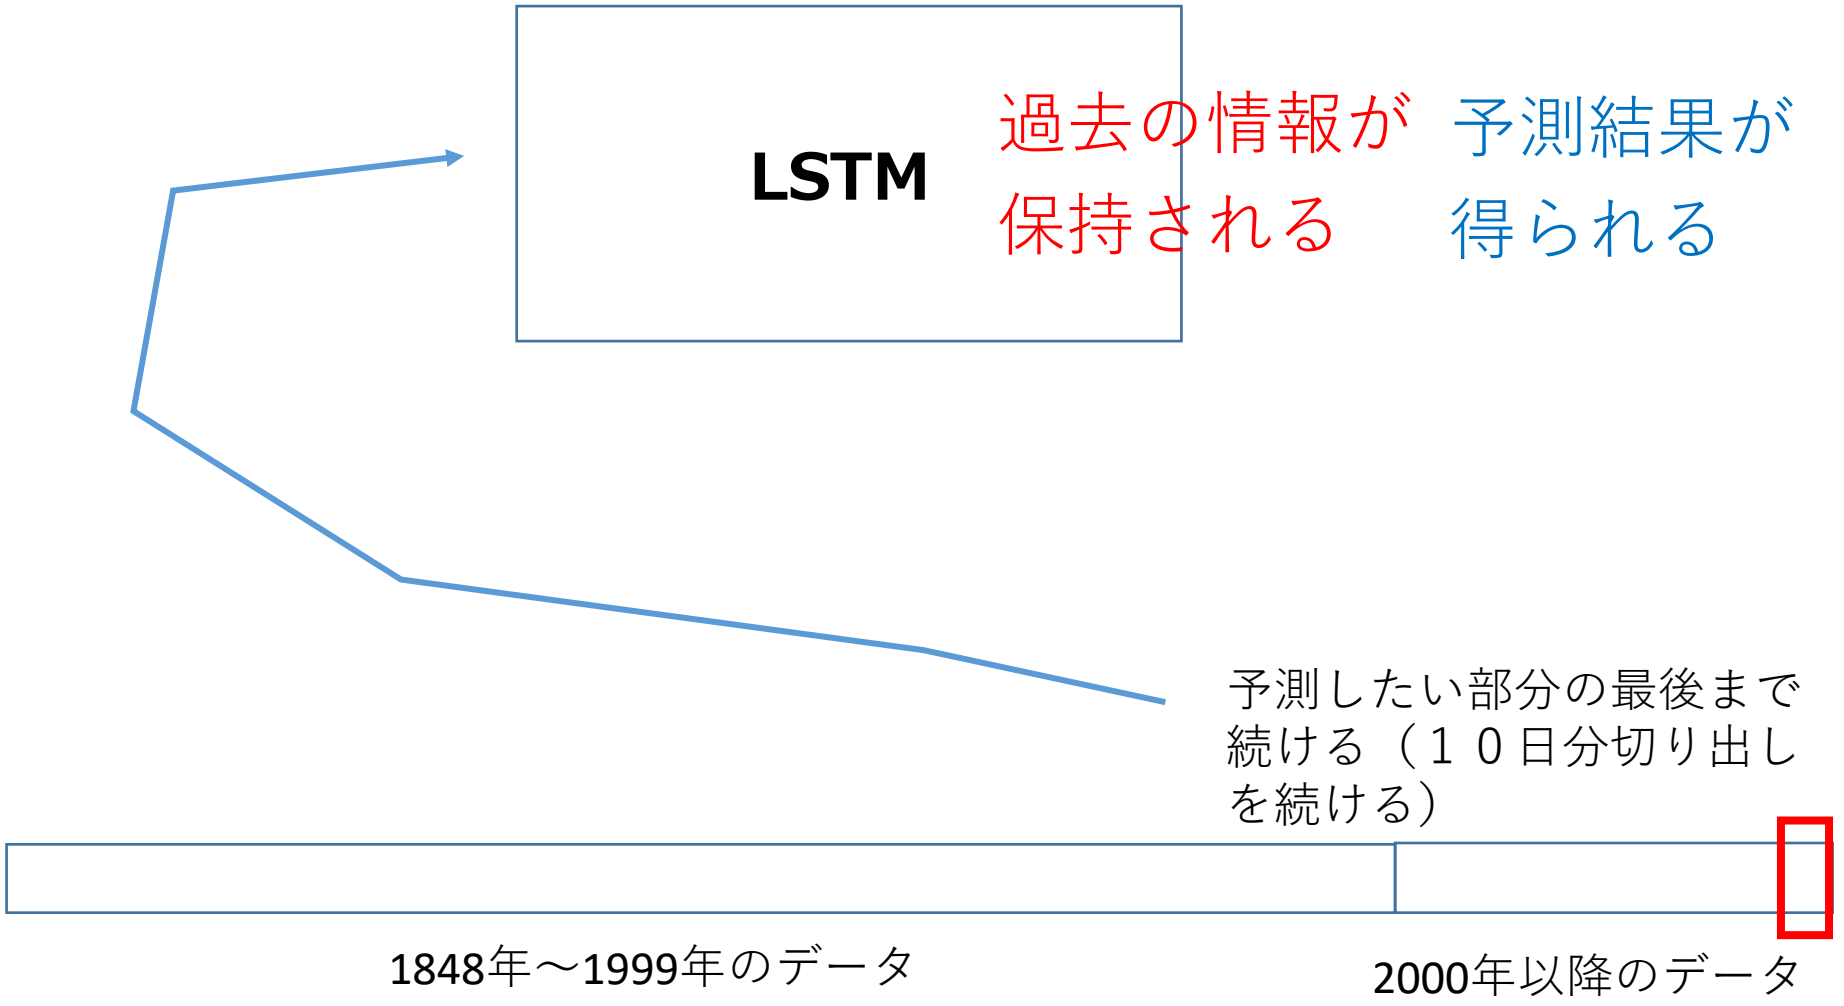
LSTM
過去の情報が保持される
予測結果が得られる
予測したい部分の最後まで続ける（１０日分切り出しを続ける）
1848年～1999年のデータ
2000年以降のデータ

LSTMによる予測

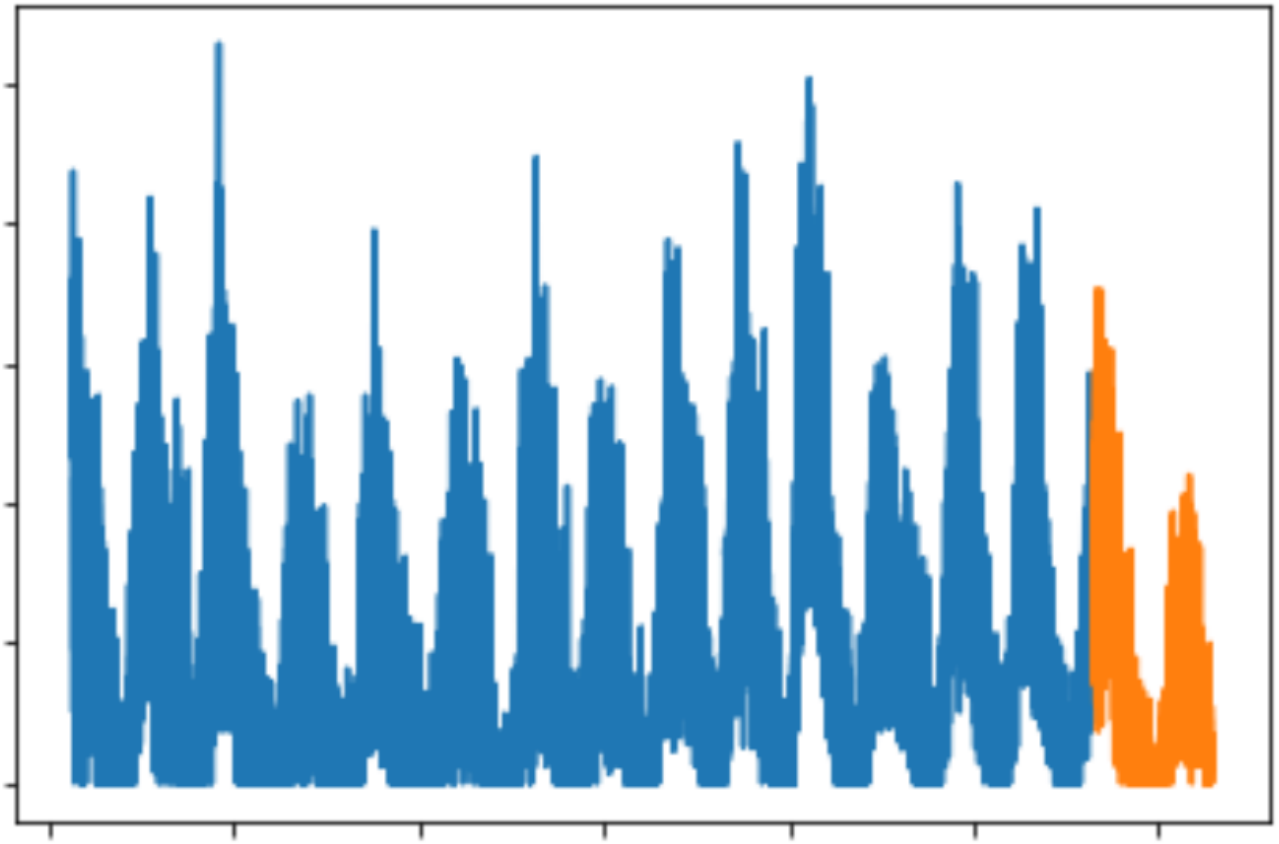

太陽の黒点数の変化　　予測

1848年～1999年のデータを用いて，2000年以降を予測
（ディープニューラルネットワークによる予測）

# 全体まとめ

- **教師あり学習**は，訓練データ(x, y)を用いて行われる．（入力xとその正解y）
- **学習**では，**訓練データ**を用いて繰り返しモデルが更新され、各更新後に**検証データを用いて性能が評価**されます。
- **時系列データ**は，**時間とともに値が変化するデータ**であり、**周期性**や**トレンド**を分析するために使用される．
- **時系列データの分析**に，**リカレントニューラルネットワーク**（RNN）が適用される場合がある。**過去の情報から未来を予測**することも可能．
- リカレントニューラルネットワークの一種であるLSTMは、状態の保持と忘却を行う機能を持つ．リカレントニューラルネットワークが持つ「長期に及ぶ過去の情報の保持が困難」であるという問題を解決．

# 授業の学ぶ意義と満足感

- 教師あり学習の概要を、実践的な演習で修得。機械学習の基本を体験的に理解。学びの楽しさを実感。
- 時系列データの特性、分析手法を学び、実社会での活用可能性を確認。
- リカレントニューラルネットワークやLSTMの仕組みを理解。AIによる時系列データ解析の実践的手法を知り、AIエンジニアとしてのスキルを向上。
- 実データを使った演習で、データから価値を引き出すAIエンジニアとしてのスキルを向上。学習意欲も向上。