

5.コンピュータビジョンの ためのディープラーニング

17t4055g 築地俊平

5.1 畳み込みニューラルネットワークの紹介

本節は

CNNの簡単なプログラムを動かし、内容を理解していく

5.1 畳み込みニューラルネットワークの紹介

- 基本的なCNNのインスタンス化

```
>>> model1 = models.Sequential()
>>>
>>> model1.add(layers.Conv2D(32,(3,3),activation='relu',input_shape=(28,28,1)))
>>> model1.add(layers.MaxPooling2D((2,2)))
>>> model1.add(layers.Conv2D(64,(3,3),activation='relu'))
>>> model1.add(layers.MaxPooling2D((2,2)))
>>>
>>> model1.add(layers.Conv2D(32,(3,3),activation='relu',input_shape=(28,28,1)))
```

—

5.1 畳み込みニューラルネットワークの紹介

```
>>> model1.summary()
```

```
Model: "sequential_3"
```

Layer (type)	Output Shape	Param #
=====		
conv2d_4 (Conv2D)	(None, 26, 26, 32)	320

max_pooling2d_4 (MaxPooling2)	(None, 13, 13, 32)	0

conv2d_5 (Conv2D)	(None, 11, 11, 64)	18496

max_pooling2d_5 (MaxPooling2)	(None, 5, 5, 64)	0

conv2d_6 (Conv2D)	(None, 3, 3, 32)	18464
=====		
Total params: 37,280		
Trainable params: 37,280		
Non-trainable params: 0		

5.1 畳み込みニューラルネットワークの紹介

```
>>> model1.add(layers.Flatten())
```

```
>>> model1.add(layers.Dense(64,activation='relu'))
```

```
>>> model1.add(layers.Dense(10,activation='softmax'))
```

10個の出力を持つ最終層とソフトマックス活性化関数を使用することで10ユニットの分類を行う

5.1 畳み込みニューラルネットワークの紹介

```
>>> model1.summary()
```

```
Model: "sequential_3"
```

Layer (type)	Output Shape	Param #
--------------	--------------	---------

conv2d_4 (Conv2D)	(None, 26, 26, 32)	320
-------------------	--------------------	-----

max_pooling2d_4 (MaxPooling2)	(None, 13, 13, 32)	0
-------------------------------	--------------------	---

conv2d_5 (Conv2D)	(None, 11, 11, 64)	18496
-------------------	--------------------	-------

max_pooling2d_5 (MaxPooling2)	(None, 5, 5, 64)	0
-------------------------------	------------------	---

conv2d_6 (Conv2D)	(None, 3, 3, 32)	18464
-------------------	------------------	-------

flatten_1 (Flatten)	(None, 288)	0
---------------------	-------------	---

dense_1 (Dense)	(None, 64)	18496
-----------------	------------	-------

dense_2 (Dense)	(None, 10)	650
-----------------	------------	-----

```
Total params: 56,426
```

```
Trainable params: 56,426
```

```
Non-trainable params: 0
```

5.1 畳み込みニューラルネットワークの紹介

```
17 from keras.datasets import mnist
18 from keras.utils import to_categorical
19
20 (train_images,train_labels),(test_images,test_labels)=mnist.load_data()
21
22 train_images=train_images.reshape((60000,28,28,1))
23 train_images=train_images.astype('float32')/255
24
25 test_images=test_images.reshape((10000,28,28,1))
26 test_images=test_images.astype('float32')/255
27
28 train_images = to_categorical(train_labels)
29 test_images = to_categorical(test_labels)
30
31 model.compile(optimizer = 'rmsprop',loss='categorical_crossentropy',metrics=['accuracy'])
32 model.fit(train_images,train_labels,epochs=5,batch_size=64)
33
```

5.1 畳み込みニューラルネットワークの紹介

```
>>>test_loss,test_acc=model.evaluate(test_images.test_labels)
```

```
>>>test_acc
```

```
0.9931999999999997
```

2章の全結合ネットワークの正解率97.8%なので、精度が上がっている。

5.1.1 畳み込み演算

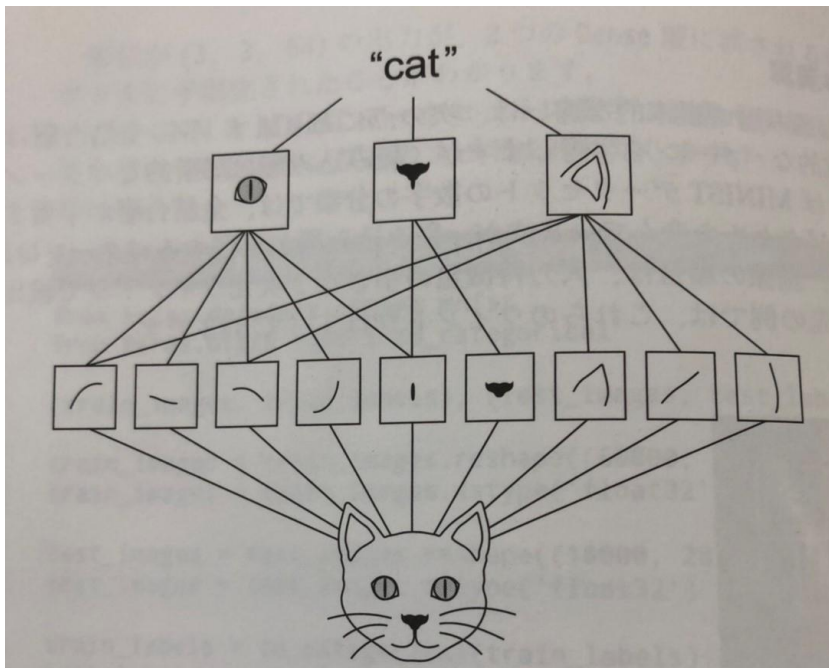
- 全結合層と畳み込み層の違い
 - 全結合層…入力特徴空間からパターンを学習
 - 畳み込み層…局所的なパターンを学習

5.1.1 畳み込み演算

- CNNの特徴

→CNNが学習するパターンは移動不変

→CNNはパターンの区間階層を学習できる



局所的なエッジが目や耳といった局所的な物体と結合される→猫

5.1.1 畳み込み演算

畳み込み演算は

2つの空間軸（幅と高さ）と1つの軸（チャンネル軸）に基づき特徴マップ（feature map）と呼ばれる3次元テンソルに対して実行される。

5.1.1 畳み込み演算

MNISTの例

入力…畳み込み層はサイズが(28,28,1)の特徴マップ

出力…サイズ(26,26,32)と特徴マップ

32個の出力フィルターはそれぞれ26×26グリッドの値を含んでいる

5.1.1 畳み込み演算

畳み込みは二つのパラメータで定義される

- ・ 入力から抽出されたパッチのサイズ
→ 通常は 3×3 か 5×5
- ・ 出力特徴マップの深さ
→ 畳み込みによって計算されるフィルタの数

KerasConv2D層では
Conv2D(output_depth,(window_height,window_width))で定義される

5.1.1 畳み込み演算

サイズが 3×3 のウィンドウをスライド



3次元パッチを抽出

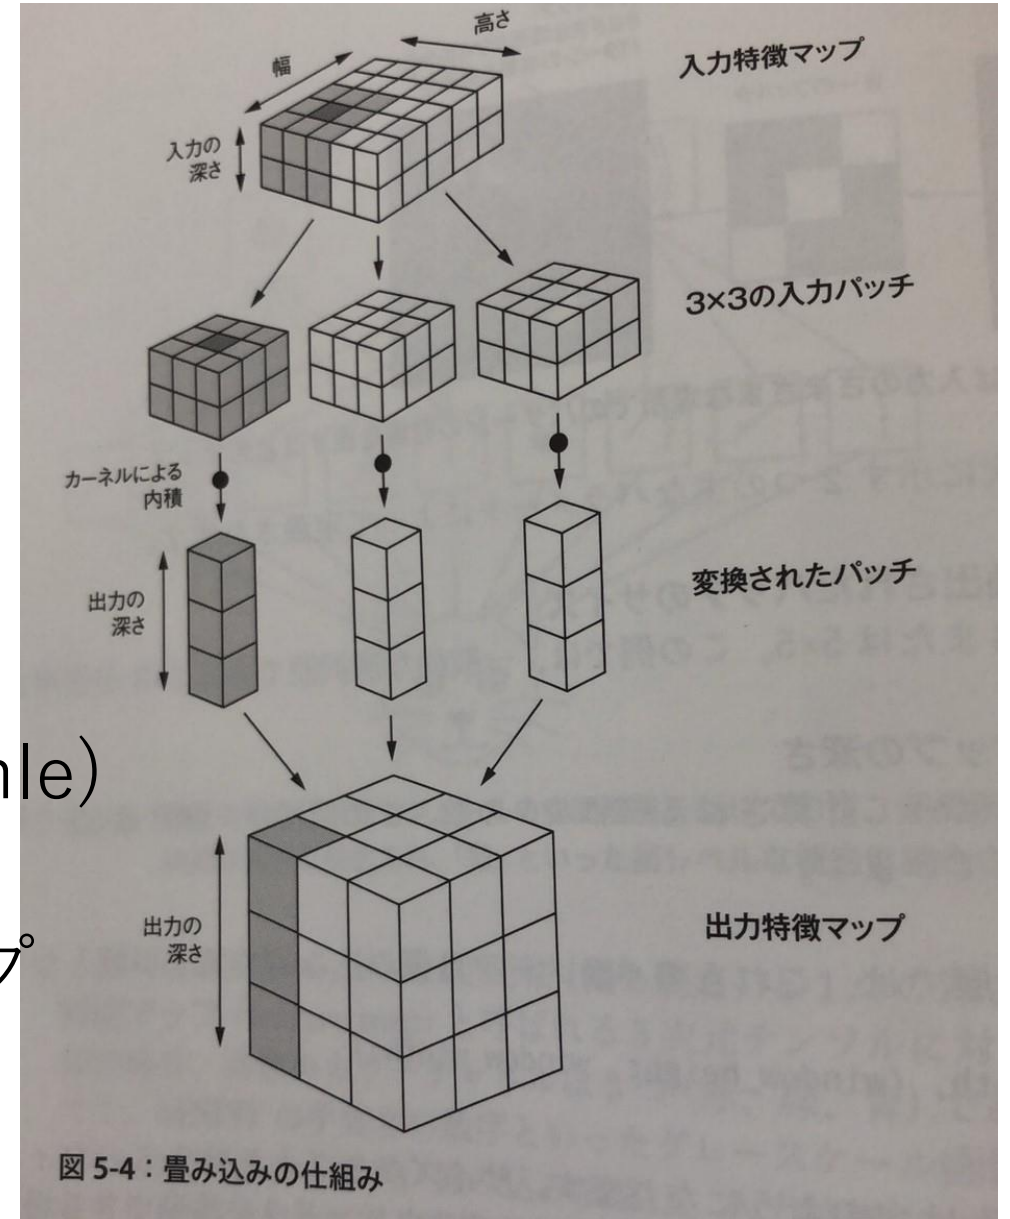


1次元ベクトルに変換

→畳み込みカーネル(convolution kernel)



すべてのベクトルが3次元の出力マップとして空間的に再結合



5.1.1 畳み込み演算

出力の幅と高さは、入力の幅と高さとは異なる場合がある

理由としては

- 周辺効果
- スライドの使用

5.1.1 畳み込み演算

周辺効果とパディング

入力と同じ空間次元を持つ出力特徴マップを取得したい場合

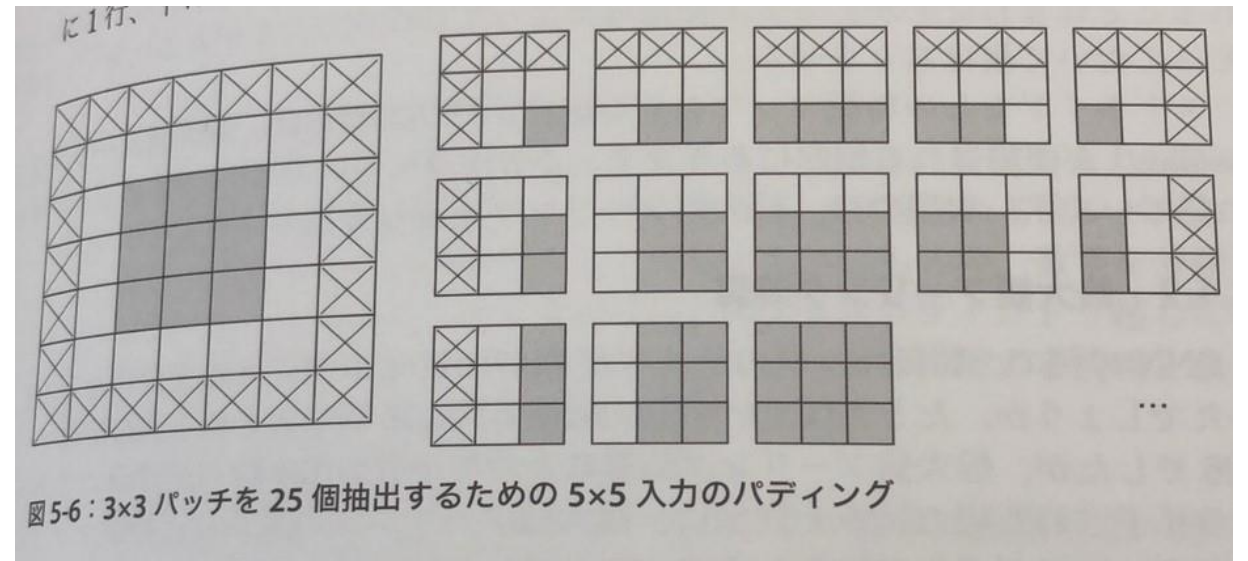
→パディング(padding)

→入力特徴マップの上下左右に適切な数の行と列を追加することで畳み込みウィンドウの中心をすべてで移動できるようにする

5.1.1 畳み込み演算

周辺効果とパディング

×を与えることで5×5の出力特徴マップができる

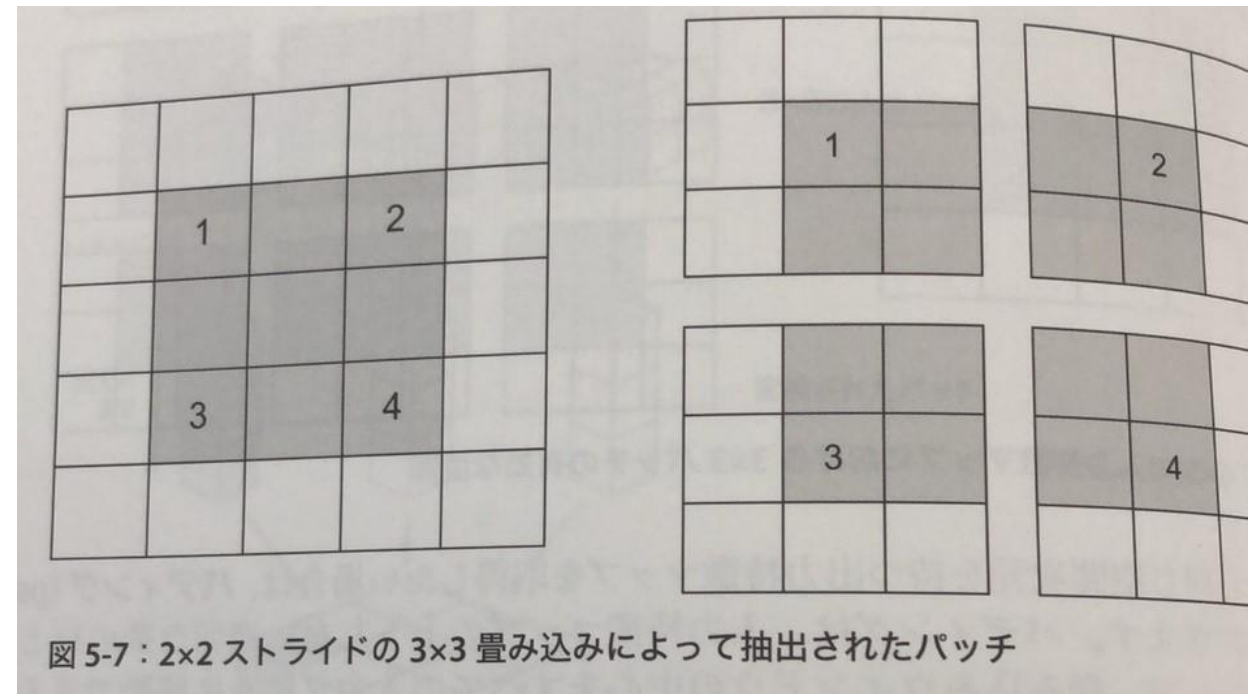


5.1.1 畳み込み演算

畳み込みのストライド

畳み込みの説明は中心のタイルが連続していないかもしれない
→連続しているときストライド1

ストライド2の 3×3 の畳み込み



5.1.2 最大プーリング演算

最大プーリング演算

→通常 2×2 ウィンドウとストライド2を使って実行される

畳み込み

→ 3×3 ウィンドウとストライドなし（ストライド1）で実行される

5.1.2 最大値プーリング変換

```
>>> model_no_max_pool = models.Sequential()
>>> model_no_max_pool.add(layers.Conv2D(32,(3,3),activation='relu',input_shape=(28,28,1)))
>>> model_no_max_pool.add(layers.Conv2D(64,(3,3),activation='relu'))
>>> model_no_max_pool.add(layers.Conv2D(64,(3,3),activation='relu'))
>>> model_no_max_pool.summary()
Model: "sequential_1"
```

Layer (type)	Output Shape	Param #
=====		
conv2d_1 (Conv2D)	(None, 26, 26, 32)	320

conv2d_2 (Conv2D)	(None, 24, 24, 64)	18496

conv2d_3 (Conv2D)	(None, 22, 22, 64)	36928
=====		
Total params: 55,744		
Trainable params: 55,744		
Non-trainable params: 0		

5.1.2 最大値プーリング変換

- ・ 特徴量の空間階層の学習に貢献しない
→ 3つ目の層の 3×3 ウィンドウに含まれているのは最初の 7×7 の情報のみ。CNNによって学習される高レベルのパターンは最初の入力からすれば依然として非常に小さいものの、数字を分類されるための学習には不十分の可能性
- ・ 最終的な特徴マップが非常に大きい
→ 最終的な特徴マップのサンプル一つで $22 \times 22 \times 64 = 30970$ 個
サイズが512にし、平坦化したとき、1580万個のパラメータになる

5.1.2 最大値プーリング変換

要するに…

ダウンサンプリングの目的

→処理の対象となる特徴マップの係数の数を減らす

→連続する畳み込みが調べるウィンドウを徐々に大きくすることで、空間フィルタ階層を抽出すること

他にも平均値プーリング(average pooling)という手法もある