

畳み込みニューラルネット (1)

前田利之（まえだ としゆき）
aipr@e-chan.jp

阪南大学 経営情報学部

(2024.11.29)

畳み込みニューラルネット

- 畳み込みニューラルネット
(Convolutional Neural Network, CNN)
とは？
 - の基礎
 - 画像認識、音声認識等、いろいろな
ところで使われている


畳み込みニューラルネット

- 畳み込みニューラルネット
(Convolutional Neural Network, CNN)
とは？
 - ディープラーニング
の基礎
 - 画像認識、音声認識等、いろいろな
ところで使われている

畳み込みニューラルネット


- 畳み込みニューラルネット
(Convolutional Neural Network, CNN)
とは？
 - ディープラーニング
(Deep Learning) の基礎
 - 画像認識、音声認識等、いろいろな
ところで使われている

畳み込みニューラルネット



畳み込みニューラルネット

- 特徴的なレイヤは



- これらは何層にも（深く）重なっている＝



畳み込みニューラルネット

- 特徴的なレイヤは

- Convolution（畳み込み）レイヤ

- レイヤ

- これらは何層にも（深く）重なっている＝



畳み込みニューラルネット

- 特徴的なレイヤは

- Convolution（畳み込み）レイヤ

- Pooling（プーリング）レイヤ

- これらは何層にも（深く）重なっている＝



畳み込みニューラルネット

- 特徴的なレイヤは
 - Convolution（畳み込み）レイヤ
 - Pooling（プーリング）レイヤ
- これらは何層にも（深く）重なっている=
ディープラーニング

畳み込みニューラルネット

- 特徴的なレイヤは
 - Convolution（畳み込み）レイヤ
 - Pooling（プーリング）レイヤ
- これらは何層にも（深く）重なっている=
ディープラーニング（深層学習）

畳み込みニューラルネット

- 先週までのニューラルネット=

(Affine レイヤ)

- 隣接層のニューロンは全て連結されていた
- 出力数は任意

- この問題点：データの が されている

- MNIST のデータの場合、元は 28×28 なのを 1×784 のデータとして Affine レイヤの入力にしていた
- $\Rightarrow$ 元々ある を捨てている (!)

畳み込みニューラルネット

- 先週までのニューラルネット = **全結合層**
(Affine レイヤ)
 - 隣接層のニューロンは全て連結されていた
 - 出力数は任意
- この問題点：データの が されている
 - MNIST のデータの場合、元は 28×28 なのを 1×784 のデータとして Affine レイヤの入力にしていた
 - $\Rightarrow$ 元々ある を捨てている (!)

畳み込みニューラルネット

- 先週までのニューラルネット = **全結合層**
(Affine レイヤ)
 - 隣接層のニューロンは全て連結されていた
 - 出力数は任意
- この問題点：データの **形状** が されている
 - MNIST のデータの場合、元は 28x28 なのを 1x784 のデータとして Affine レイヤの入力にしていた
 - ⇒ 元々ある を捨てている (!)

畳み込みニューラルネット

- 先週までのニューラルネット = **全結合層**
(Affine レイヤ)
 - 隣接層のニューロンは全て連結されていた
 - 出力数は任意
- この問題点：データの **形状** が **無視** されている
 - MNIST のデータの場合、元は 28×28 なのを 1×784 のデータとして Affine レイヤの入力にしていた
 - $\Rightarrow$ 元々ある  を捨てている (!)

畳み込みニューラルネット

- 先週までのニューラルネット = **全結合層**
(Affine レイヤ)
 - 隣接層のニューロンは全て連結されていた
 - 出力数は任意
- この問題点：データの **形状** が **無視** されている
 - MNIST のデータの場合、元は 28×28 のものを 1×784 のデータとして Affine レイヤの入力にしていた
 - $\Rightarrow$ 元々ある **空間情報** を捨てている (!)

畳み込みニューラルネット

- 畳み込みニューラルネットは
する
- なので、画像などをより正しく

畳み込みニューラルネット

- 畳み込みニューラルネットは
形状を維持する
- なので、画像などをより正しく



畳み込みニューラルネット

- 畳み込みニューラルネットは
形状を維持する
- なので、画像などをより正しく
理解できる（可能性がある）

畳み込みニューラルネット

- 畳み込み層の入出力：
- 入力：入力特徴マップ
- 出力：出力特徴マップ
- 入力データとフィルタとの で出力を導く（後述）


畳み込みニューラルネット

- 畳み込み層の入出力： 「特徴マップ」
 - 入力：入力特徴マップ
 - 出力：出力特徴マップ
- 入力データとフィルタとの で出力を導く（後述）

畳み込みニューラルネット

- 畳み込み層の入出力： 「特徴マップ」
 - 入力：入力特徴マップ
 - 出力：出力特徴マップ
- 入力データとフィルタとの 積和計算 で出力を導く（後述）

畳み込み演算



畳み込み演算＝画像処理での「フィルタ演算」

- 入力データにフィルタを適用
- 入力データ、フィルタともに がある
(行列)
 - 1 入力データに対してフィルタの (操作対象の枠) を一定の間隔で させる
 - 2 それぞれ対応する要素を掛け、その総和を求める＝

(さらににバイアスを加える)
 - 3 結果を対応する場所へ格納する
 - 4 上の処理を全ての場所で行なう

畳み込み演算＝画像処理での「フィルタ演算」


- 入力データにフィルタを適用
- 入力データ、フィルタともに **縦・横** がある (行列)

- 1 入力データに対してフィルタの  (操作対象の枠) を一定の間隔で  させる
- 2 それぞれ対応する要素を掛け、その総和を求める＝


(さらににバイアスを加える)
- 3 結果を対応する場所へ格納する
- 4 上の処理を全ての場所で行なう

畳み込み演算＝画像処理での「フィルタ演算」

- 入力データにフィルタを適用
- 入力データ、フィルタともに **縦・横** がある (行列)

- 1 入力データに対してフィルタの **ウィンドウ** (操作対象の枠) を一定の間隔で  させる
- 2 それぞれ対応する要素を掛け、その総和を求める＝

(さらににバイアスを加える)
- 3 結果を対応する場所へ格納する
- 4 上の処理を全ての場所で行なう


畳み込み演算＝画像処理での「フィルタ演算」

- 入力データにフィルタを適用
- 入力データ、フィルタともに **縦・横** がある (行列)
 - 1 入力データに対してフィルタの **ウィンドウ** (操作対象の枠) を一定の間隔で **スライド** させる
 - 2 それぞれ対応する要素を掛け、その総和を求める＝

(さらににバイアスを加える)
 - 3 結果を対応する場所へ格納する
 - 4 上の処理を全ての場所で行なう

畳み込み演算＝画像処理での「フィルタ演算」


- 入力データにフィルタを適用
- 入力データ、フィルタともに **縦・横** がある (行列)
 - 1 入力データに対してフィルタの **ウィンドウ** (操作対象の枠) を一定の間隔で **スライド** させる
 - 2 それぞれ対応する要素を掛け、その総和を求める＝**積和計算**
(さらににバイアスを加える)
 - 3 結果を対応する場所へ格納する
 - 4 上の処理を全ての場所で行なう

畳み込み演算過程




$$1 \times 1 + 2 \times 0 + 3 \times 2 + 4 \times 0 + 3 \times 2 + 2 \times 0 + 0 \times 1 + 1 \times 1 + (-1) \times 2$$

畳み込み演算過程




$$2 \times 1 + 3 \times 0 + 4 \times 2 + 3 \times 0 + 2 \times 2 + 1 \times 0 + 1 \times 1 + 2 \times 1 + 3 \times (-1)$$

畳み込み演算過程



$$4 \times 1 + 3 \times 0 + 2 \times 2 + 0 \times 0 + 1 \times 2 + 2 \times 0 + 3 \times 1 + 2 \times 1 + 1 \times (-1)$$

畳み込み演算過程





$$3 \times 1 + 2 \times 0 + 1 \times 2 + 1 \times 0 + 2 \times 2 + 3 \times 0 + 2 \times 1 + 1 \times 1 + 2 \times (-1)$$

畳み込み演算の演習


☆ 以下（リンクあり）を、Colab にコピー＆ペーストして実行する。

```
import numpy as np
ind = np.array([[1,2,3,4],
                [4,3,2,1],
                [0,1,2,3],
                [3,2,1,2]])
filt = np.array([[1,0,2],
                 [0,2,0],
                 [1,1,-1]])
outd = np.zeros((2,2))
for i in range(2):
    for j in range(2):
        outd[i][j] = np.sum(ind[i:i+3,j:j+3]*filt)
print(outd)
```


パディング (Padding)

- 入力データの  を埋めた上で、畳み込みをする
- なぜかと言うと、以下を回避するため：
 - 前の例では、 4×4 のデータに 3×3 のフィルタを適用し 2×2 の出力になった
 - つまり、出力データは  → 繰り返すと、サイズ 1 になってしまう
 - すると、それ以上処理が出来なくなる
- 前の例では幅 1 つだけパディングすると、出力も 4×4 のサイズで保たれる

パディング (Padding)

- 入力データの **周囲に 0** を埋めた上で、畳み込みをする
- なぜかと言うと、以下を回避するため：
 - 前の例では、 4×4 のデータに 3×3 のフィルタを適用し 2×2 の出力になった
 - つまり、出力データは  → 繰り返し
返すと、サイズ 1 になってしまう
 - すると、それ以上処理が出来なくなる
- 前の例では幅 1 つだけパディングすると、出力も 4×4 のサイズで保たれる

パディング (Padding)

- 入力データの **周囲に 0** を埋めた上で、畳み込みをする
- なぜかと言うと、以下を回避するため：
 - 前の例では、 4×4 のデータに 3×3 のフィルタを適用し 2×2 の出力になった
 - つまり、出力データは **入力より小さい** → 繰り返すと、サイズ 1 になってしまう
 - すると、それ以上処理が出来なくなる
- 前の例では幅 1 つだけパディングすると、出力も 4×4 のサイズで保たれる

パディング

パディング後の
入力データ

0	0	0	0	0	0
0	1	2	3	4	0
0	4	3	2	1	0
0	0	1	2	3	0
0	3	2	1	2	0
0	0	0	0	0	0

×

1	0	2
0	2	0
1	1	-1

→ 3

$$0 \times 1 + 0 \times 0 + 0 \times 2 + 0 \times 0 + 1 \times 2 + 2 \times 0 + 0 \times 1 + 4 \times 1 + 3 \times (-1)$$

ストライド (stride)

- フィルタを適用する

- つまり、1つずつずらすとは限らない、ということ

- ストライドを増やすと出力サイズは なり、パディングを増やすと出力サイズは なることに注意

ストライド (stride)

- フィルタを適用する **位置の間隔**
 - つまり、1つずつずらすとは限らない、ということ
- ストライドを増やすと出力サイズは なり、パディングを増やすと出力サイズは なることに注意

ストライド (stride)

- フィルタを適用する **位置の間隔**
 - つまり、1つずつずらすとは限らない、ということ
- ストライドを増やすと出力サイズは **小さく** なり、パディングを増やすと出力サイズは なることに注意

ストライド (stride)

- フィルタを適用する **位置の間隔**
 - つまり、1つずつずらすとは限らない、ということ
- ストライドを増やすと出力サイズは **小さく** なり、パディングを増やすと出力サイズは **大きく** なることに注意

3次元データの畳み込み演算

- 例えばカラー画像の場合、縦 (Height), 横 (Width) の2次元データではなく、 (RGB, CMY 等) もあわせた3次元データを扱う必要がある
- その場合、フィルターは1枚のフィルタですますことも出来るし、3枚用意して、その加算により2次元出力を得ることも出来る


3次元データの畳み込み演算

- 例えばカラー画像の場合、縦 (Height), 横 (Width) の2次元データではなく、**色の3要素** (RGB, CMY 等) もあわせた3次元データを扱う必要がある
- その場合、フィルターは1枚のフィルタですますことも出来るし、3枚用意して、その加算により2次元出力を得ることも出来る

3次元データの畳み込み演算

- 3次元目の軸をチャネル (channel) と表すと、データは以下の次元となる
 - 入力データ: (Channel, Height, Width)
 - フィルタ: (Channel, Filter-Height, Filter-Width)
あるいは (Filter-Number, Channel, Filter-Height, Filter-Width)
 - 出力データ: (1, Output-Height, Output-Width)

3次元データの畳み込み演算



バッチ処理 = 4次元データの畳み込み演算

- これまで同様、入力データを  にまとめたバッチ処理に対応したい
- すると、さらに次元が増える
 - 入力データ: (Batch-Number, Channel, Height, Width)
 - フィルタ: (Filter-Number, Channel, Filter-Height, Filter-Width)
 - 出力データ: (Batch-Number, Filter-Number, Output-Height, Output-Width)

バッチ処理 = 4次元データの畳み込み演算

- これまで同様、入力データを **一束** にまとめたバッチ処理に対応したい
- すると、さらに次元が増える
 - 入力データ: (Batch-Number, Channel, Height, Width)
 - フィルタ: (Filter-Number, Channel, Filter-Height, Filter-Width)
 - 出力データ: (Batch-Number, Filter-Number, Output-Height, Output-Width)

プーリング層

- 縦横方向の空間を する
- 一般的に、プーリングのウィンドウとストライドは にする
- 画像認識では Pooling、すなわちその枠内で一番大きいデータを出力とすることが多い
 - 他には Pooling (平均をとる) 等がある

プーリング層

- 縦横方向の空間を **小さく** する
- 一般的に、プーリングのウィンドウとストライドは にする
- 画像認識では Pooling、すなわちその枠内で一番大きいデータを出力とすることが多い
 - 他には Pooling (平均をとる) 等がある

プーリング層

- 縦横方向の空間を **小さく** する
- 一般的に、プーリングのウィンドウとストライドは **同じ** にする
- 画像認識では  Pooling、すなわちその枠内で一番大きいデータを出力とすることが多い
 - 他には  Pooling (平均をとる) 等がある

プーリング層

- 縦横方向の空間を **小さく** する
- 一般的に、プーリングのウィンドウとストライドは **同じ** にする
- 画像認識では **Max** Pooling、すなわちその枠内で一番大きいデータを出力とすることが多い
 - 他には Pooling (平均をとる) 等がある

プーリング層

- 縦横方向の空間を **小さく** する
- 一般的に、プーリングのウィンドウとストライドは **同じ** にする
- 画像認識では **Max** Pooling、すなわちその枠内で一番大きいデータを出力とすることが多い
 - 他には **Average** Pooling (平均をとる) 等がある

プーリング層

☆ 2x2 のプーリングをストライド 2で行なった場合
入力データ

1	2	3	4
4	3	2	1
0	1	2	3
3	2	1	2



出力データ

4	4
3	3

プーリングの演習

☆ 以下（リンクあり）を、Colab にコピー＆ペーストして実行する。

```
import numpy as np
ind = np.array([[1,2,3,4],
                [4,3,2,1],
                [0,1,2,3],
                [3,2,1,2]])

outd = np.zeros((2,2))
for i in range(2):
    for j in range(2):
        outd[i][j] = np.max(ind[i*2:i*2+2,j*2:j*2+2])
print(outd)
```

プーリング層の特徴

- 学習するデータが

- チャンネル数は

- 微小な位置変化にたいして

- データが多少ぶれてもプーリング処理で吸収できることがある（できない場合もある）
- 例えば 2x2 のウィンドウの場合、1 行 1 列目にあった最大値がずれて 1 行 2 列目に来ても、2 行 1 列目に来ても、出力は同じ、ということ

プーリング層の特徴

- 学習するデータが
ない（パラメータがない）
- チャンネル数は
- 微小な位置変化にたいして
 - データが多少ぶれてもプーリング処理で吸収できることがある（できない場合もある）
 - 例えば 2x2 のウィンドウの場合、1 行 1 列目にあった最大値がずれて 1 行 2 列目に来ても、2 行 1 列目に来ても、出力は同じ、ということ

プーリング層の特徴

- 学習するデータが
ない（パラメータがない）
- チャンネル数は 変化しない
- 微小な位置変化にたいして
 - データが多少ぶれてもプーリング処理で吸収できることがある（できない場合もある）
 - 例えば 2x2 のウィンドウの場合、1 行 1 列目にあった最大値がずれて 1 行 2 列目に来ても、2 行 1 列目に来ても、出力は同じ、ということ

プーリング層の特徴

- 学習するデータが
ない（パラメータがない）
- チャンネル数は 変化しない
- 微小な位置変化にたいして 頑強 (robust)
 - データが多少ぶれてもプーリング処理で吸収できることがある（できない場合もある）
 - 例えば 2x2 のウィンドウの場合、1 行 1 列目にあった最大値がずれて 1 行 2 列目に来ても、2 行 1 列目に来ても、出力は同じ、ということ

畳み込みニューラルネットの実装

- まず、ユーティリティ (im2col, etc)
- 畳み込み層
- プーリング層
- …以上を基に、畳み込みニューラルネットとその学習

4次元配列への対応

- 先週での議論により、バッチ対応の畳み込み処理のデータは4次元配列となる
- これを For での多重ループで計算させるのは面倒であり、かつ重い処理となる
- そこで という関数を導入する
 - Caffe, Chainer で実装されているものを手本にしている

4次元配列への対応

- 先週での議論により、バッチ対応の畳み込み処理のデータは4次元配列となる
- これを For での多重ループで計算させるのは面倒であり、かつ重い処理となる
- そこで `im2col (image to column)` という関数を導入する
 - Caffe, Chainer で実装されているものを手本にしている

im2col

- フィルタにとって都合の良いように入力データを展開する
- 3 or 4 次元データを に展開する
- 畳み込み演算ではフィルタの適用範囲が重なる場合があるので、その時には展開後の要素は元のブロック数より多くなる→メモリを しがち

im2col

- フィルタにとって都合の良いように入力データを展開する
- 3 or 4 次元データを **2次元** に展開する
- 畳み込み演算ではフィルタの適用範囲が重なる場合があるので、その時には展開後の要素は元のブロック数より多くなる→メモリを しがち

im2col

- フィルタにとって都合の良いように入力データを展開する
- 3 or 4 次元データを **2次元** に展開する
- 畳み込み演算ではフィルタの適用範囲が重なる場合があるので、その時には展開後の要素は元のブロック数より多くなる→メモリを **消費** しがち

im2col

- しかし行列計算ライブラリや GPGPU の恩恵を受けられるメリットのほうが一般的に大きい
- 展開後は、フィルタも 1 列に展開して積を計算するだけ
- → とほぼ同じ処理

im2col

- しかし行列計算ライブラリや GPGPU の恩恵を受けられるメリットのほうが一般的に大きい
- 展開後は、フィルタも 1 列に展開して積を計算するだけ
- → **Affine レイヤ** とほぼ同じ処理

im2col の実装

☆以下が実装コード（と処理例）なので、Colab にコピー＆ペーストして実行する。(長い行は適宜 \ を使って折り込んでいる)

```
import numpy as np
def im2col(input_data, filter_h, filter_w, stride=1, pad=0):
    N, C, H, W = input_data.shape
    out_h = (H + 2*pad - filter_h)//stride + 1 #整数除算
    out_w = (W + 2*pad - filter_w)//stride + 1
    img = np.pad(input_data, [(0,0), (0,0), (pad, pad), \
                               (pad, pad)], 'constant')
    col = np.zeros((N, C, filter_h, filter_w, out_h, out_w))
    for y in range(filter_h):
        y_max = y + stride*out_h
        for x in range(filter_w):
            x_max = x + stride*out_w
            col[:, :, y, x, :, :] = \
                img[:, :, y:y_max:stride, x:x_max:stride]
    col = col.transpose(0, 4, 5, 1, 2, 3).reshape(N*out_h*out_w, -1)
    return col
```

(…次頁に続く)

im2col の実装

◎前頁からの続きとして、以下が処理例なので、前頁の続きとして Colab にコピー＆ペーストするか、[im2col-ex.py](#) のリンク先をコピーして実行する

(バッチ数 10, チャンネル数 3 の 7x7 のデータを乱数で作り、それを 5x5 のフィルタ用に *im2col* を適用している)

```
x2 = np.random.rand(10, 3, 7, 7)
col2 = im2col(x2, 5, 5, stride=1, pad=0)
print(col2.shape)
```

- col2 の結果は 90,75 になるはず
- 75 は 5x5 のフィルタが 3 チャンネル分、ということ

おしまい

質問・コメント等あれば、何でもお気軽に
aipr@e-chan.jp に
メールください！

【注意】申し訳ないですが *HInT* の「連絡」は溜めてしまふことが多いのでリプライが遅れがちです。出来るだけ普通のメールで送ってください。