

潮海流発電機まわりの流速場を分析する 畳み込み層の活性化マップの解析

函館工業高等専門学校 プレントゥムル エンフマンライ、 藤原 亮

1. はじめに

2019年の日本エネルギー自給率は12.1%であり、他のOECD諸国と比較すると低い。日本のエネルギー自給率を100%とすると水力エネルギーが7.9%である[1]。流速の高い津軽海峡の潮海流を用いればより自給率は向上すると期待できる。本研究グループではつば付き漸拡型ディフューザ(以下ディフューザと呼称)になる発電手法を提案している。発電機つば付き 漸拡型ディフューザにより、流速でタービンを回転させ、発電する(図 1)。以前の研究で用いてディフューザの設計値が深層学習上で予測された[2]。全結合ニューラルネットワークで学習した出力データの誤差は 1%以内に収まっていた[2]。本研究では、空間分布を把握しより精度を上げるため畳み込みニューラルネットワークを使用し、潮海流発電機まわりの検出した流速場を解析する。本研究では、設計の上で重視すべき点を明らかにするため、既に学習した深層学習アーキテクチャの畳み込み層を解析することを目的とする。




図 1 海洋発電装置の概要図。

2. 実行環境

プログラミング言語 Python を用いて畳み込みニューラルネットワーク(CNN)のフィルタを解析した。ライブラリはニューラルネットワークライブラリである keras を用いた。ライブラリ keras のバックエンドとして、機械学習用ライブラリ TensorFlow を用いた。統合開発環境 Jupyter Notebook でプログラムの編集を行った。使用 PC の OS は macOS Big Sur version 11.5, プロセッサは 1.4 GHz Dual-Core Intel Core i5, 実装 RAM は 4 GB 1600 MHz DDR3 を用いた。

3. 畳み込みニューラルネットワーク

畳み込みネットワークは、画像などのグリッドのよう
なトポロジを持つデータの処理に特化したニューラル

ネットワークのクラスである。全結合ニューラルネットワークと畳み込みネットワークの違いは、全結合層は大域的なパターンを学習する、畳み込み層は局所的な

パターンを学習することが強みである。画像処理での畳み込み層のデータ効率が良いのは視覚の世界は基本的に移動不変から学習するために必要な数が少なくなることもある。また入力画像の学習と視覚概念の抽象化を効率よく行うことができる。

4. ノードの活性化度を示すフィルタの作成方法

設計の上で重視すべき点を明らかにするため畳み込み層の活性化マップを解析した。本研究で潮海流発電機の設計値を学習した後、結果として表 1 ネットワークの構造の通りに Conv2D, Conv2D_1, Maxpooling2D, Conv2D_2, Maxpooling2D_1 の五つのレイヤがある(図 2)。各レイヤでは 32 または 64 個のノードがある。最初の conv 2D レイヤである 32 個の視覚概念の活性化マップを解析した。

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 48, 48, 32)	16416
conv2d_1 (Conv2D)	(None, 46, 46, 32)	9248
max_pooling2d (MaxPooling2D)	(None, 23, 23, 32)	0
conv2d_2 (Conv2D)	(None, 21, 21, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 10, 10, 64)	0
dropout (Dropout)	(None, 10, 10, 64)	0
flatten (Flatten)	(None, 6400)	0
dense (Dense)	(None, 516)	3302916
dropout_1 (Dropout)	(None, 516)	0
dense_1 (Dense)	(None, 3)	1551

=====
Total params: 3,348,627
Trainable params: 3,348,627
Non-trainable params: 0

表 1 ネットワークの構造




図 2. 畳み込み層の図式

畳み込みネットワークフィルタの視覚化は、各ノードが受け入れる視覚パターンと概念を表現する。畳み込みニューラルネットワークでフィルタは画像の強度値の変化を検出することで画像の空間パターンを検出する(図2)。これに応じて入力が入力畳み込みネットワークによって学習フィルタにどのように分解されるかを確認できる。




図2. 入力画像 (横方向)

5. ノードの活性化を示すフィルタの解析

本研究では、第1層目の1から32番目までのノードのフィルタを取得し、活性化を分析した。畳み込み層はエッジ、形状またはテクスチャを検出する。図4には、第1層の17番目のノードフィルタの画像を表している。ディフューザの内側によって活性化の部分を黒丸で、ディフューザの外側の流速場を白丸で囲んでいる。入力画像と比べて分析すると畳み込み層のエンコードしたパターンが流速場の高い部分で100-200の値を示した。それによって、第1層目に17番目のノードは、横方向の流速が遅い部分に反応しているだと考えられる。第1層目の前半つまり1番目のノードから16番目のノードがディフューザーによって流速場の高い部分と低い部分の間の部分を検出した。




図4. 第1層目の17番目のノードのフィルタと入力画像

図5に第1層の24番目のノードのフィルタの画像を示している。ディフューザの内側によって活性化の特徴している部分を黒丸で、ディフューザの外側の流速場を白丸で囲んでいる。入力画像と比べて畳み込みネットワークパターンがディフューザーによって流速場の高い部分を検出されたことを表現している。検出した視覚概念の活性化を数値で表すと150~230である。




図5. 第1層目の24番目のノードのフィルタと入力画像

畳み込み層の9番目、12番目、16番目、19番目、21番目、30番目のノードが図6の通り空であった。こちらで説明すると各ノードにエンコードされている畳み込み層のパターンが入力画像から検出されなくて反応しないことを理解した。




図6. 第1層目の9番目のノードのフィルタと入力画像

6. おわりに

本研究で深層学習技術を使用して潮流発電機まわりの流速場を分析する畳み込みニューラルネットワークの活性化マップの解析した。結果として畳み込み層の最初のConv_2dネットワークの32個の活性化マップの各ノードで解析した。本研究は、当研究室のディープラーニングの方向性を示す一歩になって次の畳み込みニューラルネットワーク研究に助けると信じている。設計値を決定する上で流速場を読み解くコツを理解する一助となる。将来的に潮流発電の効率を上げることで、再生可能エネルギーに良い効果があると考えられる。

謝辞

本研究は JSPS 科研費 21K14081, および第1回リバネス高専研究費フォーカスシステムズ賞の助成を受けた。

参考文献

- [1]. 日本のエネルギーシステム
<https://www.enecho.meti.go.jp/about/pamphlet/energy2021/001/>
- [2]. 福島龍馬, 一方向流中の潮流発電装置における設計値予測のための深層学習モデルの構築, 令和2年度函館工業高等専門学校卒業論文.
- [3]. 畳み込みネットワークの図解
https://deepage.net/deep_learning/2016/11/07/convolutional_neural_network.html
- [4]. Forecasting design values of tidal/ocean power generator in the strait with unidirectional flow by deep learning
<https://www.sciencedirect.com/science/article/pii/S2667305322000084>