

## ディープラーニングを用いた海浜変形診断 Beach deformation diagnosis using Deep Learning

目野玄也<sup>1</sup>, 小林昭男<sup>2</sup>, 宇多高明<sup>3</sup>, 野志保仁<sup>4</sup>

Meno Genya<sup>1</sup>, Akio Kobayashi<sup>2</sup>, Takaaki Uda<sup>3</sup>, Yasuhito Noshi<sup>2</sup>

A lot of study on environmental conservation measures in coastal areas has been conducted so far. However, coastal erosion and inundation occur all over the world. One reason is the lack of knowledge and experience in coastal engineering for engineers working on the coast. Moreover, excellent engineers can predict to some extent what kind of problems and beach deformation will occur in the future just by looking at the target coast from knowledge and experience. In this study, we focus on the fact that “excellent engineers can predict a certain amount of beach deformation just by looking at the target sea” and imitate this by machine learning. The purpose of this study is to diagnose the final shoreline shape of beach deformation by installing the structure using deep learning.

### 1. 研究背景及び目的

沿岸域の環境保全対策はこれまで多くの技術者によって研究され、多くの研究成果がある。しかしながら現実には海岸侵食や浸水被害などが世界中で発生し続けている。その理由の一つが、海岸の仕事に携わる技術者の海岸工学に関する知識と経験の不足である。また優れた技術者や研究者は知識や経験から対象の海岸を見ただけで今後どのような問題や海浜変形が起こるのかをある程度予測することができる。

本研究では「優れた技術者や研究者は対象の海を見ただけである程度の海浜変形を予測することができる」ということに着目し機械学習によってこれを模倣することである。そこで、構造物を設置することによる海浜変形の最終汀線形状をディープラーニングを用いて診断することを目的とする。

### 2. 構築した CNN の構造

CNN とは、深層学習(ディープラーニング)の一種であり、脳のニューロンの仕組みから着想を得たニューラルネットワーク (NN) と呼ばれる機械学習手法の一種である 2)。本研究では CNN を用いて画像認識を行う。

**Fig. 1.**で示すように作成した CNN は入力層を含み 10 階層である。まず、A1 では入力画像として対象の海岸の情報を画像化したものを与え、3\*3 のフィルタで畳み込みを行い、32 枚の特徴量マップを得る。次に B2 では、A1 の出力を入力として、任意の少領域内の最大値を選択するマックスプーリングにより画像サイズを小さくする。そして、この動作を 3 度繰り返すことで B6 の出力は 4\*4 になりこれを C7 に入力して、識別させる。識別層の活性化関数にはシグモイド関数またはソフトマックス関数を用いる。

### 3. 訓練データ

**Fig. 2.**の初期地形に示す直線の汀線を有する海岸に突堤を設置し、画像右上から波が作用したとする。なお、突堤先端部は漂砂の移動限界水深で深とする。その場合の海浜変形は、漂砂が突堤により遮られ、また汀線は波向に垂直となるよう変形し、安定する。汀線の前進後退がどの程度であるのか定量的な値を求めるには、漂砂量や詳細な地形データ等必要になるが、定性的な汀線形状のパターンは波向と構造物で予測することができる。

そこで本研究では、野志ら<sup>[3]</sup>の BG モデルを用いて地形変化計算を行った。そしてその結果を参考に訓練データを作成した。BG モデルで得られた結果を参考に、簡単な地形データと波向のデータを RGB 画像の形式で作成し、汀線形状のパターンでクラス分けを行った。**Fig. 3**で示すように R (赤) のチャンネルでは、海を 25 と構造物 255 で、G (緑) では波向と突堤の先端を漂砂が通過する、しないの数値を設定した。なお B (青) は全て 0 とした。この数値設定は特徴が顕著となるよう恣意的に設定した。訓練データ全てを同様の法則で数値設定してあれば、CNN が特徴を抽出することが容易になるためである。

BG モデルを用いて行った計算を参考に 600 個の訓練データを作成した。それらの結果から汀線変化のパターンを 12 パターンに分類することができた。

### 4. 構築した CNN の学習結果

**Fig. 4** のグラフ縦軸の正解率とは、予測結果全体と答えがどれくらい一致しているのかを判断する指標。これ自体を精度という場合もある。

突堤が1基の場合の汀線形状パターンの分類を行う CNN の学習結果を図-10 に示す。CNN のパラメータは初期値をランダムに決める。学習開始時にはランダムに決定されたパラメータのため正解率が非常に低い学習を行っていくとパラメータの更新回数 400 回を超えた付近で正解率 100% となった。

5. まとめ

技術者や研究者が見ただけでどのような海浜変形が起こるのかを予測する要素として、対象海岸の構造物と波向だと考えた。そのため構造物と波向の情報から訓練用データを恣意的に作成し、BG モデルで計算した結果から汀線形状パターンでクラス分けした。このように作成した画像 600 枚と CNN を用いて分類器を構築した。学習を行った結果、表-2 に示すように汀線形状パターンの分類正解率は 100% と高い正解率だった。

これは空中写真などから得られる様々な情報をコンピューター自身が抽出するのではなく、人間が恣意的に必要な要素を抽出しコンピューターに入力したため高い精度が得られたと考えられる。

6. 参考文献

[1] 伊藤 真：「あたらしい機械学習の教科書」, SHOEISHA, p. 251, 2018  
 [2] 新村 拓也：「Tensor Flow ではじめる Deep Learning」, impress, p. 4, 2018  
 [3] 野志保仁, 宇多高明, 芹沢真澄, 熊田貴之, 酒井和也：「粒度組成を考慮した平衡勾配概念および Bagnold 概念に基づいた地形・粒径変化予測モデル」, 土木学会論文集 B2 (海岸工学 Vol. 65 No. 1 pp. 501 505 2009

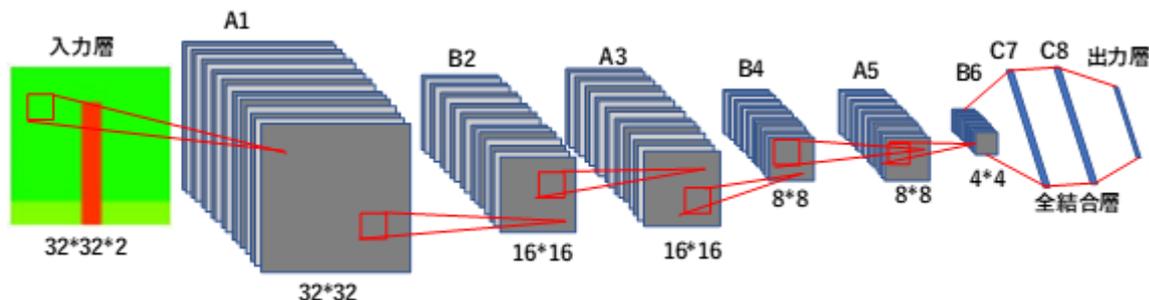


Figure 1. CNN structure

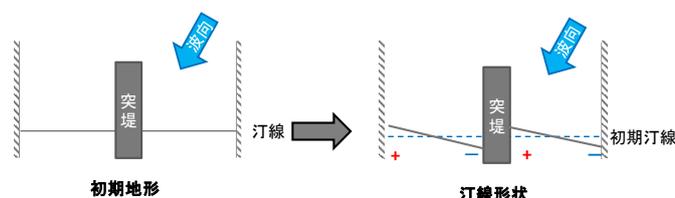


Figure 2. Example of beach deformation

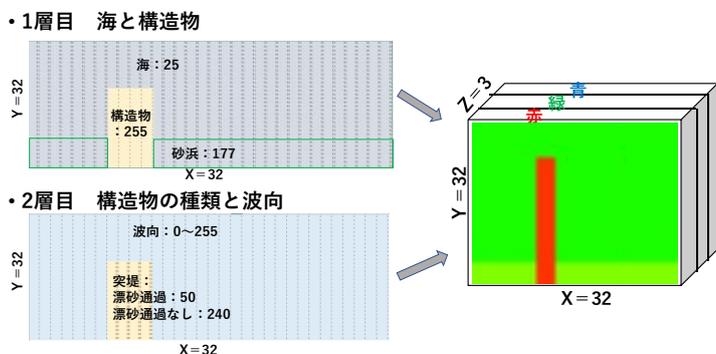


Figure 3. RGB format image

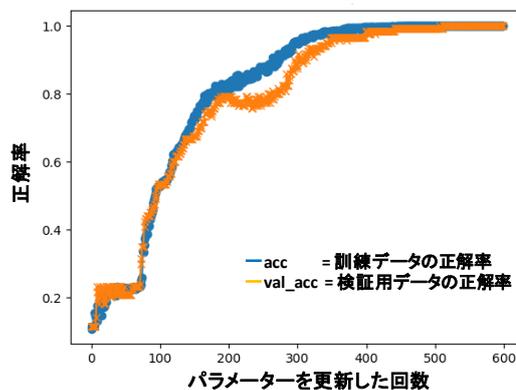


Figure 4. Learning result