

深層学習による海岸保全施設の劣化予測に関する基礎的検討

(正) 熊谷兼太郎 (国土交通省国土技術政策総合研究所)、藤井直樹 (東電設計株式会社)、
小川雅史 (京都大学経営管理大学院)

1. 序論

我が国の海岸に設けられた護岸、堤防等の海岸保全施設の延長は 9,600 km に達する。その維持管理は、主に巡視・点検という人の手で行われている。海岸保全施設の維持管理を効率的に行うには、施設の劣化状況を適切に予測する必要がある。

コンクリート構造物の劣化は、アルカリシリカ反応、凍害、塩害、中性化、乾燥、摩耗等の多様な機構で生じる。例えばアルカリシリカ反応は、コンクリート中のナトリウムなどのアルカリ金属イオンと骨材の反応性珪物とが反応してゲルが生成・膨張し、ひび割れなどが生じる現象である。建設後のナトリウムイオンの供給源は、海からの飛来等がある。1980 年代後半から対策が講じられたことによりアルカリシリカ反応が原因の劣化は少なくなっているが、現行の抑制対策を行っても 100%防止できるものではない (和泉ら, 2016)。また、コアを使った促進養生試験により膨張の進行を予測できるが、試験条件下でのものであり、精度よく推定できるものではない (同)。

そこで、これまでにない劣化の新たな予測手法として、多数の劣化事例を用いて劣化の特徴量を発見するアプローチをとることを考える (図-1)。海岸保全施設の点検結果は蓄積されてきており、また、劣化を引き起こす要因のうち環境要因 (気温、湿度、風等) は、気象官署等の全国約 1,450 地点の観測値を長期間にわたって入手できる (気象庁, online)。こうしたビッグデータの解析は、深層学習の利用が期待されている分野である。さらに、鬼頭 (2015)、吉野 (2010) 等を参考にすれば、地球温暖化等の長期の気象変化をふまえた想定シナリオを利用することがある程度可能となってきた。すなわち、想定シナリオを反映させた想定気象データを用意し、施設の劣化予想をある程度の精度で行うことが期待できる。このような、海岸保全施設の劣化の特徴量を発見して劣化予測モデルを構築し、長期の気象変化をふまえた想定シナリオに基づいて劣化予測する枠組みを提案する。

本研究は、深層学習により海岸保全施設、特にコンクリート構造の護岸の多数の劣化事例について施設建設後の環境要因と紐付けた特徴量の解析を行う、海岸保全施設の劣化予測手法 (図-1の左側部分) について基礎的な検討を行った。

2. 予測手法及び予測結果

2.1 劣化事例の抽出 中島ら

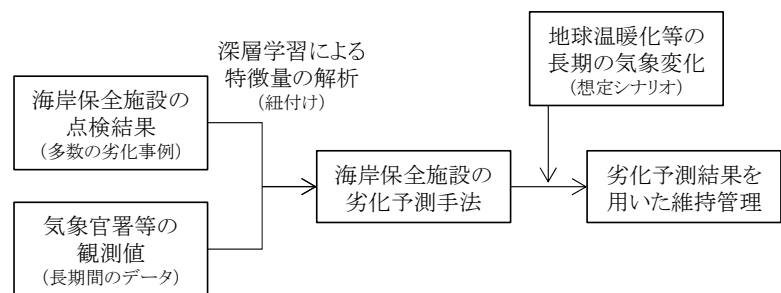


図-1 新たな劣化予測の枠組み

表-1 劣化事例の抽出条件

項目	劣化あり (Positive群)	劣化なし (Negative群)
構造・種類	コンクリート構造で、パラペットを有する護岸	
建設年	建設年 (または建設時期) が明記されている	
劣化の有無に関する記載	・施設改良理由として「コンクリートの劣化」等が明記されている	・施設改良理由が「機能向上」、「景観」または「親水」のみ、またはそれらいずれかの組合せのみ ・改良前のパラペットを、改良後も機能を維持したまま引き続き利用


(1996) のデータベースに収録された 298 例のうち、表—1 の条件に基づいて劣化あり (Positive 群) と劣化なし (Negative 群) のそれぞれ 17 例を抽出した。まず、コンクリート構造でパラペットを有する護岸であって、建設年または建設時期が明記されていることを条件とした。また、同データベースは海岸保全施設の改良事例集であるため、改良理由を記載する欄がある。その欄に注目し、Positive 群については「コンクリートの劣化」等の文言が明記されているのを条件とした。一方、Negative 群については改良理由を「機能向上」、「景観」または「親水」に限ることで劣化ではないことを条件とし、かつ、改良前の堤体を地中に完全に埋めたりパラペットを切断・撤去したりしたことが図面から分かる事例は除外した。なぜならば、例えば改良理由として機能向上のみを挙げている事例であっても、パラペット等を撤去している場合はその部分が劣化していた可能性があるためである。

抽出した結果、両群の建設後平均経過年数 (1985 年時点) はそれぞれ 22.8 年と 21.1 年であった。また、両群の施設のうち建設後の経過年数が最短のものは、それぞれ 9 年と 12 年であった。


2.2 気象データの可視化 両群の建設後平均経過年数はどちらも約 20 年であったので、解析対象とすべき環境要因は 1966~1985 年の気象観測値とした。ただし、気象官署の多くは 1978 年頃までのデータが利用できなかった。そこで各事例について、最寄り気象官署等における 1979~1985 年の 7 年間 (2,557 日間) の毎日の日平均観測値を 2.3 節の環境要因の分だけそれぞれ入手した (気象庁, online)。そして、各事例・各ケースを、それぞれ 1 枚の PNG 形式のグレースケール画像 (または、白黒 2 値画像) として可視化した。

その際、図—2 (1) のように単純に時系列順で並べると、後述 (2.4 節) のプーリング処理のときに不具合を生じる。すなわち、プーリング処理の過程では、大局的な特徴を見出すため、ある範囲内 (例えば、数 pixel 四方の正方形領域) の特徴量の最大値や平均値をその範囲内の代表値として採用し、データを圧縮する仕組みを採用している。そのとき、仮に横軸方向に無関係なデータが並びかつそれらの値がお互いに大きく異なっている場合には値が平滑化されてしまい、本来は抽出すべき特徴が消滅してしまう可能性がある。そこで、図—2 (2) のように一週間 (7 日間) のデータをまず横軸方向に並べ、翌週のデータをその直上 (縦軸方向) に積み上げた。また、年が変わると最下行から同様に積み上げることにした。これにより、縦軸方向に下から上へむかって 1 月から 12 月までのデータが並ぶとともに、横軸方向にも季節が極端に異なるデータ同士が隣接しないようにすることが出来た。

以上のように、長期間の毎日の気象観測値データを可視化し、画像を使った深層学習のプーリング処理に適合するような正方形の画像データを生成する。



(1) 単純時系列構造



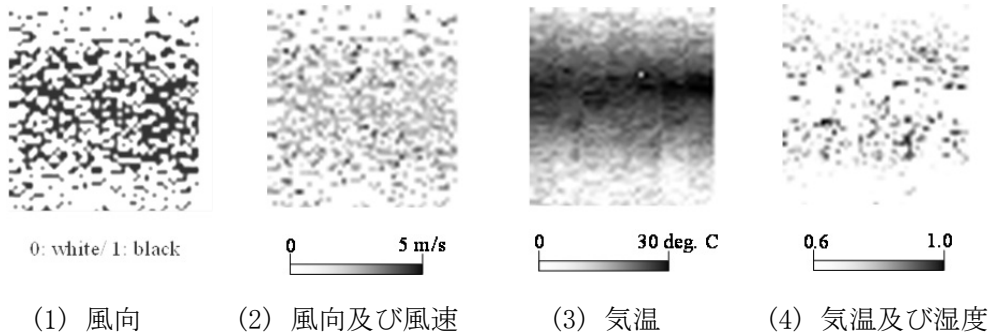
(2) 週単位積み上げ構造

図—2 画像データの構造

表—2 検討したケース

ケース	分析対象とした環境要因 ^{*1}	指標化の方法	画像の形式	劣化の機構 ^{*2}
1	風向	0 for Offshore 1 for Onshore	白黒2値	アルカリシリカ反応, (塩害)
2	風向及び風速	風速観測値に風向指標値(0または1)を乗じる	グレースケール	
3	気温	観測値をそのまま利用	グレースケール	凍害, (中性化)
4	気温及び湿度	和泉式 ¹⁾	グレースケール	(中性化)

*1: 風向は日最多風向, その他は日平均値である. *2: 文献1)を参考に, 主なものを示した. なお, 対象施設が無筋コンクリート構造の場合には, 一部の機構は当てはまらないものもある. そのような機構はカッコつきで示した.



図—3 生成した画像データの例 (両津港住吉地区, 文献5)の19ページ)

2.3 検討したケース 1章で述べたとおり劣化は多様な機構で生じる. しかし, 中島ら (1996) のデータベースでは劣化の有無が判別できるだけで, その機構は不明であった. そこで, 大胆な仮定ではあるものの, 今回収集した Positive 群は全て, ある環境要因に対して共通の特徴量を持つとの仮説を立てた. そして, 深層学習によりそのような特徴量が抽出されるか試行した. 表—2に, 検討した4つのケースでそれぞれ分析対象とした環境要因を示す. ケース1は, アルカリシリカ反応などによる劣化を想定し日最多風向が有意な特徴を示すか検討した. その際, 日最多風向が海風ならば1, 陸風ならば0を指標として与えた (欠測・静穏などの場合も0とした). 海風・陸風の判定は, 対象の施設から見て2 km以上にわたって陸がある方角からの風であれば陸風とした. この2 kmという値は, 日本規格協会 (2001) が離島などを除き海岸線から2 km以内を「飛来する海塩粒子の影響が比較的大きい地域」と定義していることから, 海からの塩化物イオンが風で運ばれるときの海岸線からの限界距離の目安として採用した. ケース2は, 風向に加え日平均風速を考慮し, 風向及び風速の統合的指標とした. ケース3は, 凍害などによる劣化を仮定し日平均気温が有意な特徴を示すか検討した. また, ケース4は, 日平均気温に加え日平均相対湿度を考慮した. その際, 以下の中性化の評価のための式(1)~(3)の和泉式¹⁾を参考にして, 式(2)及び(3)によって R_4 及び R_5 をそれぞれ求めたうえで, 両者を乗じた値を気温及び湿度の統合的指標とした:

$$C = 35.4 \cdot R_1 \cdot R_2 \cdot R_3 \cdot R_4 \cdot R_5 \cdot R_6 \cdot \sqrt{t} \quad (1)$$

$$R_4 = 0.017 \cdot T_{em} + 0.48 \quad (2)$$

$$R_5 = H_u (100 - H_u) (140 - H_u) / 192000 \quad (3)$$

ここで, C は中性化深さ (mm), R_1 はセメント種類・水セメント比の影響係数, R_2 はセメント種類・

湿潤養生の影響係数、 R_3 は炭酸ガス濃度の影響係数、 R_4 は気温の影響係数で T_{em} は気温 (°C)、 R_5 は湿度の影響係数で H_u は相対湿度 (%), R_6 は仕上げ影響係数である。また、 t は材齢 (年) である。

図—3 に、生成した画像データの例をケース 1~4 についてそれぞれ示す。各画像データは、図中に示す尺度に基づいてそれぞれグレースケールまたは白黒 2 値に着色されていて、2.2 節で述べたとおり図—2 (2) の構造をしている。


2.4 予測手法 機械学習のライブラリである Google 社の TensorFlow Ver. 1.5.0 及び tflearn Ver. 0.3.2 を用い、足立 (2017) を参考に、畳み込みニューラルネットワーク (Convolutional Neural Network. 以下、CNN という。) の画像分類器を作成した。画像分類器

はまず、与えられた画像を学習用データと、モデルの精度を検証するためのテスト用データとにランダムに分ける。次に、学習用データを用いて教師あり学習を行う。図—4 に、足立 (2017) を参考に作成した概略図を示した。CNN の入力層は 53×53 ノード、畳み込み層及びプーリング層はそれぞれ 3 層とした。各畳み込み層において特徴を抽出するためのフィルタはそれぞれ 32, 64, 128 層とし、そのサイズはいずれも 5×5 とした。各プーリング層では、一つ前の畳み込み層から受け取った特徴量について 2×2 の範囲で最大値を抽出する処理をした。中間層の最後に全結合層を作成するが、ドロップアウト比率は 0.5、学習の減衰係数は 0.5 とした。また、学習回数の指標の一つである Epoch 数は 50 とした。劣化あり (P) または劣化なし (N) の 2 クラスに分類するモデルが出来ると、モデルに基づいてテスト用データを P または N に分類してみて、モデルの精度を示す正答率を算出する。学習を行うたびに正答率は変化するので、10 回繰り返し実施してその正答率の平均値を算出した。

2.5 予測結果及び考察 表—3 に、予測結果を示す。劣化予測モデルの正答率平均値は 0.30~0.42 となった。最も良い値を示したケース 1 で 0.42 であり、今回は十分な精度は得られなかった。

以下、その原因の考察を行う。まず、機械学習の代表的なオープンソースライブラリの一つである scikit-learn のアルゴリズム選択シート⁸⁾によれば、機械学習を行う際のデータ数の目安を 50 個より多いこととしている。これと比較すると、今回収集した事例はやや少なかったようである。また、中島ら (1996) のデータベースでは劣化の有無が判別できるだけで、その機構は不明であった。従って、Positive 群のなかに劣化機構 (アルカリシリカ反応、凍害など) が異なる事例が混在している可能性がある。今後は、劣化機構まで区別できる事例の収集が必要と考えられる。

次に、学習モデルとして CNN を利用する場合は、時系列データを画像データに可視化する工程が必要である。その際、特徴量を抽出しやすくするために、分析者が画像データの構造・着色尺度を経験などに基づいて適切に調整する必要があると考えられる。それに対し、時系列データを数値的に直接読み込む学習モデルの場合は、分析者による調整の多くは不要になる。後者として、機械学習分野では統計的手法や、長期の時系列データの学習を特色とする LSTM などの手法がある⁹⁾。今



図—4 畳み込みニューラルネットワーク

表—3 劣化予測モデルの正答率平均値

ケース	正答率平均値
1	0.42
2	0.34
3	0.30
4	0.38

後は、時系列データを直接読み込む学習モデルについて検討することも必要と考えられる。

気象官署等は1か所である程度の地理的範囲をカバーしているため、カバーしている範囲内に、劣化の健全度が異なる海岸保全施設が混在している可能性がある。今回の劣化事例の収集にあたっては出来る限り近傍の施設が同様の劣化度を示している施設を抽出するように試みたが、収集できたデータベースの制約から必ずしも十分に考慮できていないため、今後の課題である。また、気象官署等よりも高密度に配置され一定の精度が保証されていると考えられる気象観測値、例えば民間気象情報会社のデータ¹⁰⁾を活用することも考えられる。

また、劣化を引き起こす要因は環境要因だけではない。セメント、骨材、混和材量などの材料要因、水セメント比などの調合要因、締固め、打継ぎ部処理、養生などの施工要因、構造、仕上げなどの設計要因等が考えられる¹⁾。これらの環境要因以外の要因が及ぼす影響を考慮して、モデルの適用範囲について検討する必要がある。なお、農林水産省・国土交通省(2014)では、堤体材料の吸出しから海岸保全施設の破壊に至ること、施設の変状が地震・津波・高潮で進展することなどを指摘している。そのような劣化のメカニズムに関する知見についても参考とする必要がある。

3. 結論

深層学習による海岸保全施設の劣化予測手法について基礎的検討を行った。コンクリート構造の護岸について風向を指標とした劣化予測モデルを構築した結果、正答率平均値は0.42であった。今回は十分な精度は得られなかったが、その原因として考えられる点を今後の課題として整理した。

謝 辞 京都大学防災研究所・小野憲司特定教授(現 同大学経営管理大学院客員教授)にはこの研究に取り組むきっかけを頂きました。また、国土技術政策総合研究所・本多和彦博士には環境要因の指標化の考え方についてご意見頂きました。ここに記して感謝の意を表します。

参考文献

- 1) 和泉意登志・竹田宣典・神谷清志・古賀裕久・鳥取誠一・長尾覚博・濱幸雄・前田俊也・横関康祐, 2016: コンクリートの劣化と補修がわかる本 update、コンクリート新聞社、127 p.
- 2) 気象庁: 過去の気象データ・ダウンロード, <http://www.data.jma.go.jp/gmd/risk/obsdl/>, 最終閲覧日 2018 年 2 月 28 日.
- 3) 鬼頭昭雄, 2015: 日本の気候はどうなるか, 異常気象と地球温暖化, 岩波書店, pp. 129-151
- 4) 吉野正敏, 2010: 地球温暖化時代の異常気象, 成山堂書店, 201 p.
- 5) 中島晋・横田弘・関根好幸・山道広人, 1996: 海岸保全施設の改良・更新事例集, 港湾技術研究所資料, 運輸省港湾技術研究所, No. 848, 316 p.
- 6) 日本規格協会, 2001: 大気暴露試験方法通則, JIS Z 2381, p. 22.
- 7) 足立悠, 2017: 初めての TensorFlow, リックテレコム, pp. 114-129.
- 8) Scikit-learn Project: Algorithm cheat-sheet, http://scikit-learn.org/stable/tutorial/machine_learning_map/ (accessed 28 February 2018).
- 9) 巢籠悠輔, 2017: 詳解ディープラーニング, マイナビ出版, pp. 227-248.
- 10) 株式会社ウェザーニューズ: Labs Channel, <http://labs.weathernews.jp/data.html>, 最終閲覧日 2018 年 2 月 28 日.
- 11) 農林水産省・国土交通省, 2014: 海岸保全施設維持管理マニュアル, 61 p.