

砕波現象に対するニューラルネットワークの構築

Neural Network Modeling of Breaking Wave

李 光浩¹・水谷法美²・藤井俊明³

Kwang-Ho LEE, Norimi MIZUTANI, Toshiaki FUJII

Wave braking is one of the most complex and important phenomena in the coastal engineering. For this reason, various empirical formulas based on the linear statistical approach have been developed to estimate breaking height and water depth, called to breaker index. This study presents an artificial neural network (ANN) model as an alternative method for predicting breaker index on a gravel and sandy beach. The published available experimental data for sandy beach is used as input system. Further, hydraulic model experiments are performed to obtain the experimental data for gravel beach. A fundamental three-layered feed forward type of network trained using the usual back-propagation training is developed to obtain breaker index from the input of the deep water height, wave period and sea bed conditions. The predicted breaking height and water depth confirmed usefulness of the proposed ANN model for the application of breaking wave.

1. はじめに

浅水変形により波が砕ける砕波現象は、波力や漂砂移動による海岸侵食など海岸工学上での様々な問題と密接に関連する物理現象の一つであり、砕波水深や砕波波高は海岸や港湾の構造物を計画・設計する上で重要なパラメータとなる。また、潮位差の大きな海岸においては、地下水面と海面との位置関係によって波浪場の特性は大きく変化することが予想される。特に、透水性の高い礫浜海岸では前面の波浪場は前浜の地下水位の影響を受けやすいことが指摘されており (Lee ら, 2007), 地下水位の影響を含めた砕波現象の検討が必要である。これまで、砂浜海岸に対しては水理模型実験により砕波波高や砕波水深などの砕波指標を評価する式が多数提案されている。例えば, Rattanapitikon・Shibayama (2006) は 26 の論文, 報告より得た 695 ケースの砕波データを検討し、底面勾配の影響を含む新たな砕波指標式を提案している。また、合田 (2007) はこれまでに報告されている砕波に関する研究を取りまとめ、新たな修正砕波指標式を提案するとともに、実務ならびに研究に使用可能な規則波と不規則波の砕波統計量の整備を行っている。しかし、礫浜海岸に対して適用可能な評価手法は提案されていないのが実状である。

一般に、砕波現象の評価には底面勾配や沖波波高から砕波指標を求める線形的な手法が用いられてきているが、砕波は非線形性の強い複雑な現象であり、非線形的な手法を用いて評価することが望ましいと考えられる。そこで、本

研究ではニューラルネットワークを砕波現象に適用することとした。ニューラルネットワークは初めて理論的に体系化された非線形近似手法として高く評価され、様々な分野で広く用いられており、近年海岸工学分野への適用も進んでいる (例えば, 間瀬ら, 2007; 加藤ら, 2007)。その中で, Deo・Jagdale (2003) はニューラルネットワークを砕波現象に適用し、これまで用いられてきた経験的な手法に比べ良好な結果が得られることを示している。しかし、既往の研究による礫浜の砕波データはほとんどなく、礫浜海岸と砂浜海岸を対象にニューラルネットワークが砕波現象に適用された例はない。

そこで、本研究では、地下水位が礫浜の砕波現象に及ぼす影響を検討するため、礫浜を対象に斜面背後での水位を強制的に上昇させることにより斜面内からの滲出流を変化させた水理模型実験を行い、砕波水深と砕波波高を測定する。そして、砕波現象に対するニューラルネットワークの適用性を検証するために、測定した砕波データと既往の砂浜を対象とした砕波データを入力データとして用いたニューラルネットワークを構築することを目的とする。

2. 水理模型実験の概要

(1) 実験装置

水理模型実験は、名古屋大学大学院工学研究科の長さ 30 m, 幅 0.7 m, 高さ 0.9 m の片面ガラス張り二次元造波水路を用いて行った。造波水路の一端にはピストン型造波装置が備えられている。また、水路内の岸側に中央粒径 $d_{50}=5\text{mm}$, 比重 2.65 の礫を敷きならして、勾配 1/7 の移動床斜面を製作した。実験中の水位を一定に保つため、板で仕切りを作ることで水槽を幅 0.3 m と 0.4 m に分割した。また、地下水位を考慮するため、斜面背後にアクリル製水槽を設置し、ポンプによる注・排水を行なうことにより地下水位を操作するとともに水槽内で水を循環させた。斜面とアク

1 正 会 員 博(工)名古屋大学大学院助教 工学研究科社会基盤工学専攻

2 正 会 員 工博 名古屋大学大学院教授 工学研究科社会基盤工学専攻

3 学生会員 学(工)名古屋大学大学院工学研究科社会基盤工学専攻

リル製水槽とは底質と比べて十分に細かい目の網によって接しているため斜面からアクリル製水槽への底質の移動はなく、また、水の移動が妨げられないように配慮している。本研究で用いた実験装置の概要を図-1に示す。

(2) 実験条件および実験方法

実験では静水深 h を40.0 cmで一定とし、波高 H を約3.0 cmから約8.0 cmの11種類、造波板の押し出す周期 T を1.0 sから2.0 sの11種類、斜面背後の水位と静水深の差を0.0 cm、7.5 cm、12.5 cm、17.5 cmの4種類ずつ変化させて、計484ケースの実験を行った。実験中は、高速度ビデオカメラ（DITECT製HAS-500）を用いて砕波点近傍（汀線より沖側に10 cm～80 cm）を200fpsで撮影した。そして、図-2に示すように砕波水深 h_b と砕波波高 H_b をそれぞれ定義し、画像解析から求めた。

3. ニューラルネットワーク

(1) ニューラルネットワークの概要

ニューラルネットワークとは生態の神経細胞（ニューロン）を模擬した人工の素子を相互に接続して構成されるネットワークのことである。素子間には生体のシナプス結合に類似した相互作用が導入されており、各シナプスには重み係数が割り振られている。ニューラルネットワークの最大の特徴として非線形性が取り上げられ、初めて理論的に体系化され、本格的、広範に利用されるようになった非線形近似手法として高く評価されている。また、必要とされる機能を訓練に基づき自動形成する学習能力も重要な特徴の一つである。

(2) 入力データとデータの基準化

ニューラルネットワークによる砕波予測を行なうための入力データとしては、礫浜を対象とした本実験484ケースのうち砕波データが得られた469ケースに砂浜を対象とした既往の実験による345ケースの砕波データを加えた計814ケースとした。なお、砂浜の実験データはDeo・Jagdale (2003) および既往の実験データを取りまとめたSmith・Kraus (1990) から得た。また、入力変数として入射波周期 T 、沖波波高 H_0 、底面勾配 m 、斜面の空隙率 $void$ および斜面背後での水位差 Δh を用い、砕波波高 H_b および砕波水深

h_b を出力した。ニューラルネットワークに用いた入出力変数の概要を表-1に示す。ニューラルネットワークは主に学習段階と評価段階に分けられる。学習段階では訓練データを用いてネットワークを訓練し、評価段階では全データから訓練データを除いた評価データを用いて、訓練したネットワークが未知の入力に対してもよい予測結果を示すかどうか（汎化能力）を評価する。本研究では、訓練データと評価データをそれぞれ407ケースに無作為に分割し予測を行った。

本研究ではニューラルネットワークの活性化関数としてシグモイド関数を用いるため、その出力は0～1の範囲となる。また、入力データとして入射波周期や沖波波高といった次元の異なる変数を用いるため、入力データをそのまま用いると各変数の変動の特徴を正確に学習できない可能性がある。そのため、本研究では加藤ら(2007)に倣い、式(1)を用いて基準化を行った。

$$x' = \frac{4}{5} \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) + 0.1 \quad (1)$$

ここに、 x' ：基準化されたデータ、 x ：基準化を行なうデータ、 $x_{\max}$ 、 $x_{\min}$ ：各データの最大値と最小値である。式(1)では入力データが0.1～0.9の範囲となるように基準化を行っている。

(3) ニューラルネットワークの構築

本研究では、入力層、中間層、出力層の3層で構成される階層型ニューラルネットワークを用いた。各層にはニュー

表-1 入出力変数の概要

変数	礫浜海岸		砂浜海岸	
	最小値	最大値	最小値	最大値
$T(s)$	1.0	2.0	0.7	6.0
$H_0(m)$	0.0304	0.0876	0.0104	0.173
m	0.143	0.143	0.0125	0.2
$void$	0.4	0.4	0.0	0.0
$\Delta h(m)$	0.0	0.175	0.0	0.0
$H_b(m)$	0.0252	0.114	0.0244	0.193
$h_b(m)$	0.0364	0.116	0.0305	0.263
データ数	469		345	




図-1 実験装置




図-2 砕波波高と砕波水深の定義

ロンと呼ばれる素子が配置されており、1つ前の層の出力の重み付け総和から閾値を差し引いた値が次の層の素子に入力され、非線形活性化関数に応じた値が出力される。本研究では非線形活性化関数として式(2)に示すシグモイド関数を用いた。

$$f(s_j) = \frac{1}{1 + e^{-s_j}} \quad (2)$$

$$s_j = \sum_{i=1}^N w_{ij} x_i - \theta_j \quad (3)$$

ここに、 $f(s_j)$: j 番目の素子の出力値、 s_j : j 番目の素子への重み付け総和、 N : 前層の素子数、 w_{ij} : 重み係数、 x_i : 入力値、 θ_j : 閾値である。なお、閾値を取り扱うために、中間層と出力層に対して常に1の値を入力するバイアスを設けている。また、訓練の開始時に与える重みの初期値には、0~1の値を無作為に与えた。学習方法として、階層型ニューラルネットワークに対して一般的に用いられている誤差逆伝播法(Back Propagation training method)を採用した。誤差逆伝播法は、入力時に目標値(教師信号)を与え、式(4)に示す予測値と目標値の誤差評価尺度が小さくなるように順次重みを調整していく学習法である。

$$E = \frac{1}{2} \sum_{n=1}^{n_{out}} (t_n - o_n)^2 \quad (4)$$

ここに、 E : 誤差評価尺度、 n_{out} : 出力層の素子数、 t_n : 目標値(教師信号)、 o_n : ニューラルネットワークの予測値である。

ニューラルネットワークでは中間層の素子数が少ないと学習時間は早くなるが、入力の特徴を正確に把握することができない可能性がある。逆に、素子数が多いと学習時間が長くなり、余計なノイズまで学習してしまうことがわかっている。そのため、中間層の素子数を決定することはネットワークの構築において極めて重要である。しかしながら、中間層の素子数を決定する方法は確立されておらず、試行錯誤的に決定する方法が一般的に用いられている。本研究でも、式(6)に示す二乗平均平方根誤差(RMSE)を用いて

試行錯誤的に中間層の素子数を決定することとした。

$$RMSE = \sqrt{\frac{1}{N_{test}} \sum_{n=1}^{N_{test}} (t_n - o_n)^2} \quad (6)$$

ここに、 N_{test} : 評価データ数である。図-3は中間層の素子数を変化させたときの碎波水深および碎波波高に対するRMSEである。同図より、RMSEは中間層の素子数が少ないと増加し、ある程度多くなると安定していることがわかる。そこで、中間層の素子数が多くなるとニューラルネットワークの複雑性が増すことを考慮し、中間層の素子数は6個とした。最終的に構築した階層型ニューラルネットワークの概要を図-4に示す。

(4) 入力データの取り扱い

ニューラルネットワークでは、砂浜海岸と礫浜海岸の碎波データのような傾向の異なるデータを同時に用いた場合でも、未知の入力に対して良好な予測結果を示すことが求められる。そこで、本研究では以下に示す3通りの方法によりニューラルネットワークの予測を行った。

a) 礫浜と砂浜の碎波データを両方用いて予測を行う(Case1).

この場合、入力変数は周期 T 、沖波波高 H_0 、底面勾配 m 、斜面の空隙率 $void$ および斜面背後での水位差 Δh である。

b) 礫浜の碎波データのみを用いて予測を行う(Case2).

この場合、入力変数は周期 T 、沖波波高 H_0 および斜面背後での水位差 Δh である。

c) 砂浜の碎波データのみを用いて予測を行う(Case3).

この場合、入力変数は入射波周期 T 、沖波波高 H_0 および底面勾配 m である。

4. ニューラルネットワークの予測結果

図-5はCase1のニューラルネットワークによる碎波波高と碎波水深の予測値(縦軸)と実験値(横軸)を比較したものである。なお、図中の R^2 は式(7)で定義される決定係数である。




図-3 中間層の素子数とRMSEの関係




図-4 階層型ニューラルネットワーク

$$R^2 = \frac{\sum_{n=1}^{N_{\text{test}}} (t_n - o_{\text{mean}})^2 - \sum_{n=1}^{N_{\text{test}}} (t_n - o_n)^2}{\sum_{n=1}^{N_{\text{test}}} (t_n - o_{\text{mean}})^2} \quad (7)$$


ここに、 o_{mean} ：予測値の平均である。図-5から、碎波水深・碎波波高とも決定係数が0.9を超えており、ニューラルネットワークはかなり精度良く予測できていることが確認できる。また、礫浜の予測結果が砂浜の予測結果に比べて決定係数が高いことや碎波水深の方が碎波波高に比べて決定係数が高いことがわかる。

つぎに、図-6に礫浜に対する予測結果を斜面背後の水位差ごとにプロットしたものを示す。なお、李ら(2008)により斜面背後の水位差が大きくなると碎波点が沖側に移動し、碎波水深が増加するとともに碎波波高が減少することが確認されている。同図より、斜面背後の水位差が小さいと決定係数が高くなる様子が認められる。これは、水位差が大きいほど斜面内からの滲出流が強くなるため、波が不


安定になることに起因すると考えられる。なお、図-6 (a)では $\Delta h=0.0$ cmの方が $\Delta h=7.5$ cmより、図-6 (b)では $\Delta h=7.5$ cmの方が $\Delta h=12.5$ cmより決定係数が小さくなっているため、今後検討する必要がある。

図-7, 8はCase1の礫浜および砂浜の予測結果とCase2の礫浜の予測結果およびCase3の砂浜の予測結果を比較したものである。図-7から、Case1はCase2より僅かながら決定係数が小さいものの、予測結果にほとんど差がないことがわかる。また、図-8ではCase1の方がCase3よりも決定係数が高くなっており、砂浜と礫浜のデータを同時に用いて予測を行っても精度の良い結果が得られることがわかる。

以上のことから、ニューラルネットワークは礫浜と砂浜の碎波データを同時に用いても精度良く予測できる可能性が高く、また、周期 T 、沖波波高 H_0 および海底勾配 m などの入力変数を無次元化することなくそのまま入力することができるため、碎波予測に対して非常に有用なツールとなりうると判断される。




(a) 碎波水深




(b) 碎波波高

図-5 実験値とニューラルネットワーク予測値の関係 (Case1)



(a) 碎波水深



(b) 碎波波高

図-6 地下水位を変化させたときの礫浜に対する予測結果 (Case1)




図-7 礫浜と砂浜 (Case1) と礫浜のみ (Case2) の比較




図-8 礫浜と砂浜 (Case1) と砂浜のみ (Case3) の比較

5. おわりに

本研究では、地下水位の影響を考慮した礫浜の碎波データと既往の実験による砂浜の碎波データを用いて、碎波波高と碎波水深の予測を行うニューラルネットワークを構築した。本研究で得られた主要な結論を以下に要約する。

- 1) 礫浜と砂浜を対象に、ニューラルネットワークによる碎波波高および碎波水深の予測値と実験結果を比較したところ、両者は良好に一致した。
- 2) 構築したニューラルネットワークでは地下水位の影響を含めても良好な予測が可能である。
- 3) 本実験では底面勾配を固定して行ったため、今後底面勾配を変えた実験を行い、データを拡充する必要がある。

参考文献

加藤 茂・若江直人・青木伸一 (2007) : ニューラルネットワークを併用した順応的管理のための汀線モニタリング法の検

討, 海岸工学論文集, 第54巻, pp.656-660.

熊沢逸夫(1998) : 学習とニューラルネットワーク, 森北出版, 192p.

合田良実(2007) : 工学的応用のための碎波統計量データの再整理, 海岸工学論文集, 第54巻, pp.81-85.

間瀬 肇・安田誠宏・高山知司(2007) : ニューラルネットワークを用いた大阪湾内への来襲津波のリアルタイム予測に関する研究, 海岸工学論文集, 第54巻, pp.201-205.

李 光浩・水谷法美・藤井俊明(2008) : 礫浜海岸の前浜における地下水位が碎波現象に及ぼす影響に関する研究, 海洋開発論文集, vol.24, 印刷中

Deo, M.C. and Jagdale, S.S. (2003) : Prediction of breaking waves with neural networks, Ocean Engineering, Vol.30, pp.1163-1178.

Lee, K.-H. and Mizutani, N., Hur, D.-S. Kamiya, A. (2007) : The effect of groundwater on topographic changes in a gravel beach, Ocean Engineering, Vol.34, pp.605-615.

Rattanapitikon, W. and Shibayama, T. (2006) : Breaking wave formulas for breaking depth and orbital to phase velocity ratio, Coastal Engineering Journal, JSCE48, pp.395-416.

Smith, E. R. and Kraus, N. C. (1990) : Laboratory study on macro-features of wave breaking over bars and artificial reefs, Technical Report CERC-90-12, WES, U.S. Army Corps of Engineers, 232 p.