

ニューラルネットワークを用いた人工リーフ周辺の水理特性評価 —トラップ式ダブルリーフを対象として—

Estimation of Hydraulic Characteristics around Artificial Reef using Neural Network
— A Case Study of Wave Trapping Artificial Reef —

齋藤武久¹・砂原啓人²・市川督人³・福本 正⁴・間瀬 肇⁵・石田 啓⁶

Takehisa SAITOH, Hiroto SUNAHARA, Masato ICHIKAWA, Tadashi FUKUMOTO,
Hajime MASE, and Hajime ISHIDA

This study aims to develop a highly accurate method for an estimation of hydraulic characteristics around an artificial reef by using an artificial neural network, instead of a conventional method using a regression analysis. The wave trapping artificial reef is chosen as the structure of an artificial reef, and transmission coefficient and wave setup behind the reef are focused as hydraulic characteristics. For the training of the artificial neural network, the Levenberg-Marquardt method with Bayesian regulation is employed. Predictions of transmission coefficient and wave setup from the trained network agreed well with the experimental results comparing with predicted ones from the method using a regression analysis.

1. 緒 論

人工リーフ設置に伴う周辺の水理特性を的確に評価することは、防護・利用・環境を考慮した持続可能な海岸環境保全のために基本的かつ重要な課題である。中でも、リーフ背後域での透過率および水位上昇量に関して、高精度な予測評価手法を構築することは、陸域への打ち上げ高や越波流量などの算定に直結するため、人工リーフの性能・機能設計において必要不可欠である。

現在、人工リーフによる透過率および背後域での水位上昇量評価は、実験結果から回帰的に整理された算定図(宇多ら, 1988; 全国海岸協会, 2004)や実験式(Van der Meer et al., 2005)が幅広く活用されている。その手法は、従来型の断面形状のリーフの場合に限らず、新型人工リーフの場合にも応用されている(白石ら, 2002; 福本ら, 2005b)。一方で、さらなる予測精度の向上を求める場合、従来の回帰的手法を用いることでは限界がある。

そこで、本研究では、上述の水理特性評価に関して、

より高精度な評価手法の構築を目的として、ニューラルネットワークの導入を試みる。評価対象には、400ケースを超える系統的な室内実験データの報告があるトラップ式ダブルリーフ(福本ら, 2005a, 2005b)を取り上げ、重回帰分析に基づく従来型の評価手法との比較により、ニューラルネットワークを導入した本手法の有効性を検討する。

2. 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法は、神経系の情報伝達機構を模擬した情報処理方式である。この中で、人間の神経細胞(ニューロン)のモデルを用いた人工システムはニューロ、ニューロンの人工モデルはユニットと呼ばれる。あるデータ間の因果関係が不明確で、入出力関係のプログラム化が困難な場合など、ニューラルネットワークではユニットをシナプスで結び付け、繰り返し学習によりその結合度を変化させ、入出力関係を具現化することが可能である。したがって、因果関係の解析が困難なデータを処理する上で極めて有効であり、多くの工学分野でニューラルネットワーク法が導入されている。最近では、後述する学習アルゴリズムやニューラルネットワークのモデル自身の改良が活発に行われていることに加えて、その基本原理、計算手続および汎用化された多くのプログラムが提供されている(例えば、Martinら, 1996; 熊沢, 1998)。本研究では、科学技術計算言語として幅広く利用されているMATLAB®のNeural Network Toolbox®を用いてニューラルネットワークの構築を試みる。以下に、本研究で採用するニューラルネットワークの構成および

-
- 1 正 会 員 博(工) 金沢大学 准教授 理工研究域環境デザイン学系
2 東京大学大学院
3 西松建設株式会社 設計部
4 博(工) 西松建設株式会社 技術研究所
5 正 会 員 工博 京都大学 教授 防災研究所
6 フェロー 工博 金沢大学 教授 理工研究域環境デザイン学系




図-1 階層型ニューラルネットワーク

学習方法の概要を述べる。

(1) ニューラルネットワークの構成

ニューロで通常用いられるモデル(ユニット)は多入力・1出力といった非常に簡略化されたモデルが用いられる。ユニット間は神経繊維に対応する線(シプナス)で結ばれ、信号は一方方向に伝わる。ユニットにつながっているシプナスからの入力信号は、ある重み(結合荷重)をかけられ加算され、さらに閾値が差し引かれた値がそのユニットに入力される。ユニットは応答関数に応じた出力値を出力する。

ニューラルネットワークにおけるユニットの応答関数として、しばしば用いられるのはシグモイド関数である。シグモイド関数には、出力が0~1のlog型と出力が-1~1のtangent型がある。実際の応用に用いられる階層型ニューラルネットワーク(図-1参照)では、最後の層がシグモイドニューロンの場合、出力値が小さい領域に制限される。そのため、線形関数が出力ニューロンに用いられる。これにより出力が任意となる。本研究では、間瀬ら(2005, 2007)にならい、中間層にはlog型シグモイド関数、出力ユニットには線形関数を用いる。

(2) 学習法

本研究で採用する階層型ニューラルネットワークは、入力層、中間層、出力層からなる。入力層に与えられる数値データ(入力パターン)と同時に、学習の指針として望ましい出力値(教師信号)を与え、ニューラルネットワークからの出力信号と教師信号との誤差をフィードバックすることにより、教師信号に近い値がでるように結合荷重と閾値を調整する。バックプロパゲーションがこの様な教師付き学習法のことであり、学習によって得られる知識は結合荷重と閾値に情報として蓄えられる。

バックプロパゲーションアルゴリズムには多くの種類があるが、最も単純なものは、パフォーマンス関数(ニューラルネットワークからの出力とターゲット出力の間の平均二乗誤差)が最も早く減少する勾配の負方向に経路の重み(結合荷重)と閾値を更新する勾配降下法である

(例えば、熊沢, 1998)。本研究では、数値最適化手法に基づく高速訓練アルゴリズムである以下の共役勾配法、1) Powell/Beale リスタート法(CGB法)、2) スケーリング共役勾配法(SCG法)、およびニュートン法に似た3) Levenberg-Marquardt法(LM法)の中から、間瀬ら(2005, 2007)が行った解析結果を参考に、Levenberg-Marquardt法(LM法)を用いた学習法を採用する。

ニューラルネットワークの訓練中に起きる問題の一つに、過学習(オーバーフィッティング)が挙げられる。これは訓練データセットに対する適合度が良くなり過ぎ、新規のデータセットに対してかえって誤差が大きくなる現象である。ニューラルネットワークは訓練データセットの特徴を記憶するが、新規の状況を一般化するための学習をすることはできないためである。これに対して、上述の一般化のための改良方法に、早期停止法および正則化法(MacKay, 1992)が提案されている。

早期停止法では、利用可能なデータを、訓練データセット、バリデーションデータセットおよびテストデータセットの3つのサブセットに分割する。バリデーションデータセットの誤差は、訓練データセット誤差と同様に、訓練の初期フェーズ中に通常減少するが、ニューラルネットワークが過学習し始めるとバリデーションデータセットの誤差は増加し始める。そこで、バリデーションデータセットに対する誤差が指定した繰り返し回数以上に連続して増加するときには訓練を停止させる。テストデータセットは訓練中には用いられないが、ニューラルネットワークの妥当性を検証するために用いられる。

一方、正則化法は、出力誤差の平均二乗和であるパフォーマンス関数に、結合荷重の平均二乗和を加えることによって、一般化の改良を行う。修正されたパフォーマンス関数を用いると、ニューラルネットワークは小さい結合荷重と閾値をもつようになり、その応答は強制的に滑らかになり、オーバーフィッティングしにくくなる。自動的に最適正則化パラメータを決定する学習方法としてBayesian法がある。本研究では、ニューラルネットワークの訓練アルゴリズムとして、教師データに対するバリデーションデータを必要とせず、実験データの効率的な利用が可能となるBayesian正則化法を付加したLM(Levenberg-Marquardt)法を採用する。

3. リーフ周辺の波浪特性評価に用いるニューラルネットワークモデル

(1) 解析に用いる実験データ

トラップ式ダブルリーフによる透過率および水位上昇量に関する実験データは、西松建設(株)技術研究所で実施された断面2次元水槽実験の結果を用いる。図-2および表-1に水槽およびリーフ模型の寸法を示す。なお、




図-2 階実験水槽およびトラップ式ダブルリーフ模型の概要

表-1 トラップ式ダブルリーフの形状

| | | | |
|----------------|-----------------|----------------|---|
| B ₁ | 5.0, 10.0, 15.0 | R ₁ | 6.0, 7.0, 8.0, 9.0, 10.0, |
| B ₂ | 15, 20, 30 | R ₂ | 3.0, 3.1, 3.4, 4.0, 4.1, 4.4, 5.0, 5.1, 5.4 |
| B ₃ | 0.0, 5.0, 10.0 | R ₃ | 1.0, 2.0, 3.0 |

(B_{1,2,3}およびR_{1,2,3}は実スケール換算値, 単位: m)

トラップ式ダブルリーフは、捨石マウンドとスリット付中空コンクリート構造物の2段で構成される新しい人工リーフである。従来型の人工リーフと同様なリーフ法面および天端上での消波機能に加えて、スリット付構造物沖側開口部からの戻り流れとスリット部での擾乱により消波効果を高め、従来型人工リーフに比べて小断面で同等の消波効果が発揮できる。さらに、低反射であること、背後域での水位上昇を大幅に抑えることができる特徴を有している。実験に際して用いられた模型縮尺は1/20であり、入射波には実スケール換算でH₀=1.0~4.0m, T₀=7.0~12.0sの範囲から12種類の不規則波を採用している。また、リーフ断面形状は、天端幅B_{1,2,3}と天端水深R_{1,2,3}を変化させた39種類であり、計342ケースに対して、透過率および水位上昇量データが取得されている。

図-3および図-4に、透過率K_tおよび水位上昇量 $\bar{\eta}/H_0$ ($\bar{\eta}$ は背後域における平均水位上昇量) 特性に関する実験結果を示す。図より、透過率特性では、同一の相対天端波高R₃/H₀に着目した場合、相対天端幅B/L₀ (B=B₂+B₃) 増加に伴う透過率の減少、さらに、同一の相対天端幅B/L₀の場合、相対天端波高R₃/H₀の増加に伴う透過




図-3 トラップ式ダブルリーフによる透過率特性

率の増加が確認できる。また、水位上昇量特性では、同一の波形勾配H₀/L₀に着目した場合、相対天端波高R₃/H₀の増加に伴う水位上昇量の減少、さらに、同一の相対天端波高R₃/H₀の場合、波形勾配H₀/L₀の増加に伴う水位上昇量の減少が確認できる。以上の結果は、従来型人工リーフの場合と同様な特徴(全国海岸協会, 2004)となっている。ただし、同等の透過率を発揮する従来型人工リーフと比較した場合、トラップ式ダブルリーフの場合、断面が小断面でその性能が発揮され、背後域での水位上昇量も大幅に軽減されていることが報告されている(福本ら, 2005a)。

上述の実験結果に対して、構造形状に関する、天端水深R_{1,2,3}および天端幅B_{1,2,3}をそれぞれH₀およびL₀で無次元化した6変数を説明変数(福本ら, 2005b)とし、透過率および水位上昇量に関する重回帰分析を行う。結果として、透過率および水位上昇量の算定式が、決定係数R²(R:相関係数)を0.875および0.758として、以下のように整理できる。

$$K_t = 0.370 - 0.039R_1/H_0 + 0.112R_2/H_0 + 0.431R_3/H_0 + 0.063B_1/L_0 - 0.467B_2/L_0 - 0.525B_3/L_0, \quad (1)$$

in the case of R²=0.875

$$\bar{\eta}/H_0 = 0.061 + 0.001R_1/H_0 - 0.004R_2/H_0 - 0.047R_3/H_0 - 0.095B_1/L_0 + 0.011B_2/L_0 + 0.114B_3/L_0, \quad (2)$$

in the case of R²=0.758

(2) ニューラルネットワークモデル

本研究では、ネットワークの概要で述べたように、入力層、中間層および出力層からなる階層型ニューラルネットワークを採用し、学習法には、Bayesian正則化法を付加したLM(Levenberg-Marquardt)法を用いる。なお、ニューラルネットワークの構築において、入力層ユニット数および中間層ユニット数の違いが、予測値の精度に影響することが指摘されている(間瀬ら, 2005; Panizzo and Briganti, 2007)。確かに、より高精度に実験結果を予測可能とする入力層ユニット数および中間層ユニット




図-4 トラップ式ダブルリーフによる水位上昇量特性




図-5 ニューラルネットワークを用いた透過率の予測値と実験値との比較 (中間層ユニット数: 10, Bayesian 正則化法)




図-6 重回帰分析を用いた透過率の予測値と実験値との比較




図-7 ニューラルネットワークを用いた水位上昇量の予測値と実験値との比較 (中間層ユニット数: 4, Bayesian 正則化法)




図-8 重回帰分析を用いた水位上昇量の予測値と実験値との比較

数を決定することは重要な課題である。ただし、本研究では、従来の回帰的手法を用いた予測値とニューラルネットワークを用いた予測値との予測精度の比較を主要な目的とするため、入力層ユニットには、重回帰分析の際に採用した説明変数を用い、説明変数の違いに伴う予測精度の比較には言及しない。つまり、入力層ユニット数は、上述の重回帰分析での説明変数、 B_1/L 、 B_2/L 、 B_3/L 、 $R_1/H_{1/3}$ 、 $R_2/H_{1/3}$ および $R_3/H_{1/3}$ の6に固定する。また、中間層ユニット数に関しては、その数を変化させた試行計算を行い、予測値と実験値との相関の違いを検討して、最も決定係数が高くなるユニット数を選択した。なお、実験データを教師データとテストデータへ分割する際には、両データで実験条件に偏りがないように均等に分割している。

4. 実験結果と算定結果の比較および考察

本研究で構築したニューラルネットワークを用いて計算したトラップ式ダブルリーフによる透過率の予測値と実験値との比較を図-5に示す。なお、中間層ユニット数

の詳細に関しては後述するが、図中の予測値は、ユニット数が10の場合である。図より、透過率の全範囲において予測値は実験値を良好に再現し、決定係数 R^2 が0.944と非常に高い相関を示すニューラルネットワークの構築が達成されている。一方、重回帰分析により得られた式(1)に、テストデータの値を代入して計算した予測値と実験値との比較を図-6に示す。決定係数は0.883と比較的高く、図中でも透過率の全範囲において予測値は比較的良好に実験結果を再現している。ただし、ニューラルネットワークを用いた場合の相関の値0.944には達成しておらず、図-5の場合に比べて実験値と予測値の等値線からの値のばらつきが大きい。

次に、ニューラルネットワークを用いて計算したリーフ背後域での水位上昇量の予測値と実験値との比較を図-7に示す。中間層ユニット数は4の場合である。さらに、図-8に式(2)を用いて計算した予測値と実験値との比較を示す。重回帰分析を用いた場合、決定係数は0.758となり、比較的良好な値を示している。しかしながら、水位上昇量の値が0.04を超える範囲で、予測値は過小評価

表-2 中間層ユニット数の違いによる決定係数の変化

| 中間層ユニット数 | 4 | 5 | 6 | 7 | 8 | 10 | 12 | 16 |
|-------------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| K_t : 決定係数 | 0.937 | 0.938 | 0.943 | 0.937 | 0.934 | 0.944 | 0.937 | 0.937 |
| $\bar{\eta}/H_0$: 決定係数 | 0.887 | 0.815 | 0.859 | 0.856 | 0.810 | 0.852 | 0.847 | 0.858 |




図-9 ニューラルネットワークを用いた透過率の予測値と実験値との比較 (中間層ユニット数: 10, 早期停止法)




図-10 ニューラルネットワークを用いた透過率の予測値と実験値との比較 (中間層ユニット数: 4, 早期停止法)

となり実験値を良好に再現できていないなど、水位上昇量の全範囲において的確に予測値を算定できていないことが分かる。これに対して、ニューラルネットワークを用いた場合、全ての水位上昇量の範囲において予測値が実験値を良好に再現できている。さらに、決定係数は0.887となり、重回帰分析の場合に比べて予測精度は大幅に改善できることが確認できる。

ここで、中間層ユニット数の変化が構築されたニューラルネットワークの予測値の精度に与える影響を検討する。図-5および図-7で検討した透過率および水位上昇量に関して、入力層ユニット数を同じ6つに固定し、中間層ユニット数を4から16まで変化させ、予測値と実験値との決定係数を計算した結果を表-2に示す。表より、図-5および図-7で用いた中間層ユニット数10および4の場合に、決定係数が最も高くなるが、決定係数の変化に規則性を見出すには至らなかった。

なお、他の学習アルゴリズムとして、上述の中間層ユニット数を用いて、バリデーションデータを使用した早期停止法による予測値と実験値との比較を図-9および図-10に示す。他の中間層ユニット数の場合も含めて、今回採用したBayesian正則化法を付加したLM(Levenberg-Marquardt)法を用いた予測値が実験値に対して最も高い相関を示していた。

5. 結論

本研究では、人工リーフ背後域での透過率および水位上昇量のより高精度な評価手法の構築を目的として、トラップ式ダブルリーフの場合を対象に、ニューラルネットワークの導入を試みた。

透過率および水位上昇量ともに、重回帰分析に基づく従来型の評価手法による算定値に比べ、本研究で構築したニューラルネットワークを用いた算定値が実験値との相関が極めて良好となり、ニューラルネットワークを導入した本手法の有効性が確認できた。

参考文献

- 宇多高明・小俣 篤・横山揚久(1988):人工リーフの機能と設計法, 土木研究所資料, 第2696号, p.79.
- 熊沢逸夫(1998):学習とニューラルネットワーク, 森北出版, p.182.
- 白石哲也・土市進・近川喜代志・千葉明裕・小森俊英(2002):新潟西海岸潜堤形状検討実験について, 海洋開発論文集, 第18巻, pp.671-676.
- 全国海岸協会(2004):人工リーフの設計の手引き, p.95.
- 福本 正・高村浩彰・土橋吉輝(2005a):トラップ式ダブルリーフと従来型人工リーフとの比較, 海洋開発論文集, 第21巻, pp.487-492.
- 福本 正・高村浩彰・土橋吉輝・安田孝志(2005b):トラップ式ダブルリーフ形状寸法の算定法, 海岸工学論文集, 第52巻, pp.826-830.
- 間瀬 肇・永橋俊二・Terry S. HEDGES(2005):緩傾斜護岸の越波流量算定におけるニューラルネットワークの適用性に関する研究, 海洋開発論文集, 第21巻, pp.593-598.
- 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.
- Panizzo A. and R. Briganti(2007): Analysis of wave transmission behind low-crested breakwaters using neural networks, Coastal Eng., 54, pp.643-656.
- MacKay, D.J.C.(1992): Bayesian interpolation, Neural Computation, Vol. 4, No. 3, 1992, pp. 415-447.
- Martin T. H., B.D. Howard, B. Mark(1996): Neural network design, PWS Publishing Company.
- Van der Meer, J. W., R. Briganti, B. Zanuttigh and W. Baoxing(2005): Wave transmission at low crested structures, Coastal Eng., 52, pp.915-929.