

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

APPLICABILITY OF NEURAL NETWORK TO ESTIMATION OF WAVE OVERTOPPING OVER SLOPING SEAWALLS

間瀬 肇¹・永橋俊二²・Terry S. HEDGES³

Hajime MASE, Shunji NAGAHASHI and Terry S. HEDGES

¹正会員 工博 京都大学助教授 防災研究所 (〒611-0011 宇治市五ヶ庄)

²工修 大阪市建設局西工営所 (〒552-0012 大阪市港区市岡2-15-74)

³Eur Ing, Senior Lecturer, Dept. Civil Eng., Univ. of Liverpool (Brownlow Hill, Liverpool, L69 3GH, UK)

This study examines the applicability of artificial neural networks (ANN) to the estimation of wave overtopping over sloping seawalls, especially for searching the best structure of ANN. The linear activation function was found to be a good choice for output units. Correlation coefficients between measurements and predictions were best when 6 input units and 12 hidden layer units were employed. The Levenberg-Marquardt method with Early Stopping (LM) and with Bayesian Regulation (BAYESIAN) both gave reasonable predictions. The LM requires a validation data set to prevent over-fitting and to judge the convergence and generalization. The BAYESIAN, recommended in this study, does not require a validation data set, but required more iterations of learning. If there are no data for non-overtopping conditions, the ANN cannot recognize when wave overtopping fails to occur. It is concluded that the ANN proposed here gives reasonable predictions for mean wave overtopping rates.

KeyWords : Neural network, wave overtopping, sloping seawall, random waves

1. はじめに

護岸設計における重要な要因は打上げ高と越波流量であり、それらに関して簡便かつ精度の良い算定図や算定式が必要である。緩傾斜護岸の耐波安定性や越波流量については多くの研究が行われ、打上高や越波流量算定図が作られているが、それぞれ適用条件に限られる。例えば、井上ら^{1),2)}は3割、5割および7割の緩傾斜護岸を対象として不規則波の越波実験を行い、越波流量算定図を提案した。適用範囲は法先水深・波高比が -0.27~0.71 および相対護岸天端高が 0.5~1.5 に対して、相対護岸天端高ごとに安全側になるよう越波流量曲線が描かれた。Hedge and Reis³⁾は、i) 護岸天端高が最大打上げ高より大きい場合、予測される越波流量は0でなければならない、ii) 天端高が0の場合、予測される越波流量は有限値でなければならない、という2つの物理条件を満たす越波流量算定式を提案した。間瀬ら⁴⁾はその越波流量算定式をより多くの実験結果を用いて適用性を拡張した。

本研究は、ニューラルネットワークによる越波流

量算定法を検討するものであり、どのような構造のネットワークが越波量算定に適しているか、ニューラルネットワークを適用する際の注意点、最適と思われるネットワークによりどの程度実験値を説明できるかについて調べる。

2. ニューラルネットワーク

(1) モデルの概要および応用例

人間の脳の情報処理システムは並列分散処理を行っており、階層構造を持っている。ニューラルネットワーク情報処理は、そうした脳の情報処理をモデルとしたものである。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は不可能である場合など、ニューラルネットワークではユニットをシプナスで結びつけ、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、ネットワークを形成する過程でプログラム化が内部的に行われ、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る。

海岸工学の分野でニューラルネットワークを応用した研究には、1) 混成防波堤における衝撃碎波力の発生判定⁵⁾、2) 捨石防波堤の安定性評価⁶⁾、3) 消波ブロック被覆工の変形量評価⁷⁾、4) 潮位予測⁸⁾、5) 波浪予測⁹⁾がある。

(2) 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値を出力する。

多層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。多層ネットワークにおいて、最後の層がシグモイドニューロンの場合、ネットワークの出力値が制限される。そのため、線形関数が出力ニューロンに用いられることがある。これにより、ネットワークの出力が任意となる。本研究では中間層にはlog型シグモイド関数、出力ユニットには線形関数を用いた。

(3) 学習法

実際の応用には、階層型ネットワークがよく用いられる。階層型ネットワークは、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は、入力パターン(学習パターン)と呼ばれる。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、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ネットワークを調整する学習法がある。学習によって得られる知識は、結合荷重と閾値に蓄えられる。バックプロパゲーションはこうした教師付き学習法のことである。

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、最も単純なバックプロパゲーション学習は、パフォーマンス関数(ネットワーク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。

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共役勾配法のうち、i) Powell/Beale リスタート法(CGB法)、ii) 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iii) Levenberg-Marquardt 法(LM法)を用いて、学習の高速化を図る。

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。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ができないためである。本研究では、一般化の改良方法として、i) 早期停止(Early Stopping)とii) 正則化(Regularization)を用いる。

i) 早期停止では、利用可能なデータを3つのサブセットに分割する。1つ目のサブセットは訓練データセットであり、ネットワークの訓練に用いる。2つ目のサブセットはバリデーションデータセットである。バリデーションデータセットに対する誤差は、訓練データセットに対する誤差と同様に、訓練の初期フェーズ中に通常減少するが、ネットワークが訓練データセットにオーバーフィットし始めるとバリデーションデータセットに対する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最小になったときに訓練を停止させる。3つ目のサブセットはテストデータセットである。訓練中には用いないが、ネットワークの妥当性を検証するために用いる。

ii) 正則化法においては、ネットワーク誤差の平均二乗和であるパフォーマンス関数に、ネットワークの重み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、ネットワークは小さい重みと閾値をもつようになり、ネットワーク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。自動化された最適正則化法としてBayesian法がある。このアルゴリズムの特徴の一つは、何個のネットワークパラメータ(重みとバイアス)が、効果的にネットワークに用いられたかの尺度がわかることである。

3. 越波流量算定用ニューラルネットワーク構築

(1) 解析に用いるデータ

本研究で用いる実験データは、井上ら^{1),2),10)~13)} Owen¹⁶⁾ および Hawkes¹⁷⁾ によるものである。実験データは、i) 護岸の設置水深が大きい実験データ、およびii) 全実験データの2つに分けて取り扱う。以下では、i) の実験データを用いて、入力ユニット、訓練アルゴリズム、中間層ユニット数、無越波流量データの取扱いの影響を調べる。

(2) 入力ユニット

越波流量に影響する要因には、海底勾配 S_0 、護岸

勾配 S , 沖波波形勾配 H_0/L_0 , 無次元法先水深 d_s/H_0 および相対護岸天端高 R/H_0 がある. そこで, 入力ユニットについて, i) $S, H_0/L_0$ および R/H_0 の3つ, および ii) $S_0, S, H_0/L_0, h/H_0, d_s/H_0$ および R/H_0 の6つを用いるという2つの場合を考え, どちらが良いかまず検討する. 越波流量は $Q^* = Q/\sqrt{gH_0^3}$ と無次元化する. i) は従来の越波流量算定式に用いられる入力パラメータに対応しており, ii) はそれらに加えて水深の影響を考慮するものである. ネットワークの学習には, CGB 法, SCG 法, LM 法の早期停止および Bayesian 法を用い, 中間層ユニット数は6, 9, 12, 15 および 18 と変化させた.

表-1 に示した算定値と実験値の相関係数から, 入力ユニットの影響をみると, 6 入力ユニットを使うのがよいことがわかった. なお, この表には学習回数も示してある.

表-1 実験値と算定値の相関係数および学習回数

Training Method	Hidden Layer Units	3 ユニット					6 ユニット				
		Input Unit: $S, H_0/L_0, R/H_0$					$S_0, S, H_0/L_0, h/H_0, d_s/H_0, R/H_0$				
		6	9	12	15	18	6	9	12	15	18
CGB	Correlation Coef.	0.56	0.58	0.67	0.63	0.74	0.79	0.58	0.81	0.79	0.58
	# of Training	23	35	48	24	37	109	28	62	65	30
SCG	Correlation Coef.	0.58	0.52	0.67	0.63	0.74	0.65	0.75	0.70	0.79	0.67
	# of Training	30	32	50	26	48	84	86	34	85	36
LM	Correlation Coef.	0.76	0.75	0.86	0.84	0.82	0.52	0.83	0.82	0.79	0.83
	# of Training	31	33	39	16	15	18	14	19	11	20
Bayesian	Correlation Coef.	0.65	0.66	0.79	0.70	0.55	0.81	0.86	0.88	0.84	0.83
	# of Training	231	180	314	271	1024	114	241	234	570	879

(3) 訓練アルゴリズム

ニューラルネットワークを構築するに当たり, どの訓練アルゴリズムが良いかを前もって判断するのは困難である. 表-1 の相関係数から判断すると, 共役勾配法のうちでは LM 法が良い. 図-1 は3種類の共役勾配法を用いた場合の算定値と実験値との比較結果を示したものであるが, LM 法を用いるのが良いようである.

一般的に Bayesian 正則化法は, 関数近似ネットワークの訓練において, 早期停止手法を用いるよりも一般化の結果が良くなると言われている. 本研究においても, 3 入力ユニットの場合に LM 法だけに相関係数が劣ったものの, Bayesian 正則化法は全般的に良い結果を示した. 訓練回数については, Bayesian 正則化法は多くなるが, バリデーションデータを用いる必要がないので, データ数が少ないときに有利である.

(4) 中間層ユニット数

中間層ユニット数については, ネットワークを構築する者の判断に任される. すなわち, 明確な判断基準がない中で, トライ・アンド・エラーで適切なユニット数を判断しなければならない. 表-1 によると, 適切な中間層のユニット数は9および12 (入力ユニット数の2倍) であった. これ以上にユニット数を




図-1 実験値と3種類の訓練法による算定値との比較

増やすと良い結果が得られる場合もあるが, それほどの改善は見られない.

以上の検討から, 入力ユニットは海底勾配 S_0 , 護岸勾配 S , 沖波波形勾配 H_0/L_0 , 一様水深 h/H_0 , 無次元法先水深 d_s/H_0 および相対護岸天端高 R/H_0 の6つ, 中間層ユニット数は9および12の2種類, ネットワークの訓練法は早期停止 LM 法および Bayesian 正則化法の2つを用いる.

(5) 無越波流量データの取扱い

偏ったデータを用いてネットワークを訓練しても, 最適なネットワークを構築することはできない. 越波流量が0となる条件は, 越波流量算定式を作成する場合に重要であった^{3),4)}のと同様, ニューラルネットワークの訓練に際しても, 一種の境界条件として重要である. そこで, 無越波流量データの取り扱いを以下のようにする. i) 無越波流量データをすべて訓練データに用いる (All と略す). ii) 無越波流量データをすべて訓練データに用いない (Non). iii) 無越波流量データを訓練データ, バリデーションデータ, テストデータに分ける (Arb).

4. 越波流量の実験値と算定値の比較・検討

(1) 護岸設置水深が大きい実験データ

無越波流量データの取扱い法毎に早期停止 LM 法による結果を図-2 に, Bayesian 法を用いた結果を図-3 に示す. 図-2 によると, 無越波流量データをすべて訓練データとして用いたネットワークがばらつきが大きい. LM 法の早期停止による一般化の過程でバリデーションデータの影響は大きく, 無越波流量データをすべて訓練データに用いると, バリデーションデータには無越波流量データがなくなり, 訓




図-2 設置水深が大きい場合の実験値と算定値の比較 (LM 訓練, 無越波量データの取り扱い法による影響)




図-3 設置水深が大きい場合の実験値と算定値の比較 (Bayesian 訓練, 無越波量データの取り扱い法による影響)

練データが偏ったデータセットとして扱われる。一方, 無越波流量データを訓練データに用いなかった場合においても, 越波量 0 となる予測が困難になることがわかる。すなわち, 越波量が 0 となるような予測は, そうした条件を用いて訓練しなければならない。したがって, 無越波流量データは訓練データ, バリデーションデータに偏りなく分けるのが良い。

Bayesian 正則化法においても, 無越波流量データを訓練データに用いない場合には, 早期停止 LM 法ほどではないが無越波流量を予測するが困難である。また, 学習経験がまったくないため, 場合によっては全く違った予測をすることがある。Bayesian 正則化法の特徴から考えれば, 無越波流量データを学習させればそれだけ精度が上がると思われる。しかし, 無

越波流量となる特異な条件を訓練データとして与えすぎる (割合が多くなる) ことはかえって望ましくないようである。

(2) 全実験データ

中間層ユニット数および訓練手法の相違による優劣の差は, ほとんど見られなかった。しかし, 無越波流量データの取り扱いごとの影響がみられた。それ結果を図-4 および図-5 に示す。LM 法を用いた図-4 によると, いくつかは予測値が実測値を大きく見積もる点はあるものの, 無越波流量データを偏りなく分ける取扱いの場合に両者の一致が良い。図-5 においては, 図-4 の結果よりばらつきは少なくなっているようであり, 実際相関係数の値は若干大きくなっている。




図-4 全実験値と算定値との比較 (LM 訓練, 無越波量データの取り扱い法による影響)




図-5 全実験値と算定値との比較 (Bayesian 訓練, 無越波量データの取り扱い法による影響)

相関係数から判定すると全般的に良い結果が得られているが、図-4および図-5の散布図を見ると、予測値と実測値の一致が悪いプロット点が多々あった。これらの実験入力条件を調べたところ、護岸の設置水深が大きいデータがほとんどであった。

(3) 越波流量算定に対する最適ニューラルネットワーク

これまでの検討により最適なニューラルネットワークは、入力ユニットを6、中間層のユニット数を12とし、無越波流量データを偏りなく分けたデータに対して、Bayesian 正則化法で訓練したネットワークであった。この方法によれば、バリデーションデータを必要としないという点で有利である。しかし、訓練データ数に占める無越波流量データ数が多すぎると算定精度が悪くなる傾向もあった。従って、早期停止 Levenberg-Marquardt 法も越波流量算定に対するネットワークとして用いるのが良い。

図-6は、設置水深が大きい条件に対して、実験値と Bayesian 訓練による全算定値（訓練データ、バリデーションデータおよびテストデータ）を比較したものである。図-7は、全データに対して整理したものである。両図から、実験値と算定値の対応が良いことがわかる。

図-8は越波流量を無次元化せず、全データを対数座標で示したものである。また、図-9は間瀬⁴⁾の結果を示したものである。越波流量が大きい領域において、ニューラルネットワークによる算定値の方が実験値との一致度が良い。

護岸に打ちあがる波が非碎波であるか、碎波した波であるかによって越波流量は異なる。本研究では入力ユニットに無次元法先水深を用いており、そのパラメータを通して護岸前面での入射波高の影響を考慮できるのではないかと考えた。しかし、越波流量が小さいので重要ではないが、全実験データで構築したネットワークでは護岸設置水深が大きな条件のデータを上手く表せなかった。従って、より推定精度のよいネットワークを構築するためには、i) 護岸前面で碎波が生じるか生じないかの水深の条件によってデータを分けてニューラルネットワークを適用する、ii) 条件を分けることなく護岸前面での波高の情報も入力ユニットに用いてニューラルネットワークを適用するという2つの方法がある。本研究では護岸設置点での波の情報がないため、ii) の方法を試すことはできなかった。

5. まとめ

本研究は、ニューラルネットワークによる越波流量算定法を検討し、どのような構造のネットワーク




図-6 設置水深が大きい場合の実験値と算定値の比較 (Bayesian 訓練)




図-7 全実験値と算定値との比較 (Bayesian 訓練)

が越波量算定に適しているか、ニューラルネットワークを適用する際の注意点、最適と思われるネットワークによりどの程度実験値を説明できるかを検討した。主要な結果は、以下の通りである。

入力ユニットには海底勾配 S_0 、護岸勾配 S 、沖波波形勾配 H_0/L_0 、無次元法先水深 d/H_0 および相対護岸天端高 R/H_0 の6つ、中間層のユニット数は12とし、無越波流量データを偏りなく分けたデータに対して、Bayesian 正則化法で訓練したネットワークが性能が良い。ただし、訓練データ数に占める無越波流量データ数が多すぎると算定精度が悪くなる傾向があったので、早期停止 Levenberg-Marquardt 法も推奨される。

注意点は以下の通りである。入力ユニットに無次元法先水深を用いており、そのパラメータを通して護岸前面での入射波高の影響を考慮できるのではな




図-8 次元量を用いた、全実験値とニューラルネットワークによる算定値との比較




図-9 設置水深が大きい条件の実験値と越波流量算定式による算定値との比較 (間瀬ら⁴⁾)

いかと考えたが、i) 護岸前面で碎波が生じるか生じないかの水深の条件によってデータを分けてニューラルネットワークを適用する、あるいは ii) 条件を分けることなく護岸前面での波高の情報も入力ユニットに用いてニューラルネットワークを適用するという2つの方法がある。

参考文献

- 1) 井上雅夫・玉田崇・手塚崇雄：緩傾斜護岸の越波特性に関する実験的研究，海洋開発論文集，第18巻，pp. 239-244，2002.
- 2) 井上雅夫・玉田崇・手塚崇雄：緩傾斜護岸の越波流量算定図とその越波低減効果に関する実験的研究，海岸工学論文集，第49巻，pp. 641～645，2002.
- 3) Hedges, T.S. and Reis, M.T.: Random wave overtopping of simple seawalls: a new regression model, Proc. Inst. Civil Eng., Water, Maritime and Energy, Vol.130, pp.1-10, 1998.
- 4) 間瀬 肇・Hedges, T.S.・Shareef, M.・永橋俊二：波の打上げを考慮した傾斜護岸に対する越波流量算定法に関する研究，海岸工学論文集，第50巻，pp. 636-640，2003.
- 5) 間瀬 肇：ニューラルネットワークを用いた捨石防波堤の安定性評価，海岸工学論文集，第41巻，pp. 761～765，1994.
- 6) 間瀬 肇：ニューラルネットワークを用いた消波ブロック被覆工の変形量評価，海岸工学論文集，第42巻，pp. 891～895，1994.

- 7) 間瀬 肇：混成防波堤における衝撃碎波力の発生判定モデル，土木工学論文集，No. 515/ II -31，pp. 95～102，1995.
- 8) Deo, M.C. and Chaudhar, G.: Tide prediction using neural networks, Computer Aided Civil and Infrastructure, Vol.13, pp.113-120, 1998.
- 9) Deo, M.C. and Sridhar, N.C.: Real time wave forecasting using neural networks, Ocean Eng., Vol.26, No.3, pp.191-203, 1999.
- 10) 井上雅夫・島田広昭・殿最浩司：不規則波による緩傾斜護岸の越波特性，海岸工学論文集，第37巻，pp. 514～519，1990.
- 11) 井上雅夫・島田広昭・円間弘起：緩傾斜護岸の越波特性に及ぼす風の影響，海岸工学論文集，第39巻，pp. 586～590，1992.
- 12) 井上雅夫・井上裕規・玉田 崇：海岸護岸における越波量の時間的変動特性，海洋開発論文集，第16巻，pp. 35～40，2000.
- 13) 井上裕規・玉田 崇・井上雅夫：緩傾斜護岸における越波流量算定図の提案と時間的変動特性に関する考察，海洋開発論文集，第17巻，pp. 311～316，2001.
- 14) Owen, M.W.: The hydraulic design of seawall profiles, Proc. Conf. on Shoreline Protection, Inst. of Civil Engineers, pp.129-136, 1982.
- 15) Hawkes, P.J.: Mean overtopping rate in swell and bimodal seas, Proc. Inst. of Civil Engineers, Water Maritime and Energy, Vol.136, pp.235-238, 1999.