

ニューラルネットワークを用いた大阪湾内のリアルタイム津波予測

間瀬 肇・加次淳一郎^{*}・安田 誠宏・高山 知司

^{*} 千代田アドバンスト・ソリューションズ(株)

要 旨

本研究は、地震発生後の津波の観測データを用いて、リアルタイムで大阪湾内に来襲する津波を予測する手法検討を行ったものである。ここでは、来襲津波の時間波形の情報は無視し、水位の最大上昇量と低下量をすばやく予測するシステムとして、ニューラルネットワークを援用するリアルタイム津波予測法を取り扱った。その結果、(1) 津波予測に用いるネットワークは、中間層ユニットの数が 10、中間層ユニットの応答関数が $\tanh$ 型、出力層ユニットの応答関数が linear 関数がよいこと、(2) 各地点毎に、ニューラルネットワークによる引波および押波の予測値と津波シミュレーション結果を比較したところ、両者は良く一致すること、(3) 5 地点における引波と押波を同時予測するように訓練したニューラルネットワークはうまく機能することがわかった。

キーワード：津波、ニューラルネットワーク、リアルタイム予測

1. はじめに

近い将来、南海地震と東南海地震の巨大地震が発生すると指摘されている。震源域に海域を含む地震は、津波も発生させるので、地震被害と津波被害の 2 重の被害が生じる。気象庁の津波予報は、日本近海の様々な場所に様々な規模の地震モデルを想定して津波シミュレーションを行い、それらの計算結果のデータベースを利用して、地震が起きた場合、推定された震源位置とマグニチュードに最も近い地震に対する計算結果を選び出して、予想される津波の高さを予報するものである。

津波予報区は原則として府県単位（66 予報区）であり、沿岸地形の特性を考慮できるほど細分化されていない。和歌山下津港や大阪湾内の各港では、津波の到達まで時間が比較的あるため、この間に的確な津波情報を得ることができれば、港湾管理者あるいは港湾事業者は諸対策を適切に講ずることが可能となる。

安田ら (2004, 2005) は、気象庁の予報を補完するものとして、地震発生後の津波の観測データを用いて、リアルタイムで大阪湾内に来襲する津波を予測する手

法の開発をしている。本研究は、安田らの研究と目的は同じであるが、来襲津波の時間波形までの情報は無視し、水位の最大上昇量と低下量をすばやく予測するシステムとして、ニューラルネットワークを援用するリアルタイム津波予測法の検討を行うものである。

2. ニューラルネットワークの概要

2.1 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ナプスで結びつけ、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




Fig. 1 Layered neural network

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、混成防波堤における衝撃碎波力の発生判定、捨石防波堤の安定性評価、消波ブロック被覆工の変形量評価、越波流量の算定（例えば、間瀬ら、1994; 2005）、潮位予測（Deo, 1998）や波浪予測（Deo, 1999）等がある。

2.2 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。実際の応用には、Fig.1

階層型ネットワークがよく用いられる。

2.3 学習法

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データは、入力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。

本研究では、入力パターンとして後に示す地震発生後京都大学防災研究所白浜観測塔で観測される2分ごとの水位データを用いる。出力値としては、大阪湾内の1つの対象地点、あるいは、多地点における最大水位上昇量と低下量を用いる。

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、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。一般化の改良方法としては、早期停止と正則化を用いる。

早期停止法では、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。

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2乗和を加えることによって、一般化の改良を行う。自動化された最適正則化法として Bayesian 法がある。

本研究では、用いるケース数が少ないことからサブセットに分けなくても良い Bayesian 正則化法を用いる。

3. ニューラルネットワークに用いる津波計算結果

3.1 リアルタイム津波予測

本研究で検討するリアルタイム津波予測は、大阪




Fig. 2 Map of Shirahama Oceanographic Observatory and tsunami forecasted locations

湾外あるいは外洋における観測データを用いて、大阪湾内に来襲する津波を予測するものである。ここでは、地震発生後に京都大学防災研究所白浜観測塔の波形データが得られたと仮定し、その時間波形を用い、ニューラルネットワークにより、1~1.5 時間後に湾内に到達する津波を予測するものである。Fig.2 に、白浜

観測塔と津波予測対象地点の位置図を示す。

3.2 想定津波

河田ら (2003) の研究による不均一性を導入した波源を用いた津波計算結果を、観測された津波波形として用いる。不均一性は、地震規模、地震規模とアスペリ




Fig. 3 Simulated time series of tsunami for modified Ando's fault model




Fig. 4 Simulated time series of tsunami at Shirahama Oceanographic Observatory and sea level falls and rises at five locations

ティ、および、地震規模とアスペリティと断層形状を考慮した断層モデルによって考慮される。また、地震規模のみを考慮した（地震モーメントを地震調査研究推進本部の震源域モデル(2001)のそれと等しく補正する）Ando モデル(1975)と相田モデル(1981)に対する津波シミュレーション結果を用いる。

Fig.3 は、規模を考慮した Ando モデルによる津波計算結果を示したものであり、こうした一連のシミュレーション結果から白浜観測塔における地震発生後 20 分間の時間波形および大阪湾内の神戸港、尼崎港、大阪港、堺泉北港および関西空港の 5 地点における水位の最大上昇量と低下量を求めた。

Fig.4 の上段は、異なる 5 ケースの白浜観測所における 20 分間の時間波形、Fig.4 の下段は神戸港、尼崎港、大阪港、堺泉北港、関西空港における第 1 波水位低下量、第 1 波水位上昇量、第 2 波水位低下量、第 2 波水位上昇量を示したものである。

テストケースは Fig.5 に示す、1707 年宝永東海・南海地震（相田モデル, 1981; Case A）、1946 年昭和南海地震（相田モデル, 1981; Case B）、中央防災会議による東南海・南海地震モデル（2001; Case C）を用いた津

波シミュレーション結果である。

少なくとも訓練データをうまく整理することができ、テストケースに対して予測できることが必要である。中央防災会議による東南海・南海地震モデルは、テストケースとしてだけでなく、訓練データとしても用い、その相違を調べた。

4. ニューラルネットワークによる津波予測

4.1 ニューラルネットワークの設定

過学習を防ぐため、また、今回用いるケース数が少ないため、バリデーションデータを用いなくてもよい最適 Bayesian 正則化法と高速訓練アルゴリズム LM 法の組み合わせを用いた。

中間層は 5, 10, 20 個の 3 ケース、中間層に用いる応答関数として、tangent 型シグモイド関数と log 型シグモイド関数の 2 ケース、出力層の応答関数として、tangent 型、log 型、linear 関数の 3 ケースを考え、それぞれの組み合わせを用いた訓練を行った。

入力パターンとして白浜観測塔での 0 ～ 20 分までの 2 分おきの波形データ 10 個、出力値として、対象地点の第 1 波および第 2 波の最大水位上昇量とおよび







Fig. 5 Time series of tsunami and sea level falls and rises at five locations of test cases




(a) Kobe




(b) Amagasaki



(c) Osaka



(d) Sakai



(e) Kansai Airport

Fig. 6 Predictions by neural network and comparison with simulations

水位低下量の4つを、各地点毎、あるいは、5地点全部に対して出力する。各地点毎に津波計算値とニューラルネットワークによる予測値の対応を調べ、予測に適したネットワークのパラメータを決定した。その結果は、以下のようであった。

- 1) 出力層ユニットには、線形関数を用いるのが良い。
- 2) 中間層ユニットには、tangent 型シグモイド関数を用いるのがよい。
- 3) 中間層ユニットを5個とした場合、10個および20個を用いた結果と比べて良くない。しかし、10個と20個を用いる結果にはほとんど差はみられないので、訓練回数の少ない10個とする。

4.2 ニューラルネットワークによる予測精度の検討

Fig.6 は、5地点毎にニューラルネットワークによる予測値（縦軸）と津波シミュレーション値（横軸）を比較したものである。1つの図面に第1波および第2波の最大水位上昇量と低下量をすべてプロットしてある。

Case C の中央防災会議による東南海・南海地震モデルを除いてネットワークを訓練し、Case C に対して予測を行った結果は、シミュレーション結果との対応がそれほどよくなかった。このモデル地震は今後起こるであろう地震として提案されているので、訓練データとして用い、少なくともこの断層モデルによる津波は

整理できなければならないと考え、訓練データとして用いることとした。

Fig.6 から、訓練データとして用いた津波の計算結果はうまく整理できること、テストデータとして用いた Case A と Case B のそれぞれ 1707 年宝永東海・南海地震および 1946 年昭和南海地震に対する津波に対して良く予測できることがわかる。

Fig.7 は全5地点の水位上昇量および低下量に対して、Bayesian 正則化法にて自動的に訓練されたネットワークを用いて予測を行った結果と、津波シミュレーション結果を比較したものである。訓練データには Case C を加えた。訓練回数は 520 回となり、訓練データに対しては相関係数がほぼ 1.0 となるほど一致がよくなるが、テストデータに対しては、相関係数が 0.87 となって両者の対応が悪くなる。

Fig.8 は訓練回数を強制的に 100 回としたもので、Fig.7 と比較して、訓練データに対する相関は少し小さくなり両者の分布幅が若干広がるが、テストデータに対する相関係数は 0.91 と大きく、図のように良い対応関係が見られる。

5. まとめ

本研究は、来襲津波の時間波の情報は無視するが、即座に大阪湾内への来襲津波の規模を推定する方法として、ニューラルネットワークを援用したリアルタイ




Fig. 7 Comparison between tsunami simulations and predictions by neural network automatically stopped training




Fig. 8 Comparison between tsunami simulations and predictions by neural network with 100 training

ム津波予測法の検討を行ったものである。本研究で得られた主要な結論は、以下の通りである。

- (1) 津波予測に用いるネットワークは、中間層ユニットの数が10、中間層ユニットの応答関数が $\tanh$ 型、出力層ユニットの応答関数が linear 関数である。
- (2) 各地点毎に、ニューラルネットワークによる引波および押波の予測値と津波シミュレーション結果を比較した結果、両者は良く一致する。
- (3) 5 地点における引波と押波を同時予測するように訓練したニューラルネットワークはうまく機能する。

今回は白浜観測塔のデータを用いたが、到達時間の観点からは、より外洋の観測結果を用いるのが良い。その他に、多地点のより短い観測時間波形を用いる場合の検討、GPS 津波計の観測データの活用方法、実際に観測された波形を取り込み予測結果を配信するシステムの検討が必要である。

参考文献

相田 勇 (1981)：南海道沖の津波の数値実験，東京大学地震研究所彙報，Vol.56, pp.713-730.
 河田恵昭・奥村与志弘・高橋智幸・鈴木進吾 (2003)：アスペリティに起因する南海地震津波の波源不均一性に関する研究，海岸工学論文集，第 50 巻，pp.306-310.

地震調査研究推進本部地震調査委員会 (2001)：南海トラフの地震を想定した強振動評価手法について（中間報告），平成 13 年 12 月 7 日。

間瀬 肇 (1994)：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.

間瀬 肇・永橋俊二・Hedges, T.S. (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.

安田誠宏・高山知司・川村健太・間瀬 肇 (2005)：大阪湾内におけるリアルタイム津波予測手法の検討，海洋開発論文集，第 21 巻，pp.145-150.

安田誠宏・高山知司・川村健太 (2006)：観測データを用いたグリーン関数重ね合わせ法によるリアルタイム津波波源域推定法，海岸工学論文集，第 53 巻，pp.311-315.

Ando, M. (1975): Source mechanism and tectonic significance of historical earthquakes along the Nankai Trough, *Tectonophysics*, Vol.27, pp.119-140.

Deo, M.C. and G. Chaudhar (1998): Tide prediction using neural networks, *Computer Aided Civil and Infrastructure*, Vol.13, pp.113-120.

Real-time Prediction of Tsunami into the Osaka Bay by using Artificial Neural Network

Hajime MASE, Jun-ichirou KAJI*, Tomohiro YASUDA and Tomotsuka TAKAYAMA

* Chiyoda Advanced Solutions, Japan

Synopsis

This study examines the validity to use an artificial neural network (ANN) for the prediction of tsunami magnitudes at several locations in the Osaka Bay by using observed water surface elevations of 20 minutes, at the tower of Shirahama Oceanographic Observatory. The tsunami data used as training and test data for ANN were simulated for different fault models considering tsunami source non-uniformity. The linear activation function was found to be a good choice for output units and the tangent sigmoid function for hidden layer's units. For the training of ANN the Levenberg-Marquardt method with Bayesian regulation were employed. Outputs from the trained network such as the first and the second sea surface falls and rises well correspond to the results of tsunami simulations at each location and all five locations.