

国土技術政策総合研究所 研究報告

RESEARCH REPORT of National Institute for Land and Infrastructure Management

No.63

March 2019

ニューラルネットワークの数値流体力学への適用

本多和彦

Study on Application of Artificial Neural Networks to Computational Fluid Dynamics

Kazuhiko HONDA

国土交通省 国土技術政策総合研究所

National Institute for Land and Infrastructure Management
Ministry of Land, Infrastructure, Transport and Tourism, Japan

ニューラルネットワークの数値流体力学への適用

本多和彦*

要 旨

本研究は、機械学習の1つであるニューラルネットワークを用いて、3次元非静水圧モデルの解析部を代替する手法を提案したものである。学習過程における教師データは、3次元非静水圧モデルによる解析の各変数の出力値を用いた。このニューラルネットワークによって解析部を代替したモデルを、一様水深のモデル地形上を伝播する津波に適用し、非常に精度良く流速および水圧を再現できることを示した。

本提案手法は、3次元非静水圧モデルの解析部を代替するモデルとして適用可能であり、今後の活用が期待できる。

キーワード：機械学習，数値流体力学，ニューラルネットワーク，3次元非静水圧モデル

* 沿岸海洋・防災研究部 主任研究官
〒239-0826 横須賀市長瀬3-1-1 国土交通省国土技術政策総合研究所
電話：046-844-5019 Fax：046-842-9265 e-mail：ysk.nil-kikaku@ml.mlit.go.jp

Study on Application of Artificial Neural Networks to Computational Fluid Dynamics

Kazuhiko HONDA*

Synopsis

In this study, an alternative solver of the differential equations in a three-dimensional tsunami numerical model is proposed, which consists of an artificial neural network (ANN) trained by using the outputs of simulations with the 3D model. This alternative solver with an ANN shows good performance in simulation of the flow velocity and the pressure in tsunami propagation on a flat bottom basin.

This method has potential as an alternative solver for 3D models.

Key words: machine learning, computational fluid dynamics, artificial neural network, 3D non-hydrostatic models

* Senior Researcher, Coastal, Marine and Disaster Prevention Department
National Institute for Land and Infrastructure Management
Ministry of Land, Infrastructure, Transport and Tourism
3-1-1 Nagase, Yokosuka, 239-0826 Japan
Phone: +81-46-844-5019 Fax: +81-46-842-9265 e-mail: ysk.nil-kikaku@ml.mlit.go.jp

目 次

1. まえがき	1
2. 3次元非静水圧モデルの代替解析モデル	2
2.1 ニューラルネットワーク	2
2.2 学習過程	3
2.3 教師モデル	4
2.4 代替解析モデルの設計	4
3. 代替解析モデルの適用性の検証	7
3.1 検証方法	7
3.2 検証結果	9
4. 影響範囲の予備検討	9
4.1 検討方法	9
4.2 検討条件	10
4.3 検討結果	11
5. まとめ	12
6. あとがき	13
参考文献	13

1. まえがき

津波は、沖合では非常に長い波長であり、鉛直方向の加速度は無視できる。そのため、沖合における津波は、静水圧近似を用いた平面2次元モデルにより解析することが可能である。一方、防波堤等の構造物周りの津波に伴う流れは複雑であり、鉛直方向の加速度を無視することができず、非静水圧の現象となる。構造物周りの複雑な津波の流れを解析するためには、3次元非静水圧モデルを用いる必要がある。

また、波浪は、津波と比較して波長が非常に短いため、構造物周りだけではなく、海域においても、鉛直方向の加速度を無視することができず、非静水圧の現象となる。そのため、波浪に伴う流況および水圧を解析するためには、3次元非静水圧モデルを用いる必要がある。

このように、波浪や構造物周りの津波の複雑な流れを対象として、その流況および水圧を評価するためには、3次元非静水圧モデルによる解析が必要になる。しかし、3次元非静水圧モデルによる解析は、小さな計算セルを用いるとともに、計算ステップを短い時間とする必要がある。そのため、3次元非静水圧モデルは、平面2次元モデルと比較して、非常に長い解析時間を要する。

防波堤等の港湾構造物の設計や配置を検討するためには、港湾構造物について、異なる構造形式や異なる配置を対象とした比較検討を試行錯誤する必要がある。そのため、実務では、多くの解析条件を用いて解析が行われている。解析に必要な容量や時間といったコストを踏まえると、このような港湾構造物の設計や配置を検討する際には、3次元非静水圧モデルによる解析は非効率である。

最近では、様々な分野において、ニューラルネットワークが用いられ、研究においても活用されている。海岸工学の分野では、例えば、海域の生態系に対する環境因子の影響評価（松原ら、1994）、観測データから湾内の浮遊ゴミの集積場所の予測（内田ら、2011）、沖合の津波観測情報から沿岸の津波高の予測（安田ら、2005；間瀬ら、2007；Maseら、2011）、台風情報や気象官署の観測情報から高潮偏差の予測（金ら、2013；金ら、2015）、波浪や構造の情報から捨石マウンド式の防波堤の安定性の評価（間瀬ら、1994；Maseら、1995）、消波ブロックの変形量の評価（間瀬ら、1995）、緩傾斜護岸の越波流量の算定（間瀬ら、2005）砕波波高および砕波水深の予測（李ら、2008；李ら、2009）、沖合の波浪情報から港内の波高分布の評価（Londhe SNら、2004）等が挙げられる。

一方、微分方程式を差分化した方程式を対象に、ニューラルネットワークを用いた研究（例えば、Meadeら、1994；Lgarisら、1997）が行われている。

しかし、本研究で提案する手法のように、3次元非静水圧モデルの解析部を、ニューラルネットワークを用いて代替する研究については、Lingら（2016）のように解析部内の乱流モデルを対象とした限定的なものはあるものの、解析部全体を代替するものは見当たらない。

本研究では、3次元非静水圧モデルによる解析時間を短縮するため、3次元非静水圧モデルの差分方程式を解析する新たな手法を提案する。具体的には、機械学習の1つであるニューラルネットワークを用いて、差分基礎式の解析部を代替するモデル（以降、「代替解析モデル」という。）である。また、本手法の適用性を確認するための予備検討として、一様水深のモデル地形を伝播する津波を対象に精度検証を実施する。

ニューラルネットワークの学習や精度検証には、学習データ、検証データおよびテストデータの3つのデータセットが必要となる。本研究では、これらのデータセットとして、3次元非静水圧モデルによる解析における時間ステップ毎の全ての変数を無作為に3つに分割して用意した。これらのデータセットを用いて検証した結果、本手法を用いた代替モデルによる出力は、3次元非静水圧モデルによる出力の再現性が非常に高い。このことから、3次元非静水圧モデルの解析部をニューラルネットワークで代替する本手法の適用性が高いことが明らかである。

ニューラルネットワークでの入力層に変数を入力する対象範囲によっては、本手法の精度を低下させることが考えられる。そのため、精度を確保できる対象範囲として、任意の計算セルの変数に変化を生じさせる範囲（以降、「影響範囲」という。）について、基礎的な検討も実施した。

本稿の構成は、以下のとおりである。

第2章では、本研究で提案する手法について、その基礎となるニューラルネットワーク、学習過程、学習に用いる3次元非静水圧モデルの概要、および、提案するモデルの設計内容を示す。

第3章では、本手法を一様水深の津波伝播に適用した精度検証の結果を示す。

第4章では、本手法において、入力層に変数を入力するために必要な計算セルの範囲の基礎資料として、影響範囲の予備検討の結果を示す。

なお、本稿は、Honda（2016）の内容に補足説明を追加したものである。そのため、本研究を引用する際には、Honda（2016）も参考文献に挙げられたい。

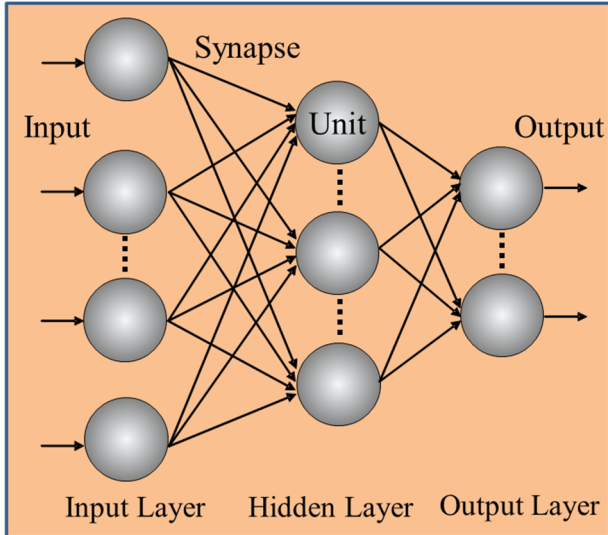


図-1.1 階層型ニューラルネットワーク (イメージ)

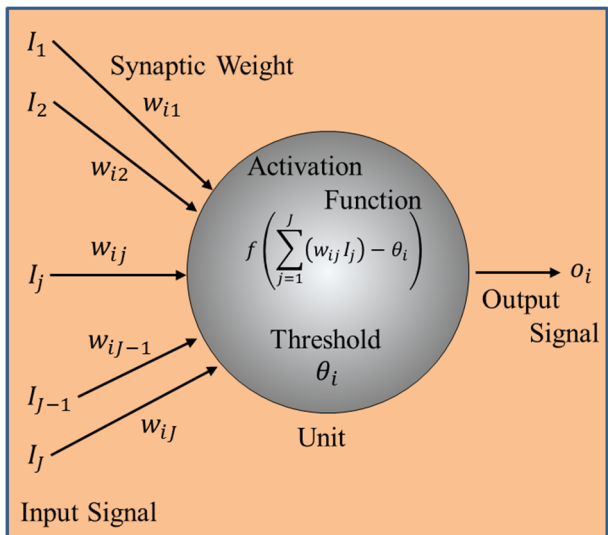


図-1.2 ニューロンのユニット

2. 3次元非静水圧モデルの代替解析モデル

2.1 ニューラルネットワーク

ニューラルネットワークは、人間の脳の情報伝達過程を簡易にモデル化したものであり、数値的な情報伝達システムである。ニューラルネットワークには幾つかの種類があり、それらのネットワーク構造によって、階層型ニューラルネットワーク、相互結合型ニューラルネットワーク等に分類される。

本研究は、3次元非静水圧モデルの解析部を代替するモデルとしての機械学習の適用性の有無を確認することを目的としている。そのため、機械学習の手法の1つであり、また、学習過程が比較的簡易であることから、本研究では、順伝播型の3層ニューラルネットワークを採用し、ネットワークの学習には、誤差伝播学習法を採用

した。

図-1.1に、本研究で採用した順伝播型の階層型ニューラルネットワーク (3層) のイメージを示す。この図のような3層のニューラルネットワークの場合には、入力層 (Input Layer)、1層の中間層 (Hidden Layer)、および、出力層 (Output Layer) から構成される。これらの全ての層は、図-1.2に示すユニット (Unit) と呼ばれる人間のニューロンをモデル化したものを有する。

このネットワークでは、入力層の各ユニットは、1つの入力信号に対し、1つの信号を出力する構成である。一方で、中間層および出力層の各ユニットは、複数の入力信号 (Input Signal) を受信し、1つの信号を出力する構成となっている。入力層の各ユニットは、中間層の各ユニットに対して、シナプス (Synapse) と呼ばれる1つの信号伝達経路で接続されている。中間層と出力層についても、同様に、層間の各ユニットは1つのシナプスで接続されている。なお、入力層の各ユニットと出力層の各ユニット、同一層内の各ユニットどうしは、シナプスで接続されていない。このネットワークでは、シナプス内の信号は一方方向のみに伝播し、その伝播方向は、入力層から中間層、および、中間層から出力層へ方向である、

各ユニットは、活性化関数 (Activation Function) f を有し、1つ前の層のユニットと結合する各シナプスに対してシナプス結合荷重 (Synapse Weight) w_{ij} を有する。ユニットからの出力信号 (Output Signal) o_i は、式(2.1)で表される。

$$o_i = f \left(\sum_{j=1}^J (w_{ij}I_j) - \theta_i \right) \quad (2.1)$$

i および j は、それぞれ、その層におけるユニット番号、および、1つ前の層におけるユニット番号であり、 J は1つ前の層のユニットの総数である。また、 θ_i は出力に関する閾値 (Threshold) である。 I_j は1つ前の層のユニット番号 j のユニットからの入力信号であり、これは、1つ前の層のユニット番号 j のユニットの出力信号と等しい値である。

ここで、形式的に式(2.2)および式(2.3)を仮定し、式(2.1)から、より普遍的な記述となる式(2.4)に拡張した。

$$I_0 = 1 \quad (j = 0) \quad (2.2)$$

$$w_{i0} = -\theta_i \quad (j = 0) \quad (2.3)$$

$$o_i = f \left(\sum_{j=0}^J w_{ij} I_j \right) \quad (2.4)$$

一般的に、活性化関数としては、ステップ関数、線形関数およびシグモイド関数を用いられる。階層型ニューラルネットワークの学習過程では、微分可能な活性化関数を用いる方が、解析的な手法で解くことが可能であるため、より効率的である。そこで、本研究では、活性化関数として、微分可能ではないステップ関数は採用せず、線形関数およびシグモイド関数を採用した。

本研究で採用した線形関数およびシグモイド関数を、それぞれ、式(2.5)および式(2.6)に示す。

$$y = f(x) = x \quad (2.5)$$

$$y = f(x) = \tanh(x) \quad (2.6)$$

シグモイド関数は、非線形性を有していることから、非線形な現象を対象にする場合には、有効である。しかし、シグモイド関数の出力値の範囲は限定的である。例えば、式(2.6)のシグモイド関数は、-1から+1までの範囲の出力値となる。一方、線形関数の出力値の範囲には制限がない。しかし、線形関数は、非線形な現象には適用できない。

つまり、全ユニットの活性化関数に線形関数のみを用いたニューラルネットワークは、非線形の現象を再現することができない。また、出力層のユニットの活性化関数にシグモイド関数を用いたニューラルネットワークは、その出力値の範囲が制限される。

本研究では、非線形性を有する津波伝播を対象とし、また、流速および水圧といった変数値の範囲には制限がない。そのため、中間層の活性化関数には、式(2.6)に示すシグモイド関数を用い、出力層の活性化関数には、式(2.5)に示す線形関数を用いた。なお、入力層については、一般的に用いられるものとし、活性化関数は式(2.5)に示す線形関数であり、出力の閾値 $\theta_i = -w_{i0}$ は全て0である。

2.2 学習過程

(1) 学習手法

このニューラルネットワークでは、教師データを用いてシナプス結合荷重を補正するといった学習を繰り返す、正解または正解に近い答えを出力するようにネットワークを構築するといった学習過程となる。

まず初めに、学習前のシナプス結合荷重を任意に設定する。この初期のネットワークは、教師データの入力信号パターンに対して、正しい出力をすることはできない。学習過程を通して、全てのシナプス結合荷重を補正する必要がある。本研究では、この学習過程において、一般的に用いられている誤差逆伝播学習法を採用した。誤差逆伝播学習法は、誤差の補正といったネットワークの学習情報を、出力層から入力層に向かって伝播させるという特徴がある。

誤差逆伝播学習法は、全ての教師データの信号パターンを対象に、誤差関数と呼ばれるニューラルネットワークからの出力誤差の合計を算出し、その出力誤差の合計を最小とすることである。なお、教師データの信号パターンは、入力信号パターンと、それに対応する出力信号パターンから構成される。

学習過程での評価関数として、式(2.7)で示される誤差関数 E を用いる。ここで、 p および k は、それぞれ、教師信号パターンの通し番号および出力層のユニット番号であり、 P および K は、それぞれ、教師信号パターンの総数および出力層のユニットの総数である。また、 $t_{p,k}$ および $o_{p,k}$ は、それぞれ、教師信号の出力値およびニューラルネットワークからの出力値である。

$$E = \frac{1}{2} \sum_p^P \sum_k^K (t_{p,k} - o_{p,k})^2 \quad (2.7)$$

最急降下法は、誤差関数を最小化する1つの手法である。これは、全てのシナプス結合荷重について、式(2.8)で示される補正量を算出し、補正を繰り返す方法である。ここで、 Δw_{ij} は、シナプス結合荷重の補正量であり、 η は、学習率である。この学習過程は、学習停止の条件を満たすまで、式(2.7)および式(2.8)の処理を繰り返す。

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (\eta > 0) \quad (2.8)$$

誤差関数の最小化は、最適化問題の1つであり、最急降下法は、単純な最適化問題には効果的である。しかし、この最急降下法は、複雑な最適化問題に用いると、収束性が著しく低下するため、学習の効率が悪くなる。

そこで、本研究では、ニューラルネットワーク内のユニット数が多く、複雑な最適化問題であるため、最急降下法より学習の効率がよく、一般的に複雑な最適化問題への適用事例が多いLevenberg-Marquardt法を採用した。

(2) 学習停止条件

このニューラルネットワークの学習過程には、過学習 (overfitting) と呼ばれる問題がある。ある教師信号のデータセットに対して、誤差関数を最小化するだけの学習とした場合、その学習後のニューラルネットワークは、他の入力信号パターンに対して正しい出力ができない可能性が高い。つまり、特定の入出力信号のデータセットに対してだけ最適化されたニューラルネットワークについては、他の入力信号に対して適切な出力信号が得られる保証はない。

本研究では、この過学習を避けるために、教師データを、学習データおよび検証データという2つのデータセットに分割した。学習過程では、これら2つのデータセットを用いる。なお、学習後のニューラルネットワークの性能を評価するために、さらにテストデータと呼ばれるデータセットを用いる。このテストデータは、学習過程では利用しない。

学習データを用いて、誤差関数を最小化するようにネットワークを更新するためのシナプス結合荷重の補正量を算出する。このとき、同時に、別途、検証データを用いた誤差関数も算出する。学習過程の初期の段階では、学習データに対する誤差関数の減少とともに、一般的には、検証データに対する誤差関数も減少する。しかし、ニューラルネットワークが過学習に推移すると、学習データに対する誤差関数が減少しても、検証データに対する誤差関数は増加する。そのため、過学習を防ぐ方法として、検証データに対する誤差関数が増加を始めたとき、学習過程を終了させる。

2.3 教師モデル

ニューラルネットワークを学習させたり、学習後のネットワークの性能を評価したりするためには、学習データ、検証データおよびテストデータという3つのデータセットが必要である。これらのデータは、入力信号パターンと出力信号パターンからなる。

本研究では、3次元津波解析モデルによる解析において、全ての計算セルにおける全ての時間ステップの流速および水圧のデータを無作為に3つに分割し、学習データ、検証データおよびテストデータとする。

つまり、3次元津波解析モデルをニューラルネットワークの学習過程における教師としているため、学習後のニューラルネットワークは、3次元津波解析モデルの代替解析モデルとして採用できる (図-2.1)。

Tomitaら (2006) は、STOC (Storm surge and Tsunami

simulator in Oceans and Coastal areas) と呼ばれる津波解析モデルを開発した。STOCは、多くの水理模型実験や実際の津波伝播・浸水を対象に適用され、実験結果や観測・測量結果の再現性が高いことが確認されている (Tomitaら, 2006; Tomitaら, 2007; Hondaら, 2008; Honda, 2015)。

STOCは、STOC-ICと呼ばれる3次元非静水圧津波解析モデルのサブモデルを有している。このSTOC-ICの支配方程式は、Reynolds平均したNavier-Stokes (RANS) 方程式および非圧縮流体の連続式である。STOC-ICは、連続式を鉛直方向に積分することによって、自由水面の位置を算出する。これらの支配方程式は、時間方向にはLeap-frog法、空間方向にはStaggered格子を用いて、有限差分法により解析している。

2.4 代替解析モデルの設計

STOC-ICの解析のフロー、および、本研究におけるニューラルネットワークによる代替解析モデルの概念を、図-2.1に示す。

STOC-ICは、最初に、地形データおよび解析条件等の情報といった入力データを読み込み、その後、時間ステップ毎に、流速、水圧および水位といった変数の更新を繰り返す時間積分計算を開始する。支配方程式に基づいた解析部が、前の時間ステップ (Previous Step) における変数値 (Variable) から、次の時間ステップ (Next Step) における変数値を計算し、この処理を最終の時間ステップまで繰り返す。

このように、流体解析モデルでは、全ての計算セルにおいて、全ての時間ステップで流速、水圧および水位といった変数の値を算出している。一般的な実港湾等を対象とした津波数値解析では、計算セル数は1,000万程度であり、時間ステップ数も10万程度である。そのため、3次元非静水圧モデルを用いれば、1ケースの解析からであっても、1兆もの教師データ (Teacher Signal) を得ることが可能であり、3次元非静水圧モデルは、非常に膨大なビッグデータを提供できる。

STOC-IC等の3次元非静水圧モデルの解析部において、水位の算出には、収束計算を必要としないことが多い。一方で、流速および水圧の算出には、時間ステップ毎に、収束計算が必要になるため、平面2次元モデルと比較して、非常に長い解析時間を要する。解析時間の一例として、計算セル数が81万 (300×150×18) セルの3次元非静水圧モデルによる津波伝播の解析時間は、同じ解析領域の計算セル数4.5万 (300×150) セルの平面2次元モデルによる津波伝播の解析時間の80倍以上となる。

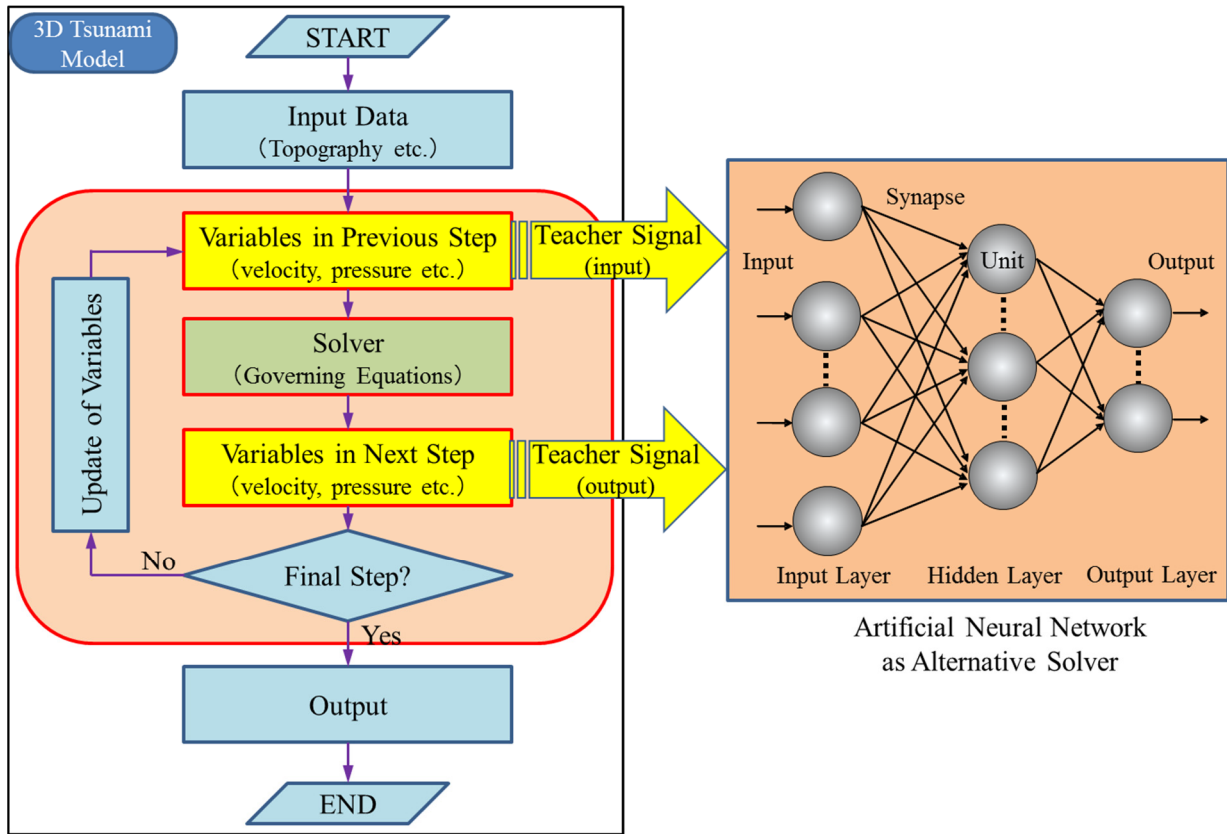


図-2.1 ニューラルネットワークによる代替解析モデルの概念




図-2.2 影響範囲

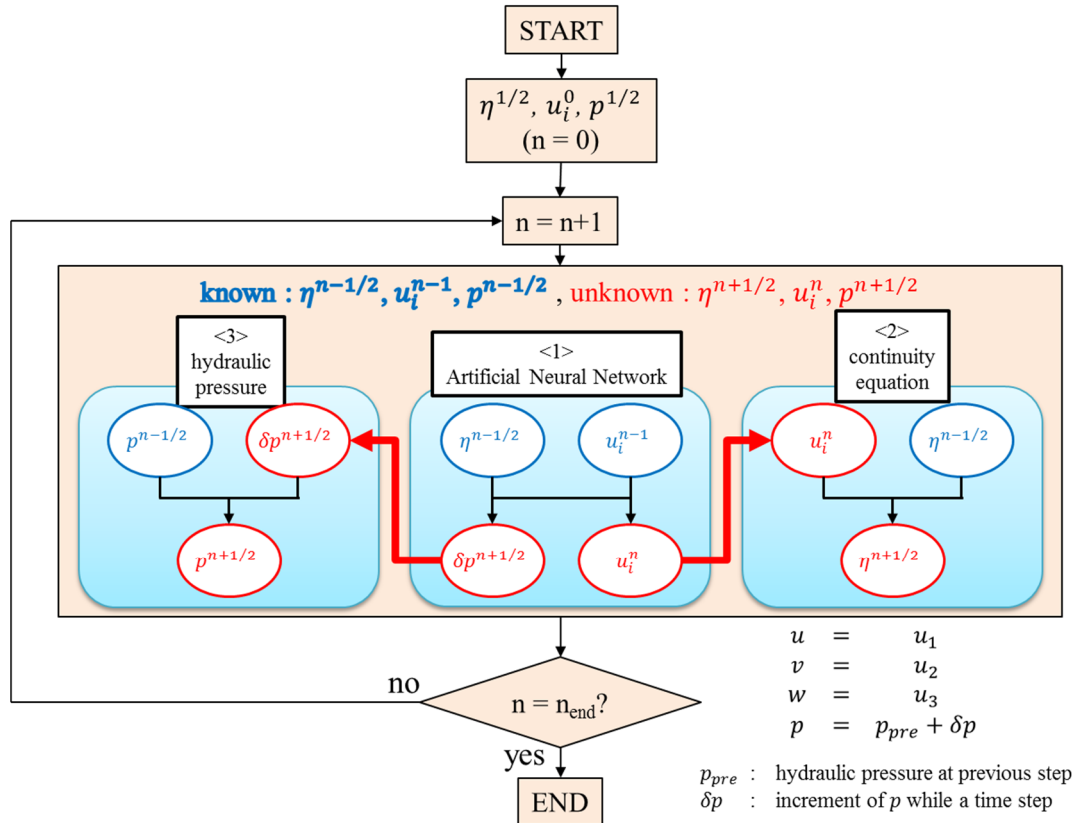


図-2.3 ニューラルネットワークによる代替解析モデルの設計

そこで、本研究では、3次元非静水圧モデルの解析時間を短縮するために、収束計算を必要としない水位の算出ではなく、収束計算が必要な流速および水圧を対象に、ニューラルネットワークを代替解析モデル（Alternative Solver）として適用した。

ニューラルネットワークの学習および学習後のネットワークの性能を評価するためには、入力信号パターンおよび出力信号パターンからなるデータセットを用意する必要がある。出力信号パターンは、次の時間ステップにおける計算セル毎の流速および水圧に関する変数である。この計算セル毎の出力信号パターンには、それに対応した入力信号パターンが必要である。この入力信号パターンは、前の時間ステップにおける水位および流速に関する変数である。

入力信号パターンとして変数値を与える計算セルが存在する空間的な範囲は、対応する出力信号パターンの計算セルから一定の距離を有する。本研究では、この一定の距離のことを「影響範囲」（Affected Range）と呼ぶ（図-2.2）。

ニューラルネットワークによる3次元非静水圧モデルの代替解析モデルの設計概要を、図-2.3に示す。前の時間ステップの水位 $\eta^{n-1/2}$ 、流速 u_i^{n-1} および水圧

$p^{n-1/2}$ といった既知の変数値から、未知の変数値である次の時間ステップの水位 $\eta^{n+1/2}$ 、流速 u_i^n および水圧 $p^{n+1/2}$ を算出する。なお、STOC-ICは、時間方向にLeap-frog法を用いていることから、水位および水圧を算出する時刻と流速を算出する時刻の差は、時間ステップの半分と設定しているため、それらの変数の上付インデックスは、1/2の差を明記している。

代替解析モデルとしてのニューラルネットワークは、計算セル毎、または、時間ステップ毎に構築するものではなく、全ての計算セルおよび全ての時間ステップを対象とした1つのニューラルネットワークを構築するため、非常に汎用性が高い代替解析モデルとして用いることが可能となる。

ニューラルネットワークの入力信号パターンは、前の時間ステップにおける流速 u_i^{n-1} 、および、水位に関する変数である。計算セルから水面までの距離 $\eta^{n-1/2} + h$ とする。なお、水位に関する変数として、計算セルから水面までの距離ではなく、水位 $\eta^{n-1/2}$ を直接用いる場合には、計算セルの鉛直位置 h も用いる必要がある。そのため、本研究では、より一般化するために、水位と計算セルの鉛直位置を包含する変数として、計算セルから水面までの距離を用いた。

一方、ニューラルネットワークの出力信号パターンは、次の時間ステップにおける、流速 u_i^n 、および、水圧に関する変数である前の時間ステップの水圧 p_{pre} からの時間変化量 $\delta p^{n+1/2}$ とする。なお、水圧に関する変数として、前の時間ステップからの水圧変化ではなく、例えば、静水圧からの水圧増分を用いることも可能である。しかし、本研究では、教師データとしているSTOC-ICが水圧を算出する際に解いているPoisson方程式の処理手法と揃えるために、水圧の時間変化量を用いた。

このように、代替解析モデルとしての学習後のニューラルネットワークは、計算セルの鉛直位置とともに、前の時間ステップにおける水位および流速を用いて、次の時間ステップにおける流速および水圧の時間変化量を出力する。

次の時間ステップにおける水圧は、ニューラルネットワークから出力された水圧の時間変化量を、前の時間ステップにおける水圧に加算することで算出することができる。

一方、次の時間ステップにおける水位については、STOC-ICと同様に、前の時間ステップにおける水位 $\eta^{n-1/2}$ 、および、ニューラルネットワークから出力された次の時間ステップにおける流速 u_i^n を用いて、連続式から算出することができる。

3. 代替解析モデルの適用性の検証

3.1 検証方法

本研究で提案したニューラルネットワークを用いた3次元非静水圧モデルの代替解析モデルについて、その適用可能性を評価するため、モデル地形上を伝播する津波を対象に、精度検証を実施した。本手法は、学習後のニューラルネットワークから、流速および水圧に関する変

数を入力するものであり、水位については、それらの流速および水圧を用いて、収束計算が不要な連続式により算出するものである。そのため、精度検証の対象は、ニューラルネットワークから出力される流速および水圧のみとする。

精度検証の対象は、一様水深のモデル地形を伝播する津波を対象とした。モデル地形、津波の初期波形等の概要を図-3.1に示し、STOC-ICによる解析条件を表-3.1に示す。

津波の初期波形は、10mの一様水深のモデル地形の中心に位置し、その形状は、振幅4mで波長200mの正弦波 (Sinusoidal Wave) である。解析領域は、水平方向5km、鉛直方向20mとし、計算格子間隔は0.5mである。解析領域の両端の境界条件は、開境界である。解析対象時間および時間間隔は、それぞれ、30秒および0.02秒である。

本研究の目的は、3次元非静水圧モデルへのニューラルネットワークの適用可能性の確認である。そのため、代替解析モデルとしてのニューラルネットワークの学習および精度検証の対象は、解析領域内の全計算セルにおける変数とする必要はないため、津波の初期波形の先端から離れた10個の計算セルに限定した。

対象とした計算セルの中心は、津波の初期波形の先端から水平方向に99.75m離れており、初期水位に対する水深は0.75mから5.25mの範囲にある。

津波が対象の計算セルの地点に到達する時間は、約10秒である。そのため、学習や精度検証で使用する変数値は、対象の計算セルの変数値のうち、10秒から30秒までの0.1秒間隔のものを採用した。

出力信号パターンの変数は、水平流速 u および鉛直流速 w 、ならびに、水圧の時間変化量を水の密度と重力加速度で除した $\delta p/\rho g$ とした。




図-3.1 モデル地形と学習対象の計算セル

表-3.1 解析条件

Domain	5000 m×0.5 m×20 m (x×y×z)
Grid size	$dx = dy = dz = 0.5$ m
Integrated time	30 s
Time interval	0.02 s
Bathymetry	Flat sea bottom: $h_0 = 10$ m
Boundary condition	Open boundary
Initial velocity	0 m/s
Initial surface	Sinusoidal wave
Amplitude of sinusoidal wave	$a_0 = 4$ m
Length of sinusoidal wave	$L_0 = 200$ m

入力信号パターンの変数は、対象の計算セルに対する影響範囲内の全ての計算セルの変数であり、その変数値は前の時間ステップの値である。これらの変数は、水平流速 u および鉛直流速 w 、ならびに、計算セルから水面までの距離 $\eta + h$ である。

ここでは、中間層のユニット数を10個とした。しかし、本来であれば、中間層の総数および各中間層のユニット数といった、対象の問題に対する最適なネットワーク構造の検討が必要である。

再現の精度には、水面の境界条件が影響すると考えられる。そこで、対象とする計算セルを1個とするケース (Case-A) と、前述の全ての計算セルの10個とするケース (Case-B) の2ケースについて、精度検証を実施した。

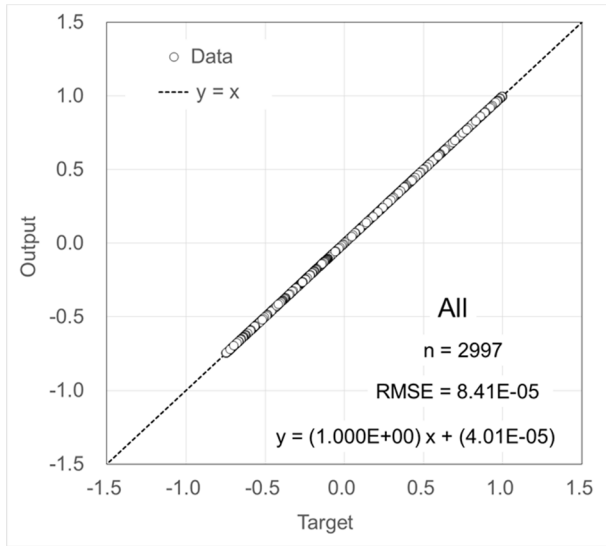


図-3.2 出力信号の比較 (Case-A)

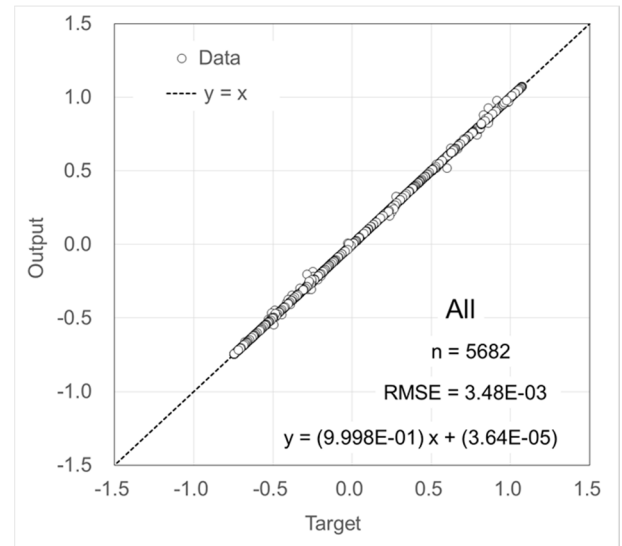


図-3.4 出力信号の比較 (Case-B)

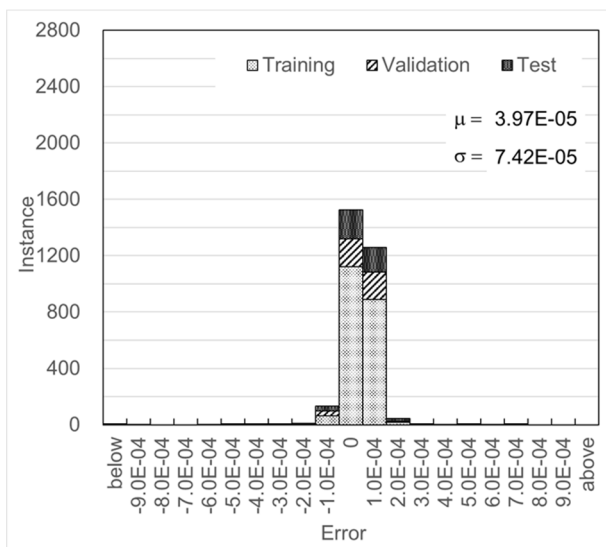


図-3.3 出力信号の誤差 (Case-A)




図-3.5 出力信号の誤差 (Case-B)

Case-Aについては、津波が伝播している際にも常に水面より下に位置している計算セルとし、その位置は、 $z = -5.25[m]$ とした。一方、Case-Bについては、津波が伝播している際に、水面が、幾つかの対象の計算セルの下に位置するときがある。

本研究では、水面が計算セルの位置よりも下になるときの出力信号パターン、および、それに対応する入力信号パターンは、学習および精度検証から除外する。

入力信号パターンおよび出力信号パターンからなるデータを無作為に、学習データ、検証データおよびテストデータに分割し、それらの比率は、学習データが70%、検証データが15%、テストデータが15%とした。

影響範囲については、後述の第4章での検討結果を踏まえて、3mとした。

3.2 検証結果

Case-Aについて、ニューラルネットワークからの出力値と、3次元非静水圧モデルであるSTOC-ICの結果との比較を、図-3.2に示す。なお、この図は、学習データ(Training Data)、検証データ(Validation Data)およびテストデータ(Test Data)の全てを合わせてプロットしたものである。2乗平均平方根誤差は、出力信号パターンの0.01%以下であり、相関係数は、1.00である。

Case-Aについて、出力信号の誤差を、図-3.3に示す。出力信号の誤差の平均値 μ および標準偏差 σ は、それぞれ、 3.97×10^{-5} および 7.42×10^{-5} である。正規分布の場合には、99.7%は $\pm 3\sigma$ の範囲に含まれる。出力値は-1から+1の範囲程度に含まれることから、そのオーダーは 10^0 程度である。このことと、 $3\sigma = 2.23 \times 10^{-4}$ であることから、ニューラルネットワークからの出力の99.7%は、約0.023%以下の誤差の範囲に含まれている。

Case-Bについて、ニューラルネットワークからの出力値と、STOC-ICの結果との比較を、図-3.4に示す。2乗平均平方根誤差は、出力信号パターンの1%以下であり、相関係数は、1.00である。

Case-Bについて、出力信号の誤差を、図-3.5に示す。出力信号の誤差の平均値 μ および標準偏差 σ は、それぞれ、 2.97×10^{-5} および 3.48×10^{-3} である。同様に、出力値のオーダーは 10^0 程度であり、 $3\sigma = 1.04 \times 10^{-2}$ であることから、ニューラルネットワークからの出力の99.7%は、約1.0%以下の誤差の範囲に含まれている。

これらの結果から、ニューラルネットワークは、3次元非静水圧モデルの代替解析モデルとして、非常に高い再現性を有することが分かる。なお、Case-Aと比較して、Case-Bの誤差が大きいことについては、Case-Bでは水面

が近い計算セルが含まれることにより、水面の境界の影響が推察される。

4. 影響範囲の予備検討

4.1 検討方法

出力信号パターンは、次の時間ステップにおける各計算セルの変数値であり、また、入力信号パターンは、前の時間ステップにおける、対象の計算セルに対する影響範囲内の全ての計算セルの変数値である(図-2.2)。

圧縮性流体における影響範囲については、理論上は、流体の音速を時間間隔で除した値とすることが正しい。一方、非圧縮性流体の場合、理論上は、影響範囲は ∞ となり、本研究で提案したニューラルネットワークの代替解析モデルは成立しない。しかし、第3章での精度検証の結果のとおり、非圧縮性流体であっても、ある程度の誤差を許容すれば、有限の影響範囲を設定することができる。そこで、許容する誤差に対する影響範囲について、その検証方法の検討を実施した。

一様水深の地形上の静水に、パルス状のトリガーとして、水位のトリガー η_0 または流速のトリガー u_0 を与え、次の時間ステップにおける全ての変数の時間変化を評価する。

水位 η 、水圧 p および流速 u_i の時間変化は、それぞれ、式(4.1)、式(4.2)および式(4.3)で表される。なお、時間間隔および初期時刻は、それぞれ、 Δt および t_0 である。

$$\Delta\eta(x) = \eta(x, t_0 + \Delta t) - \eta(x, t_0) \quad (4.1)$$

$$\Delta p(x, z) = p(x, z, t_0 + \Delta t) - p(x, z, t_0) \quad (4.2)$$

$$\Delta u_i(x, z) = u_i(x, z, t_0 + \Delta t) - u_i(x, z, t_0) \quad (4.3)$$

異なる変数を比較するために、各変数の代表値 (η_0 , p_0 , u_0) で無次元化したものを用いる。水位、水圧および流速の代表値を、それぞれ、式(4.4)、式(4.5)および式(4.6)に示す。これらは、運動方程式の次元解析から導出したものである。なお、 ρ , g および Δs は、それぞれ、水の密度、重力加速度および計算セルの間隔を表している。また、ここでは、全ての計算セルの間隔は、水平方向も鉛直方向も同一としている。

$$\eta_0 = (1/g)(\Delta s/\Delta t)u_0 \quad (4.4)$$

$$p_0 = \rho g \eta_0 = \rho(\Delta s/\Delta t)u_0 \quad (4.5)$$

$$u_0 = g(\Delta t / \Delta s) \eta_0 \quad (4.6)$$

全ての変数を同時に比較するために用いる無次元化した時間変化量は、式(4.1)～式(4.6)から次のように求められる。

$$\Delta \eta'(x) = \Delta \eta(x) / \eta_0 \quad (4.7)$$

$$\Delta p'(x, z) = \Delta p(x, z) / p_0 \quad (4.8)$$

$$\Delta u'_i(x, z) = \Delta u_i(x, z) / u_0 \quad (4.9)$$

これら式(4.7)、式(4.8)および(4.9)で表される無次元化した時間変化率を用いて、影響範囲の検証方法の検討を行う。本研究では、この無次元化した時間変化率を、「影響率」(Affected Rate)と呼ぶ。

4.2 検討条件

一様水深のモデル地形を対象に検討する。水位および流速をトリガーとした場合のレイアウトを、それぞれ、図-4.1および図-4.2に示す。また、検討に使用する3次元非静水圧モデルであるSTOC-ICの解析条件を、表-4.1に示す。

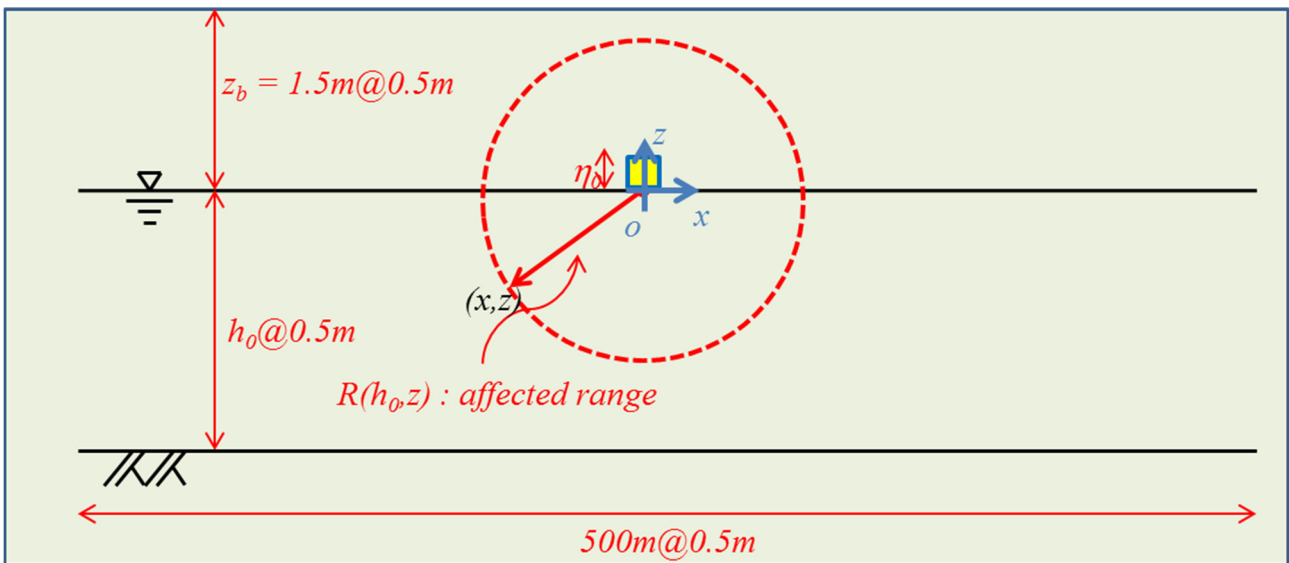


図-4.1 水位上昇によるトリガー




図-4.2 流速によるトリガー

表-4.1 解析条件

Domain	500.5 m × 0.5 m × (h ₀ +1.0) m (x × y × z)
Grid size	dx = dy = dz = 0.5 m (=Δs)
Integrated time	0.02 s (=Δt)
Bathymetry	Uniform sea bottom (seven cases) h ₀ = 5, 10, 50, 100, 500, 1000, 5000 m
Boundary condition	Open boundary
Initial surface	η = 0 m
Initial velocity	0 m/s
Surface trigger	η ₀ = 1 m
Flow trigger	u ₀ = 0.392 m/s or w ₀ (= u ₀) = 0.392 m/s
Depth of flow trigger	h _t = 0.2 × h ₀ , 0.4 × h ₀ , 0.6 × h ₀ , 0.8 × h ₀ , 1.0 × h ₀ (five cases)
Size of trigger	dx = dy (= dz) = 0.5 m

トリガーの位置は、水平方向については、領域の中央に設定した。領域の両端における境界条件は、開境界とした。積分時間は、影響範囲を検討するための時間間隔と同一とした。

流速トリガーを与える水中の計算セルの位置は、鉛直方向に5ケースとした。また、流速トリガーの向きは、正負の2ケースとした。そのため、同一のモデル地形を対象とした流速トリガーは、合計10ケースとなる。

モデル地形の水深は、7ケースとした。そのため、水位トリガーのケース数は、合計7ケースであり、流速トリガーのケース数は、合計70ケースとなる。

4.3 検討結果

影響範囲の一例として、正方形となる水深500mのモデル地形における水位トリガーの場合の影響率を、図-4.3から図-4.6に示す。図中の数値は、影響率の常用対数であり、例えば、図中の-4.0の表記は、10⁻⁴の影響率を表している。なお、図中の横軸および縦軸は、それぞれ、領域の幅で無次元化した水平方向の座標、および、水深で無次元化した鉛直方向の座標である。

水位トリガーは、水平流速に対しては、主にトリガーの斜め下に向かう対角線方向に影響し(図-4.3)、鉛直流速に対しては、主に鉛直方向および水平方向に影響する(図-4.4)。一方、これら水平流速と鉛直流速の合成流速に対しては、水位トリガーは、全方位に同等に影響し、高い影響率は、水位トリガーの近傍に集中している(




図-4.3 水平流速に対する影響率 (水位トリガー)
(h₀=500 m)




図-4.4 鉛直流速に対する影響率 (水位トリガー)
(h₀=500 m)

図-4.5). 水圧に対しては、水位トリガーは、広い範囲に影響しているが、水面近くでは影響率が非常に小さい(図-4.6)。これは、水面は大気圧と等しくなり、水圧が解放されることによるものである。




図-4.5 合成流速に対する影響率 (水位トリガー)
($h_0=500$ m)




図-4.6 水圧に対する影響率 (水位トリガー)
($h_0=500$ m)

全てのケースについて水平方向および鉛直方向の影響範囲を算出し、それらの最大値を影響率毎に整理したものについて、水位トリガーの場合を表-4.2に、流速トリガーの場合を表-4.3に示す。ただし、計算セル毎に影響

表-4.2 影響範囲 (水位トリガー)

Affected Rate	Direction	Pressure	Velocity	Water Surface
10^{-3}	Horizontal	1.5 m	3.0 m	0.5 m
	Vertical	3.0 m	3.0 m	-
10^{-4}	Horizontal	19.0 m	10.5 m	0.5 m
	Vertical	36.0 m	10.0 m	-
10^{-5}	Horizontal	148.5 m	33.5 m	2.0 m
	Vertical	251.5 m	32.0 m	-

表-4.3 影響範囲 (流速トリガー)

Affected Rate	Direction	Pressure	Velocity	Water Surface
10^{-3}	Horizontal	0.0 m	9.5 m	0.0 m
	Vertical	0.0 m	8.5 m	-
10^{-4}	Horizontal	3.0 m	29.5 m	2.0 m
	Vertical	1.5 m	27.5 m	-
10^{-5}	Horizontal	9.5 m	97.0 m	8.0 m
	Vertical	5.0 m	90.0 m	-

響率を判定しているため、計算セルの間隔である0.5m毎の算出となっている。なお、ニューラルネットワークによる代替解析モデルについては、水圧および流速の影響範囲のみが必要な情報であるが、参考までに、これらの表には、水位に対する影響範囲も示している。

水圧に対する影響範囲については、流速トリガーと比較して、水位トリガーの影響が大きい。一方、流速に対する影響範囲については、水位トリガーと比較して、流速トリガーの影響が大きい。

以上の結果から、許容誤差を 10^{-3} に設定した場合には、水位変化に起因する影響範囲は3.0mであり、流速変化に起因する影響範囲は9.5mであることが分かる。今回の検討における解析条件は、計算セルの間隔は0.5m、時間間隔は0.02秒である。そのため、これ以外の解析条件の場合には、影響範囲が変化することに注意が必要である。

5. まとめ

本研究では、機械学習の1つであるニューラルネットワークを、3次元非静水圧モデルの代替解析モデルとして適用する手法を提案した。

本手法は、1つの計算セルを対象に1つのニューラルネットワークを構築するものではなく、全ての計算セルを対象とした1つのニューラルネットワークを構築するも

のであるため、非常に汎用性が高い手法である。

3次元非静水圧モデルによる解析値を教師データとして学習させたニューラルネットワークは、前の時間ステップにおける水位および流速に関する変数を入力することにより、次の時間ステップにおける流速および水圧に関する変数を出力するものである。

本研究の提案手法の適用性の検証のため、一様水深のモデル地形上を津波が伝播する現象について、幾つかの計算セルを対象に、変数値の再現性を確認した。なお、この適用性の検討では、3次元非静水圧モデルとしてSTOC-ICによる解析結果を用いた。

ニューラルネットワークによる代替解析モデルは、水面近くの計算セルについては、誤差が認められたが、その値は非常に小さい。そのため、本研究の提案手法の適用性は、非常に高いものと考えられる。

ニューラルネットワークによる代替解析モデルは、影響範囲と呼ばれる入力信号を与える計算セルの範囲を、適切に設定する必要がある。

許容誤差に対する影響範囲を設定する手法について、非圧縮性流体を対象に検討を行った。

計算セルの間隔を0.5m、時間間隔を0.02秒、許容誤差を 10^{-3} とした場合、非圧縮性流体に対する影響範囲は、水位変化に起因する影響範囲は3.0mであり、流速変化に起因する影響範囲は9.5mである。

6. あとがき

本研究は、3次元非静水圧モデルの代替解析モデルとして、ニューラルネットワークを用いることを提案し、その提案手法の適用可能性を示した。

3次元非静水圧モデルは、解析ステップ毎に収束計算を必要とすることから、平面2次元モデルと比較して数十倍程度の解析時間を要する。学習後のニューラルネットワークは収束計算を必要としないことから、本提案手法により、大幅な解析時間の短縮が期待できる。

今後、本提案手法を実用化するためには、以下に示す検討が必要である。

水面の境界近傍では誤差が生じやすいことから、水面の境界処理に関する検討が必要である。また、構造物や地形等の境界に関する検討も必要である。

ニューラルネットワークによる出力値の精度向上、学習の効率化等のために、最適なネットワーク構造（中間層の層数、中間層のユニット数、活性化関数等）に関する検討が必要である。

連続式を用いて、ニューラルネットワークから出力さ

れた流速および水圧から算出される水位に関する精度検証が必要である。

任意の計算セルの間隔および時間間隔を対象に、影響範囲の検討が必要である。なお、計算セルの間隔が小さい場合、解析の時間間隔も小さく設定する必要があることから、影響範囲内の計算セルの総数は、大きく変化しないことが推察される。

解析時間が膨大な3次元非静水圧モデルと比較して、学習後のニューラルネットワークを代替解析モデルとして用いると、非常に短い解析時間となることが期待できる。解析コストの低減を評価するためには、異なる解析条件および解析規模を対象に、解析時間の比較も実施する必要がある。

(2019年2月14日受付)

参考文献

- 内田吉文・本多和彦・吉村藤謙・間瀬 肇・加藤英紀・片山美可・米澤泰雄 (2011) : ニューラルネットワーク法による伊勢湾内浮遊ゴミ集積場所の予測可能性の検討, 土木学会論文集 B2, Vol. 67, No. 2, pp. I_1366-I_1370.
- 金 洙列・塩崎信一・松見吉晴・玉井和久・福岡宏人 (2013) : ニューラルネットワークを用いたリアルタイム高潮予測における学習パラメータの感度分析に関する研究, 土木学会論文集 B2, Vol. 69, No. 2, pp. I_246-I_250.
- 金 洙列・松見吉晴・出田裕二郎・間瀬 肇・森 信人・安田誠宏 (2015) : ニューラルネットワークによる高潮予測モデル, 土木学会論文集 B2, Vol. 71, No. 2, pp. I_223-I_228.
- 間瀬 肇・坂本雅信・酒井哲郎・後藤仁志 (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・酒井哲郎 (1995) : 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.
- 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・加次淳一郎・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のリアルタイム津波予測, 京都大学防災研究所年報, 第50号 B, pp. 527-535.

- 松原雄平・野田英明 (1994) : ニューラルネットワークによる生態系環境評価システムの開発, 海岸工学論文集, 第 41 巻, pp. 1136-1140.
- 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.
- 李 光浩・水谷法美・藤井俊明 (2008) : 砕波現象に対するニューラルネットワークの構築, 海岸工学論文集, 第 55 巻, pp. 106-110.
- 李 光浩・藤井俊明・水谷法美 (2009) : ソフトコンピューティングによる砕波波高及び砕波水深の予測に関する研究, 土木学会論文集 B2, Vol. 65, No. 1, pp. 111-115.
- Fujima, K, Masamura, K, and Goto, C (2002): Development of the 2D/3D hybrid model for tsunami numerical simulation, *Coastal Eng. J.*, JSCE, Vol. 44, No. 4, pp. 373-397.
- Honda, K and Tomita, T (2008): Tsunami Inundation Simulation by Three-Dimensional Model, *Proc. 31st Int. Conf. Coastal Eng., ASCE*, pp. 1433-1445.
- Honda, K (2015): Development of Connecting Method between two-dimensional and three-dimensional Tsunami Numerical Model, *Proc. 25th Int. Offshore and Polar Eng. Conf.*, Kona, ISOPE, pp. 719-724.
- Honda, K (2016): Study on Application of Artificial Neural Networks to Solver of Three-dimensional Tsunami Numerical Model, *Proc. 26th Int. Offshore and Polar Eng. Conf.*, Rhodes, ISOPE, pp. 739-746.
- Lagaris I. E., Likas A., and Fotiadis D.I. (1998): Artificial Neural Networks for Solving Ordinary and Partial Differential Equations, *IEEE T. Neural Networks*, IEEE, Vol. 9, No. 5, pp. 987-1000.
- Londhe SN, and Deo MC (2004): Artificial Neural Networks for Wave Propagation, *J. Coastal Res.*, CERF, Vol. 20, No. 4, pp. 1061-1069.
- Mase H, Sakamoto M, and Sakai T (1995): Neural network for stability analysis of rubble-mound breakwaters, *J. Waterway, Port, Coastal, & Ocean Eng.*, Vol. 121, No. 6, pp. 294-299.
- Mase H, Yasuda T, and Mori N (2011): Real-Time Prediction of Tsunami Magnitudes in Osaka Bay, Japan, Using an Artificial Neural Network, *J. Waterway, Port, Coastal, & Ocean Eng.*, ASCE, Vol. 137, No. 5, pp. 263-268.
- Meade Jr., A. J., and Fernandez A. A. (1994): Solution of nonlinear ordinary differential equations by feedforward neural networks, *J. Mathematical & Computer Modelling*, Vol. 20, No. 9, pp. 19-44.
- Tomita, T, Honda, K, and Kakinuma, T (2006): Application of three-dimensional tsunami simulator to estimation of tsunami behavior around structures, *Proc. 30th Int. Conf. Coastal Eng.*, ASCE, pp. 1677-1688.
- Tomita, T, and Honda, K (2007): Tsunami estimation including effect of coastal structures and buildings by 3d-model, *Proc. 5th Int. Conf. Coastal Structures*, ASCE, pp. 681-692.

国土技術政策総合研究所研究報告

RESEARCH REPORT of NILIM

No. 63

March 2019

編集・発行 ©国土技術政策総合研究所

本資料の転載・複写のお問い合わせは
〔〒239-0826 神奈川県横須賀市長瀬 3-1-1
管理調整部企画調整課 電話:046-844-5019〕
E-mail:ysk.nil-kikaku@ml.mlit.go.jp