

II-134

非線形自己回帰モデルによる有義波高の予測について

鳥取大学工学部 正会員 太田隆夫・木村 晃
アサヒコンサルタント 稲田真由子

1. はじめに

従来の簡便な波浪予測法としては、重回帰式や多変量自己回帰式を用いた統計モデルが挙げられる。いくつかの研究¹⁾によりその適用性が検討され、実用的な精度の予測結果を得られる場合があることも報告されている。これらの方法では、予測値(目的変数、出力)はそれ以前の波浪などのデータ(説明変数、入力)の線形和により与えられる。しかし、波浪などの自然現象を対象とする場合、仮にその変動が回帰モデルで表現できるとしても、入出力の関係は非線形とするほうがより一般的である。ただし、現象のメカニズムが明確でない場合は、ある特定の非線形関数を選択する根拠がないことになる。このような場合には、関数を陽に仮定せずに、学習という操作で現象の特徴抽出を行っていくニューラルネットワークの適用が考えられる。本研究では、ニューラルネットワークにより非線形自己回帰モデルを作成し有義波高の予測を試みる。

2. 予測モデルの作成

ニューラルネットワークは、人間の脳神経細胞を模擬した数理モデルであり、これにより任意の非線形関数を任意の精度で近似可能であることが証明されている。最近では、入力層・中間層・出力層からなる階層型ネットワークと誤差逆伝播法という学習法との組合せで用いられることが多い。ここで、学習とは与えられた学習データ(入力データとそれに対応する出力データの組)に合うように、ネットワークのパラメータを調整していく操作のことである。本研究では、階層型ネットワークを用いて自己回帰モデルを作成するが、その構造を図-1に示す。中間層の各ユニットには、入力層からのデータに対する出力を決定する基底関数が組み込まれており、ここではガウス関数をベースにしたラジアル基底関数²⁾を用いる。自己回帰モデルにおいて時刻 t での出力 $y(t)$ は、それ以前の観測値を $y(t-1), \dots, y(t-s)$ とすると次式のように表される。

$$y(t) = f_s \{ y(t-1), y(t-2), \dots, y(t-s) \} \quad (1)$$

この関数 f_s を N 個の入出力データ組(学習データ)が与えられたもとの、ニューラルネットワークにより同定する。本研究で用いるネットワークモデルでは、 f_s は次のように与えられる。

$$f_s = \sum_{k=1}^n w_k \mu_k(\mathbf{x}_s, \mathbf{a}_k, \mathbf{b}_k) \quad , \quad \mu_k(\mathbf{x}_s, \mathbf{a}_k, \mathbf{b}_k) = \prod_{i=1}^s A_{ik} \{ y(t-i), a_{ik}, b_{ik} \} \quad (2)$$

ここに、 $\mu_k(\cdot)$: k 番目の基底関数、 n : 基底関数数、 w_k : k 番目の基底関数の出力値に対する重み係数、 $\mathbf{x}_s$: 入力データのベクトル、 $\mathbf{a}_k$: ガウス関数の中心値のベクトル、 $\mathbf{b}_k$: ガウス関数の分布幅パラメータのベクトル、 $A_{ik}\{\cdot\}$: 入力 $y(t-i)$ に対するガウス関数の値

このネットワークで学習の対象となるパラメータは、 a 、 b および w である。学習においては、入力データ $\mathbf{x}_s$ に対するネットワークの出力値 $\bar{y}$ と、 $\mathbf{x}_s$ に対応する出力データ y との差の2乗和が小さくなるようにパラメータを決定するが、この問題は次のように表される。

$$\min_{(\mathbf{a}^n, \mathbf{b}^n, \mathbf{w}^n)} E_n(\mathbf{a}^n, \mathbf{b}^n, \mathbf{w}^n) = \frac{1}{2} \sum_{p=1}^N (y^p - \bar{y}^p)^2 \quad (3)$$

このような問題は勾配法で解くことができ、ここでは最も基本的な最急降下法を用いる。また、基底関数数 n を固定して学習を行い、




図-1 ネットワークの構造

有義波高、自己回帰モデル、ニューラルネットワーク、ラジアル基底関数

〒680-0945 鳥取市湖山町南4-101・0857-31-5334・0857-31-0882

E_n の値の減少率が小さくなった段階で中間層ユニットを 1 つ増やして、新規の基底関数を発生させる方法（自己増殖型アルゴリズム²⁾）をとる。このような学習過程を経てネットワークモデルが作成されるが、入力データ数および基底関数数の最適値に関する問題が残る。これに対しては、AIC（赤池情報量規準）を用いて、その値が最小となるときに入力データ数および基底関数数を採用した。本研究で用いたデータは、全国港湾海洋観測資料のうち、鳥取港における 1987 年 12 月から 1989 年 10 月までの有義波高である。日本海側の有義波高データでは季節変動が顕著であるため、学習データを季節ごとに作成した。すなわち、1987 年 12 月と 88 年 1 月、88 年 3 月と 4 月、6 月と 7 月、9 月と 10 月の各 2 ヶ月分のデータから、入力データ数を 4~10、出力データ数を 1 として学習データを作成した。また出力データは、最新の入力データから 6 時間後および 12 時間後の有義波高とした。

3. 学習および予測の結果

表-1 に AIC により選択されたネットワークモデルの入力データ数および基底関数数を示す。図-2 (a), (b) には 87 年 12 月と 88 年 1 月、88 年 9 月と 10 月の学習結果を示す。図中の実線が学習データの出力データ、破線がネットワークの出力値である。これらの図より、ネットワークが学習データの入出力関係をよく捉えていることがわかる。87 年 12 月と 88 年 1 月の学習データから作成したネットワークモデルにより 89 年 1 月の予測を、88 年 9 月と 10 月の学習データによるモデルで 89 年 10 月の予測を行った。図-3 (a), (b) はそれぞれの 6 時間後予測の結果である。図中の実線は観測値、破線は予測値である。図-3 (a), (b) ともに予測値の観測値からの遅れが見られるが、1 月のほうがずれの程度が小さい。これは、冬期のほうが波高の変動にパターンがあることを示唆している。

4. おわりに

本研究ではニューラルネットワークによる自己回帰モデルを作成し、有義波高の予測を行った。その結果は、従来の統計モデルと同様に予測値の時間的なずれなどを示すものであった。予測精度向上のためには、気圧などのデータを取り込んだ多変量モデルとすることが考えられる。ネットワークにより多変量モデルを作成することは可能であり、今後の課題としたい。【参考文献】1) たとえば、小舟浩治 他 (1990) : 統計モデルを用いた波浪予測手法の適用性に関する検討、港湾技研資料, No.673, pp.1-42 2) 片山 立 他 (1992) : 自己増殖型ラジアル基底関数による非線形ダイナミカルシステムの同定と予測、計測自動制御学会システム 3 部会合同シンポジウム講演論文集, pp.187-194

表-1 入力データ数と基底関数数

データ \ 出力	6 時間後	12 時間後
1987.12, 1988.1	入力データ 4 基底関数 5	入力データ 4 基底関数 4
1988.3, 1988.4	入力データ 4 基底関数 4	入力データ 4 基底関数 2
1988.6, 1988.7	入力データ 4 基底関数 5	入力データ 4 基底関数 2
1988.9, 1988.10	入力データ 4 基底関数 3	入力データ 4 基底関数 3




図-2 (a) '87.12,'88.1の学習結果




図-2 (b) '88.9,10の学習結果




図-3(a) '89.1の予測結果




図-3(b) '89.10の予測結果