

ニューラルネットワークモデルによる富栄養湖のクロロフィル a の動態予測 Prediction of Chlorophyll a Dynamics in Eutrophic Lake by Artificial Neural Network Model

齋 幸治*・原田昌佳**・吉田 勲***・平松和昭**
Sai Koji, Harada Masayoshi, Yoshida Isao and Hiramatsu Kazuaki

1.はじめに 現在多くの湖沼などの閉鎖性水域で富栄養化の進行により,アオコに代表される植物プランクトンの異常繁殖などの水環境の劣化が大きな問題となり,その水環境の保全や改善が急務となっている.そのため,水域内の水環境動態の解析,評価さらに予測は非常に重要な課題である.ところで,近年 AI 技術を援用した非物理モデルによる水環境の評価・予測に関する研究が盛んになされている(例えば,斉藤ら,1998).本研究では鳥取県湖山池を対象に,パターン認識の分野で優れているニューラルネットワークモデル(以下,NN)を用い,植物プランクトン量の目安となるクロロフィル a(以下,Chl. a)の動態予測の可能性を検討した.

2.観測概要 湖山池においてとくに水環境の悪化が著しい池北岸の最深部を本研究の観測地点とした.水質測定項目を Table 1 にまとめる.定期観測では,11時~12時の間に表層(水面下約15cm)と底層(水底面上約15cm)の2点で採水を行い,水質分析に供した.連続観測は10分間隔で測定を行ったが,以後の解析では,1時間間隔のデータを使用した.観測期間は平成16年4月~平成17年11月である.

3.ニューラルネットワークモデルについて

本研究では, Fig. 1 に示すような3層構造の階層型 NN を採用し,学習は一般化デルタ則に基づいて行なった.また,各ユニットの閾値関数にはシグモイド関数を採用した(八名ら,1992).さらに,重みの修正方法として一括修正法を採用し,学習は5万回の反復回数をもって終了することとした.

4.結果と考察 計算は Table 2 に示す2ケースについて行なった. Case 1, 2 の入力層のユニット数 n_1 は閾値用入力を加えてそれぞれ11, 15である.また,2ケースとも出力層のユニット数は表層と底層の Chl. a の $n_3 = 2$, 中間層は $n_2 = 20$ とした.なお,閉鎖性水域における水環境要素の動態には水塊の水深方向の輸送が大きく関わってくることを考慮し,水域の鉛直構造を表すパラメータとしてウェダバーン数を入力データに加えた.平成16年4月~平成17年11月の観測データを

Table 1 Water quality measurement

| 観測区分 | 測定項目 | 測定位置 | 測定間隔 |
|------|--------------------|---------|--------|
| 定期観測 | Chl. a | 表層および底層 | 約1週間間隔 |
| | 全窒素(TN) 全リン(TP) | | |
| 連続観測 | 電気伝導度(EC) | 表層および底層 | 10分間隔 |
| | 塩分 | | |
| | DO | | |
| | 水温 | | |
| | 全天日射量 | 水面上約2m | |
| 気温 | 水面上約5.3m | | |
| 風速 | | | |

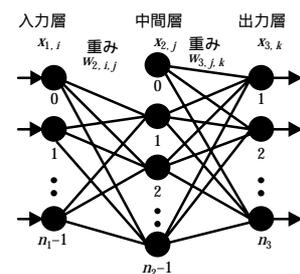


Fig. 1 Typical three-layer perceptron model

Table 2 Input variables

| ケース | 入力データ |
|--------|---|
| Case 1 | 表層および底層のDO, 水温と塩分, 日射量, 気温, 風速, ウェダバーン数 |
| Case 2 | 表層および底層のTN, TP, DO, 水温と塩分, 日射量, 気温, 風速, ウェダバーン数 |

*九州大学大学院生物資源環境科学府 Graduate School of Bioresource and Bioenvironmental Sciences, Kyushu University

**九州大学大学院農学研究院 Faculty of Agriculture, Kyushu University

***鳥取大学名誉教授 Emeritus Professor, Tottori University

キーワード: ニューラルネットワークモデル, 閉鎖性水域, 富栄養化, クロロフィル a

用いて Case 1, 2 をそれぞれ入力層とする NN に対して学習を行った。教師データ数は定期観測を行った回数 $n_t = 69$ である。ここで、出力データである Chl. a ならびに Case 2 の入力データの一部である TN, TP は、定期観測の行われた日の 12 時時点のデータとして取り扱った。そのため、入力データのうち連続観測項目については定期観測を行った日の 12 時時点の値を用いた。以下では、表層 Chl. a の計算結果のみ考察する。なお、計算結果の再現（予測）精度の評価には出力値と観測値の 2 乗平均誤差 (E_r) を用いた。

反復学習後の出力値と観測値の相関図を E_r の値と併せて Fig. 2 に示す。いずれのケースも E_r の値は非常に小さく、学習は良好に行われたと考えられる。ところで、一般に植物プランクトンの発生量は水中の栄養塩濃度、とくに TN, TP の影響を強く受ける。2 ケースの E_r の値を比較すると、入力データとして TN, TP を付加したことで再現性が向上したことから、Case 2 のネットワーク構造は Chl. a と栄養塩類の相関構造を取得していることが伺える。

つぎに、NN による Chl. a の動態予測の可能性について検討した。全 69 組の定期観測データから無作為に選んだ 44 組のデータを教師データとして NN の学習をした後、残りの 25 組の入力データから Chl. a を計算し、これを予測値とした。Case 2 を入力データとした場合の予測結果を Fig. 3 に示す。同図より、計算値と観測値の較差は大きく、十分な予測結果が得られていない。そこで、次のように入力データの時間的推移を考慮することで予測精度の向上を検討した。すなわち、Case 2 の入力データのうち連続観測によって得られる項目に関して、予測時点の 12 時より 12 時間遡り、その間の入力データの時間的推移を考慮した。つまり、0~3 時、3~6 時、6~9 時、9~12 時の 4 つの時間帯で 3 時間平均値を計算し、それらを入力データとして追加した。これを Case 3 とし、予測結果を Fig. 4 に示す。同図より、計算結果と観測値のばらつきは若干あるものの Chl. a の挙動は概ね再現されていることが分かる。以上のように、入力データの時間的推移を考慮することで、予測精度の向上が期待される。

5. おわりに 本研究では、3 層構造の階層型 NN による Chl. a の動態予測の可能性を検討した。入力層に TN, TP を付加した NN では、その内部構造に Chl. a の動態と栄養塩類との相関構造を取得することで、良好な再現結果が得られた。また、入力層の連続観測データの時間的推移を考慮し、多くの学習データを蓄積することによって予測精度の向上が期待された。

参考文献 齊藤ら (1998): ニューラルネットワークによる水道原水の水質予測, EICA, 3(1), 49-54.
八名ら (1992): ニューロ情報処理技術 基礎と応用, 海文堂出版, 21-71.

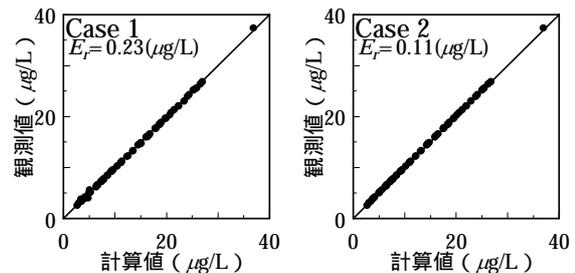


Fig. 2 Scatter plots comparing observed with calculated Chl. a

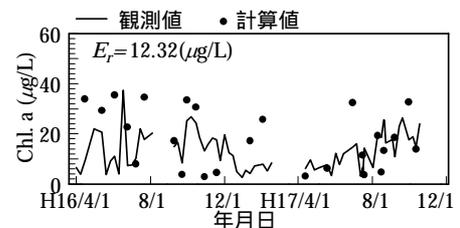


Fig. 3 Predicted results of Case 2

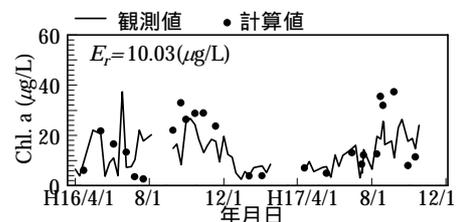


Fig. 4 Predicted results of Case 3