

カオスリカレントニューラルネットワークによるクロロフィル a 時系列の短期予測

Short-term Prediction of Chlorophyll-a Time Series using Recurrent Neural Network with Periodic Chaos Neurons

○原田 昌佳^{*}・堂馬 彰史^{**}・平松 和昭^{*}・丸居 篤^{***}
 Masayoshi Harada^{*}, Akifumi Douma^{**}, Kazuaki Hiramatsu^{*} and Atsushi Marui^{***}

1. はじめに

近年の計測技術の高度化により、クロロフィル a 濃度（以下、Chl.a）の現地計測手法が開発され、短いタイムスケールでのデータ集録が可能となった。このような時系列データは、富栄養化水域を対象とした水環境の解析・予測において重要な知見を与える。原田ら（2011）は、連続観測データに基づいたカオスリカレントニューラルネットワークによる Chl.a の短期予測手法を提案した。本報告では、wavelet 解析を援用した観測ノイズの処理により予測精度の向上を図り、本予測手法の有効性を検討した。

2. 対象池と連続観測データの概要

対象池は水面積約 19,300m²、平均水深約 3.5m、総貯水量約 54,200m³ の農業用貯水池であり、富栄養化の進行が顕著である。護岸近くの水面付近に設置した多波長励起蛍光光度計（bbe Moldaenke 社製）により、総 Chl.a および藻類綱別 Chl.a（緑藻類、藍藻類、珪藻／渦鞭毛藻類、クリプト藻類）の連続観測（15 分インターバル）を実施した（Fig. 1）。観測期間は 2009 年 5 月～2011 年 12 月であるが、計測器の故障等によりデータ欠損が断続的にあるため、時系列データを計 8 個の観測ブロックに分割した（Table 1）。

3. Chl.a 時系列の短期予測

総 Chl.a の時系列データ x_t を対象に、現時点 t から過去に τ 遅った $(t-\tau)$ 時点までのデータ $x_{t-\tau} \sim x_t$ を入力値とし、 T_{\max} 時点先までの $x_{t+1} \sim x_{t+T_{\max}}$ の短期予測を考えた（Fig. 2）。本研究では、3 階層型リカレントニューラルネットワークによる時系列予測を採用し、さらに学習能力の高さが報告されている周期型カオスニューロンに着目した（Nakagawa, 1995）。原田ら（2011）は、一つの観測ブロックのデータを用いて学習した後、残りの観測ブロックについて予測を行う一連の計算から以下の結果を得た。まず、 $\tau = 24\text{h}$ 、 $T_{\max} = 48\text{h}$ として、リードタイム $T (= 1 \sim T_{\max})$ ごとに計算した Nash-Sutcliffe

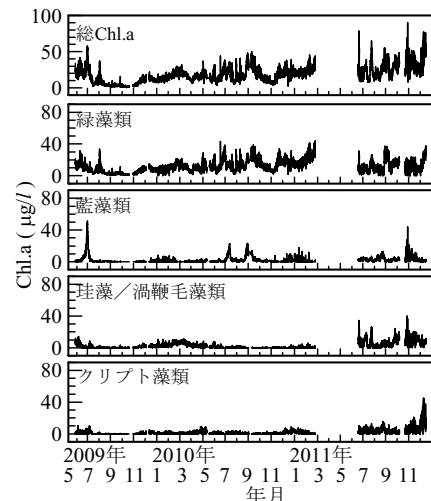


Fig. 1 Continuous observations of Chl.a by a multi-wavelength excitation fluorometer

Table 1 Definition of observation blocks

観測ブロック	期間
1	2009年05月28日～2009年07月21日
2	2009年07月24日～2009年10月04日
3	2009年10月28日～2009年12月02日
4	2009年12月09日～2010年05月11日
5	2010年05月18日～2010年08月30日
6	2010年09月06日～2011年02月23日
7	2011年07月12日～2011年09月26日
8	2011年10月19日～2011年12月13日

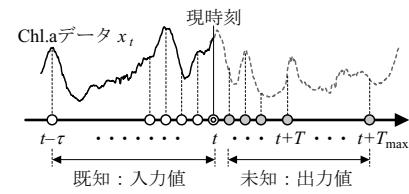


Fig. 2 Outline of short-term prediction

*九州大学大学院農学研究院/Faculty of Agriculture, Kyushu University
 Development Bureau, Ministry of Agriculture, Forestry and Fisheries
 New Campus Planning Office, Kyushu University

**農林水産省農村振興局/Rural
 ***九州大学新キャンパス計画推進室/New Campus Planning Office, Kyushu University

キーワード：富栄養化、閉鎖性水域、クロロフィル a、時系列予測、ニューラルネットワーク

係数 R^2 を用いて予測精度を評価したところ、 T の増大に伴い R^2 は低下した。また、計算精度として $R^2 \approx 0.7$ 程度を許容し、実用上予測可能な T の最大値として定義した限界リードタイム T_{\lim} を検討した結果、学習や予測の対象となる観測ブロックによって T_{\lim} は 1~12h で変化し、限界リードタイムの向上が課題として挙げられた。そこで本研究では、下記の 2 つの点で予測モデルの改良を図った。

(1) ノイズ処理 時系列データに含まれる観測ノイズの処理による予測精度の向上を検討した。具体的には、1h タイムステップの時系列データに対して $\tau = 32h$, $T_{\max} = 32h$ と設定し、入力データ $x_{t-\tau} \sim x_t$ および学習時の期待出力値 $x_{t+1} \sim x_{t+T_{\max}}$ について高位二つのレベルの wavelet 成分 (2h, 4h 周期の高周波数成分) をカットすることでノイズ処理を行なった。**Fig. 3** は、観測ブロック 4, 5 を対象とした予測計算のうち限界リードタイムに対する結果である。また、緑線はノイズ未処理、赤線はノイズ処理を表し、いずれも観測ブロック 3 のみを用いて学習した結果である。**Fig. 3(1)** のようにノイズ処理による限界リードタイムの向上 ($T_{\lim} : 1h \rightarrow 28h$) が確認されたが、**Fig. 3(2)** ではわずかな改善 ($T_{\lim} : 1h \rightarrow 8h$) にとどまった。

(2) 教師データの補充 教師データ数を増やし、季節に依存する Chl.a の複雑な変動パターンを網羅した教師データによる学習を考えた。上記のノイズ処理を導入する上で、全 8 ブロックのうち、7 ブロックの観測データを用いて学習し、残り 1 つの観測ブロックについて短期予測を行った。観測ブロック 4, 5 の予測結果を **Fig. 3** 中の青線で示すように、 $T_{\max} = 32h$ に対して良好な予測が可能となった。そこで、2h タイムステップの時系列データを用いて $T_{\max} = 64h$ と設定し、限界リードタイムを再検討した。その結果、 $\tau = 64h$ とすることで、計算結果の一例を **Fig. 4** に示すように限界リードタイムは $T_{\lim} = 46 \sim 64h$ と大幅に改善された。

4. おわりに

観測データに基づいた水環境解析手法として、カオスリカレントニューラルネットワークによる Chl.a の短期予測を提案した。Wavelet 解析を援用したノイズ処理の導入や教師データの補充による学習の強化により予測精度は大幅に改善され、実用性の向上が図られた。

参考文献

- 原田昌佳, 平松和昭, 富永貴史, 丸居篤 (2011) : 連続観測データに基づいたクロロフィル a 時系列のリアルタイム予測, 第 92 回農業農村工学会九州支部講演要旨集, pp.60-63.
 Nakagawa, M. (1995): An artificial neuron model with a periodic activation function, *J. Phys. Soc. Jpn.*, **64**(3), pp.1023-1031.

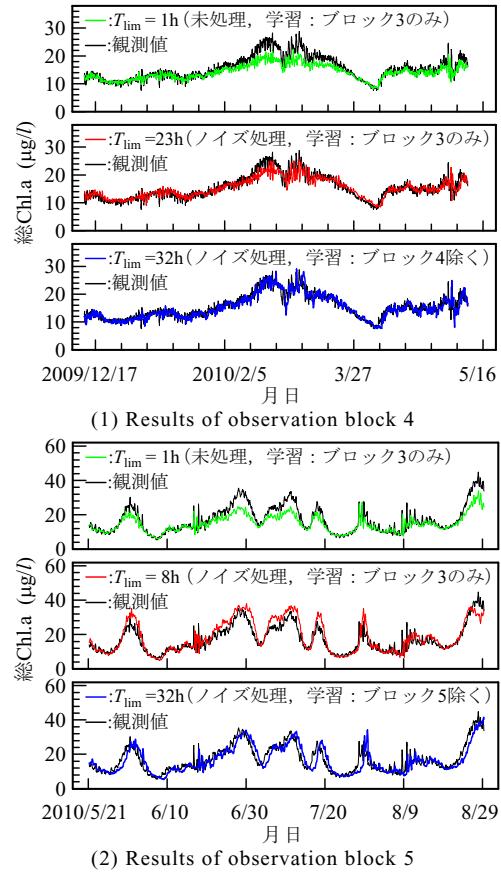


Fig. 3 Examples of prediction results in the case of $\tau = 32h$ and $T_{\max} = 32h$

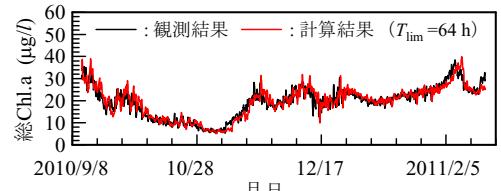


Fig. 4 Prediction results in observation block 6 in the case of $\tau = 64h$ and $T_{\max} = 64h$