

## Estimasi Konsentrasi Klorofil-a menggunakan *Refined Neural Network* (Studi Kasus: Perairan Danau Kasumigaura)

Muhammad Aldila Syariz<sup>a,\*</sup>, Lino Garda Denaro<sup>a</sup>, Salwa Nabilah<sup>a</sup>, Dewinta Heriza<sup>a</sup>, Lalu Muhamad Jaelani<sup>b</sup>, Chao-Hung Lin<sup>a</sup>

<sup>a</sup>Dept. of Geomatics, National Cheng Kung University, Tainan, Taiwan, 70101

<sup>b</sup>Teknik Geomatika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 60111

\* Korespondensi Penulis, E-mail: [aldilasyariz@gmail.com](mailto:aldilasyariz@gmail.com)



Dikirim: 1 Feb 2019;  
Diterima: 15 Feb 2019;  
Diterbitkan: 28 Feb 2019.

**Abstrak.** Klorofil-a menjadi salah satu bagian penting dalam merepresentasikan tingkat kesehatan suatu perairan. Beberapa peneliti menggunakan metode *neural network* untuk mengestimasi konsentrasi klorofil-a di wilayah perairan. Namun, dikarenakan oleh tidak mumpuninya jumlah sampel data pada beberapa stasiun, keakuratan hasil estimasi menjadi kurang dapat dipercaya. *Inverse distance weighting* (IDW) akan digunakan dalam penelitian untuk menginterpolasi konsentrasi klorofil-a di wilayah perairan non stasiun sehingga dapat memperkaya data sampel. Data sampel non stasiun ini selanjutnya digunakan dalam proses training pada *neural network*; dan selanjutnya, data sampel pada stasiun akan digunakan dalam proses *network refinement* sehingga tingkat akurasi dalam mengestimasi konsentrasi klorofil-a menjadi meningkat. Citra MERIS akan digunakan dalam penelitian ini. Berdasarkan hasil analisa statistik, nilai RMSE sebelum dan sesudah *network refinement* menurun dari 6,7872 mg m<sup>-3</sup> menjadi 6,5606 mg m<sup>-3</sup>.

**Kata kunci:** *Neural network, network refinement, IDW, MERIS*

---

### Estimation of Chlorophyll-a Concentration using Refined Neural Network (Case Study: Lake Kasumigaura)

**Abstract.** Chlorophyll-a has been become one of clinical in-water constituents to represent water quality. Many researchers have used neural network method to estimate chlorophyll-a concentration in the water body. However, a few number of water samples limits the use of neural network, meaning that those number is insufficient to train the neural network model and makes the result is not reliable. One of famous interpolation method, that is Inverse Distance Weighting (IDW), is utilized in this study to enrich water samples dataset over non-station points. The data from those non-station points would further be used to train the neural network model. After the training, the neural network method was refined by using the water samples over stations such that the accuracy in chlorophyll-a estimation was increased. MERIS images are used in this study. Based on statistical analysis, RMSE value before and after the refinement is decreased from 6,7872 mg m<sup>-3</sup> to 6,5606 mg m<sup>-3</sup>.

**Keywords:** Neural network, network refinement, IDW, MERIS

## I. PENDAHULUAN

Salah satu hal penting dalam penentuan kesehatan dari perairan danau adalah eutrofikasi [1]. Sebagai salah satu indeks dari eutrofikasi, konsentrasi klorofil-a menjadi indikator utama dalam proses monitoring danau [1],[2]. Maka dari itu, proses estimasi konsentrasi klorofil-a di wilayah perairan menjadi sangat penting sebagai salah satu proses dari monitoring.

Algoritma empiris, yang berbasis pada rasio antara kanal biru dan hijau, sangat sering digunakan oleh beberapa peneliti untuk membangun relasi statistik antara nilai reflektan dengan data lapangan konsentrasi klorofil-a, seperti OC4v4 untuk SeaWiFS dan OC3M untuk MODIS [3], [4]. Namun, pada perairan yang keruh, nilai optik dari suatu citra akan menjadi sangat kompleks sehingga beberapa kesulitan akan terjadi di saat algoritma empiris diaplikasikan [5]–[7].

Dalam beberapa tahun terakhir, *neural network* juga sangat sering digunakan oleh para peneliti karena kemampuannya dalam mengestimasi konsentrasi klorofil-a [1], [2], [5], [8]–[10]. [11] mengestimasi konsentrasi klorofil-a dengan menggunakan citra *Medium Resolution Imaging System* (MERIS) milik *European Space Agency* (ESA). Hasil yang akurat dalam mengestimasi konsentrasi klorofil-a dapat diperoleh saat *neural network* diaplikasikan. Namun, jumlah sampel yang digunakan sangat tidak cukup untuk memberikan hasil yang dapat dipercaya dikarenakan kurangnya proses training dalam *neural network*. [12] mengunduh data simulasi dari *NASA bio-Optical Marine Algorithm Data set* (NOMAD) untuk memperkaya sampel sehingga hasil yang lebih terpercaya bisa diperoleh.

Dalam penelitian ini, 21 data lapangan, 15 data bagian training dan 6 bagian data testing, akan digunakan untuk mengestimasi konsentrasi klorofil-a dengan menggunakan metode *neural network*. Pada tahap *pre-processing*, 21 data lapangan tersebut akan digunakan untuk menginterpolasi konsentrasi klorofil-a pada wilayah perairan non stasiun; sehingga jumlah sampel pada proses training di *neural network* ini menjadi sangat cukup.

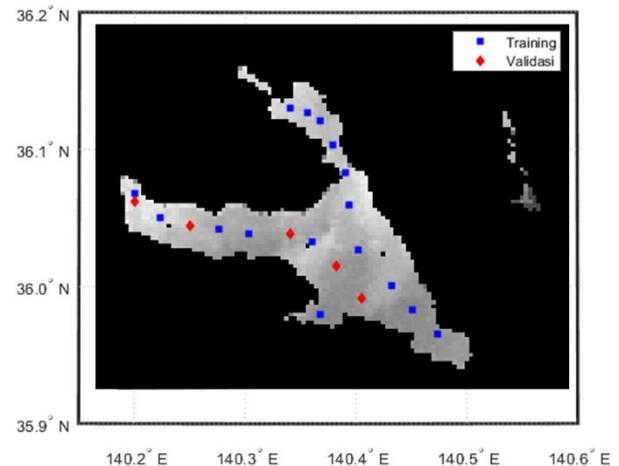
Setelah proses training dengan menggunakan sampel konsentrasi klorofil-a di wilayah perairan non stasiun berhasil dilakukan, proses *network refinement* dengan menggunakan data stasiun akan dilakukan. Hal ini bertujuan untuk memberikan tingkat akurasi yang lebih tinggi dalam mengestimasi nilai klorofil-a dengan menggunakan metode *neural network*.

Area penelitian ini adalah perairan Danau Kasumigaura pada tahun 2010, serta citra MERIS digunakan sebagai data citra pada penelitian ini.

## II. METODOLOGI

### 2.1 Area dan Data Penelitian

Area dalam penelitian ini adalah Danau Kasumigaura, salah satu danau terbesar yang berada di Negara Jepang. Dalam dua atau tiga dekade sebelumnya, Danau Kasumigaura memiliki rata-rata konsentrasi TSM yang meningkat dari 14.1 sampai 26.4 gm-3 dan rata-rata konsentrasi klorofil-a yang menurun dari 87 sampai 61 mg m-3 [13]. Dengan kondisi tersebut, maka Danau Kasumigaura diindikasikan sebagai danau yang keruh.



Gambar 1. Tampak Perairan Danau Kasumigaura menggunakan MERIS Band 5

Sebanyak 21 observasi konsentrasi klorofil-a dari 21 stasiun yang tersebar di Danau Kasumigaura pada tanggal 18 Mei 2010 digunakan dalam penelitian ini. Untuk selanjutnya, 21 observasi ini akan dibagi menjadi dua bagian, yaitu bagian training dan bagian testing dimana bagian training akan digunakan sebagai data untuk membuat algoritma sedangkan bagian testing akan digunakan sebagai penilaian akurasi dari algoritma. Gambar (1) menunjukkan sebaran dari 21 stasiun di Danau Kasumigaura.

Selain itu, data satelit MERIS juga digunakan dalam penelitian ini, dikarenakan waktu pengambilan data yang bertepatan dengan waktu pengambilan data klorofil-a serta kemampuan untuk menganalisa perairan. Namun, pada penelitian ini, 9 kanal dari citra MERIS (dari panjang gelombang 412 sampai 708 nm akan digunakan mengacu pada [11].

### 2.2 Interpolasi Inverse Distance Weigthing (IDW)

IDW adalah salah satu metode interpolasi yang mempertimbangkan jarak dari satu titik terhadap stasiun sehingga apabila jarak tersebut semakin bertambah, efek dari stasiun itu akan berkurang. Hal yang berbeda, yaitu efek dari stasiun akan menguat, akan terjadi ketika jarak tersebut semakin berkurang. Persamaan IDW ditunjukkan dalam persamaan (1) seperti berikut:

$$chla_i = \sum_{j=1}^n W_{ij} * chla_j \quad (1)$$

dimana  $chla_i$  adalah nilai konsentrasi klorofil-a di titik non-stasiun  $i$ ;  $chla_j$  adalah nilai konsentrasi klorofil-a di stasiun  $j$ ; dan  $W_{ij}$  adalah nilai pembobotan dari stasiun  $j$  terhadap titik non-stasiun  $i$ . Penentuan nilai  $W_{ij}$  dapat menggunakan persamaan (2) sebagai berikut:

$$W_{ij} = 1/d_{ij}^p \quad (1)$$

dimana  $d_{ij}$  adalah jarak dari stasiun  $j$  terhadap titik non-stasiun  $i$ ; dan  $p$  adalah nilai pemangkatan dari jarak tersebut. Semakin tinggi nilai  $p$ , maka efek dari stasiun yang dekat akan meningkat dan efek dari stasiun yang jauh akan berkurang.

Konsentrasi klorofil-a di wilayah perairan danau non stasiun diestimasi dengan menggunakan metode interpolasi IDW dari informasi konsentrasi klorofil-a di 21 stasiun. Data estimasi konsentrasi klorofil-a di wilayah perairan danau non stasiun akan digunakan sebagai training dataset dalam aplikasi neural network.

### 2.3 Back-propagation Neural Network

Neural network yang digunakan dalam penelitian ini memiliki 4 layer dimana layer pertama merupakan layer input dengan 9 neuron, layer kedua dan ketiga merupakan hidden layer yang masing-masing memiliki 10 neuron, serta layer keempat adalah layer output dengan satu neuron. Perhitungan setiap nilai neuron ditunjukkan dalam persamaan (3) sebagai berikut:

$$net_j^q = \sum_{i=1}^n w_{ij}^{pq} * x_i^p - \theta_j^q \quad (3)$$

dimana  $x_i^p$  adalah nilai neuron  $i$  pada layer  $p$ ;  $w_{ij}^{pq}$  merupakan nilai bobot pada neuron  $i$  di layer  $p$  terhadap neuron  $j$  di layer  $q$ ;  $\theta_j^q$  merupakan nilai bias pada neuron  $j$  di layer  $q$ .  $net_j^q$  merupakan nilai hasil dari persamaan (3) yang untuk selanjutnya akan digunakan untuk mengestimasi nilai neuron di layer selanjutnya dengan menggunakan persamaan (4) sebagai berikut:

$$x_j^q = 1 / (1 + e^{-net_j^q}) \quad (4)$$

dimana  $x_j^q$  merupakan nilai neuron  $j$  di layer  $q$ . Persamaan (4) selanjutnya akan disebut dengan fungsi aktivasi dengan tipe *sigmoid*.

Desain *neural network* ini akan dilakukan proses training dengan menggunakan nilai konsentrasi klorofil-a di wilayah perairan danau non stasiun. Selanjutnya, nilai klorofil-a di stasiun yang tersebar pada wilayah perairan danau akan digunakan untuk melakukan *network*

*refinement* sehingga desain pembobotan akan mengalami perbaikan (*refined neural network*).

Pada penelitian ini, *neural network* pada penelitian ini memiliki 4 layer (1 layer input, 2 hidden layer, dan 1 layer output) dengan fungsi aktivasi berupa tipe *sigmoid*.

### 2.4 Penilaian Akurasi

Satu metode penilaian akurasi akan digunakan untuk mengetahui tingkat akurasi dari *refined neural network*. Metode tersebut adalah nilai RMSE yang masing masing persamaan ditunjukkan pada persamaan (5) sebagai berikut:

$$RMSE = \sqrt{\sum_{k=1}^n (x^{obs} - x^{nn})^2 / n} \quad (5)$$

dimana  $RMSE$  merupakan nilai RMSE dari hasil observasi lapangan konsentrasi klorofil-a  $x^{obs}$  dengan hasil estimasi konsentrasi klorofil-a menggunakan neural network  $x^{nn}$ .

## III. HASIL DAN PEMBAHASAN

### 3.1 Interpolasi Data Klorofil-a

Nilai konsentrasi klorofil-a di wilayah perairan danau non-stasiun didapatkan dari perhitungan interpolasi dengan menggunakan data stasiun bagian training dan dengan metode IDW. Mengacu pada Tabel (1), terdapat 1553 data konsentrasi klorofil-a yang terekstraksi dengan menggunakan metode interpolasi IDW. Selain itu, nilai rata-rata dan standar deviasi dari data interpolasi konsentrasi klorofil-a di wilayah perairan danau non-stasiun adalah 50,2732 mg m<sup>-3</sup> dan 4,2655 mg m<sup>-3</sup>. Dengan nilai RMSE adalah 10,4230 mg m<sup>-3</sup>, hal ini menunjukkan bahwa estimasi nilai klorofil-a dengan menggunakan metode interpolasi IDW dapat digunakan sebagai data training di proses *neural network*.

TABEL 1. DETIL STATISTIK DARI DATA INTERPOLASI KONSENTRASI Klorofil-A MENGGUNAKAN METODE IDW

Jumlah Data	Rata-rata	Standar deviasi	RMSE
1553	50,2732	4,2655	10,4230

(\*Satuan klorofil-a: mg m<sup>-3</sup>)

### 3.2 Estimasi Nilai Klorofil-a menggunakan Refined Neural Network

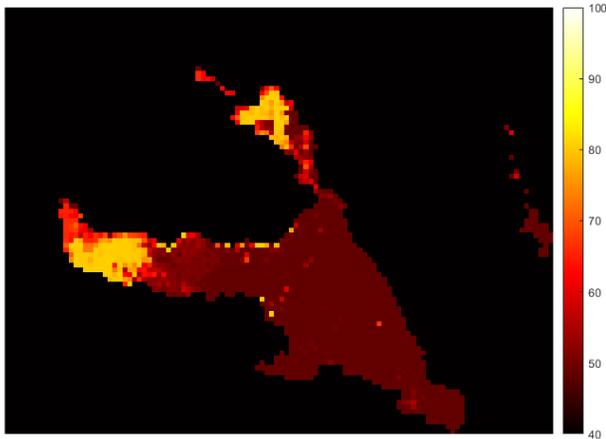
*Network* ini akan dilakukan proses training dengan menggunakan data konsentrasi klorofil-a di wilayah perairan danau non-stasiun yang berjumlah 1553 data. Mengacu pada tabel (2), dengan menggunakan 5 data testing, nilai RMSE yang didapat adalah 6,7872 mg m<sup>-3</sup>. Hal ini mengindikasikan bahwa *neural network* dapat memberikan nilai estimasi konsentrasi klorofil-a dengan cukup akurat.

TABEL 2. ANALISA AKURASI DARI ORDINARY DAN REFINED NEURAL NETWORK

Metode NN	Jumlah Data Training	Jumlah Data Testing	RMSE
Ordinary	1553	5	6,7872
Refined	15		6,5606

(\*Satuan klorofil-a: mg m<sup>-3</sup>)

Selanjutnya, *network* ini akan dilakukan proses training kembali dengan menggunakan 15 data stasiun di wilayah perairan danau. Mengacu pada tabel (2), nilai RMSE menurun sampai di angka 6,5606 mg m<sup>-3</sup>. Penurunan ini sebagai indikasi bahwa proses *refined neural network* dapat memberikan nilai estimasi konsentrasi klorofil-a lebih akurat daripada tingkat akurasi *ordinary neural network*.



Gambar 2. Peta Estimasi Konsentrasi Klorofil-a di Danau Kasumigaura dengan Menggunakan Metode Refined Neural Network

Gambar (2) menunjukkan peta hasil estimasi konsentrasi klorofil-a di wilayah perairan Danau Kasumigaura dengan menggunakan *refined neural network*. Nilai estimasi konsentrasi klorofil-a di Danau Kasumigaura tersebut memiliki rata-rata dan standar deviasi sebesar 53,6087 mg m<sup>-3</sup> dan 10,1253 mg m<sup>-3</sup>, seperti yang ditunjukkan pada Tabel (3).

TABEL 3. DETIL STATISTIK DARI DATA ESTIMASI KONSENTRASI KLOROFIL-A MENGGUNAKAN METODE REFINED NEURAL NETWORK

Jumlah Data	Rata-rata	Standar deviasi
1572	53,6087	10,1253

(\*Satuan klorofil-a: mg m<sup>-3</sup>)

#### IV. KESIMPULAN

Interpolasi dengan menggunakan metode IDW sangat dibutuhkan dalam memperkaya informasi data konsentrasi klorofil-a yang dapat digunakan sebagai data training di

proses training pada *neural network*. Dengan adanya data interpolasi ini, desain *neural network* yang sudah ditentukan sebelumnya, dapat mengestimasi konsentrasi klorofil-a dengan cukup akurat. Hal ini dapat dilihat pada nilai RMSE yang cukup kecil, yaitu 6,7872 mg m<sup>-3</sup>. Proses *refinement* terhadap *neural network* juga dapat memberikan perbaikan akurasi dari estimasi konsentrasi klorofil-a di Danau Kasumigaura. Dengan menggunakan 21 data stasiun, nilai RMSE semakin mengecil sampai pada angka 6,5606 mg m<sup>-3</sup>. Hal ini mengindikasikan bahwa proses *refinement* memberikan efek perbaikan pada desain *neural network* sehingga dapat memberikan akurasi yang lebih baik dalam mengestimasi konsentrasi klorofil-a.

#### DAFTAR PUSTAKA

- [1] X. Li, J. Sha, and Z. L. Wang, "Chlorophyll-A Prediction of lakes with different water quality patterns in China based on hybrid neural networks," *Water (Switzerland)*, vol. 9, no. 7, 2017.
- [2] R. Samli, N. Sivri, S. Sevgen, and V. Z. Kiremitci, "Applying artificial neural networks for the estimation of chlorophyll-a concentrations along the Istanbul coast," *Polish J. Environ. Stud.*, vol. 23, no. 4, pp. 1281–1287, 2014.
- [3] J. E. O'Reilly, S. Maritorena, D. A. Siegel, S. A. Garver, M. Kahru, and C. R. McClain, "Ocean chlorophyll algorithms for SeaWiFS," *J. Geophys. Res.*, vol. 103, no. C11, pp. 24937–24953, 1998.
- [4] V. M. T. Garcia, S. Signorini, C. A. E. Garcia, and C. R. McClain, "Empirical and semi-analytical chlorophyll algorithms in the south-western Atlantic coastal region (25-40°S and 60-45°W)," *Int. J. Remote Sens.*, vol. 27, no. 8, pp. 1539–1562, 2006.
- [5] Y. S. Kown *et al.*, "Monitoring coastal chlorophyll-a concentrations in coastal areas using machine learning models," *Water (Switzerland)*, vol. 10, no. 8, pp. 1–17, 2018.
- [6] Y. H. Ahn and P. Shanmugam, "Detecting the red tide algal blooms from satellite ocean color observations in optically complex Northeast-Asia Coastal waters," *Remote Sens. Environ.*, vol. 103, no. 4, pp. 419–437, 2006.
- [7] W. D. L., S. R. P., S. J. A., and P. H. W., "Remote Estimation of Water Clarity in Optically Complex Estuarine Waters," *Remote Sens. Environ.*, vol. 68, no. 98, p. 41, 1999.
- [8] Y. Zhang, S. S. Koponen, J. T. Pulliainen, and M. T. Hallikainen, "Application of empirical

- neural networks to chlorophyll-a estimation in coastal waters using remote optosensors,” *IEEE Sens. J.*, vol. 3, no. 4, pp. 376–382, 2003.
- [9] H. S. Yi, S. Park, K. G. An, and K. C. Kwak, “Algal bloom prediction using extreme learning machine models at artificial weirs in the nakdong river, Korea,” *Int. J. Environ. Res. Public Health*, vol. 15, no. 10, 2018.
- [10] B. Vinçon-Leite and C. Casenave, “Modelling eutrophication in lake ecosystems: A review,” *Sci. Total Environ.*, vol. 651, pp. 2985–3001, 2019.
- [11] L. González Vilas, E. Spyarakos, and J. M. Torres Palenzuela, “Neural network estimation of chlorophyll a from MERIS full resolution data for the coastal waters of Galician rias (NW Spain),” *Remote Sens. Environ.*, vol. 115, no. 2, pp. 524–535, 2011.
- [12] I. Ioannou, A. Gilerson, B. Gross, F. Moshary, and S. Ahmed, “Deriving ocean color products using neural networks,” *Remote Sens. Environ.*, vol. 134, pp. 78–91, 2013.
- [13] L. M. Jaelani, B. Matsushita, W. Yang, and T. Fukushima, “Evaluation of four MERIS atmospheric correction algorithms in Lake Kasumigaura, Japan,” *Int. J. Remote Sens.*, vol. 34, no. 24, pp. 8967–8985, 2013.