

Pemetaan Transparansi Air di Waduk Saguling dengan Menggunakan ANN dan Landsat 8

Azzahra Magfhira¹, Prayatni Soewondo^{2*}, Winda Wijayasari³, FIW. Rohmat³

¹Magister Teknik Lingkungan, Fakultas Teknik Sipil dan Lingkungan, Institut Teknologi Bandung, Indonesia

²Teknik Lingkungan, Fakultas Teknik Sipil dan Lingkungan, Institut Teknologi Bandung, Indonesia

³Pusat Pengembangan Sumber Daya Air, Institut Teknologi Bandung, Indonesia

*Koresponden email: prayatnisoe@yahoo.com

Diterima: 20 Juni 2025

Disetujui: 01 Juni 2025

Abstract

The decline in water transparency in the Saguling Reservoir indicates deteriorating water quality due to increasing pollutant loads from domestic, industrial, agricultural, and aquaculture activities. This study aims to predict water transparency using an ANN model, integrating remote sensing data from Landsat 8 (2013-2024) and in-situ measurements from 12 sampling points. The analysis began with correlation tests, which revealed weak to moderate relationships between transparency and other variables. Subsequent simple and multiple linear and logistic regression analyses produced weak correlations, with the highest R^2 of 0.1853 observed in multiple logistic regression. The Random Forest algorithm was applied to identify the most influential variables. The selected predictors included Bands 3, 4, 5, and 7, as well as temperature, EC, and TSS. These variables were used as inputs for the ANN model, which demonstrated high performance with an R^2 of 0.8514, explaining 85.14% of the variability in water transparency. The prediction results were visualized in a distribution map, indicating a predominance of transparency class IV (0-2.5 m) across the reservoir. This suggests limited light penetration due to high pollutant loads. The study shows that integrating remote sensing and ML enables effective large-scale water quality monitoring and supports sustainable water resource management.

Keywords: *artificial neural network (ann), remote sensing, machine learning, transparency, Saguling Reservoir*

Abstrak

Penurunan transparansi air di Waduk Saguling merupakan indikator penurunan kualitas perairan akibat peningkatan beban pencemar dari aktifitas domestik, industri, pertanian, dan budidaya perikanan. Penelitian ini bertujuan untuk memprediksi nilai transparansi air di Waduk Saguling menggunakan *Artificial Neural Network* (ANN) dengan integrasi data penginderaan jauh Landsat 8 (2013-2024) dan data in-situ dari 12 titik sampel. Tahapan analisis dimulai dengan uji korelasi yang menunjukkan hubungan lemah hingga sedang antara transparansi dengan variabel lainnya. Selanjutnya, dilakukan uji regresi linear dan logistik, baik sederhana maupun berganda, yang menunjukkan nilai R^2 tertinggi sebesar 0,1853 pada regresi logistik berganda. Algoritma *Random Forest* digunakan untuk menyeleksi variabel. Hasilnya diperoleh Band 3, Band 4, Band 5, Band 7, suhu, DHL, dan TSS sebagai variabel yang paling berpengaruh. Variabel-variabel tersebut digunakan sebagai input pada model ANN. Performa yang dihasilkan cukup tinggi dengan nilai R^2 sebesar 0,8514, mampu menjelaskan 85,14% variabilitas transparansi air. Hasil prediksi divisualisasikan dalam peta sebaran, yang menunjukkan dominasi kelas IV (0-2,5 m) di seluruh area Waduk Saguling, menandakan rendahnya transparansi secara merata. Transparansi rendah menunjukkan minimnya penetrasi cahaya akibat tingginya beban pencemar. Penelitian ini membuktikan bahwa integrasi data penginderaan jauh dan ML efektif untuk pemantauan kualitas air skala besar, dan menjadi dasar pengelolaan sumber daya air yang lebih berkelanjutan.

Kata Kunci: *jarangan saraf tiruan, penginderaan jauh, kecerdasan buatan, transparansi, waduk saguling*

1. Pendahuluan

Waduk Saguling merupakan salah satu infrastruktur sumber daya air yang memiliki fungsi strategis dalam skala nasional, tidak hanya sebagai penyedia energi listrik, tetapi juga untuk keperluan irigasi, perikanan dan air baku domestik [1]. Keberlanjutan fungsi-fungsi Waduk Saguling sangat bergantung pada kualitas air waduk yang semakin terancam akibat meningkatnya tekanan antropogenik di sekitarnya. Salah satu parameter utama dalam penilaian kualitas air adalah transparansi air, yang mencerminkan kedalaman penetrasi cahaya sebelum tersebar atau diserap oleh partikel tersuspensi di dalam air [2], [3].

Transparansi air berperan penting dalam pengaturan proses biogeokimia seperti fotosintesis, pertumbuhan fitoplankton, dan keseimbangan suhu [4]. Rendahnya nilai transparansi sering dikaitkan dengan masuknya bahan tersuspensi ke dalam perairan akibat aktifitas antropogenik di sekitar daerah tangkapan air seperti pemukiman, pertanian, industri, dan budidaya ikan [5], [6]. Penurunan transparansi tidak hanya berdampak pada kualitas ekologi perairan, tetapi juga mengganggu keberlanjutan fungsi ekonomi waduk dalam jangka panjang.

Pemantauan transparansi air secara rutin menjadi penting untuk mendeteksi perubahan kualitas air dan mendukung pengambilan keputusan dalam pengelolaan sumber daya air. Metode konvensional memiliki keunggulan dalam memberikan hasil yang akurat, terutama karena dinamika kualitas air dapat berubah dengan cepat dan bervariasi secara spasial [7]. Namun, metode pemantauan konvensional dengan cara pengambilan sampel secara langsung dan analisis laboratorium memiliki keterbatasan dalam cakupan spasial dan frekuensi waktu pengukuran [8], [9]. Hal tersebut menjadi tantangan tersendiri untuk ekosistem perairan berskala besar seperti Waduk Saguling.

Teknologi penginderaan jauh telah berkembang pesat sebagai pendekatan alternatif yang menawarkan cakupan spasial dan temporal yang lebih luas dalam pemantauan kualitas air [10]. Citra satelit bekerja dengan merekam reflektansi permukaan air dalam berbagai spektrum elektromagnetik, yang mencerminkan kondisi optik perairan [11]. Citra satelit Landsat 8 dilengkapi dengan sensor *Operational Land Imager* (OLI) yang mampu merekam data reflektansi permukaan air dalam spektrum elektromagnetik resolusi spasial 30 meter dan temporal 16 hari [12]. Reflektansi spektral tersebut berpotensi untuk digunakan dalam estimasi transparansi air [13]. Namun, hubungan antara data reflektansi dan parameter kualitas air bersifat kompleks dan tidak linier, sehingga pendekatan statistik konvensional cenderung kurang mampu mengakomodasi kompleksitas tersebut.

Pendekatan berbasis *Machine Learning* (ML) mulai banyak diterapkan dalam studi kualitas air. Khususnya model *Artificial Neural Network* (ANN) dan *Random Forest* (RF) karena mampu menangkap hubungan non-linier dan multidimensional antar variabel. Pada penelitian sebelumnya [14], [15], [16], ANN telah terbukti memiliki akurasi tinggi dalam memprediksi kualitas air dengan capaian nilai R^2 mencapai lebih dari 0,70. Di sisi lain metode RF efektif dalam mengidentifikasi variabel-variabel penting dan kombinasi band spektral yang paling berpengaruh terhadap parameter yang diamati [17].

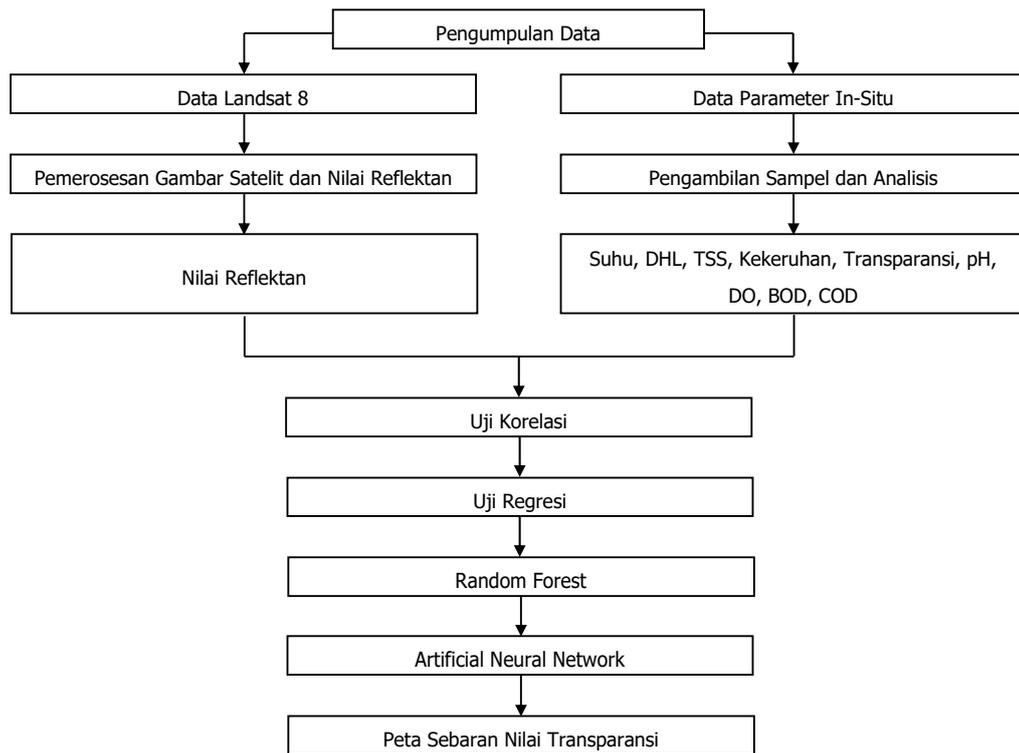
Kemajuan penginderaan jauh dan ML dapat mendukung penelitian dalam mengembangkan model prediksi transparansi air di Waduk Saguling melalui integrasi data citra satelit dan parameter fisik-kimia in-situ. Meskipun ML telah digunakan dalam berbagai studi kualitas air, penerapannya pada waduk tropis dengan tekanan antropogenik tinggi masih terbatas. Studi ini mengevaluasi performa ANN dan RF dalam mengestimasi nilai transparansi serta mengidentifikasi faktor-faktor utama yang memengaruhinya, sebagai dasar untuk mendukung pemantauan dan pengelolaan kualitas air yang lebih efisien dan berkelanjutan.

2. Metode Penelitian

2.1 Lokasi Penelitian dan Pengambilan Sampel

Penelitian dilaksanakan di Waduk Saguling yang terletak di wilayah Kabupaten Bandung Barat, Provinsi Jawa Barat, Indonesia yang secara geografis terletak di 6°54'45" Lintang Selatan – 107°21'58" Bujur Timur (**Gambar 1**) dengan luas 5.606 hektar dan digunakan secara massif sebagai pembangkit tenaga Listrik.

Pada penelitian ini dilakukan pengambilan sampel di 12 lokasi yang merepresentasikan variasi spasial kualitas perairan Waduk Saguling. Pengambilan sampel dilakukan dengan menggunakan metode *grab sampling* yang mengacu pada SNI 6989.57:2008 tentang Metoda Pengambilan Contoh Air Permukaan. Data yang diperoleh berupa suhu, pH, DHL, DO, kekeruhan, dan transparansi diukur langsung di lapangan, sedangkan parameter *Total Suspended Solids* (TSS), *Biochemical Oxygen Demand* (BOD), dan *Chemical Oxygen Demand* (COD) dianalisis di Laboratorium Kualitas Air, Program Studi Teknik Lingkungan, Institut Teknologi Bandung.



Gambar 2. Metode penelitian

2.3 Uji Korelasi

Uji korelasi dilakukan sebagai analisis awal dengan metode Spearman untuk mengevaluasi kekuatan hubungan antara parameter spektral dan parameter kualitas air terhadap transparansi. Persamaan yang digunakan terdapat pada persamaan 1 [19].

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2-1)} \quad (1)$$

dimana:

r_s = Koefisien korelasi peringkat Spearman

d_i = Perbedaan antara peringkat untuk pasangan nilai dari 2 (dua) variabel yang dibandingkan

n = Jumlah observasi atau pengamatan dalam sampel yang digunakan

Rentang nilai r_s berada pada +1 hingga -1 yang menunjukkan korelasi positif sempurna hingga negatif yang sempurna, seperti pada **Tabel 1** berikut [20].

Tabel 1. Koefisien korelasi peringkat Spearman

Koefisien Korelasi Peringkat Spearman (r_s)	Tingkat Korelasi
$0,80 \leq r_s \leq 1,0$	Sangat Kuat
$0,60 \leq r_s \leq 0,79$	Kuat
$0,40 \leq r_s \leq 0,59$	Sedang
$0,20 \leq r_s \leq 0,39$	Lemah
$0,00 \leq r_s \leq 0,19$	Sangat Lemah

2.4 Uji Regresi

2.4.1 Regresi Linear dan Logistik Sederhana

Regresi linear mempelajari pola data dari kumpulan data pelatihan untuk menggambarkan hubungan antara transparansi (Y_i) sebagai fungsi linear dari satu parameter spektral (X_i) [21]. Sementara itu, regresi logistik menganalisis pengaruh parameter spektral (X_i) terhadap probabilitas transparansi (Y_i) berada dalam kategori tertentu, seperti tinggi atau rendah [22]. Persamaan umum kedua metode ditunjukkan pada persamaan 2 [21] dan 3 [22].

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon \quad (2)$$

dimana:

- Y_i = Variabel dependen (transparansi)
- X_i = Variabel independen (parameter spektral)
- β_0 = Konstanta (*intercept*)
- β_1 = Koefisien regresi
- ε = Galat

$$\ln\left(\frac{Y}{1-Y}\right) = \beta_0 + \beta_1 X_i \quad (3)$$

dimana:

- Y = Probabilitas pada kategori transparansi tertentu
- X_i = Variabel independen (parameter spektral)
- β_0 = Konstanta (*intercept*)
- β_1 = Koefisien regresi

2.4.2 Regresi Linear dan Logistik Berganda

Regresi linear berganda adalah model statistik yang digunakan untuk memprediksi hubungan antara variabel dependen (Y_i) yaitu transparansi, berdasarkan 2 (dua) atau lebih variabel independen (X_i) yaitu parameter spektral [23], [24]. Sementara itu, regresi logistik berganda menganalisis pengaruh 2 (dua) atau lebih variabel independen (X_i), yaitu parameter spektral, terhadap probabilitas variabel dependen (Y_i), yaitu transparansi yang dikategorikan sebagai rendah atau tinggi [25]. Selain itu, dalam model regresi, setiap variabel independen memiliki koefisien regresi (β) yang menunjukkan besarnya pengaruh variabel tersebut terhadap transparansi air. Persamaan umum dari regresi linear dan logistik berganda dinyatakan pada persamaan 4 [24] dan 5 [25].

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (4)$$

dimana:

- Y_i = Variabel dependen (transparansi)
- X_i = Variabel independen (parameter spektral)
- β_0 = Konstanta (*intercept*)
- $\beta_{1,2,p}$ = Koefisien regresi
- ε_i = Galat

$$\ln\left(\frac{Y}{1-Y}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_i X_i \quad (5)$$

dimana:

- Y = Probabilitas pada kategori transparansi tertentu
- X_i = Variabel independen (parameter spektral)
- β_0 = Konstanta (*intercept*)
- $\beta_{1,2,i}$ = Koefisien regresi

2.5 Random Forest

Random Forest (RF) adalah algoritma yang membangun beberapa pohon keputusan pada sampel data yang berbeda, di mana setiap pohon memisahkan data berdasarkan kondisi yang dibentuk dalam struktur bercabang, kemudian hasil akhir ditentukan berdasarkan suara mayoritas [17]. Dalam penelitian ini, fungsi dari *random forest* yang digunakan adalah *feature importance* untuk mengetahui variabel spektral dan parameter kualitas air yang memiliki tingkat kontribusi paling tinggi terhadap model prediksi transparansi air. Metode yang digunakan dalam *feature importance* adalah *mean decrease in accuracy* (MDA) yang mengukur penurunan akurasi saat nilai dari parameter tertentu diacak secara acak [17]. Persamaan umum dari MDA dinyatakan pada persamaan 6 [17].

$$MDA_j = err^{perm} - err^{orig} \quad (6)$$

dimana:

- err^{perm} = Kesalahan model asli
- err^{orig} = Kesalahan yang diperoleh setelah mengubah urutan nilai parameter tertentu

2.6 Artificial Neural Network

Artificial Neural Network (ANN) adalah sistem komputasi yang meniru cara kerja jaringan saraf biologis dalam memproses informasi dengan kemampuan unik untuk mempelajari pola non-linear yang kompleks dari data [26]. ANN memiliki keunggulan dalam menangkap hubungan kompleks yang sulit

untuk dimodelkan dengan metode statistik sederhana, sehingga sering digunakan dalam berbagai bidang, termasuk pemodelan lingkungan [27].

Penggunaan ANN dalam bidang lingkungan telah banyak diterapkan, terutama dalam pemantauan dan prediksi kualitas air. Berdasarkan beberapa penelitian yang telah dilakukan, ditunjukkan bahwa ANN mampu mengolah data dari sumber yang beragam, seperti data satelit dan data in-situ untuk memprediksi parameter kualitas air dengan akurasi tinggi. ANN telah digunakan untuk memprediksi transparansi [3], [14], [28], kekeruhan [29], [30], total fosfat [26], [28], Chl-a [28], [30], dan TDS [15], [30]. Hal ini membuktikan bahwa penerapan ANN bermanfaat dalam pengelolaan lingkungan seperti deteksi dini pencemaran perairan, optimalisasi pengelolaan waduk, dan pendukung kebijakan pengelolaan kualitas air.

Input yang digunakan pada model ANN adalah variabel penting yang berasal dari hasil seleksi *feature importance* pada algoritma RF. Selanjutnya, dilakukan normalisasi data dengan menggunakan metode *Min-Max Normalization* untuk mengonversi data ke dalam skala 0 – 1. Normalisasi ini bertujuan untuk meningkatkan efisiensi proses komputasi, mempercepat konvergensi model, dan memastikan ANN dapat mengolah data dengan rentang yang lebih seragam. Kemudian, data dibagi menjadi 2 (dua) kelompok, yaitu data *training* (70%) untuk memastikan bahwa model dapat belajar dengan baik, dan data *testing* (30%) untuk mengevaluasi akurasi prediksi model [23]. *Output* dari pemodelan ANN dihasilkan melalui persamaan 7 [31].

$$y = f(x) = \sum_{i=1}^n W_i X_i \quad (7)$$

dimana:

y = Nilai output

W = *Weight*

X = *Input*

i = W dan X berada pada layer yang sama

Kinerja model ANN yang dirancang dievaluasi dengan mempertimbangkan koefisien korelasi sebagai ukuran hubungan antara nilai prediksi dan nilai aktual berdasarkan koefisien determinasi (R^2) yang menyatakan variasi transparansi (persamaan 8), *Mean Absolute Error* (MAE) yang menyatakan rata-rata kesalahan absolut (persamaan 9), dan *Mean Squared Error* (MSE) yang menyatakan tingkat error kuadrat dari model (persamaan 10) [32], [33].

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (8)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (9)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (10)$$

dimana:

y_i = Nilai aktual

\hat{y}_i = Nilai prediksi dari model

\bar{y}_i = Nilai rata-rata dari data aktual

n = Jumlah sampel

Hasil prediksi transparansi dari ANN kemudian divisualisasikan dalam bentuk peta sebaran yang disusun menggunakan perangkat lunak QGIS dengan menerapkan metode *Inverse Distance Weighted* (IDW) *Interpolation*. Selanjutnya, nilai transparansi pada peta tersebut diklasifikasikan ke dalam beberapa kelas berdasarkan baku mutu transparansi air dalam Lampiran VI Peraturan Pemerintah Nomor 22 Tahun 2021 tentang Penyelenggaraan Perlindungan dan Pengelolaan Lingkungan Hidup [34], seperti yang terdapat pada **Tabel 2** berikut.

Tabel 2. Klasifikasi kelas transparansi

Konsentrasi (m)	Kelas
0 - 2.5	IV
2.5 - 4	III
4 - 10	II
> 10	I

Klasifikasi kelas transparansi pada **Tabel 2** menggambarkan kondisi lingkungan perairan danau serta potensinya dalam mendukung ekosistem akuatik dan pemanfaatan air [34]. Kelas IV (0-2,5 m) menunjukkan transparansi rendah akibat tingginya kekeruhan dari aktifitas domestik, pertanian, industri, dan budidaya ikan, yang menghambat penetrasi cahaya, menurunkan kadar oksigen terlarut, dan menimbulkan stres pada biota; perairan ini digunakan untuk irigasi dan keperluan yang tidak memerlukan mutu tinggi. Kelas III (2,5-4 m) mencerminkan transparansi sedang dengan konsentrasi zat tersuspensi yang masih tinggi namun memungkinkan fotosintesis, dipengaruhi oleh musim, curah hujan, dan aktifitas manusia; dimanfaatkan untuk budidaya ikan, peternakan, dan irigasi. Kelas II (4-10 m) menunjukkan transparansi tinggi dengan penetrasi cahaya optimal dan pencemaran terkendali, mendukung ekosistem dan cocok untuk rekreasi, budidaya, dan irigasi. Kelas I (>10 m) menggambarkan mutu air sangat baik dan pencemaran minimal, sesuai untuk air baku minum, meskipun transparansi yang terlalu tinggi dapat menunjukkan rendahnya nutrisi dan produktivitas biologis.

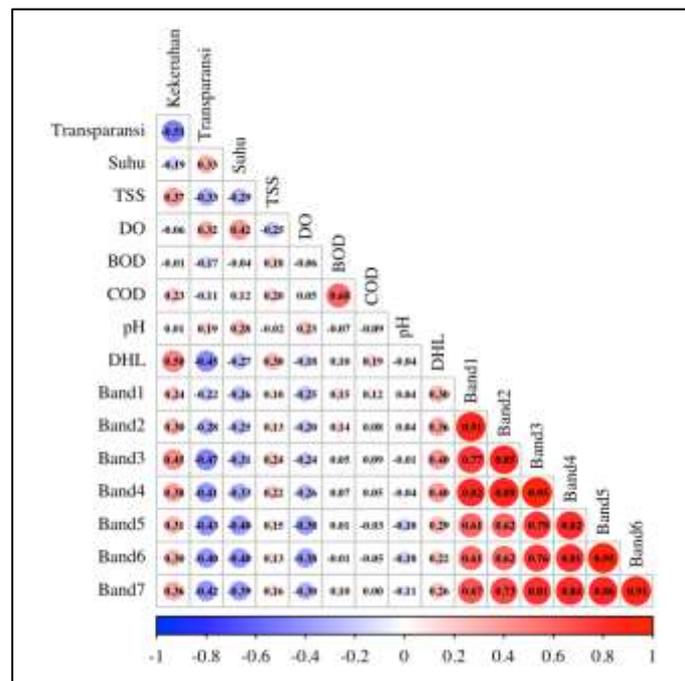
3. Hasil dan Pembahasan

3.1 Uji Korelasi

Gambar 3 menunjukkan hasil uji korelasi Spearman yang menggambarkan kekuatan hubungan antara parameter spektral dan parameter kualitas air terhadap transparansi. Pada Gambar 3 diketahui bahwa korelasi antara parameter spektral dan transparansi bersifat negatif dengan r_s berkisar antara -0,22 hingga -0,47 yang berada dalam kategori lemah hingga sedang, dimana Band 3 memiliki korelasi negatif tertinggi dengan $r_s = -0,47$, diikuti oleh Band 5 dengan $r_s = -0,43$, dan diakhiri oleh Band 1 dengan $r_s = -0,22$. Hal ini mencerminkan bahwa peningkatan transparansi menurunkan intensitas pantulan cahaya.

Selain parameter spektral, parameter kualitas air DHL dan TSS juga memiliki korelasi terhadap transparansi. DHL memiliki korelasi negatif sedang terhadap transparansi dengan $r_s = -0,45$ yang mencerminkan muatan ionik air yang dipengaruhi oleh sedimen limbah, sehingga memperburuk kondisi optik air. Sementara itu, TSS memiliki korelasi negatif lemah dengan $r_s = -0,33$ yang mencerminkan bahwa jumlah partikel padat yang berada dalam kolom air dapat menurunkan transparansi. Parameter kualitas air lainnya, seperti suhu, DO, BOD, COD, dan pH menunjukkan korelasi lemah hingga sangat lemah dengan $-0,17 \leq r_s \leq 0,33$ terhadap transparansi karena tidak berkontribusi secara langsung terhadap kondisi optik air yang dapat direkam oleh sensor satelit.

Meski demikian korelasi tertinggi antara band spektral dengan parameter air terdapat pada antara Band 3 dengan TSS yaitu 0,49 dan Band 4 dengan TSS yaitu 0,48 (**Gambar 3**).



Gambar 3. Hasil uji korelasi

3.2 Uji Regresi

Input pada model regresi adalah Landsat 8 dengan nilai reflektansi spektral Band 1 hingga Band 7. Parameter kualitas air hasil pengukuran lapangan tidak digunakan dalam model regresi karena keterbatasan dalam mengintegrasikan variabel heterogen. Meskipun penggabungan data citra satelit seperti panjang gelombang Band dan data kualitas air seperti suhu dalam °C dan TSS dalam mg/L secara teori memungkinkan, tetapi pada pelaksanaannya hal tersebut sulit karena jenis data tidak sebanding dan perlu transformasi atau normalisasi untuk dapat dibandingkan. Variabel reflektansi citra satelit bersifat radiometrik dan kontinu dalam rentang nilai normalisasi tertentu, sedangkan parameter kualitas air memiliki skala, unit, dan distribusi yang tidak homogen. Oleh karena itu, model regresi tidak mampu menyatukan variabel-variabel yang berasal dari domain spektral dan parameter kualitas air secara bersamaan tanpa mempengaruhi validitas model.

Model regresi dievaluasi berdasarkan nilai koefisien determinasi (R^2) (persamaan 8), MAE (persamaan 9), MSE (persamaan 10) dan persamaan Y untuk menentukan seberapa baik masing-masing model menjelaskan variasi transparansi, seperti yang tertera pada **Tabel 3** berikut.

Tabel 3. Hasil uji regresi transparansi

Model Regresi	R^2	MAE	MSE	Persamaan
Linear Sederhana	0,1255	0,038	0,0052	$Y = 0,1295 - 0,1472 \times X$
Logistik Sederhana	0,1240	0,0086	0,0043	$\text{logit}(P) = 0,8471 - 5,2666 \times X$
Linear Berganda	0,1552	0,0362	0,0050	$Y = 0,1229 + 0,1108 \times X_1 + 0,0872 \times X_2 - 0,113 \times X_3 - 0,0796 \times X_4 - 0,0011 \times X_5 - 0,0147 \times X_6 - 0,1618 \times X_7$
Logistik Berganda	0,1853	0,0086	0,0043	$\text{logit}(P) = 0,9472 + 2,2149 \times X_1 + 16,9993 \times X_2 - 50,9544 \times X_3 + 9,62 \times X_4 + 2,2286 \times X_5 - 1,206 \times X_6 - 6,3566 \times X_7$

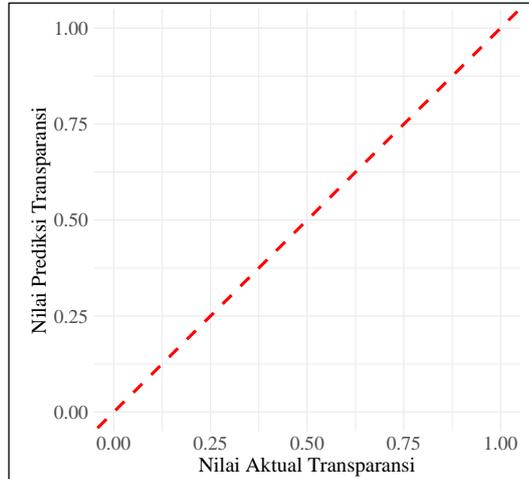
Berdasarkan hasil uji regresi transparansi yang disajikan pada **Tabel 3**, diketahui bahwa model regresi linear sederhana menunjukkan nilai R^2 sebesar 0,1255 yang mengindikasikan bahwa hanya 12,55% variasi transparansi dapat dijelaskan oleh variabel independen yaitu parameter spektral. Nilai MAE sebesar 0,038 menunjukkan rata-rata kesalahan absolut yang relatif kecil, sedangkan MSE sebesar 0,0052 menandakan tingkat *error* kuadrat dari model. Persamaan regresi yang diperoleh menunjukkan hubungan negatif antara variabel independen dengan transparansi. Namun, rendahnya nilai R^2 menandakan bahwa model linear kurang dapat menangkap kompleksitas hubungan antara variabel.

Selanjutnya, model regresi logistik sederhana memiliki nilai R^2 sebesar 0,1240 yang mampu menjelaskan 12,40% variasi transparansi. Nilai MAE sebesar 0,0086 dan MSE sebesar 0,0043 menunjukkan tingkat kesalahan prediksi yang relatif rendah. Persamaan regresi logistik sederhana yang diperoleh menunjukkan hubungan negatif antara parameter spektral dengan probabilitas kategori transparansi. Meskipun demikian, rendahnya nilai R^2 menunjukkan keterbatasan model dalam menangkap pola hubungan antarvariabel secara komprehensif.

Model regresi linear berganda menunjukkan peningkatan performa dibanding model regresi linear sederhana, dengan nilai R^2 sebesar 0,1552. Nilai ini menunjukkan bahwa sebesar 15,52% variasi transparansi dapat dijelaskan oleh kombinasi variabel independen, yaitu parameter spektral Band 1 hingga Band 7. Selain itu, nilai MAE sebesar 0,0362 dan MSE sebesar 0,0050 menunjukkan rata-rata kesalahan absolut dan error kuadrat yang lebih rendah dibandingkan regresi linear sederhana dan logistik sederhana. Hasil ini menunjukkan bahwa kombinasi beberapa parameter spektral lebih efektif dalam memprediksi transparansi dibandingkan penggunaan satu parameter tunggal, meskipun peningkatan nilai R^2 masih relatif rendah.

Sementara itu, model regresi logistik berganda menunjukkan performa terbaik di antara seluruh model regresi yang diuji, dengan nilai R^2 sebesar 0,853. Hal ini menunjukkan bahwa model ini mampu menjelaskan sebesar 85,3% variasi transparansi berdasarkan kombinasi parameter spektral Band 1 hingga Band 7. Nilai MAE sebesar 0,0066 dan MSE sebesar 0,0040 menunjukkan tingkat kesalahan prediksi yang lebih kecil dibandingkan model linear sederhana dan berganda. Hasil ini menunjukkan bahwa penggunaan beberapa parameter spektral secara simultan memberikan kontribusi yang lebih baik dalam menjelaskan variasi transparansi dibandingkan model logistik sederhana maupun model linear.

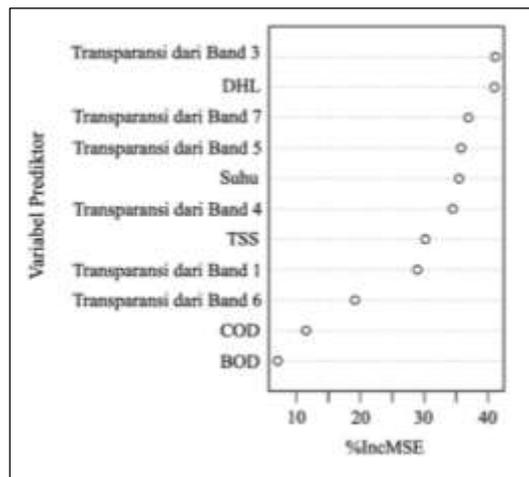
Berdasarkan hasil regresi, dapat disimpulkan bahwa model regresi logistik berganda merupakan pendekatan yang lebih unggul dibandingkan regresi linear maupun regresi logistik. Berdasarkan hasil uji regresi yang disajikan pada **Tabel 3**, diketahui bahwa regresi logistik berganda memiliki nilai R^2 yang paling tinggi dibandingkan regresi lainnya, namun nilai R^2 yang dimiliki masih terlalu rendah yaitu 0,1853. Hal ini terjadi karena model regresi memiliki keterbatasan dalam menjelaskan variabilitas transparansi berdasarkan parameter spektral yang tersedia. Grafik perbandingan nilai aktual dan prediksi dari model regresi logistik berganda untuk transparansi ditampilkan pada **Gambar 4** berikut.



Gambar 4. Grafik perbandingan nilai aktual dan prediksi transparansi model regresi logistik berganda

3.3 Random Forest

Dalam penelitian ini, *feature importance* pada model RF digunakan untuk mengidentifikasi faktor-faktor utama yang berkontribusi terhadap prediksi transparansi air di Waduk Saguling. Selain parameter spektral Landsat 8, parameter kualitas air juga digunakan sebagai input dalam model ini yang bertujuan untuk memperkuat kemampuan prediktif model ML yang dikembangkan. Melalui algoritma ini, variabel independen dievaluasi berdasarkan tingkat kepentingannya dalam model yang diukur melalui %IncMSE (*increase in mean squared error*) atau disebut juga dengan *mean decrease in accuracy* (MDA). Metrik %IncMSE mengukur tingkat degradasi akurasi model apabila suatu variabel dieliminasi, sehingga semakin tinggi nilai %IncMSE, maka semakin besar kontribusi variabel tersebut dalam meningkatkan kemampuan prediktif model. Adapun hasil *feature importance* dari transparansi ditampilkan pada **Gambar 5** berikut.



Gambar 5. *Feature importance* model random forest dari transparansi

Hasil *feature importance* yang dihasilkan menggambarkan bahwa variabel yang paling berpengaruh terhadap transparansi adalah Band 3, diikuti oleh DHL, Band 7, Band 5, Suhu, Band 4, TSS, Band 1, Band 6, COD, dan BOD. Pada transparansi, Band 3 memiliki tingkat kontribusi tertinggi yang mengindikasikan bahwa panjang gelombang dalam spektrum hijau efektif dalam menangkap variasi transparansi air karena sensitif terhadap partikel tersuspensi halus dan penetrasi cahaya di dalam kolom air, sehingga reflektansi

pada panjang gelombang ini berkorelasi kuat dengan kejernihan air. Selain itu, reflektansi spektral dari Band 7, Band 5, dan Band 4 menunjukkan kontribusi yang relatif signifikan dalam model yang menunjukkan bahwa panjang gelombang ini sensitif terhadap perubahan kejernihan perairan. Kemudian, variabel DHL, suhu dan TSS juga memiliki kontribusi yang relatif tinggi. Hal ini berkaitan dengan peningkatan DHL yang dapat memengaruhi viskositas air dan dinamika partikel tersuspensi, sementara suhu yang lebih tinggi mempercepat aktifitas biologis dan dekomposisi organik yang pada akhirnya meningkatkan TSS dan mengurangi transparansi akibat akumulasi partikel dalam kolom air.

3.4 Artificial Neural Network

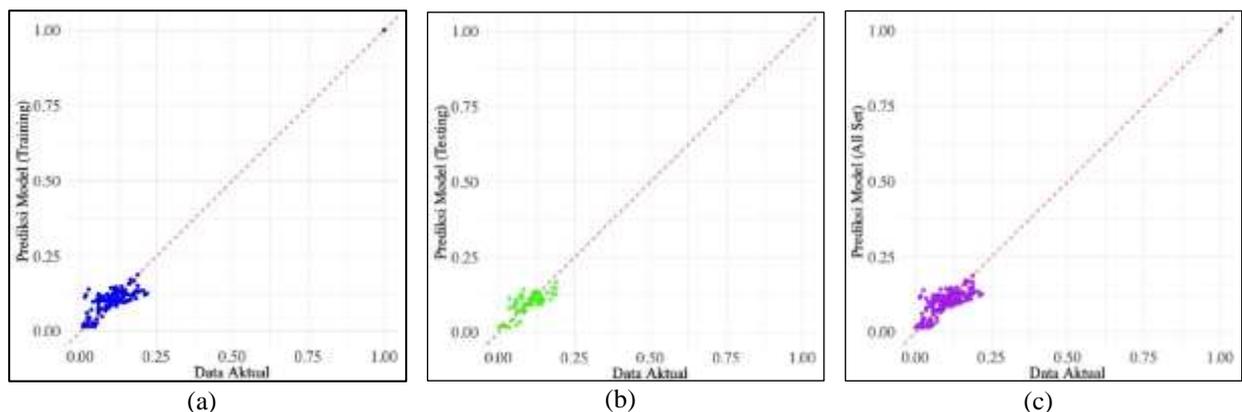
Berdasarkan hasil analisis *feature importance* menggunakan RF, variabel yang selanjutnya digunakan dalam pendekatan ANN adalah variabel dengan nilai %IncMSE >30% yaitu Band 3, Band 5, Band 7, suhu, DHL, dan TSS. Hal ini didasari pada tingkat signifikansi variabel tersebut terhadap model, di mana variabel dengan nilai %IncMSE <30% tidak memberikan peningkatan yang signifikan pada model.

Evaluasi performa model ANN dilakukan berdasarkan nilai koefisien determinasi (R^2), MAE, dan MSE untuk masing-masing subset data, yaitu *training*, *testing*, dan *all set*. Hasil evaluasi menunjukkan bahwa nilai R^2 untuk data *training* sebesar 0,8652 yang berarti model mampu menjelaskan 86,52% variasi transparansi air pada data pelatihan. Sementara itu, data *testing* memperoleh nilai R^2 dan 0,8376 atau 83,76% variasi transparansi yang dapat dijelaskan oleh model dan secara keseluruhan model ANN memiliki nilai R^2 sebesar 0,8514 yang menunjukkan bahwa ANN memiliki kemampuan prediktif yang tinggi dalam memodelkan hubungan antara input dan transparansi air hingga 85,14%.

Nilai evaluasi lengkap dari model ANN ditampilkan pada **Tabel 4** yang menunjukkan bahwa model ANN memiliki performa prediksi yang tinggi dengan nilai MAE dan MSE yang rendah. Nilai MSE dan MAE yang rendah menunjukkan keandalan model dalam memprediksi [35]. Hal ini menunjukkan bahwa model ANN mampu memberikan estimasi transparansi air yang lebih stabil dan konsisten dibandingkan dengan metode lainnya. Perbandingan antara nilai aktual dan hasil prediksi ditunjukkan dalam **Gambar 6**. Grafik tersebut memperlihatkan kesesuaian antara hasil prediksi dan data aktual pada masing-masing subset data.

Tabel 4. Evaluasi model ANN transparansi

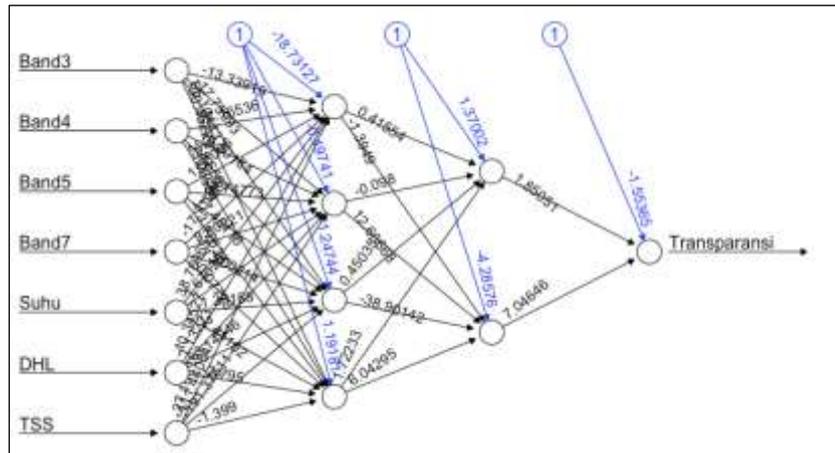
Dataset	R^2	MAE	MSE
<i>Training</i>	0,8652	0,0224	0,0010
<i>Testing</i>	0,8376	0,0227	0,0009
<i>All Data</i>	0,8514	0,0225	0,0010



Gambar 6. Grafik perbandingan nilai aktual dan prediksi ANN transparansi (a) Training; (b) Testing; (c) All data

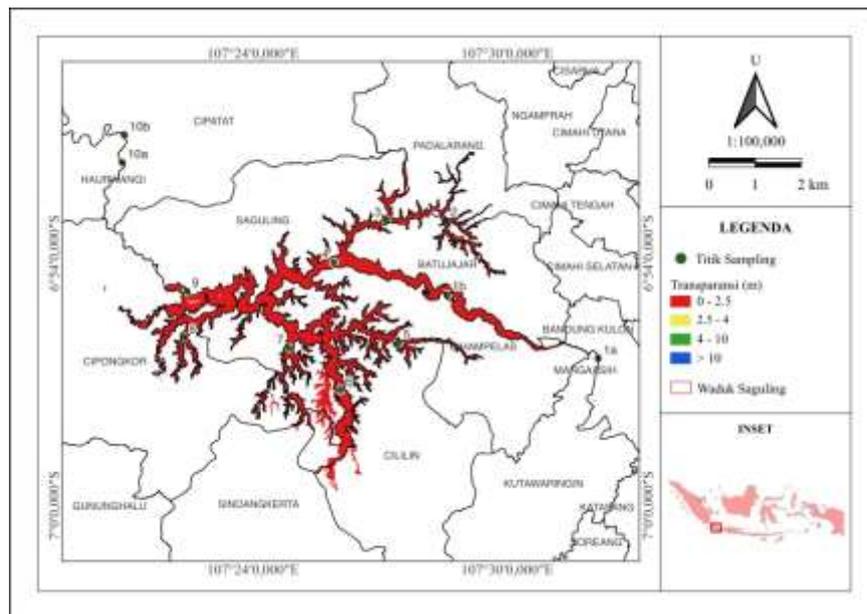
Proses pelatihan model ANN dilakukan dengan menggunakan algoritma *backpropagation* yang secara iteratif menyesuaikan bobot neuron untuk meminimalkan selisih antara nilai prediksi dan nilai aktual [36]. Model ANN dalam penelitian ini memanfaatkan jaringan saraf tiruan dengan 2 *hidden layers*, masing-masing terdiri dari 4 neuron pada *layer* pertama dan 2 neuron pada *layer* kedua, seperti yang terdapat pada **Gambar 7**. Fungsi aktivasi sigmoid diterapkan pada seluruh jaringan, termasuk *hidden layers* dan lapisan *output*, untuk menginterpretasikan hasil prediksi sebagai nilai transparansi air dalam skala probabilitas. Selain itu, ditetapkan batas *error (threshold)* dan jumlah iterasi maksimum (*stepmax*) memastikan proses

pembelajaran lebih ketat dan meningkatkan akurasi model, serta menghindari model berhenti terlalu cepat selama proses pelatihan.



Gambar 7. Struktur ANN transparansi

Hasil prediksi transparansi yang telah dihasilkan oleh ANN kemudian divisualisasikan melalui peta untuk melihat sebaran transparansi air di Waduk Saguling seperti yang ditampilkan pada Gambar 8 berikut.



Gambar 8. Prediksi peta sebaran transparansi tahun 2025

Gambar 8 menunjukkan bahwa berdasarkan hasil prediksi transparansi air di Waduk Saguling tahun 2025, yang menunjukkan seluruh wilayah Waduk Saguling didominasi oleh warna merah yang merepresentasikan transparansi Waduk Saguling berada pada kelas IV dengan tingkat transparansi rendah dengan kisaran (0 – 2,5 m). Pola distribusi transparansi ini mencerminkan terbatasnya penetrasi cahaya ke dalam kolom perairan yang berpotensi menurunkan proses fotosintesis dan kadar oksigen terlarut, serta berdampak negatif terhadap keseimbangan ekosistem akuatik [2]. Rendahnya transparansi tersebut merupakan akibat akumulasi beban pencemar dari berbagai sumber, seperti aktifitas domestik, pertanian, industri, dan budidaya ikan di keramba jaring apung (KJA) [5]. Selain itu, kondisi morfometri Waduk Saguling yang memiliki banyak lekukan dan inlet juga berpotensi menahan sedimentasi dan partikel tersuspensi, sehingga memperparah tingkat kekeruhan yang berdampak pada transparansi air [5].

Hasil visualisasi peta sebaran pada Gambar 8 menegaskan perlunya upaya pengendalian beban pencemar dan pengelolaan aktifitas di sekitar Waduk Saguling untuk meningkatkan kualitas air dan transparansi. Upaya ini tidak hanya memulihkan kualitas air, tetapi menjaga keberlanjutan fungsi ekologis dan ekonomis waduk.

Namun demikian, interpretasi ini perlu mempertimbangkan keterbatasan data. Landsat 8 dengan resolusi spasial 30 meter membuat variasi kecil dalam transparansi air sulit terdeteksi secara akurat. Selain itu, pengambilan sampel dari 12 titik penelitian juga sangat terbatas terutama untuk Waduk Saguling dengan luas lebih dari 5.000 hektar. Meskipun demikian, gambaran transparansi air untuk seluruh kawasan Waduk Saguling dengan memanfaatkan Citra Satelit akan sangat membantu pembuat kebijakan untuk menentukan langkah pemeliharaan Waduk. Terutama karena pemodelan transparansi air dengan citra satelit sangat efisien, murah dan memiliki cakupan yang luas dalam memetakan kondisi transparansi air.

4. Kesimpulan

Penelitian ini mengembangkan model prediksi transparansi air di Waduk Saguling melalui kombinasi antara *machine learning* berbasis data satelit dan data in-situ. Metode yang digunakan meliputi regresi linear dan logistik sederhana, regresi linear dan logistik berganda, *random forest*, dan ANN.

Hasil analisis menunjukkan bahwa regresi linear dan logistik sederhana memiliki keterbatasan dalam menangkap hubungan kompleks antara parameter spektral dan transparansi air dengan nilai R^2 masing-masing sebesar 0,1255 dan 0,1240. Selanjutnya, terdapat peningkatan akurasi pada regresi linear dan logistik berganda dengan nilai R^2 masing-masing sebesar 0,1552 dan 0,1853. Namun, hasil tersebut belum optimal karena penggabungan data spektral dan parameter air pada metode regresi cenderung sulit akibat jenis data yang tidak sebanding dan sulit untuk dinormalisasi. Oleh karena itu, metode berbasis *machine learning* diterapkan untuk meningkatkan performa model.

Pendekatan RF digunakan untuk menentukan variabel independen yang paling berpengaruh terhadap transparansi air. Hasil analisis menunjukkan bahwa Band 3, Band 7, Band 5, dan Band 4 pada Landsat 8, serta parameter fisik-kimia seperti DHL, suhu, dan TSS, memiliki pengaruh signifikan terhadap transparansi air di Waduk Saguling.

ANN memiliki performa yang baik dengan nilai R^2 pada *all set* sebesar 0,8514 yang mampu menjelaskan 85,14% variabilitas transparansi air secara keseluruhan, sehingga menjadikannya pendekatan yang lebih unggul dalam prediksi berbasis penginderaan jauh. Hasil prediksi transparansi 2025 menunjukkan bahwa sebagian besar wilayah Waduk Saguling berada pada kategori transparansi rendah yaitu kelas IV: 0 – 2,5 m yang mengindikasikan tingginya tekanan pencemar dari aktifitas antropogenik.

Hasil penelitian ini dapat memberikan kontribusi pada strategi pengelolaan kualitas air di daerah tropis dengan kriteria lingkungan yang padat dengan aktifitas ekonomi terutama Waduk Saguling. Pengendalian beban pencemar dari hulu serta optimalisasi sistem pengelolaan limbah domestik dan industri dapat menjadi prioritas utama. Selain itu, penguatan kebijakan zonasi budidaya perairan, terutama dalam distribusi keramba jaring apung, diperlukan untuk mencegah penurunan transparansi air. Pemantauan berbasis penginderaan jauh merupakan salah satu alternatif yang dapat diintegrasikan dalam sistem peringatan dini untuk mendeteksi perubahan kualitas air secara *real-time*. Melalui pendekatan berbasis data ilmiah dan *machine learning*, penelitian ini diharapkan dapat mendukung pengelolaan Waduk Saguling yang lebih berkelanjutan, menjaga keseimbangan ekosistem, serta memastikan ketersediaan air yang berkualitas bagi berbagai kebutuhan.

5. Ucapan Terima Kasih

Penelitian ini didanai oleh Badan Riset dan Inovasi Nasional (BRIN) melalui dana hibah program Riset dan Inovasi untuk Indonesia Maju (RIIM) gelombang 1 tahun 2023-2025. Selain itu, ucapan terima kasih disampaikan kepada PT. Indonesia Power Unit Pembangkitan Saguling atas dukungan non-finansial terhadap penelitian ini.

6. Referensi

- [1] Kementerian Pekerjaan Umum dan Perumahan Rakyat, "Peraturan Menteri Pekerjaan Umum dan Perumahan Rakyat Nomor 04/PRT/M/2015 Tahun 2015 tentang Kriteria dan Penetapan Wilayah Sungai," 2015.
- [2] L. Feng, X. Hou, and Y. Zheng, "Monitoring and Understanding The Water Transparency Changes of Fifty Large Lakes On The Yangtze Plain Based On Long-Term MODIS Observations," *Remote Sens Environ*, vol. 221, pp. 675–686, Feb. 2019, doi: 10.1016/j.rse.2018.12.007.
- [3] A. R. May, P. Soewondo, F. I. W. Rohmat, P. W. Sarli, and M. Hadi, "Predictive Modelling Of Water Clarity Based On Remote Sensing Data Using Artificial Neural Network (ANN): A Case Study In Saguling Reservoir, West Java, Indonesia," *E3S Web of Conferences*, vol. 485, p. 03009, Feb. 2024, doi: 10.1051/e3sconf/202448503009.

- [4] D. Yu, T. Qi, L. Yang, Y. Zhou, C. Zhao, and S. Pan, "Monitoring Water Clarity Using Landsat 8 Imagery in Jiaozhou Bay, China, From 2013 to 2022," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 17, pp. 1938–1948, 2024, doi: 10.1109/JSTARS.2023.3340438.
- [5] E. Wardhani, S. Notodarmojo, and D. Roosmini, "Sediment Quality Assesment by Using Geochemical Index at Saguling Reservoir West Java Province Indonesia," *Energy and Environment Research*, vol. 8, no. 2, p. 34, Nov. 2018, doi: 10.5539/eer.v8n2p34.
- [6] M. Hadi, P. Soewondo, F. Immaddudin Wira Rohmat, and A. Ritka May, "Model Prediktif Pertumbuhan Fitoplankton di Waduk Saguling Berbasis Artificial Neural Network," *Jurnal Serambi Engineering*, vol. 8, no. 3, pp. 6551–6560, 2023.
- [7] N. T. J. Ong and S. K. Yee, "Review on water quality monitoring technologies," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 18, no. 3, pp. 1416–1423, 2020, doi: 10.11591/ijeecs.v18.i3.pp1416-1423.
- [8] S. Geetha and S. Gouthami, "Internet of things enabled real time water quality monitoring system," *Smart Water*, vol. 2, no. 1, Dec. 2016, doi: 10.1186/s40713-017-0005-y.
- [9] A. T. Putri, P. Soewondo, W. Wijayasari, F. Immaddudin, and W. Rohmat, "Analisis dan Penentuan Model Empiris untuk Estimasi Sebaran Klorofil-a menggunakan Citra Satelit Sentinel-2 (Studi Kasus: Waduk Saguling, Sungai Citarum)," vol. X, no. 2, 2025.
- [10] M. Zhu *et al.*, "A review of the application of machine learning in water quality evaluation," Jun. 01, 2022, *Elsevier B.V.* doi: 10.1016/j.eehl.2022.06.001.
- [11] H. Yang, J. Kong, H. Hu, Y. Du, M. Gao, and F. Chen, "A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges," *Remote Sens (Basel)*, vol. 14, no. 8, Apr. 2022, doi: 10.3390/rs14081770.
- [12] M. A. Chowdhury *et al.*, "Recent Machine Learning Guided Material Research - A Review," *Computational Condensed Matter*, vol. 29, p. e00597, Dec. 2021, doi: 10.1016/j.cocom.2021.e00597.
- [13] W. Wijayasari, F. I. W. Rohmat, and S. Viridi, "Malaccha: An R-based end-to-end Markov transition matrix extraction for land cover datasets," *SoftwareX*, vol. 21, p. 101315, Feb. 2023, doi: 10.1016/J.SOFTX.2023.101315.
- [14] Y. Liao, Y. Li, J. Shu, Z. Wan, B. Jia, and Z. Fan, "Water transparency prediction of plain urban river network: A case study of yangtze river delta in china," *Sustainability (Switzerland)*, vol. 13, no. 13, Jul. 2021, doi: 10.3390/su13137372.
- [15] E. S. Salami, M. Salari, M. Ehteshami, N. T. Bidokhti, and H. Ghadimi, "Application Of Artificial Neural Networks And Mathematical Modeling For The Prediction Of Water Quality Variables (Case Study: Southwest Of Iran)," *Desalination Water Treat*, vol. 57, no. 56, pp. 27073–27084, Dec. 2016, doi: 10.1080/19443994.2016.1167624.
- [16] A. Sarkar and P. Pandey, "River Water Quality Modelling Using Artificial Neural Network Technique," *Aquat Procedia*, vol. 4, pp. 1070–1077, 2015, doi: 10.1016/j.aqpro.2015.02.135.
- [17] M. Chaibi, E. M. Benghoulam, L. Tarik, M. Berrada, and A. El Hmaidi, "Machine Learning Models Based on Random Forest Feature Selection and Bayesian Optimization for Predicting Daily Global Solar Radiation," *International Journal of Renewable Energy Development*, vol. 11, no. 1, pp. 309–323, Feb. 2022, doi: 10.14710/IJRED.2022.41451.
- [18] M. Sahu, A. Shrivastava, D. C. Jhariya, S. Diwan, and J. Subhadarsini, "Evaluation of correlation of physicochemical parameters and major ions present in groundwater of Raipur using discretization," *Measurement: Sensors*, vol. 34, p. 101278, Aug. 2024, doi: 10.1016/J.MEASEN.2024.101278.
- [19] A. K. J and S. Abirami, "Aspect-based opinion ranking framework for product reviews using a Spearman's rank correlation coefficient method," *Inf Sci (N Y)*, vol. 460–461, pp. 23–41, Sep. 2018, doi: 10.1016/j.ins.2018.05.003.
- [20] G. Zhao *et al.*, "Spearman rank correlations analysis of the elemental, mineral concentrations, and mechanical parameters of the Lower Cambrian Niutitang shale: A case study in the Fenggang block, Northeast Guizhou Province, South China," *J Pet Sci Eng*, vol. 208, Jan. 2022, doi: 10.1016/j.petrol.2021.109550.
- [21] G. M. Fitzmaurice, "Regression," *Diagn Histopathol*, vol. 7, no. 22, pp. 271–278, 2016.
- [22] J. C. Stoltzfus, "Logistic Regression: A Brief Primer," *Academic Emergency Medicine*, vol. 18, no. 10, pp. 1099–1104, Oct. 2011, doi: 10.1111/j.1553-2712.2011.01185.x.

- [23] S. R. Shams, A. Jahani, S. Kalantary, M. Moeinaddini, and N. Khorasani, "The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO₂ concentration," *Urban Clim*, vol. 37, May 2021, doi: 10.1016/j.uclim.2021.100837.
- [24] X. Lu, S. Y. Teh, C. J. Tay, N. F. Abu Kassim, P. S. Fam, and E. Soewono, "Application of Multiple Linear Regression Model and Long Short-Term Memory with Compartmental Model to Forecast Dengue Cases in Selangor, Malaysia Based on Climate Variables," *Infect Dis Model*, vol. 10, no. 1, pp. 240–256, Mar. 2025, doi: 10.1016/j.idm.2024.10.007.
- [25] J. H. McDonald, "Multiple Logistic Regression," Libre Texts Statistics. Accessed: Mar. 28, 2025. [Online]. Available: [https://stats.libretexts.org/Bookshelves/Applied_Statistics/Biological_Statistics_\(McDonald\)/05%3A_Tests_for_Multiple_Measurement_Variables/5.07%3A_Multiple_Logistic_Regression](https://stats.libretexts.org/Bookshelves/Applied_Statistics/Biological_Statistics_(McDonald)/05%3A_Tests_for_Multiple_Measurement_Variables/5.07%3A_Multiple_Logistic_Regression)
- [26] T. Vakili and J. Amanollahi, "Determination of Optically Inactive Water Quality Variables Using Landsat 8 Data: A Case Study in Geshlagh Reservoir Affected by Agricultural land Use," *J Clean Prod*, vol. 247, Feb. 2020, doi: 10.1016/j.jclepro.2019.119134.
- [27] T. M. Tung and Z. M. Yaseen, "A Survey On River Water Quality Modelling Using Artificial Intelligence Models: 2000–2020," *J Hydrol (Amst)*, vol. 585, Jun. 2020, doi: 10.1016/j.jhydrol.2020.124670.
- [28] A. Shamloo and S. Sima, "Investigating the potential of remote sensing-based machine-learning algorithms to model Secchi-disk depth, total phosphorus, and chlorophyll-a in Lake Urmia," *J Great Lakes Res*, vol. 50, no. 4, p. 102370, Aug. 2024, doi: 10.1016/j.jglr.2024.102370.
- [29] L. Kumar, M. S. Afzal, and A. Ahmad, "Prediction of water turbidity in a marine environment using machine learning: A case study of Hong Kong," *Reg Stud Mar Sci*, vol. 52, May 2022, doi: 10.1016/j.rsma.2022.102260.
- [30] E. S. Leggesse, F. A. Zimale, D. Sultan, T. Enku, R. Srinivasan, and S. A. Tilahun, "Predicting Optical Water Quality Indicators from Remote Sensing Using Machine Learning Algorithms in Tropical Highlands of Ethiopia," *Hydrology*, vol. 10, no. 5, May 2023, doi: 10.3390/hydrology10050110.
- [31] C. Ciaburro and B. Venkateswaran, *Neural Network with R: Smart Models Using CNN, RNN, Deep Learning, and Artificial Intelligence Principles*. Birmingham: Packt Publishing Ltd, 2017.
- [32] A. Jahani, S. Kalantary, and A. Alitavoli, "An application of artificial intelligence techniques in prediction of birds soundscape impact on tourists' mental restoration in natural urban areas," *Urban For Urban Green*, vol. 61, p. 127088, Jun. 2021, doi: 10.1016/j.ufug.2021.127088.
- [33] M. Saffariha, A. Jahani, and D. Potter, "Seed germination prediction of *Salvia limbata* under ecological stresses in protected areas: an artificial intelligence modeling approach," *BMC Ecol*, vol. 20, no. 1, p. 48, Dec. 2020, doi: 10.1186/s12898-020-00316-4.
- [34] Pemerintah Republik Indonesia, "Peraturan Pemerintah Nomor 22 Tahun 2021 tentang Penyelenggaraan Perlindungan dan Pengelolaan Lingkungan Hidup," 2021
- [35] Sukatmo, H. A. Nugroho, B. H. Rusanto, and S. Soekirno, "Performance Comparison of 1D-CNN and LSTM Deep Learning Models for Time Series-Based Electric Power Prediction," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 13, no. 1, p. 44, Feb. 2025, doi: 10.26760/elkomika.v13i1.44.
- [36] F. I. W. Rohmat, J. W. Labadie, and T. K. Gates, "Deep learning for compute-efficient modeling of BMP impacts on stream- aquifer exchange and water law compliance in an irrigated river basin," *Environmental Modelling and Software*, vol. 122, Dec. 2019, doi: 10.1016/j.envsoft.2019.104529.