

## Analisis Klasifikasi Kekeruhan Air Berbasis Citra Dengan K-NN Pada Variasi Pencahayaan

M. Fatuhrahman<sup>1</sup>, Gasim<sup>2</sup>, Zaid Romegar Mair<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknik Informatika, Fakultas Ilmu Komputer dan Sains, Universitas Indo Global Mandiri

<sup>1</sup>[fatuhrahman06@gmail.com](mailto:fatuhrahman06@gmail.com), <sup>2</sup>[gasim@uigm.ac.id](mailto:gasim@uigm.ac.id), <sup>3</sup>[zaidromegar@uigm.ac.id](mailto:zaidromegar@uigm.ac.id)

### Abstract

Clean and high-quality water is an essential requirement for public health and the continuity of industrial processes, including at PT Pupuk Sriwidjaja Palembang. One of the main parameters of water quality is turbidity, which is related to the presence of suspended particles such as mud, organic matter, and microorganisms. This study aims to analyze the effect of lighting intensity variations on the performance of water turbidity classification based on digital image processing using the K-Nearest Neighbor (K-NN) algorithm. The experiment was conducted under five lighting intensity levels: 10, 30, 50, 80, and 100 lux. The research stages included image acquisition, pre-processing (resizing, color conversion, and normalization), feature extraction of color and texture using mean, standard deviation, and Gray Level Co-occurrence Matrix (GLCM), followed by classification using the K-NN algorithm. The value of  $k = 5$  was selected because it provides a balance between sensitivity to noise and classification stability, and preliminary testing showed more consistent performance compared to smaller or larger  $k$  values. System performance evaluation was carried out using accuracy, precision, F1-score, and confusion matrix. The results showed that the best performance was achieved at 100 lux lighting intensity with an accuracy of 91.67%, precision of 93.33%, and F1-score of 91.53%, while the lowest performance occurred at 10 lux with an accuracy of 61.54%. These findings indicate that lighting intensity significantly affects turbidity classification performance, with optimal conditions found in the range of 80–100 lux. This study proves that proper lighting adjustment can improve the reliability of digital image-based classification systems for automatic water quality monitoring.

**Keywords:** gray level co-occurrence matrix, k-nearest neighbor, water turbidity, lighting intensity, digital image processing.

### Abstrak

Air bersih dan berkualitas merupakan kebutuhan penting bagi kesehatan masyarakat serta kelancaran proses industri, termasuk di PT Pupuk Sriwidjaja Palembang. Salah satu parameter utama kualitas air adalah tingkat kekeruhan yang berkaitan dengan keberadaan partikel tersuspensi seperti lumpur, bahan organik, dan mikroorganisme. Penelitian ini bertujuan menganalisis pengaruh variasi tingkat pencahayaan terhadap performa klasifikasi kekeruhan air berbasis citra digital menggunakan algoritma K-Nearest Neighbor (K-NN). Pengujian dilakukan pada lima tingkat pencahayaan, yaitu 10, 30, 50, 80, dan 100 lux. Tahapan penelitian meliputi pengambilan citra, *pre-processing* (resize, konversi warna, dan normalisasi), ekstraksi fitur warna dan tekstur menggunakan nilai mean, standar deviasi, serta *Gray Level Co-occurrence Matrix* (GLCM), kemudian dilanjutkan dengan proses klasifikasi menggunakan K-NN. Nilai  $k = 5$  dipilih karena memberikan keseimbangan antara sensitivitas terhadap noise dan kestabilan hasil klasifikasi, serta berdasarkan pengujian awal menunjukkan performa yang lebih konsisten dibandingkan nilai  $k$  yang lebih kecil maupun lebih besar. Evaluasi kinerja sistem dilakukan menggunakan akurasi, presisi, *F1-score*, dan *confusion matrix*. Hasil penelitian menunjukkan performa terbaik pada pencahayaan 100 lux dengan akurasi 91,67%, presisi 93,33%, dan *F1-score* 91,53%, sedangkan performa terendah terjadi pada pencahayaan 10 lux dengan akurasi 61,54%. Hasil ini menunjukkan bahwa intensitas pencahayaan berpengaruh signifikan terhadap performa klasifikasi kekeruhan air, dengan kondisi optimal pada rentang 80–100 lux. Penelitian ini membuktikan bahwa pengaturan pencahayaan yang tepat dapat meningkatkan keandalan sistem klasifikasi citra digital untuk pemantauan kualitas air secara otomatis.

**Kata kunci:** gray level co-occurrence matrix, k-nearest neighbor, kekeruhan air, pencahayaan, pengolahan citra digital

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

### 1. Pendahuluan

Air bersih dengan kualitas yang terjaga merupakan kebutuhan esensial dalam sektor industri, terutama untuk kebutuhan air proses dan air minum di lingkungan pabrik. Salah satu parameter penting dalam menentukan kualitas air adalah tingkat kekeruhan (turbidity), yang berkaitan dengan keberadaan partikel tersuspensi seperti lumpur, bahan organik, maupun mikroorganisme di dalam air. Tingkat kekeruhan yang tinggi dapat menurunkan kualitas air, mempengaruhi efisiensi proses produksi industri, serta berpotensi

menimbulkan risiko kesehatan apabila digunakan sebagai air konsumsi. Oleh karena itu, pemantauan tingkat kekeruhan air menjadi salah satu indikator penting dalam sistem pengawasan kualitas air [1].

Seiring dengan perkembangan teknologi digital, metode pengolahan citra (*image processing*) dan kecerdasan buatan mulai dimanfaatkan untuk menilai kualitas air secara lebih objektif dan otomatis. Teknologi ini memanfaatkan citra digital untuk mengekstraksi karakteristik visual seperti intensitas warna dan distribusi cahaya yang kemudian dianalisis menggunakan algoritma klasifikasi. Pendekatan ini

dinilai lebih praktis dan efisien dibandingkan metode konvensional karena tidak selalu memerlukan alat ukur khusus seperti turbidimeter [2]. Penelitian sebelumnya menunjukkan bahwa analisis citra digital mampu mengidentifikasi perbedaan tingkat kekeruhan air melalui pola intensitas cahaya dan distribusi warna pada citra [3].

Selain metode klasifikasi konvensional, perkembangan deep learning seperti *Convolutional Neural Networks* (CNN) juga menunjukkan performa yang baik dalam klasifikasi citra. CNN memiliki kemampuan dalam mengekstraksi fitur secara otomatis dari citra digital sehingga dapat meningkatkan akurasi klasifikasi pada berbagai kasus pengolahan citra [4]. Penelitian oleh Mair et al. (2025) menunjukkan bahwa penggunaan arsitektur CNN seperti VGG16 mampu memberikan performa klasifikasi yang cukup baik, terutama ketika dikombinasikan dengan teknik *preprocessing* seperti konversi *grayscale* dan deteksi tepi (*Canny edge detection*) untuk meningkatkan kualitas fitur citra sebelum proses klasifikasi dilakukan.

Selain itu, penelitian lain juga menunjukkan bahwa proses preprocessing seperti penghilangan noise dan peningkatan kontras citra merupakan tahap penting dalam meningkatkan akurasi sistem klasifikasi berbasis citra digital, karena kualitas data masukan sangat mempengaruhi hasil ekstraksi fitur dan performa model [5]. Salah satu algoritma yang sering digunakan dalam klasifikasi citra adalah *K-Nearest Neighbor* (K-NN), yang bekerja dengan mengelompokkan data berdasarkan kedekatan jarak fitur antara data uji dan data latih. Metode ini memiliki keunggulan berupa implementasi yang sederhana serta kemampuan klasifikasi yang cukup baik pada berbagai aplikasi pengolahan citra berbasis fitur warna [6].

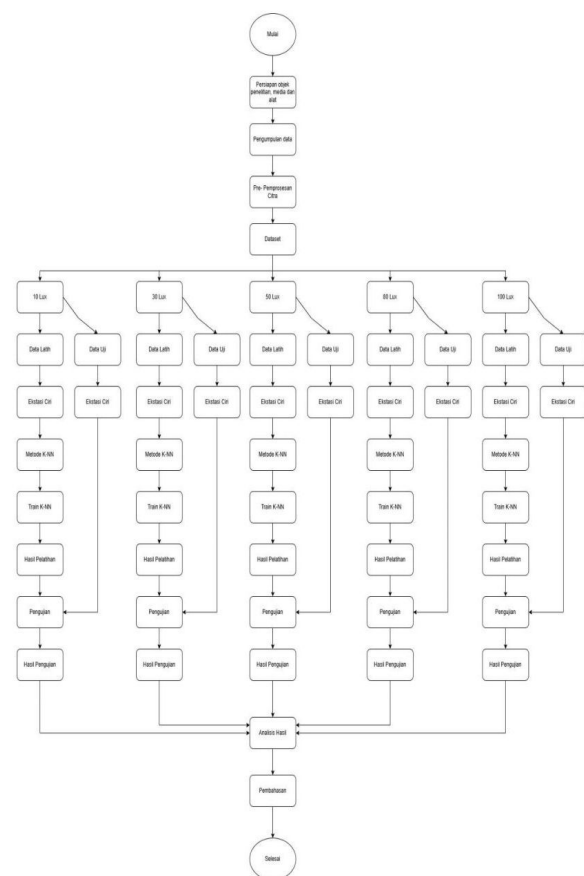
Penelitian yang dilakukan oleh Alfarizi dan Sela pada Jurnal FASILKOM menunjukkan bahwa kombinasi metode *Gray Level Co-occurrence Matrix* (GLCM) dan *K-Nearest Neighbor* mampu memberikan hasil klasifikasi yang cukup baik pada identifikasi citra rimpang, dengan tingkat akurasi yang stabil pada berbagai kelas objek. Penelitian tersebut menegaskan bahwa fitur tekstur hasil ekstraksi GLCM sangat efektif dalam membantu proses klasifikasi berbasis citra digital [7]. Selain itu, penelitian lain pada juga menunjukkan bahwa kualitas preprocessing citra sangat berpengaruh terhadap hasil klasifikasi, karena perbaikan kualitas citra sebelum proses ekstraksi fitur dapat meningkatkan performa model secara signifikan [8].

Namun demikian, sistem klasifikasi berbasis citra memiliki tantangan utama terkait kondisi pencahayaan saat proses pengambilan gambar, karena variasi intensitas cahaya dapat menyebabkan perubahan nilai warna pada citra (*color shift*) yang berpengaruh terhadap akurasi klasifikasi [9]. Oleh karena itu, penelitian ini bertujuan untuk menganalisis pengaruh variasi tingkat pencahayaan terhadap akurasi

pengenalan tingkat kekeruhan air menggunakan metode *K-Nearest Neighbor* (K-NN) pada kondisi operasional industri, khususnya di lingkungan PT Pupuk Sriwidjaja Palembang, sehingga diharapkan dapat mendukung pengembangan sistem monitoring kualitas air yang lebih stabil dan andal [10].

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang bertujuan untuk menguji secara empiris pengaruh variabel bebas terhadap variabel terikat. Dalam konteks penelitian ini, variabel bebas yang diuji adalah variasi tingkat pencahayaan (intensitas cahaya), sedangkan variabel terikatnya adalah tingkat akurasi sistem dalam mengenali jenis kekeruhan air dengan menggunakan algoritma *K-Nearest Neighbor* (K-NN). Pendekatan kuantitatif eksperimental memungkinkan peneliti melakukan pengujian secara sistematis terhadap hubungan antara variabel yang diteliti sehingga dapat diperoleh hasil yang objektif dan terukur. Metode ini banyak digunakan dalam penelitian bidang pengolahan citra dan klasifikasi data untuk menganalisis performa algoritma terhadap perubahan kondisi tertentu dalam proses pengambilan data [5]. Berikut gambar diagram alur langkah penelitian.



Gambar 1. Diagram Alur Langkah Penelitian

Pendekatan kuantitatif dipilih karena seluruh data yang dikumpulkan selama proses pengujian berbentuk numerik atau angka-angka hasil pengukuran. Hal ini memungkinkan data untuk dianalisis secara statistik guna memperoleh hasil yang objektif dan terukur. Fokus utama analisis statistik dalam penelitian ini adalah membandingkan performa klasifikasi algoritma K-NN pada masing-masing kondisi pencahayaan yang telah ditentukan, guna mengetahui pada tingkat intensitas cahaya mana sistem bekerja paling optimal.

Prosedur eksperimen dilakukan dengan mengatur pencahayaan pada beberapa tingkatan tertentu (seperti 10 lux, 30-50 lux, dan 80-100 lux) saat pengambilan citra air. Data citra tersebut kemudian diekstraksi fitur warnanya dan diklasifikasikan menggunakan K-NN. Hasil dari proses ini kemudian dievaluasi menggunakan metrik performa seperti akurasi, presisi, dan F1-score untuk memberikan gambaran komprehensif mengenai keandalan model di bawah pengaruh variasi iluminasi yang berbeda.



(a) (b) (c)

Gambar 2. Contoh Sampel Air: (a) Jernih, (b) Agak Keruh, (c) Keruh

### 3. Hasil dan Pembahasan

Tabel 1. Rincian *Dataset* per Kelas Berdasarkan Tingkat Pencahayaan (Lux)

Lux	Jernih	Agak Keruh	Keruh	Total Data
10	20	20	20	60
30	20	20	20	60
50	20	20	20	60
80	20	20	20	60
100	20	20	20	60
Jumlah	100	100	100	300

Berdasarkan Tabel 1, distribusi data citra air pada setiap tingkat intensitas pencahayaan (10 lux, 30 lux, 50 lux, 80 lux, dan 100 lux) disusun secara seimbang. Data yang digunakan dalam penelitian ini berasal dari proses pengambilan sampel air secara langsung di lingkungan PT Pupuk Sriwidjaja Palembang, yang mewakili tiga kategori tingkat kekeruhan, yaitu jernih, agak keruh, dan keruh. Setiap kategori ditentukan berdasarkan kondisi visual air dan perbedaan tingkat partikel tersuspensi yang terkandung di dalamnya. Proses pengambilan citra dilakukan menggunakan kamera smartphone dengan posisi tetap dan jarak pengambilan yang sama untuk setiap sampel guna menjaga konsistensi data.

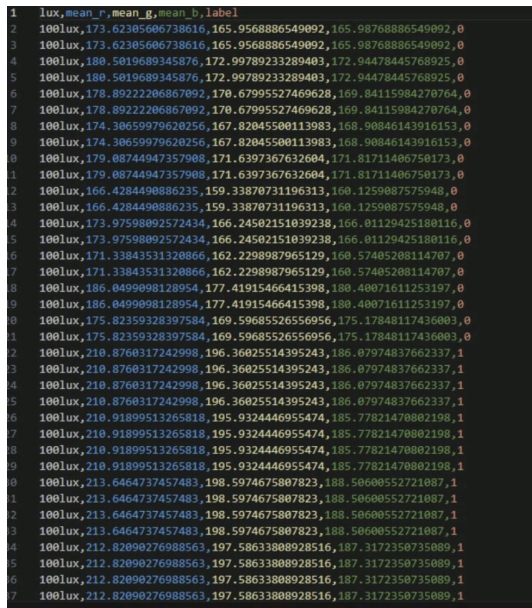
Pada setiap tingkat pencahayaan, masing-masing kategori kejernihan air memiliki 20 data citra sehingga total data pada setiap variasi pencahayaan adalah 60 citra. Pengambilan gambar dilakukan di dalam ruangan tertutup untuk meminimalkan pengaruh cahaya dari lingkungan luar, dengan bantuan lampu LED yang intensitas cahayanya diatur menggunakan lux meter sesuai skenario pengujian. Setiap sampel air ditempatkan pada wadah transparan yang sama dengan latar belakang seragam agar tidak menimbulkan gangguan visual saat proses ekstraksi fitur citra dilakukan.

Secara keseluruhan, penelitian ini menggunakan 300 citra dengan komposisi yang merata, di mana setiap kategori kejernihan air memiliki 100 data. Distribusi data yang seimbang ini bertujuan untuk meminimalkan bias dalam proses pelatihan dan pengujian model serta memastikan setiap kelas terwakili secara proporsional dalam evaluasi performa sistem klasifikasi yang dikembangkan [5].

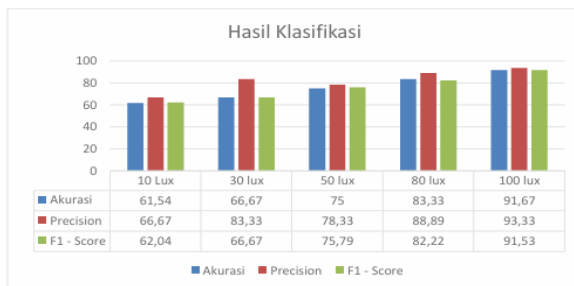
Tabel 2. Distribusi Data Latih dan Data Uji per Kelas

Kelas	Total Data	Data Latih	Data Uji
Jernih	100	80	20
Agak Jernih	100	80	20
Keruh	100	80	20
Jumlah	300	240	60

Berdasarkan tabel diatas menunjukkan distribusi dataset berdasarkan variasi tingkat pencahayaan, yaitu 10 lux, 30 lux, 50 lux, 80 lux, dan 100 lux. Dataset dibagi ke dalam tiga kelas, yaitu jernih, agak keruh, dan keruh, dengan masing-masing 20 citra pada setiap tingkat pencahayaan sehingga total data pada setiap kelas berjumlah 100 citra. Penyusunan dataset yang seimbang ini bertujuan untuk mengurangi potensi bias antar kelas serta memastikan proses pelatihan dan evaluasi model klasifikasi dapat menghasilkan performa yang lebih akurat dan objektif [11].




Gambar 3. Hasil Sebagian Ekstraksi Fitur



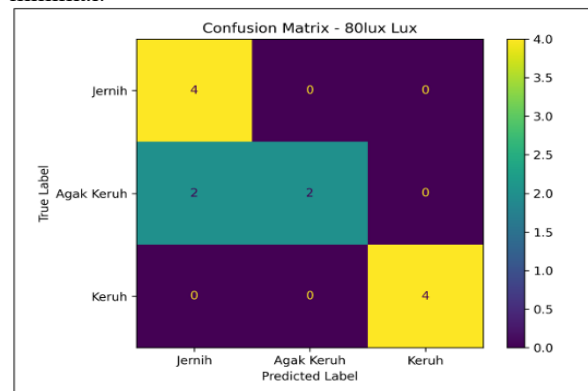
Gambar 4. Diagram Hasil Klasifikasi Menggunakan Metode K-NN

Performa metode *K-Nearest Neighbor* (K-NN) meningkat seiring bertambahnya intensitas pencahayaan. Nilai terbaik diperoleh pada 100 lux dengan akurasi 91,67%, presisi 93,33%, dan F1-score 91,53%, karena pencahayaan yang lebih baik menghasilkan fitur warna yang lebih jelas sehingga perbedaan antar kelas kekeruhan air dapat dikenali secara lebih akurat oleh model. Pada pencahayaan menengah (50–80 lux) performa sistem masih tergolong baik, namun sedikit menurun. Sebaliknya, pada kondisi pencahayaan rendah 10 lux terjadi penurunan signifikan dengan akurasi 61,54%, presisi 66,67%, dan *F1-score* 62,04%, yang disebabkan oleh rendahnya kontras citra dan meningkatnya noise sehingga distribusi nilai RGB antar kelas menjadi lebih tumpang tindih. Hasil ini menunjukkan bahwa intensitas pencahayaan memiliki pengaruh penting terhadap akurasi sistem klasifikasi berbasis citra digital, karena kualitas representasi visual sangat dipengaruhi oleh kondisi iluminasi saat pengambilan gambar [12].



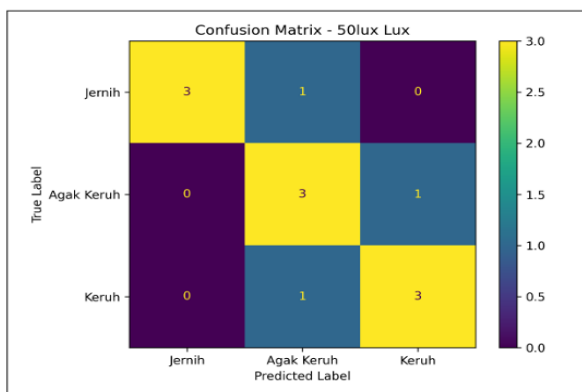
Gambar 5. Confusion Matrix 100 Lux

Analisis *confusion matrix* pada pencahayaan 100 lux menunjukkan bahwa sebagian besar nilai berada pada diagonal utama, yang menandakan model mampu mengklasifikasikan data dengan baik. Kelas jernih dan keruh masing-masing memiliki 4 sampel yang seluruhnya diprediksi dengan benar oleh algoritma *K-Nearest Neighbor* (K-NN). Pada kelas agak keruh, dari 4 data uji terdapat 3 data yang diklasifikasikan dengan benar dan 1 data salah diprediksi sebagai jernih, kemungkinan karena kemiripan karakteristik warna antar kelas. Secara keseluruhan, 11 dari 12 data uji berhasil diklasifikasikan dengan benar sehingga menghasilkan akurasi sebesar 91,67%, yang menunjukkan bahwa pencahayaan 100 lux mampu memberikan representasi fitur warna yang lebih jelas dan mendukung kinerja model dengan kesalahan yang minimal.




Gambar 6. Confusion Matrix 80 Lux

Analisis *confusion matrix* pada pencahayaan 80 lux, Terjadi peningkatan kesalahan klasifikasi terutama pada kelas agak keruh yang terprediksi sebagai jernih atau keruh. Hal ini disebabkan oleh penurunan intensitas cahaya yang mengurangi kontras citra dan mengubah distribusi nilai RGB sehingga jarak antar kelas dalam ruang fitur menjadi lebih berdekatan. Meskipun demikian, model masih tergolong cukup *robust*, karena performa klasifikasi tetap berada pada kategori tinggi dan relatif stabil dibandingkan kondisi optimal pada pencahayaan 100 lux.



Gambar 7. Confusion Matrix 50 Lux


Analisis *confusion matrix* pada pencahayaan 50 lux, nilai pada diagonal utama *confusion matrix* masih mendominasi, namun jumlah kesalahan klasifikasi mulai meningkat, terutama pada kelas agak keruh yang beberapa datanya terprediksi sebagai jernih maupun keruh. Kondisi ini menunjukkan bahwa pada pencahayaan menengah batas pemisah antar kelas mulai kurang tegas. Penurunan intensitas cahaya menyebabkan kontras citra berkurang sehingga distribusi nilai RGB antar kelas menjadi lebih berdekatan dan jarak *Euclidean* dalam ruang fitur tidak lagi terpisah secara optimal, yang pada akhirnya meningkatkan ambiguitas pada algoritma *K-Nearest Neighbor* dalam menentukan tetangga terdekat. Meskipun demikian, sistem masih mampu melakukan klasifikasi dengan cukup baik, meskipun performanya mulai mengalami degradasi dibandingkan kondisi pencahayaan yang lebih tinggi [13].



Gambar 8. Confusion Matrix 30 Lux

Analisis *confusion matrix* pada pencahayaan 30 lux, nilai pada diagonal utama *confusion matrix* masih menunjukkan dominasi yang lebih baik dibandingkan kondisi 10 lux, di mana kelas jernih dapat diklasifikasikan dengan benar tanpa kesalahan. Namun, kesalahan klasifikasi masih terjadi pada kelas agak keruh dan keruh yang sebagian diprediksi sebagai jernih, sehingga menunjukkan bahwa batas pemisah antar kelas belum sepenuhnya tegas. Penurunan intensitas cahaya menyebabkan kontras citra menurun dan meningkatkan *noise*, sehingga distribusi nilai fitur RGB antar kelas menjadi lebih tumpang tindih dan

jarak *Euclidean* dalam ruang fitur menjadi kurang diskriminatif.



Gambar 9. Confusion Matrix 10 Lux

Rendahnya performa model pada intensitas 10 lux dengan akurasi 61,54% menunjukkan bahwa ketergantungan pada fitur warna RGB sangat rentan terhadap penurunan kualitas pencahayaan. Kondisi ini menyebabkan terjadinya *overlapping* pada ruang fitur sehingga algoritma *K-Nearest Neighbor* (K-NN) kehilangan kemampuan diskriminatifnya ketika kontras visual menurun. Fenomena ini sejalan dengan penelitian Mair dkk. (2025) yang menyatakan bahwa variasi pencahayaan merupakan salah satu faktor utama yang memengaruhi akurasi klasifikasi citra. Penelitian tersebut juga menyarankan penggunaan teknik *preprocessing* seperti *Canny edge detection* untuk mengekstraksi fitur struktural yang lebih stabil sehingga proses klasifikasi tetap dapat berjalan lebih baik meskipun pada kondisi pencahayaan rendah.

Hasil penelitian menunjukkan bahwa intensitas pencahayaan memiliki pengaruh yang signifikan terhadap performa klasifikasi tingkat kekeruhan air menggunakan algoritma *K-Nearest Neighbor* (K-NN). Pada kondisi pencahayaan tinggi, khususnya 100 lux, sistem mampu menghasilkan performa terbaik dengan tingkat akurasi yang tinggi karena fitur warna RGB yang diekstraksi dari citra menjadi lebih jelas dan stabil. Sebaliknya, pada pencahayaan rendah seperti 10 lux, performa model menurun secara signifikan akibat berkurangnya kontras citra dan meningkatnya *noise*, yang menyebabkan distribusi nilai fitur antar kelas menjadi lebih tumpang tindih. Kondisi ini membuat algoritma K-NN mengalami kesulitan dalam menentukan tetangga terdekat yang paling representatif dalam ruang fitur.

Analisis *confusion matrix* pada berbagai tingkat pencahayaan juga menunjukkan bahwa kesalahan klasifikasi paling sering terjadi pada kelas agak keruh, yang sering diprediksi sebagai jernih atau keruh. Hal ini menunjukkan bahwa kelas dengan karakteristik visual yang saling berdekatan lebih rentan mengalami kesalahan prediksi, terutama ketika kualitas pencahayaan menurun. Pada pencahayaan menengah seperti 50 lux, sistem masih mampu mempertahankan

performa yang cukup baik, namun mulai menunjukkan tanda-tanda penurunan stabilitas klasifikasi. Hal ini disebabkan oleh semakin berkurangnya perbedaan nilai statistik fitur seperti mean, standar deviasi, dan entropi antar kelas, sehingga jarak *Euclidean* yang digunakan oleh algoritma K-NN menjadi kurang diskriminatif dalam memisahkan data.

Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa kondisi iluminasi merupakan salah satu faktor penting yang mempengaruhi keberhasilan sistem klasifikasi citra digital. Variasi pencahayaan dapat menyebabkan perubahan distribusi nilai piksel sehingga mempengaruhi kualitas ekstraksi fitur dan akurasi model klasifikasi [14]. Selain itu, penelitian lain juga menunjukkan bahwa pada kondisi pencahayaan rendah, fitur warna saja seringkali tidak cukup kuat untuk membedakan objek dengan karakteristik visual yang mirip, sehingga diperlukan teknik *preprocessing* tambahan seperti deteksi tepi atau peningkatan kontras citra untuk memperkuat informasi visual sebelum proses klasifikasi dilakukan. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa kondisi pencahayaan yang optimal berada pada rentang 80–100 lux, di mana sistem mampu menghasilkan tingkat akurasi yang tinggi dan kesalahan klasifikasi yang minimal.

Dari sisi implementasi, hasil penelitian ini memberikan implikasi bahwa sistem klasifikasi kekeruhan air berbasis citra digital sebaiknya dioperasikan pada kondisi pencahayaan yang terkontrol, khususnya pada rentang intensitas optimal. Penggunaan sumber cahaya buatan seperti lampu LED dengan intensitas yang stabil dapat menjadi solusi untuk meminimalkan variasi pencahayaan dari lingkungan. Selain itu, integrasi sistem dengan metode *preprocessing* tambahan seperti peningkatan kontras atau reduksi noise juga dapat dipertimbangkan untuk meningkatkan performa sistem pada kondisi pencahayaan yang kurang ideal. Oleh karena itu, dalam implementasi sistem klasifikasi kekeruhan air berbasis citra digital di lingkungan industri, pengendalian kondisi pencahayaan saat proses pengambilan gambar menjadi faktor yang sangat penting untuk menjaga stabilitas dan keandalan performa model.

Selain faktor pencahayaan, performa sistem klasifikasi juga dipengaruhi oleh kualitas fitur yang digunakan dalam proses pembelajaran. Dalam penelitian ini, fitur warna dan tekstur yang diekstraksi melalui metode statistik dan *Gray Level Co-occurrence Matrix* (GLCM) terbukti cukup efektif dalam membedakan tingkat kekeruhan air. Namun demikian, penggunaan fitur tersebut masih memiliki keterbatasan, terutama ketika kondisi pencahayaan tidak optimal. Oleh karena itu, pengembangan lebih lanjut dapat dilakukan dengan mengombinasikan fitur lain yang lebih robust terhadap perubahan iluminasi, seperti fitur berbasis bentuk atau pendekatan berbasis *deep learning* yang mampu mengekstraksi fitur secara otomatis.

Selain itu, aspek jumlah dan variasi dataset juga menjadi faktor penting dalam meningkatkan performa model klasifikasi. Meskipun dataset yang digunakan dalam penelitian ini telah disusun secara seimbang, penambahan jumlah data dengan variasi kondisi lingkungan yang lebih luas berpotensi meningkatkan kemampuan generalisasi model. Dengan demikian, sistem yang dikembangkan tidak hanya optimal pada kondisi laboratorium, tetapi juga mampu beradaptasi dengan kondisi nyata di lapangan yang cenderung lebih dinamis dan tidak terkontrol.

Selain itu, dalam konteks implementasi sistem di lingkungan industri, faktor konsistensi kondisi pengambilan citra juga menjadi aspek penting yang perlu diperhatikan. Variasi posisi kamera, jarak pengambilan gambar, serta kondisi lingkungan sekitar seperti pantulan cahaya dan warna latar belakang dapat mempengaruhi hasil citra yang diperoleh. Oleh karena itu, diperlukan standarisasi prosedur akuisisi citra agar data yang dihasilkan tetap konsisten dan tidak menimbulkan bias pada proses klasifikasi. Konsistensi ini sangat penting terutama ketika sistem akan diimplementasikan secara real-time dalam skala industri.

Lebih lanjut, pengembangan sistem klasifikasi berbasis citra digital juga dapat diarahkan pada integrasi dengan sistem monitoring berbasis *Internet of Things* (IoT), sehingga proses pengambilan data, analisis, dan pelaporan dapat dilakukan secara otomatis dan berkelanjutan. Dengan adanya integrasi tersebut, sistem tidak hanya mampu memberikan hasil klasifikasi secara akurat, tetapi juga dapat mendukung pengambilan keputusan secara cepat dalam pengelolaan kualitas air. Hal ini tentunya akan meningkatkan efisiensi operasional serta meminimalkan risiko kesalahan akibat keterlambatan dalam proses *monitoring*.

Hasil penelitian ini juga mengindikasikan bahwa pemilihan parameter pada algoritma K-Nearest Neighbor, seperti nilai K dan metode pengukuran jarak, dapat mempengaruhi sensitivitas model terhadap variasi pencahayaan. Pada kondisi tertentu, nilai K yang terlalu kecil dapat menyebabkan model menjadi lebih sensitif terhadap noise, sedangkan nilai K yang terlalu besar dapat mengurangi kemampuan model dalam membedakan karakteristik antar kelas. Oleh karena itu, diperlukan optimasi parameter yang tepat agar model dapat bekerja secara optimal pada berbagai kondisi pencahayaan yang berbeda.

#### 4. Kesimpulan

Berdasarkan hasil penelitian dan pengujian mengenai perbandingan tingkat pencahayaan terhadap akurasi pengenalan jenis kekeruhan air menggunakan metode *K-Nearest Neighbor* (K-NN), dapat disimpulkan bahwa variasi intensitas cahaya terbukti berpengaruh signifikan terhadap hasil klasifikasi. Pada kondisi pencahayaan rendah (10 lux), sistem menunjukkan

tingkat kesalahan klasifikasi yang tinggi dengan performa terendah, yakni akurasi sebesar 61,54%, presisi 66,67%, dan *F1-score* 62,04%. Kinerja model mulai mengalami peningkatan pada pencahayaan menengah (30–50 lux), meskipun masih ditemukan adanya tumpang tindih antar kelas pada proses identifikasi. Peningkatan akurasi dan stabilitas sistem yang paling optimal ditemukan pada kondisi pencahayaan yang lebih tinggi, yaitu 80–100 lux. Hasil evaluasi menunjukkan bahwa model K-NN mencapai performa puncaknya pada tingkat pencahayaan 100 lux dengan nilai akurasi sebesar 91,67%, presisi 93,33%, dan *F1-score* 91,53%. Secara keseluruhan, hasil ini menegaskan bahwa terdapat korelasi positif antara tingkat pencahayaan dengan akurasi sistem, di mana penurunan intensitas cahaya akan menyebabkan penurunan performa model secara bertahap dalam mengenali jenis kekeruhan air.

### Ucapan Terimakasih

Penulis menyampaikan penghargaan dan terima kasih kepada PT Pupuk Sriwidjaja Palembang atas izin penelitian dan dukungan data selama pelaksanaan penelitian ini. Terima kasih juga disampaikan kepada Program Studi Teknik Informatika, Fakultas Ilmu Komputer dan Sains, Universitas Indo Global Mandiri atas dukungan akademik dan fasilitas penelitian. Penulis juga mengucapkan terima kasih kepada seluruh pihak yang telah memberikan bantuan, arahan, dan motivasi sehingga penelitian ini dapat diselesaikan dengan baik.

### Daftar Rujukan

- [1] World Health Organization, 2017, *Guidelines for Drinking-Water Quality*, 4th ed. Geneva: WHO Press.
- [2] Mohammed A., 2024, Determine water turbidity by using image processing technology. *International Journal of Intelligent Systems and Applications in Engineering*, 12(2), pp. 115–121.
- [3] Wahyudi A. M., Hasrawati, and Fitriyanti, 2024, Analysis of water turbidity using image processing and polarimetry based on light intensity patterns. *Jurnal Sains Fisika*, 20(1), pp. 45–52.
- [4] Z. Alfarizi and E. I. Sela, 2024, “Klasifikasi Rimpang Menggunakan Metode K-Nearest Neighbor dan Ekstraksi Ciri Gray Level Co-occurrence Matrix,” *Jurnal FASILKOM*, vol. 14, no. 1, pp. 1–8.
- [5] Mair, R. Syafitri, and D. Pratama, 2025, “Image Classification Using CNN with Preprocessing Enhancement Based on VGG16 Architecture,” *Journal of Computer Vision and Artificial Intelligence*, vol. 5, no. 2, pp. 88–97.
- [6] Herdiansyah, A. Hermawan, and Sutarman, 2024, “Implementasi Algoritma Convolutional Neural Network Untuk Identifikasi Kode Seri Keramik Merk Arwana,” *Jurnal FASILKOM*, vol. 14, no. 3, pp. 1–8.
- [7] Gonzalez and R. Woods, 2018, *Digital Image Processing*, 4th ed. New York: Pearson.
- [8] S. Zhang and X. Wu, 2022, “Performance Analysis of K-Nearest Neighbor Algorithm in Image Classification,” *International Journal of Computer Applications*, vol. 176, no. 12, pp. 20–27.
- [9] Y. Chen, H. Li, and J. Wang, 2023, “Effect of Illumination Variations on Image-Based Classification Systems,” *Journal of Imaging Science*, vol. 9, no. 4, pp. 233–241.
- [10] PT Pupuk Sriwidjaja Palembang, 2024, *Laporan Sistem Monitoring Kualitas Air Industri*. Palembang: PT Pupuk Sriwidjaja Palembang
- [11] Hidayat R., Pratama A., and Setiawan D., 2022, Penerapan algoritma K-Nearest Neighbor pada klasifikasi citra digital. *Jurnal Teknologi Informasi dan Komunikasi (JUTIK)*, 5(2), pp. 85–92.
- [12] Ruslan R. A. and Arbaiy N., 2024, Handling imbalanced datasets in machine learning: Challenges, approaches, and best practices. *Journal of Applied Science, Technology and Computing*, 1(2), pp. 20–27.
- [13] Trisanti N., Romadloni N. T., and Sya'bani N. H., 2023, Klasifikasi citra menggunakan algoritma K-Nearest Neighbor dan metode Euclidean distance. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 3(1), pp. 12–18.
- [14] Mair Z. R., Cholil W., Yulianti E., et al., 2023, Convolutional Neural Network Analysis on Handwriting Patterns and Its Relationship to Personality: A Systematical Review. In *Proceedings of the International Conference on Informatics, Multimedia, Cyber and Information Systems (ICIMCIS)*, pp. 308–312.