

ANALISIS KLASIFIKASI TINGKAT KEKERUHAN AIR BERBASIS CITRA MENGGUNAKAN HYBRID RESNET50 DAN SUPPORT VECTOR MACHINE

Tegar Surya Prayoga^{1*}, Emil Agusalim Habi Talib², Muhammad Faisal³

^{1, 2, 3} Universitas Muhammadiyah Makassar, Indonesia

¹105841106222@student.unismuh.ac.id

²muhfaisal@unismuh.ac.id, ³emil@unismuh.ac.id

*Corresponding Author

Info Artikel

Pengajuan : 18-08-2026
Peninjauan : 17-08-2026
Revisi : 25-08-2026
Diterima : 10-09-2026
Diterbitkan : 19-09-2026

Kata Kunci:

Kekeruhan Air, Klasifikasi Citra, Resnet50, Support Vector Machine.

Abstrak

Kualitas air merupakan aspek krusial yang memerlukan pemantauan berkelanjutan, salah satunya melalui tingkat kekeruhan secara visual. Meskipun arsitektur deep learning telah banyak digunakan, lapisan klasifikasi bawaannya sering kali kurang optimal dalam menangani batas keputusan yang kompleks (ambigu) pada citra dengan variasi visual tinggi, sehingga diperlukan integrasi dengan pengklasifikasi margin maksimal. Penelitian ini bertujuan mengembangkan model klasifikasi kekeruhan air berbasis citra menggunakan pendekatan Hybrid ResNet50 dan Support Vector Machine (SVM). Dataset terdiri dari 450 citra yang terbagi secara seimbang ke dalam tiga kelas: Air Jernih, Air Keruh, dan Air Kotor. Tahapan eksperimen meliputi preprocessing (normalisasi dan resize 224×224 piksel), ekstraksi fitur menggunakan ResNet50 (Transfer Learning ImageNet), dan klasifikasi menggunakan SVM Linear ($C=0,1$). Hasil pengujian menunjukkan bahwa model Hybrid ResNet50-SVM memperoleh Accuracy sebesar 86,67%, Precision 88,03%, Recall 86,67%, dan F1-Score 86,77%. Kinerja model hibrida ini terbukti lebih superior dalam membedakan kelas transisi dibandingkan arsitektur ResNet50-Softmax mandiri (83,33%) dan SVM fitur histogram (74,44%). Penggunaan hybrid ekstraktor fitur mendalam dan pengklasifikasi margin terbukti secara signifikan meningkatkan ketepatan deteksi. Secara praktis, akurasi tinggi dan arsitektur model yang robust ini memberikan fondasi yang kuat untuk implementasi sistem pemantauan kualitas air real-time berbasis Internet of Things (IoT) di lapangan, yang berpotensi memangkas waktu dan biaya operasional instrumen fisik konvensional.

How to Cite : Prayoga, T. S., Talib, E. A. H., & Faisal, M. (2026). Analisis klasifikasi tingkat kekeruhan air berbasis citra menggunakan hybrid ResNet50 dan support vector machine. *Journal of Computer Science and Information Technology (JCSIT)*, 3(4), 436–449.

DOI: 10.70248/jcsit.v3i4.4365

This is an open access article under <https://creativecommons.org/licenses/by/4.0/>
Copyright© 2026 by Author. Published by Yayasan Nuraini Ibrahim Mandiri



PENDAHULUAN

Ketersediaan air dengan kualitas fisik yang memadai menjadi indikator krusial bagi kelestarian lingkungan dan kesehatan masyarakat [1]. Parameter fisik utama yang umum diamati adalah tingkat kekeruhan (*turbidity*), yang mencerminkan keberadaan partikel tersuspensi dan polutan. Evaluasi kekeruhan yang dilakukan secara visual oleh manusia rentan terhadap bias subjektivitas, sementara penggunaan instrumen spesifik seperti turbidimeter membutuhkan pengadaan alat serta biaya pengukuran berkala yang tinggi[2]. Berangkat dari urgensi tersebut, otomatisasi pemantauan berbasis kecerdasan buatan dan visi komputer menjadi solusi alternatif yang efisien..

Perkembangan *deep learning*, khususnya *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50, memberikan keunggulan dalam ekstraksi fitur visual laten seperti tekstur dan sebaran spektrum warna air [3]. Namun, lapisan klasifikasi akhir bawaan dari algoritma konvolusi konvensional (yaitu lapisan *Softmax*) bekerja berdasarkan prinsip *Empirical Risk Minimization* (ERM). Prinsip ini rentan mengalami

penurunan performa generalisasi (*overfitting*) saat dihadapkan pada dataset berskala kecil atau citra air dengan kompleksitas gangguan optik yang tinggi. Sebaliknya, *Support Vector Machine* (SVM) bekerja dengan landasan *Structural Risk Minimization* (SRM), di mana algoritma difokuskan pada minimalisasi kesalahan generalisasi melalui pencarian *hyperplane* atau batas margin paling optimal di antara kelas-kelas data[4]. Integrasi arsitektur ekstraktor CNN dengan pengklasifikasi SVM (*hybrid model*) secara teoretis diproyeksikan mampu mengatasi kelemahan arsitektur tunggal, terutama dalam memetakan batas wilayah keputusan yang saling beririsan[1].

Perkembangan teknologi pengolahan citra dan kecerdasan buatan memberikan alternatif untuk melakukan klasifikasi tingkat kekeruhan air secara otomatis berdasarkan citra digital [5]. Salah satu pendekatan yang banyak digunakan adalah deep learning, khususnya arsitektur ResNet50 yang memiliki kemampuan mengekstraksi fitur visual seperti warna, tekstur, dan pola citra secara efektif. Namun, lapisan klasifikasi bawaan ResNet50 belum selalu memberikan hasil optimal pada data dengan batas keputusan yang kompleks sehingga diperlukan algoritma klasifikasi yang lebih kuat, seperti Support Vector Machine (SVM), untuk meningkatkan performa klasifikasi[4].

Beberapa kajian terdahulu telah mengeksplorasi penggunaan klasifikasi pada pemantauan kualitas sumber daya alam. Klasifikasi parameter lingkungan menggunakan algoritma *machine learning* standar sering mengalami saturasi pada data tak terstruktur[6]. Di sisi lain, metode hibrida terbukti menaikkan stabilitas metrik pada deteksi cacat objek karena CNN mengonversi gambar menjadi fitur numerik solid, yang lalu dipisahkan oleh SVM [7]. Akan tetapi, eksplorasi sistematis terkait integrasi ResNet50 dan SVM yang difokuskan khusus pada klasifikasi kekeruhan air permukaan di mana citra sangat dipengaruhi oleh kondisi pencahayaan dinamis dan turbulensi air masih belum didokumentasikan dengan komprehensif. Celah penelitian (*research gap*) inilah yang belum banyak dieksplorasi oleh kajian terdahulu, terutama perbandingan efektivitas model *hybrid* terhadap model mandiri klasiknya dalam satu kondisi data uji yang ekuivalen.


Berpijak pada argumentasi dan celah literatur di atas, penelitian ini mengusulkan model klasifikasi tingkat kekeruhan air menggunakan *Hybrid* ResNet50 dan SVM. Model difokuskan untuk mengklasifikasikan citra ke dalam tiga kategori batas: air jernih, air keruh, dan air kotor.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk menganalisis performa model hybrid ResNet50 dan Support Vector Machine (SVM) dalam mengklasifikasikan tingkat kekeruhan air berbasis citra. Tahapan penelitian meliputi pengumpulan data, preprocessing citra, ekstraksi fitur menggunakan ResNet50, klasifikasi menggunakan SVM, serta evaluasi performa model. Dataset yang digunakan berupa citra digital air yang dikategorikan ke dalam tiga kelas, yaitu air jernih, air keruh, dan air kotor. Setiap citra diproses melalui tahapan preprocessing untuk menyeragamkan ukuran dan format data sehingga sesuai dengan kebutuhan model. Selanjutnya, ResNet50 digunakan sebagai feature extractor untuk memperoleh representasi fitur visual yang mampu menggambarkan karakteristik tingkat kekeruhan air. Fitur yang dihasilkan kemudian menjadi masukan bagi algoritma SVM untuk membangun model klasifikasi berdasarkan batas keputusan (*hyperplane*) yang optimal. Setelah proses pelatihan selesai, model diuji menggunakan data pengujian untuk mengetahui kemampuan generalisasinya terhadap data yang belum pernah

dikenali sebelumnya. Performa model dievaluasi menggunakan Confusion Matrix dengan metrik Accuracy, Precision, Recall, dan F1-Score. Hasil evaluasi tersebut digunakan untuk menilai tingkat ketepatan model dalam mengklasifikasikan setiap kategori tingkat kekeruhan air. Alur keseluruhan proses penelitian mulai dari data masukan

hingga evaluasi model ditunjukkan pada Gambar 1.



Berdasarkan diagram tersebut, tahapan dimulai dari *input dataset* yang kemudian diproses pada tahap *preprocessing data* (mencakup penyesuaian ukuran/*resize* dan normalisasi piksel secara terpadu). Setelah itu, data didistribusikan melalui tahapan *Split Dataset* untuk memisahkan data pelatihan dan pengujian.

Dataset penelitian yang berjumlah 450 citra dikategorikan ke dalam small dataset (dataset skala kecil) untuk pelatihan deep learning. Untuk memastikan kecukupan data, rasio pembagian train-test split ditetapkan sebesar 80:20 secara stratified, yang menghasilkan 360 citra untuk proses pelatihan (termasuk validasi) dan 90 citra untuk pengujian akhir. Pendekatan Data Augmentation (rotasi acak,

Gambar 1. Alur Penelitian Dan sistem klasifikasi Air Resnet50 dan SVM

pembalikan horizontal, dan manipulasi kecerahan) serta strategi Transfer Learning dari bobot (weight) ImageNet diaplikasikan agar 360 data latih tersebut memiliki variabilitas informasi yang memadai, sehingga mencegah overfitting.

selanjutnya diproses menggunakan ResNet50 untuk mengekstraksi fitur visual yang menjadi masukan bagi algoritma Support Vector Machine (SVM) dalam membangun model klasifikasi. Model yang telah dilatih kemudian diuji menggunakan data testing dan dievaluasi menggunakan Confusion Matrix dengan metrik Accuracy, Precision, Recall, dan F1-Score untuk mengetahui performa klasifikasi. Dataset yang digunakan pada penelitian ini terdiri atas tiga kelas utama berdasarkan tingkat kekeruhan air, yaitu air jernih, air keruh, dan air kotor. Deskripsi masing-masing kelas disajikan pada Tabel 1.

Tabel 1. Kategori Kelas Dataset Penelitian

No	Kelas	Deskripsi
1	Air Jernih	Air yang memiliki tingkat kekeruhan sangat rendah sehingga tampak bening dan tembus pandang. Pada citra digital, air jernih umumnya memiliki warna

No	Kelas	Deskripsi
		yang relatif seragam dengan sedikit partikel yang terlihat secara visual.
2	Air Keruh	Air yang mengandung partikel tersuspensi seperti lumpur, pasir halus, atau sedimen sehingga mengurangi kejernihan air. Secara visual, air tampak kurang bening dan memiliki warna yang lebih pekat dibandingkan air jernih.
3	Air Kotor	air yang mengandung berbagai kotoran atau bahan organik yang menyebabkan perubahan warna dan penurunan kualitas fisik air. Pada citra digital, air kotor biasanya menunjukkan warna yang lebih gelap, memiliki banyak partikel, dan adanya busa, minyak, atau material lain yang mengindikasikan pencemaran

HASIL DAN PEMBAHASAN

Pengumpulan Data

Dataset penelitian diperoleh melalui proses pengambilan citra secara langsung terhadap sampel air dengan memperhatikan konsistensi kondisi pengambilan gambar. Seluruh citra yang dikumpulkan kemudian melalui proses seleksi (*screening*) untuk memastikan bahwa gambar memiliki kualitas yang baik, tidak mengalami kerusakan, tidak buram (*blur*), serta mampu merepresentasikan karakteristik visual dari masing-masing kelas tingkat kekeruhan. Proses seleksi ini bertujuan untuk meminimalkan keberadaan data yang tidak representatif sehingga model dapat mempelajari pola visual secara lebih optimal.

Berdasarkan proses pengumpulan dan seleksi tersebut, diperoleh sebanyak 450 citra air yang selanjutnya digunakan sebagai dataset penelitian. Seluruh citra kemudian dikelompokkan ke dalam tiga kategori tingkat kekeruhan berdasarkan karakteristik visualnya yang di deskripsikan pada tabel 2 Jumlah Citra Perkelas.

Tabel 2. Jumlah Citra Perkelas


No	Kelas	Jumlah Citra
1	Air Jernih	150
2	Air Keruh	150
3	Air Kotor	150

Distribusi jumlah citra pada masing-masing kelas yang di deskripsikan pada tabel 2 jumlah citra perkelas disusun secara seimbang (*balanced dataset*), sehingga setiap kategori memiliki jumlah data yang sama. Keseimbangan jumlah data antar kelas merupakan aspek penting dalam proses pelatihan model klasifikasi karena dapat mengurangi potensi *class imbalance* yang sering menyebabkan model lebih cenderung mengenali kelas yang memiliki jumlah data lebih banyak.

Visualisasi Karakteristik Dataset

Selain memperhatikan keseimbangan jumlah data pada setiap kelas, penelitian ini juga mempertimbangkan karakteristik visual dari masing-masing kategori citra. Setiap kelas memiliki ciri visual yang berbeda, baik dari segi tingkat kejernihan, intensitas warna, tingkat transmisi cahaya, maupun jumlah partikel tersuspensi yang tampak pada permukaan air. Perbedaan karakteristik tersebut menjadi informasi penting yang dimanfaatkan oleh model dalam proses pembelajaran. Arsitektur ResNet50 berperan untuk mengekstraksi fitur-fitur visual yang merepresentasikan karakteristik setiap kelas, sedangkan Support Vector Machine (SVM) memanfaatkan hasil ekstraksi tersebut untuk membentuk batas keputusan (*decision boundary*) yang optimal dalam proses klasifikasi. Dengan demikian, model tidak hanya memanfaatkan perbedaan warna air, tetapi juga mempelajari pola tekstur, distribusi intensitas cahaya, dan karakteristik visual lainnya yang menjadi pembeda antar kategori tingkat

kekeruhan. Semakin jelas representasi fitur yang dihasilkan, semakin baik pula kemampuan model dalam membedakan citra air jernih, air keruh, dan air kotor. Untuk memberikan gambaran mengenai perbedaan karakteristik visual pada setiap kategori tingkat kekeruhan air, beberapa contoh citra dari masing-masing kelas disajikan pada Gambar 2. Melalui visualisasi tersebut, pembaca dapat mengamati perbedaan karakteristik setiap kelas secara langsung sehingga lebih mudah memahami dasar pembentukan fitur yang digunakan oleh model dalam proses klasifikasi.




Gambar 2. Sampel data tiap kategori

Berdasarkan Gambar 2 sampel data tiap kategori dapat diamati bahwa setiap kelas memiliki karakteristik visual yang berbeda. Kelas Air Jernih menunjukkan tingkat transparansi yang tinggi dengan warna air relatif bening dan sedikit partikel yang terlihat. Kelas Air Keruh memperlihatkan tingkat kejernihan yang mulai berkurang akibat meningkatnya jumlah partikel tersuspensi sehingga warna air tampak lebih kusam. Sementara itu, kelas Air Kotor memiliki tingkat kekeruhan paling tinggi yang ditandai dengan dominasi warna yang lebih gelap, terkontaminasi, rendahnya tingkat transparansi, serta tingginya konsentrasi partikel yang terlihat pada citra.

Preprocessing Data

Tahap preprocessing merupakan proses awal yang dilakukan untuk mempersiapkan citra sebelum memasuki tahap ekstraksi fitur menggunakan model ResNet50. Pada penelitian ini, tahapan preprocessing diawali dengan proses penyesuaian ukuran citra (resize) karena citra hasil pengambilan data memiliki dimensi yang bervariasi sesuai dengan resolusi kamera yang digunakan. Agar seluruh citra dapat diproses oleh arsitektur ResNet50, setiap gambar diubah ukurannya menjadi 224×224 piksel, yang merupakan ukuran input standar model. Proses ini bertujuan untuk menyeragamkan dimensi citra sehingga seluruh data memiliki format yang konsisten tanpa menghilangkan karakteristik visual penting, seperti warna, tekstur, dan pola permukaan air yang menjadi dasar dalam proses ekstraksi fitur. Berikut gambar 3 perbandingan sebelum dan sesudah resize.



Gambar 3. perbandingan sebelum dan sesudah resize

Gambar 3 menunjukkan hasil proses *resize* ditunjukkan pada Gambar 3. Selain menunjukkan perbandingan resolusi citra asli (4624×3468 px) yang disusutkan menjadi 224×224 px, panel gambar juga menyertakan visualisasi uji *Degradasi*. Uji degradasi ini bukanlah bagian mutlak dari alur *preprocessing* reguler, melainkan sebuah injeksi *noise* buatan (simulasi gangguan visual ekstrem) yang ditambahkan sebagai *robustness testing* (uji ketahanan). Tujuannya adalah untuk mengobservasi sejauh mana ekstraktor fitur ResNet50 dan batasan SRM pada SVM mampu mempertahankan akurasi prediksi saat dihadapkan pada rekaman citra di lapangan yang mengalami pelemahan sensor atau *blur* optik akibat kondisi cuaca.

Implementasi Model Hybrid Resnet50 dan SVM

Setelah melalui tahapan *preprocessing*, citra air yang telah dinormalisasi selanjutnya memasuki tahap ekstraksi fitur (*feature extraction*). Tahap ini bertujuan untuk mengubah citra yang masih berupa kumpulan nilai piksel menjadi representasi numerik yang mampu menggambarkan karakteristik visual dari setiap kategori air. Representasi numerik tersebut nantinya akan digunakan sebagai masukan (input) bagi algoritma *Support Vector Machine* (SVM) pada proses klasifikasi.


Model yang dievaluasi merupakan kombinasi arsitektur Hybrid ResNet50-SVM, yaitu ResNet50 yang berperan sebagai *feature extractor* dan *Support Vector Machine* (SVM) sebagai pengklasifikasi. Lapisan *Global Average Pooling* pada ResNet50 menghasilkan vektor fitur berdimensi 2048 yang selanjutnya digunakan sebagai masukan bagi SVM untuk menentukan kelas kualitas air. Performa model diukur menggunakan empat metrik evaluasi yang umum digunakan pada permasalahan klasifikasi, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score* pengujian model secara keseluruhan disajikan pada Tabel 3 berikut.

Tabel 3. Hasil Evaluasi Keseluruhan Model Hybrid ResNet50-SVM

Metrik Evaluasi	Nilai
<i>Accuracy</i>	86,67%
<i>Precision (Weighted Average)</i>	88,03%
<i>Recall (Weighted Average)</i>	86,67%
<i>F1-Score (Weighted Average)</i>	86,77%

Berdasarkan Tabel 3, model *Hybrid ResNet50-SVM* memperoleh *Accuracy* sebesar


86,67%, yang menunjukkan bahwa sebanyak 78 dari 90 citra pada data uji berhasil diklasifikasikan secara benar. Nilai *Precision*, *Recall*, dan *F1-Score* yang berada pada kisaran 86–88% menunjukkan keseimbangan performa model dalam melakukan klasifikasi. Untuk memperoleh detail yang lebih rinci mengenai pola klasifikasi yang dihasilkan model, dilakukan analisis menggunakan *Confusion Matrix*. Matriks menyajikan hubungan antara label aktual dan label hasil prediksi sehingga dapat diketahui distribusi prediksi benar maupun kesalahan klasifikasi pada setiap kelas. Visualisasi *Confusion matrix* tersebut dipaparkan pada gambar 4 berikut.



Gambar 4. Visualisasi *Confusion matrix*

Gambar 4 menampilkan hasil evaluasi model *Hybrid ResNet50-SVM* menggunakan *Confusion Matrix* dalam dua bentuk, yaitu berdasarkan jumlah sampel (kiri) dan persentase (kanan). Kedua visualisasi tersebut memberikan gambaran mengenai distribusi prediksi benar maupun kesalahan klasifikasi pada setiap kelas kualitas air. Pada kelas Air Jernih, model berhasil mengklasifikasikan 28 dari 30 citra (93,3%) dengan benar, sedangkan 2 citra (6,7%) diprediksi sebagai Air Keruh. Untuk kelas Air Keruh, model mengklasifikasikan 23 citra (76,7%) secara benar, sementara 6 citra (20,0%) diprediksi sebagai Air Jernih dan 1 citra (3,3%) sebagai Air Kotor. Adapun pada kelas Air Kotor, sebanyak 27 citra (90,0%) berhasil dikenali dengan benar dan 3 citra (10,0%) diprediksi sebagai Air Jernih.

Masuk pada tahap pelatihan dan evaluasi bertujuan mengukur kemampuan ResNet50 dengan pengklasifikasi Softmax dalam mempelajari karakteristik citra kualitas air serta melakukan generalisasi terhadap data yang belum pernah dilatih (*unseen data*). Proses pembelajaran diamati melalui kurva *loss* dan *accuracy* selama 15 epoch, sedangkan evaluasi dilakukan pada tiga kelas, yaitu Air Jernih, Air Keruh, dan Air Kotor, menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, serta *Confusion*



Matrix. Learning nya dipaparkan pada gambar 5 berikut

Gambar 5. *Learning Curve*


Gambar 5 menunjukkan training *loss* menurun dari sekitar 1,35 menjadi 0,20,

sementara validation loss stabil pada kisaran 0,25–0,30. Training accuracy mencapai lebih dari 92% dan validation accuracy sekitar 89%, dengan fluktuasi kecil pada akhir pelatihan. Kedekatan kurva menunjukkan proses pembelajaran yang stabil tanpa indikasi overfitting berlebihan dan model telah mencapai kondisi konvergen.

Pada data uji, model memperoleh Accuracy 83,33%, Precision 84,02%, Recall 83,33%, dan F1-Score 83,53%. Hasil ini menunjukkan kemampuan generalisasi yang cukup baik, meskipun performanya sedikit lebih rendah dibandingkan data pelatihan dan validasi. Berdasarkan Confusion Matrix, kesalahan klasifikasi terutama terjadi antara Air Jernih dan Air Keruh, yang menunjukkan keterbatasan model dalam membedakan karakteristik visual yang serupa akibat degradasi citra.

Secara keseluruhan, pola kesalahan didominasi oleh pertukaran prediksi antara Air Keruh dan Air Jernih, sedangkan kesalahan antara Air Jernih dan Air Kotor sangat sedikit. Hal ini menunjukkan bahwa model mampu membedakan dua kelas ekstrem dengan baik, namun masih mengalami kesulitan pada kelas transisi. Temuan tersebut konsisten dengan hasil evaluasi sebelumnya yang menunjukkan Accuracy sebesar 86,67% dan *F1-Score* sebesar 86,77%, sehingga mengindikasikan bahwa model *Hybrid ResNet50-SVM* memiliki performa klasifikasi yang baik, meskipun masih terdapat ruang perbaikan dalam pengenalan kelas Air Keruh.

Untuk memperoleh gambaran performa yang lebih rinci pada setiap kelas, dilakukan analisis menggunakan parameter dasar evaluasi, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)* melalui pendekatan *One-vs-Rest*. Parameter tersebut menjadi dasar dalam perhitungan *Precision*, *Recall*, *F1-Score*, dan *Accuracy* pada masing-masing kelas. Visualisasi nya dipaparkan pada gambar ke 6 berikut.



Gambar 6. Visualisasi Nilai Tiap Kelas

Gambar 6 menyajikan hasil evaluasi model *Hybrid ResNet50-SVM* yang meliputi *Confusion Matrix*, metrik *Precision*, *Recall*, *F1-Score*, serta distribusi *TP*, *TN*, *FP*, dan *FN*. Hasil *Confusion Matrix* menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, yang menandakan model mampu mengklasifikasikan data uji dengan baik. Model berhasil mengenali Air Jernih sebanyak 28 sampel (93,3%), Air Keruh sebanyak 23 sampel (76,7%), dan Air Kotor sebanyak 27 sampel (90,0%). Kesalahan klasifikasi terbesar terjadi pada kelas Air Keruh yang sering diprediksi sebagai Air Jernih, menunjukkan adanya kemiripan karakteristik visual antara kedua kelas tersebut.

Grafik metrik evaluasi menunjukkan bahwa Air Kotor memiliki performa terbaik dengan *Precision* 0,96, *Recall* 0,90, dan *F1-Score* 0,93, didukung oleh nilai *False Positive* terendah. Sebaliknya, Air Jernih memiliki *Recall* tertinggi (0,93) namun *Precision* lebih rendah (0,76) akibat masih adanya *False Positive*. Sementara itu, Air Keruh memperoleh *Recall* terendah (0,77) dan *False Negative* tertinggi, menunjukkan bahwa

kelas ini paling sulit dibedakan karena memiliki karakteristik visual yang menyerupai kelas lain. Secara keseluruhan, model Hybrid ResNet50-SVM mencapai Accuracy 86,67%, Precision 88,03%, Recall 86,67%, dan F1-Score 86,77%, yang menunjukkan kinerja klasifikasi yang baik. Rincian hasil evaluasi disajikan pada Tabel 4.

Tabel 4. Kelas Target TP, TN, FP, Dan FN.

Kelas Target	TP	TN	FP	FN
Air Jernih	28	51	9	2
Air Keruh	23	58	2	7
Air Kotor	27	59	1	3

Berdasarkan Tabel 4 terlihat bahwa kelas Air Kotor memiliki jumlah False Positive paling rendah, yaitu hanya satu sampel. Hal tersebut menunjukkan bahwa model sangat jarang mengelompokkan citra dari kelas lain sebagai Air Kotor sehingga ketepatan prediksinya relatif tinggi. Sebaliknya, kelas Air Jernih memiliki jumlah False Positive terbesar, yaitu sembilan sampel. Kondisi ini menunjukkan bahwa masih terdapat sejumlah citra dari kelas lain yang memiliki karakteristik visual menyerupai Air Jernih sehingga diprediksi ke dalam kelas tersebut.

Di sisi lain, kelas Air Keruh memiliki nilai *False Negative* tertinggi, yaitu tujuh sampel. Temuan ini menunjukkan bahwa sebagian citra Air Keruh belum berhasil dikenali sebagai kelasnya sendiri dan lebih sering diprediksi sebagai Air Jernih. Hasil tersebut konsisten dengan analisis *Confusion Matrix* yang menunjukkan bahwa Air Keruh merupakan kelas dengan tingkat kompleksitas visual paling tinggi. Berdasarkan parameter TP, TN, FP, dan FN tersebut selanjutnya dihitung nilai *Precision*, *Recall*, *F1-Score*, dan *Accuracy* untuk masing-masing kelas sebagaimana disajikan pada Tabel 5.

Tabel 5. Hasil Evaluasi Setiap Kelas

Kelas Target	Precision	Recall	F1-Score	Accuracy
Air Jernih	0,7568	0,9333	0,8358	0,8778
Air Keruh	0,9200	0,7667	0,8364	0,9000
Air Kotor	0,9643	0,9000	0,9310	0,9556

Berdasarkan Tabel 5, kelas Air Kotor menunjukkan performa klasifikasi terbaik dengan Precision 96,43%, Recall 90,00%, dan F1-Score 93,10% berkat karakteristik visualnya yang konsisten dan mudah dipisahkan. Sebaliknya, kelas Air Jernih mencatat Recall tertinggi (93,33%) yang menandakan model sangat sensitif dalam mendeteksinya, namun memiliki Precision lebih rendah (75,68%) akibat masuknya prediksi positif yang keliru dari kelas lain. Sementara itu, kelas Air Keruh (Precision 92,00%, Recall 76,67%) terbukti menjadi kelas yang paling sulit dibedakan; meskipun tebakannya sangat presisi, banyak sampel yang gagal terdeteksi dan keliru diprediksi sebagai Air Jernih karena ciri visualnya yang berada pada fase transisi.


Analisis Komparatif dan Evaluasi Menyeluruh Model Klasifikasi

Tahap akhir penelitian ini bertujuan untuk membandingkan performa tiga model klasifikasi yang digunakan, yaitu *SVM* Murni berbasis fitur histogram sebagai model pembandingan (*baseline*), *ResNet50* Murni dengan pengklasifikasi *Softmax*, dan *Hybrid ResNet50-SVM* sebagai model yang diusulkan. Ketiga model dievaluasi menggunakan data uji yang sama sebanyak 90 citra yang telah mengalami berbagai bentuk degradasi visual, seperti *noise*, *blur*, dan penurunan resolusi (*downscale*). Dengan menggunakan dataset dan skenario pengujian yang identik, perbedaan performa yang diperoleh dapat menggambarkan kontribusi masing-masing metode secara objektif. Evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil evaluasi keseluruhan ketiga model dilampirkan pada Tabel 6 berikut.

Tabel 6. Perbandingan Performa Keseluruhan Antar Model

Model	Accuracy	Precision	Recall	F1-Score
Hybrid ResNet50 + SVM	86,67%	88,03%	86,67%	86,77%
ResNet50 Murni (Softmax)	83,33%	84,02%	83,33%	83,53%
SVM Murni (Fitur Histogram)	74,44%	73,58%	74,44%	73,49%

Berdasarkan Tabel 6, model *Hybrid ResNet50-SVM* memperoleh performa terbaik pada seluruh metrik evaluasi. Model ini mencapai *Accuracy* sebesar 86,67%, lebih tinggi dibandingkan *ResNet50* Murni yang memperoleh 83,33% maupun *SVM* Murni sebesar 74,44%. Pola yang sama juga terlihat pada nilai *Precision*, *Recall*, dan *F1-Score*, di mana model *Hybrid* secara konsisten menghasilkan nilai tertinggi. Hasil tersebut menunjukkan bahwa kombinasi ekstraksi fitur mendalam menggunakan *ResNet50* dengan proses klasifikasi menggunakan *SVM* mampu meningkatkan kualitas prediksi secara menyeluruh. Berikut gambar 7 perbandingan confusion matrix dari ketiga model yang dilampirkan pada gambar 7 berikut.




Gambar 7. Perbandingan Confusion Matrix SVM, Resnet50, dan Hybrid

Perbandingan *Confusion Matrix* pada gambar 7 memberikan gambaran yang lebih rinci mengenai pola keberhasilan dan kesalahan klasifikasi pada masing-masing model. Pada model *SVM* Murni, kesalahan klasifikasi masih banyak terjadi, terutama pada kelas Air Kerasih, yang hanya berhasil dikenali sebanyak 50,00% dari seluruh sampel pada kelas tersebut. Sebagian besar citra Air Kerasih diprediksi sebagai Air Jernih maupun Air Kotor, yang menunjukkan bahwa fitur histogram belum mampu membedakan karakteristik visual kelas transisi secara konsisten.

Setelah menggunakan *ResNet50* sebagai ekstraktor fitur, jumlah kesalahan klasifikasi pada kelas Air Kerasih berkurang secara signifikan. Model mampu mengenali sekitar 80% sampel Air Kerasih dengan benar, sehingga menunjukkan bahwa fitur mendalam (*deep features*) memiliki kemampuan representasi yang lebih baik dibandingkan histogram warna.

Performa terbaik diperoleh pada model *Hybrid ResNet50-SVM*. Distribusi kesalahan klasifikasi menjadi semakin kecil pada seluruh kelas, khususnya pada kelas Air Jernih dan Air Kotor. Hasil tersebut menunjukkan bahwa fitur yang dihasilkan *ResNet50* mampu merepresentasikan karakteristik visual citra secara lebih lengkap, sedangkan *SVM* mampu memanfaatkan representasi tersebut untuk membentuk batas keputusan yang lebih efektif sehingga kesalahan klasifikasi dapat diminimalkan. Berikut gambar 8 perbandingan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Ketiga Model yang dilampirkan.



Gambar 8. Perbandingan Accuracy, Precision, Recall, dan F1-Score

Perbandingan metrik evaluasi menunjukkan bahwa setiap pengembangan metode memberikan peningkatan performa yang konsisten. Peralihan dari *SVM* Murni menuju *ResNet50* Murni menghasilkan peningkatan yang cukup besar pada seluruh metrik evaluasi. Selanjutnya, penggantian pengklasifikasi *Softmax* dengan *SVM* kembali meningkatkan nilai *Accuracy*, *Precision*, *Recall*, maupun *F1-Score*. Pola tersebut menunjukkan bahwa peningkatan performa tidak hanya dipengaruhi oleh kualitas fitur yang dihasilkan *ResNet50*, tetapi juga oleh kemampuan *SVM* dalam memanfaatkan fitur tersebut selama proses klasifikasi. Berikut Tabel 7 Analisis Peningkatan Performa Antar Model.

Tabel 7. Analisis Peningkatan Performa Antar Model.

Perbandingan Model	Peningkatan Accuracy	Interpretasi
Hybrid ResNet50 + SVM vs ResNet50 Murni (Softmax)	+3,33%	Penggunaan SVM sebagai pengklasifikasi menghasilkan performa yang lebih baik dibandingkan Softmax pada fitur yang sama.
Hybrid ResNet50 + SVM vs SVM Murni	+12,22%	Ekstraksi fitur ResNet50 menghasilkan representasi citra yang jauh lebih baik dibandingkan fitur histogram konvensional.

Berdasarkan Tabel 7, model Hybrid ResNet50-SVM menunjukkan performa terbaik dibandingkan model pembanding. Peningkatan akurasi terbesar berasal dari penggunaan ResNet50 sebagai feature extractor, yang meningkatkan akurasi sebesar 12,22% dibandingkan SVM murni, karena mampu menghasilkan representasi fitur yang lebih kaya dibandingkan fitur histogram. Sementara itu, penggantian lapisan klasifikasi Softmax dengan SVM memberikan tambahan peningkatan akurasi sebesar 3,33%, menunjukkan bahwa SVM mampu memanfaatkan fitur ResNet50 secara lebih optimal melalui pembentukan decision boundary yang efektif. Secara keseluruhan, ResNet50 dan SVM menghasilkan kinerja klasifikasi terbaik pada seluruh metrik evaluasi, sehingga membuktikan bahwa pendekatan hybrid lebih efektif dibandingkan penggunaan masing-masing metode secara terpisah dalam klasifikasi kualitas air berbasis citra.

Sebagai pembuktian akhir atas implementasi sistem pengenalan kualitas air secara otomatis, dilakukan pengujian visual dengan memberikan sampel citra air secara langsung kepada model terbaik, yakni *Hybrid ResNet50 + SVM*. Sistem dirancang untuk menerima input citra, mengekstrak fitur semantik mendalam melalui lapisan konvolusi *ResNet50*, mengklasifikasikannya menggunakan *Support Vector Machine*, dan menguraikan probabilitas keyakinan untuk setiap kelas yakni Air Jernih, Air Keruh, dan


Air Kotor seperti pada gambar 9 sebagai berikut.



Gambar 9. Sampel Hasil Pengujian Prediksi model Hybrid ResNet50 SVM

Berdasarkan visualisasi hasil prediksi yang di tunjukkan pada gambar 9, model Hybrid ResNet50-SVM menunjukkan kemampuan generalisasi yang baik dalam mengenali karakteristik visual setiap kelas kualitas air. Pada kelas Air Jernih, model menghasilkan tingkat keyakinan prediksi hingga 94,1% dan 75,6%, sedangkan pada kelas Air Kotor seluruh sampel berhasil diklasifikasikan dengan benar dengan tingkat keyakinan di atas 97,8%. Hasil ini menunjukkan bahwa ResNet50 mampu mengekstraksi fitur visual seperti tekstur dan pola partikel secara efektif, sementara SVM memanfaatkan fitur tersebut untuk membedakan kelas yang memiliki karakteristik visual berdekatan. Dengan demikian, model hybrid mampu meningkatkan kemampuan klasifikasi, terutama pada kelas Air Kotor yang sebelumnya menjadi tantangan pada model SVM murni.

Adapun visualisasi terkait tingkat keyakinan model dalam proses klasifikasi pada data citra air untuk masing masing kelas dipaparkan pada gambar 10 dibawah.



Gambar 10. Distribusi Probabilitas Keyakinan pada Klasifikasi

Meskipun model Hybrid ResNet50-SVM mencapai akurasi keseluruhan 86,67%, telaah analitik terhadap misclassification (kesalahan prediksi) tetap krusial. Berdasarkan Gambar 10, terdapat anomali di mana satu sampel citra Air Kotor terprediksi keliru sebagai Air Jernih dengan probabilitas tertinggi 47,1%. Apabila dianalisis dari sudut pandang fisis dan karakteristik optik, anomali ini sangat dipengaruhi oleh fenomena refraksi cahaya dan pantulan dari kumpulan busa pekat (foam reflection) di permukaan air kotor tersebut. Kumpulan busa menghasilkan spektrum warna putih dengan intensitas kecerahan sangat tinggi yang mendominasi

fitur spasial citra. ResNet50 merespons intensitas putih terang ini sebagai feature map yang menyerupai tingkat transparansi dan pantulan cahaya matahari natural yang biasa ditemukan di kelas Air Jernih. Kegagalan optik semacam ini membuktikan bahwa batas keputusan pada fitur tekstur transparan masih rentan terganggu oleh objek polutan berwarna kontras cerah.

Secara keseluruhan, capaian akurasi model Hybrid (86,67%) menunjukkan daya saing yang sangat unggul (competitive state-of-the-art) dalam konteks riset sejenis. Evaluasi literatur memperlihatkan bahwa klasifikasi kualitas air dengan CNN/ResNet50 tanpa intervensi arsitektur klasifikasi tambahan (murni Softmax) cenderung tertahan pada akurasi 82-84% akibat bias kelas transisional [8],[6]. Penyatuan deep feature extraction dan SVM terbukti meningkatkan sensitivitas deteksi (terutama pergeseran Recall yang naik drastis di kelas Air Keruh), mengukuhkan bahwa transisi optis air memerlukan pembentukan hyperplane geometris (SVM) alih-alih mengandalkan probabilitas empiris semata (Softmax).

KESIMPULAN

Penelitian ini menyimpulkan bahwa model Hybrid ResNet50-SVM terbukti lebih efektif dan robust dalam mengklasifikasikan tingkat kekeruhan air (Air Jernih, Air Keruh, dan Air Kotor) dibandingkan arsitektur tunggal. Ekstraksi fitur visual laten berdimensi 2048 oleh ResNet50 yang dikombinasikan dengan pengklasifikasi hyperplane SVM Linear ($C=0,1$) berhasil mengatasi kelemahan Softmax, menghasilkan akurasi cross-validation terbaik 90,28% serta performa pengujian dengan Accuracy 86,67%, Precision 88,03%, Recall 86,67%, dan F1-Score 86,77%. Kinerja ini secara signifikan mengungguli ResNet50-Softmax (83,33%) dan SVM histogram (74,44%) dalam mengenali pola kelas transisional yang ambigu. Meskipun sangat andal, penelitian ini masih memiliki limitasi pada skala dataset yang kecil (450 citra) dan kerentanan terhadap ilusi optik variasi pencahayaan (foam reflection). Oleh karena itu, penelitian lanjutan disarankan untuk menerapkan data augmentation masif serta mengintegrasikan algoritma ini ke dalam sistem Internet of Things (IoT) pada kamera lapangan (edge computing) guna mewujudkan pemantauan kualitas sungai secara real-time, efisien, dan kontinu.

Pernyataan Mengenai Penggunaan Kecerdasan Buatan (AI)

Dalam penyiapan naskah artikel ini, penulis memanfaatkan perangkat kecerdasan buatan (*Artificial Intelligence*) secara terbatas sebagai sarana penunjang untuk menyempurnakan struktur tata bahasa, memperbaiki perangkaian kalimat, serta memperjelas maksud penyampaian. Teknologi AI ini sama sekali tidak menggantikan proses inti penelitian, pengolahan data, maupun analisis ilmiah. Seluruh substansi teks yang mendapatkan sentuhan AI telah melalui proses peninjauan, verifikasi, dan penyesuaian menyeluruh oleh penulis agar tetap selaras dengan hasil eksperimen yang sebenarnya. Penulis memegang penuh tanggung jawab atas keakuratan, keaslian, serta integritas dari keseluruhan isi naskah yang dipublikasikan.

Konflik Kepentingan

Penulis secara tegas menyatakan bahwa tidak terdapat segala bentuk potensi konflik kepentingan, baik yang bersifat finansial, institusional, maupun personal, yang dapat mempengaruhi arah substansi penelitian ataupun proses publikasi artikel ini.

Kontribusi Penulis

Tegar Surya Prayoga memegang tanggung jawab utama dalam keseluruhan rangkaian penelitian, meliputi perancangan riset, pengembangan sistem, pengolahan data, implementasi metode *Hybrid* ResNet50-SVM, analisis hasil evaluasi, hingga penyusunan draf naskah. Emil Agusalim Habi Talib dan Muhammad Faisal berperan aktif dalam memberikan arahan strategis penelitian, melakukan peninjauan kritis terhadap hasil pengujian model, serta memberikan masukan konstruktif untuk menyempurnakan kualitas naskah. Seluruh penulis menyatakan telah membaca secara menyeluruh dan menyetujui versi final artikel ini untuk diterbitkan.

Ucapan Terima Kasih

Rasa terima kasih yang mendalam disampaikan kepada Universitas Muhammadiyah Makassar, khususnya kepada Fakultas Teknik dan Program Studi Informatika, atas fasilitas, lingkungan akademik, serta dukungan penuh yang diberikan selama pelaksanaan penelitian. Penghargaan serta ucapan terima kasih juga penulis haturkan kepada dosen pembimbing atas segala arahan, bimbingan, dan masukan berharga yang sangat membantu kelancaran penyelesaian riset dan naskah ini. Ucapan terima kasih turut disampaikan kepada seluruh pihak yang telah memberikan bantuan, baik secara moral maupun teknis, hingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] M. Mustapha *et al.*, "A hybrid machine learning approach for imbalanced irrigation water quality classification," *Desalin. Water Treat.*, vol. 321, no. November 2024, p. 100910, 2025, doi: 10.1016/j.dwt.2024.100910.
- [2] M. A. A. M. Hridoy *et al.*, "Advanced machine learning models for accurate water quality classification and WQI prediction: Implications for aquatic disease risk management," *Sci. Total Environ.*, vol. 1008, no. November, p. 180965, 2025, doi: 10.1016/j.scitotenv.2025.180965.
- [3] J. S. Mugunthan, C. R. Duguay, and E. Zakharova, "Machine learning based classification of lake ice and open water from Sentinel-3 SAR altimetry waveforms," *Remote Sens. Environ.*, vol. 299, no. April, p. 113891, 2023, doi: 10.1016/j.rse.2023.113891.
- [4] B. L. Nkuna, K. Abutaleb, J. G. Chirima, S. W. Newete, A. J. van der Walt, and A. Nyamugama, "Identification of maize leaf diseases using red, green, blue-based images with convolutional neural network (CNN) and residual network (ResNet50) models," *Smart Agric. Technol.*, vol. 12, no. July, p. 101226, 2025, doi: 10.1016/j.atech.2025.101226.
- [5] W. M. Salama and M. H. Aly, "Brain tumor segmentation and classification: A CVAE-UNETR-ResNet50-VGG16 hybrid deep learning approach," *Alexandria Eng. J.*, vol. 135, no. September 2025, pp. 433–449, 2026, doi: 10.1016/j.aej.2026.01.003.
- [6] N. Sebastian, "Enhanced ResNet-50 with Multi-Feature Fusion for Robust Detection of Pneumonia in Chest X-Ray Images," 2025.
- [7] Y. Yuan *et al.*, "Water Body Identification from Satellite Images Using a Hybrid Evolutionary Algorithm-Optimized U-Net Framework," pp. 1–17, 2025.
- [8] N. Nuraeni, "Klasifikasi dengan metode Support Vector Machine (SVM) dalam menentukan kualitas air minum," vol. 3, pp. 2248–2258, 2025.