

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

SKRIPSI

*Diajukan Untuk Memenuhi Syarat Memperoleh Gelar Sarjana Komputer (S.Kom)
Informatika Fakultas Teknik Universitas Muhammadiyah Makassar*



TEGAR SURYA PRAYOGA

105841106222

**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MUHAMMADIYAH MAKASSAR**

2026

HALAMAN JUDUL

Analisis Klasifikasi Tingkat Kekeruhan Air Berbasis Citra Menggunakan *Hybrid Resnet50 Dan Support Vector Machine*

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Program
Studi Informatika (S.Kom)

Disusun Dan Diajukan Oleh

TEGAR SURYA PRAYOGA

105841106222

**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MUHAMMADIYAH MAKASSAR
2026**



MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
FAKULTAS TEKNIK



HALAMAN PENGESAHAN

Tugas Akhir ini diajukan untuk memenuhi syarat ujian guna memperoleh gelar Sarjana Komputer (S.Kom) Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.

Judul Skripsi : **ANALISIS KLASIFIKASI TINGKAT KEKERUHAN AIR BERBASIS CITRA MENGGUNAKAN HYBRID RESNET50 DAN SUPPORT VECTOR MACHINE**

Nama : TEGAR SURYA PRAYOGA

Stambuk : 105 84110 6222

Makassar, 19 Agustus 2026

Telah Diperiksa dan Disetujui
Oleh Dosen Pembimbing;

Pembimbing I

Emil Agusalim Habi Talib, S.Pd., M.Eng

Pembimbing II

H. Muhammad Faisal, S.Si., M.T., Ph.D., IPM

Mengetahui,

Ketua Prodi Informatika



Rizki Yustiana Bakti, S.T., M.T.

NBM : 1307 284





MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
FAKULTAS TEKNIK



PENGESAHAN

Skripsi atas nama TEGAR SURYA PRAYOGA dengan nomor induk Mahasiswa 105 84 11062 22, dinyatakan diterima dan disahkan oleh Panitia Ujian Tugas Akhir/Skripsi sesuai dengan Surat Keputusan Dekan Fakultas Teknik Universitas Muhammadiyah Makassar Nomor: 0008/SK-Y/55202/091004/2026, sebagai salah satu syarat guna memperoleh gelar Sarjana Komputer pada Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar pada hari Rabu, 19 Agustus 2026.

Panitia Ujian :

1. Pengawas Umum

Makassar,

6 Rabiul Awal 1448 H

19 Agustus 2026

a. Rektor Universitas Muhammadiyah Makassar

Dr. Ir. H. Abd. Rakhim Nanda, ST, MT, IPU

b. Dekan Fakultas Teknik Universitas Hasanuddin

Prof. Dr. Eng. Muhammad Isran Ramli, S.T., M.T., ASEAN, Eng

2. Penguji

a. Ketua : Prof. Dr. Ir. Hafsah Nirwana, M.T

b. Sekretaris : Lukman Anas, S.Kom., M.T

3. Anggota

: 1. Fahrin Irfhamna Rachman, S.Kom., M.T

2. Rizki Yushiana Bakti, S.T., M.T

3. Damiaty, S.Kom., M.T

Mengetahui :

Pembimbing I

Emil Agusalim Habi Talib, S.Pd., M.Eng

Pembimbing II

Ir. Muhammad Faisal, S.Si., M.T., Ph.D., IPM

Dekan



Ir. Muh. Syafaat S. Kuba, S.T., M.T.

NBM : 795288

Gedung Menara Iqra Lantai 3

Jl. Sultan Alauddin No. 259 Telp. (0411) 866 972 Fax (0411) 865 588 Makassar 90221

Web: <https://teknik.unismuh.ac.id/>, e-mail: teknik@unismuh.ac.id



MOTTO DAN PERSEMBAHAN

MOTTO

Jangan menjadikan kesulitan sebagai alasan untuk berhenti melangkah. Percayalah bahwa setiap proses yang dijalani dengan sabar, ikhtiar, dan doa akan membawa seseorang menuju hasil terbaik. Ketika jalan terasa berat dan hasil belum sesuai harapan, tetaplah yakin kepada Allah SWT, karena setiap perjuangan memiliki waktu dan hikmahnya sendiri. Teruslah berusaha, belajar dari kesalahan, dan jangan menyerah sebelum perjuangan benar-benar selesai.

“Barangsiapa bersungguh-sungguh, maka ia akan memperoleh apa yang diusahakannya.”

Imam Syafi'i

PERSEMBAHAN

Dengan mengucapkan puji dan syukur ke hadirat Allah SWT atas segala rahmat, nikmat, kekuatan, dan kemudahan yang telah diberikan, karya sederhana ini saya persembahkan kepada kedua orang tua tercinta yang senantiasa menjadi sumber doa, kasih sayang, dukungan, dan semangat dalam setiap langkah yang saya tempuh. Kepada keluarga tercinta, terima kasih atas perhatian dan dukungan yang selalu diberikan selama proses pendidikan dan penyelesaian skripsi ini.

Kepada dosen pembimbing dan seluruh dosen Program Studi Informatika, saya sampaikan terima kasih atas ilmu, arahan, bimbingan, kritik, dan saran yang telah diberikan sehingga penelitian ini dapat diselesaikan dengan baik. Terakhir, karya ini saya persembahkan kepada diri saya sendiri sebagai bentuk penghargaan atas keberanian untuk memulai, kesabaran dalam menjalani setiap proses, serta keteguhan untuk tetap bertahan hingga sampai pada tahap ini. Semoga skripsi ini menjadi bukti bahwa setiap usaha, doa, dan perjuangan yang dilakukan dengan sungguh-sungguh akan memiliki makna.

ABSTRAK

TEGAR SURYA PRAYOGA, 2026. Analisis Klasifikasi Tingkat Kekeruhan Air Berbasis Citra Menggunakan *Hybrid Resnet50* Dan *Support Vector Machine* (Dibimbing Oleh Emil Agusalim Habi Talib, S.Pd., M.Eng Dan Ir. Muhammad Faisal, S.SI.,M.T., Ph.D., IPM)

Kualitas air merupakan salah satu aspek penting yang perlu dipantau, salah satunya melalui tingkat kekeruhan yang dapat diamati secara visual. Penelitian ini bertujuan mengembangkan model klasifikasi tingkat kekeruhan air berbasis citra menggunakan pendekatan *Hybrid ResNet50* dan *Support Vector Machine (SVM)*. Dataset penelitian terdiri dari 450 citra yang terbagi secara seimbang ke dalam tiga kelas, yaitu Air Jernih, Air Keruh, dan Air Kotor. Tahapan penelitian meliputi preprocessing citra berupa *resize* menjadi 224×224 piksel dan normalisasi, ekstraksi fitur menggunakan *ResNet50* dengan *Transfer Learning ImageNet*, serta klasifikasi menggunakan *SVM Linear*. *ResNet50* menghasilkan representasi fitur berdimensi 2048 yang kemudian digunakan sebagai masukan bagi *SVM* dengan parameter $C=0,1$. Evaluasi dilakukan menggunakan *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan Confusion Matrix pada 90 data uji. Hasil penelitian menunjukkan bahwa model *Hybrid ResNet50-SVM* memperoleh *Accuracy* sebesar 86,67%, *Precision* 88,03%, *Recall* 86,67%, dan *F1-Score* 86,77%, dengan akurasi *cross-validation* terbaik sebesar 90,28%. Model *hybrid* juga menunjukkan performa lebih tinggi dibandingkan *ResNet50* dengan Softmax yang memperoleh *Accuracy* 83,33% dan *SVM* berbasis fitur histogram sebesar 74,44%. Dengan demikian, kombinasi *ResNet50* sebagai ekstraktor fitur dan *SVM* sebagai pengklasifikasi terbukti mampu meningkatkan kinerja klasifikasi tingkat kekeruhan air berbasis citra serta memberikan hasil yang lebih baik dibandingkan metode pembandingan.

Kata kunci: Kekeruhan air, klasifikasi citra, *ResNet50*, *Support Vector Machine*, *deep learning*.

KATA PENGANTAR

Puji Syukur atas kehadiran Allah SWT karena dengan Rahmat dan izin-Nya, salam serta shalawat tak lupa kami haturkan kepada Nabi Muhammad SAW serta dukungan dan peran dari orangtua, keluarga yang senantiasa memberikan semangat sehingga proposal yang disusun oleh peneliti yang berjudul “Analisis Klasifikasi Tingkat Kekeruhan Air Berbasis Citra Menggunakan *Hybrid ResNet50* Dan *Support Vector Machine*” dapat di selesaikan oleh peneliti sebagai syarat untuk memenuhi penyusunan tugas akhir Prodi Informatika. Salawat dan salam tak lupa dihaturkan kepada Nabi yang menjadi suri tauladan yakni Nabi Muhammad SAW yang membawa peradaban dari kegelapan menuju ke terang menerang seperti saat ini dengan kata lain *Minadzulumati ilannur*.

Peneliti menyadari bahwa dalam proses penyusunan proposal penelitian ini bukan lah menjadi akhir dari sebuah pembelajaran, peneliti juga memahami bahwa proposal yang disusun masih sangat jauh dari kata sempurna dari segala aspek yang disebabkan keterbatasan pengetahuan dan pemahaman peneliti. Untuk itu peneliti mengucapkan permohonan maaf yang sebesar besarnya atas segala keterbatasan tersebut. Dan mengharapkan saran, kritik serta masukan yang dapat menjadi motivasi bagi peneliti kedepannya

Peneliti juga tidak lupa mengucapkan terima kasih terhadap pihak pihak yang memberikan arahan dan masukan dalam proses penyusunan skripsi ini, khususnya kepada:

1. Bapak **Dr. Ir. H. Abd Rakhim Nanda, S.T., M.T IPU.** sebagai Rektor Universitas Muhammadiyah Makassar.
2. Bapak **Ir. Muhammad Syafaat S. Kuba, S.T., M.T** Sebagai Dekan Fakultas Teknik Universitas Muhammadiyah Makassar.
3. Ibu **Rizki Yusliana Bakti, S.T., M.T.** sebagai Ketua Prodi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.
4. Bapak **Emil Agusalim Habi Talib, S.Pd., M.Eng** dan **Ir. Muhammad Faisal, S.SI.,M.T., Ph.D., IPM** selaku dosen yang memberikan bimbingan serta arahan dalam proses penyelesaian tugas akhir ini.

5. Segenap Bapak/Ibu Dosen Program studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar Dimana telah menyalurkan pengalaman dan pengetahuan pengetahuan serta mendidik penulis selama proses belajar mengajar di Universitas Muhammadiyah Makassar.
6. Rekan - rekan mahasiswa utamanya dari Angkatan 2022 Prodi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar terima kasih atas dukungan dan kerjasamanya selama menempuh Pendidikan serta penyelesaian penyusunan proposal skripsi ini.
7. Teman Teman seperjuangan saya, Terima kasih atas dukungan dan kerjasamanya selama menempuh Pendidikan serta penyelesaian penyusunan skripsi ini.
8. Terakhir, terima kasih untuk diri sendiri, karena telah mampu berusaha keras dan berjuang sampai sejauh ini.

Semoga pihak pihak yang disebutkan diatas serta pihak yang tidak sempat disebutkan oleh peneliti meraih keridhohan disisi Allah SWT dan skripsi yang menjadi tugas akhir ini mampu memerikan dampak positif bagi peneliti, keluarga dan rekan serta masyarakat indonesia. Aamiin

Billahi Fisabilhaq, Fastabiqul Khairat.

Wassalamualaikum Wr. Wb.

Makassar, 1 April 2026

Tegar Surya Prayoga

DAFTAR ISI

KATA PENGANTAR.....	vii
DAFTAR ISI	ix
DAFTAR GAMBAR	xi
DAFTAR TABEL.....	xii
DAFTAR ISTILAH	xiii
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah	5
C. Tujuan Penelitian.....	5
D. Manfaat Penelitian	5
E. Ruang Lingkup Penelitian.....	6
F. Sistematika Penulisan	7
BAB II TINJAUAN PUSTAKA	8
A. Landasan Teori	8
B. Penelitian Terkait.....	19
C. Kerangka Berpikir.....	20
BAB III METODE PENELITIAN.....	22
A. Tempat dan waktu penelitian	22
B. Alat dan bahan.....	22
C. Perancangan system	23
D. Teknik pengujian system.....	25
BAB IV HASIL DAN PEMBAHASAN.....	27
A. Pengumpulan Data	27
B. Preprocessing Data.....	30
C. Implementasi Model Hybrid Resnet50 dan SVM.....	33
D. Pelatihan Model <i>Resenet50</i> Sebagai <i>Baseline</i>	50
E. Pelatihan Model <i>Support Vector Machine</i> sebagai <i>Baseline</i>	58
F. Analisis Komparatif dan Evaluasi Menyeluruh Model Klasifikasi	64

G. Hasil Pengujian Prediksi Pada <i>Hybrid Resnet50</i> Dan <i>SVM</i>	68
BAB V KESIMPULAN	71
A. KESIMPULAN	71
B. SARAN	72
DAFTAR PUSTAKA	74
LAMPIRAN.....	77



DAFTAR GAMBAR

Gambar 1. Ilustrasi <i>Resnet50</i> pada klasifikasi air	12
Gambar 2. Ilustrasi <i>SVM</i> pada klasifikasi air	14
Gambar 3. Ilustrasi <i>hybrid ResNet50 dan SVM</i>	17
Gambar 4. Kerangka Pikir.....	21
Gambar 5. <i>Flowchart</i> sistem klasifikasi Air <i>Resnet50 dan SVM</i>	25
Gambar 6. Distribusi jumlah gambar per kelas.....	28
Gambar 7. Sampel data tiap kategori	29
Gambar 8. Perbandingan sebelum dan sesudah <i>resize</i>	31
Gambar 9. Perbandingan hasil <i>resize</i> dan hasil degradasi	33
Gambar 10. Visualisasi <i>Confusion matrix</i>	43
Gambar 11. Visualisasi nilai tiap kelas	47
Gambar 12. <i>Learning Curve</i>	52
Gambar 13. <i>Confusion matrix Resnet50</i>	54
Gambar 14. Metrik per kelas.....	56
Gambar 15. Grafik TP,TN,FP, dan FN per kelas.....	57
Gambar 16. <i>Confusion matrix model SVM</i>	60
Gambar 17. Distribusi TP,TN,FP, dan FN Model <i>SVM</i>	61
Gambar 18. Matrix Evaluasi Per Kelas.....	63
Gambar 19. Perbandingan <i>CF SVM, Resnet50, Dan Hybrid</i>	65
Gambar 20. Perbandingan <i>Accuracy, precision, recall, F1-Score</i>	66
Gambar 21. Sampel Hasil Pengujian Prediksi model <i>Hybrid</i>	68
Gambar 22. Distribusi Probabilitas Keyakinan Pada Klasifikasi	69

DAFTAR TABEL

Tabel 1. Penelitian terdahulu.....	19
Tabel 2. Hasil evaluasi model <i>hybrid Resnet50-Svm</i>	42
Tabel 3. Intrepretasi ilmiah	44
Tabel 4. Distribusi Nilai TP,TN,FP, dan FN.....	48
Tabel 5. Hasil Evaluasi Setiap Kelas.....	49
Tabel 6. Ringkasan Performa Model <i>Resnet50</i>	53
Tabel 7. <i>Confusion matrix Resnet50</i>	55
Tabel 8. Matrix Evaluasi per kelas	56
Tabel 9. Detail nilai TP,TN,FP, dan FN.....	58
Tabel 10. Pelatihan model <i>SVM</i>	59
Tabel 11. Hasil <i>Confusion matrix</i> Model <i>SVM</i>	60
Tabel 12. Distribusi TP,TN,FP, Dan FN.....	62
Tabel 13. Matrix Evaluasi Per Kelas.....	63
Tabel 14. Perbandingan Performa Keseluruhan Antar Model	64
Tabel 15. Analisis Peningkatan Performa Antar Model	67

DAFTAR ISTILAH

Hyperlane

Garis (pada 2D) atau bidang (pada dimensi lebih tinggi) yang digunakan oleh algoritma *SVM* untuk memisahkan data ke dalam beberapa kelas. *Hyperplane* ini berfungsi sebagai batas keputusan terbaik yang memaksimalkan jarak (margin) antara kelas yang berbeda.

ReLU

Fungsi aktivasi pada *hidden layer* yang mengubah nilai negatif menjadi 0 dan membiarkan nilai positif apa adanya.

Margin

jarak antara *hyperplane* dengan titik data terdekat dari masing-masing kelas (*support vector*). *SVM* berusaha memaksimalkan margin agar model memiliki akurasi dan generalisasi yang lebih baik.

Pooling

proses dalam *CNN* yang digunakan untuk mengurangi ukuran fitur (*feature map*) tanpa menghilangkan informasi penting. Teknik ini membantu mempercepat komputasi dan mengurangi risiko *overfitting*.

Dataset

Kumpulan data yang digunakan untuk melatih dan menguji model *machine learning*.

Convolution layer

lapisan pada *CNN* yang berfungsi mengekstraksi fitur dari citra seperti tepi, warna, dan tekstur menggunakan filter (*kernel*).

Polynomial

metode yang digunakan untuk menangani data yang tidak dapat dipisahkan secara garis lurus.

Image Preprocessing

tahap awal pengolahan citra sebelum digunakan oleh model. Proses ini bertujuan untuk memperbaiki kualitas gambar dan menyesuaikan format agar lebih optimal untuk analisis.

Confusion matrix

tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi dan data sebenarnya. Tabel ini menunjukkan jumlah prediksi benar dan salah pada setiap kelas.

Machine learning

Cabang kecerdasan buatan yang berfokus pada penggunaan algoritma untuk mempelajari pola data.

SVM

algoritma *machine learning* yang digunakan untuk klasifikasi dengan memisahkan data ke dalam beberapa kelas.

Resnet50

model *deep learning* berbasis *CNN* yang digunakan untuk mengenali dan mengekstraksi fitur dari citra. Model ini memiliki 50 lapisan dan menggunakan *shortcut connection* untuk meningkatkan akurasi serta mengatasi masalah pelatihan jaringan dalam.



BAB I

PENDAHULUAN

A. Latar Belakang

Air merupakan sumber daya alam yang sangat penting sehingga menjadi elemen vital bagi keberlangsungan hidup manusia dan makhluk hidup lainnya. Air digunakan dalam berbagai aktivitas kehidupan sehari-hari seperti konsumsi, pertanian, serta kebutuhan domestik lainnya. Selain itu, air juga memiliki peranan penting dalam sektor publik seperti rumah sakit, industri, dan fasilitas umum yang membutuhkan ketersediaan air dalam jumlah besar dengan kualitas yang baik. Dalam dunia industri, air digunakan sebagai bahan baku produksi, pendingin mesin, hingga proses pembersihan (Mustapha et al., 2025). Sementara itu, pada sektor kesehatan seperti rumah sakit, air yang bersih dan layak menjadi faktor penting dalam menjaga kebersihan lingkungan serta mendukung pelayanan medis yang optimal. Oleh karena itu, keberadaan air yang berkualitas menjadi aspek yang sangat penting dalam menunjang kehidupan manusia secara menyeluruh (Hridoy et al., 2025).

Kualitas air menjadi faktor utama yang menentukan apakah air layak digunakan atau tidak. Air bersih memiliki manfaat besar bagi kesehatan manusia, lingkungan, serta aktivitas industri. Sebaliknya, air yang terkontaminasi atau memiliki kualitas buruk dapat menimbulkan berbagai dampak negatif seperti penyebaran penyakit, pencemaran lingkungan, hingga gangguan pada proses produksi industri (Mugunthan et al., 2023). Salah satu indikator fisik yang dapat digunakan untuk menilai kualitas air adalah tingkat kekeruhan. Air yang jernih umumnya menunjukkan kualitas yang baik, sedangkan air yang keruh sering kali mengandung partikel tersuspensi seperti lumpur, bahan organik, maupun mikroorganisme yang berpotensi membahayakan kesehatan. Oleh karena itu, pemantauan kualitas air secara berkala sangat penting untuk memastikan air yang digunakan memenuhi standar kesehatan dan lingkungan (Nkuna et al., 2025).

Namun, dalam praktiknya masih terdapat berbagai permasalahan terkait kualitas air, seperti sulitnya akses terhadap air bersih serta penurunan kualitas air akibat pencemaran lingkungan. Banyak masyarakat yang masih mengandalkan penilaian visual secara manual untuk menentukan kualitas air, yang bersifat subjektif dan tidak memiliki standar pengukuran yang pasti (Mustapha et al., 2025). Hal ini dapat menyebabkan kesalahan dalam pengambilan keputusan, seperti penggunaan air yang sebenarnya tidak layak konsumsi. Selain itu, metode pengukuran menggunakan alat laboratorium seperti turbidimeter memang lebih akurat, tetapi memiliki keterbatasan dari segi biaya, waktu, serta kebutuhan tenaga ahli dalam pengoperasiannya. Kondisi tersebut menunjukkan adanya kesenjangan antara kebutuhan pemantauan kualitas air yang akurat dengan keterbatasan metode yang tersedia saat ini (Mugunthan et al., 2023).

Seiring dengan perkembangan teknologi, berbagai solusi mulai dikembangkan untuk mengatasi permasalahan tersebut, salah satunya melalui pemanfaatan teknologi pengolahan citra dan kecerdasan buatan. Teknologi ini memungkinkan sistem komputer untuk menganalisis kualitas air berdasarkan citra atau gambar secara otomatis (Salama & Aly, 2026). Dengan memanfaatkan metode *ResNet50* sebagai ekstraktor fitur serta *Support Vector Machine (SVM)* sebagai algoritma klasifikasi, diharapkan sistem dapat mengidentifikasi tingkat kekeruhan air secara lebih akurat dan efisien. Pendekatan *hybrid* antara *ResNet50* dan *SVM* diharapkan mampu meningkatkan performa klasifikasi serta memberikan solusi alternatif dalam pemantauan kualitas air secara otomatis, cepat, dan ekonomis (Vishal et al., 2025).

Guna mengatasi hambatan dalam ekstraksi fitur visual yang kompleks tersebut, penggunaan teknik *deep learning* dengan arsitektur *ResNet50* menawarkan solusi yang sangat efektif. Arsitektur *ResNet50* dikenal memiliki kemampuan luar biasa dalam mempelajari karakteristik citra yang mendalam, mulai dari warna, tekstur, hingga pola visual yang spesifik berkaitan dengan tingkat kekeruhan air. Namun, meskipun *ResNet50* sangat andal dalam mengambil fitur (*feature extractor*), penggunaan lapisan klasifikasi standar pada

arsitektur aslinya sering kali kurang optimal dalam menangani pemisahan kelas pada dataset yang memiliki batas keputusan yang rumit. Hal ini memicu perlunya algoritma tambahan yang lebih tangguh untuk melakukan klasifikasi akhir berdasarkan fitur yang telah diekstraksi tersebut (Nkuna et al., 2025).

Beberapa penelitian terdahulu telah berupaya mengatasi tantangan pemantauan kualitas air melalui berbagai pendekatan komputasi yang beragam. Studi dalam *International Journal of Advances in Data and Information Systems* menunjukkan bahwa algoritma klasifikasi seperti *K-Nearest Neighbor* (KNN) mampu mengidentifikasi kelayakan air secara fungsional (Kusumawati et al., 2023). Namun, penelitian tersebut juga mengungkapkan adanya keterbatasan dalam menangani *dataset* yang memiliki kompleksitas fitur tinggi, sehingga performanya cenderung menurun pada data citra yang bervariasi (Buah, 2023).

Sementara itu, aspek teknis dalam penyiapan data citra menjadi perhatian utama para peneliti untuk meningkatkan presisi hasil klasifikasi. Penelitian yang dilakukan sebelumnya (Syaukani et al., 2025) menekankan pentingnya tahap *preprocessing*, seperti penggunaan *Gaussian Filtering*, untuk mereduksi *noise* pada citra air agar fitur-fitur kekeruhan dapat diekstraksi dengan lebih jelas. Hal ini sejalan dengan analisis pada jurnal *AIM (Advances in Information and Management)* yang membuktikan bahwa penggunaan teknologi *Deep Learning* mampu memberikan akurasi yang lebih stabil dibandingkan metode statistik konvensional dalam mengenali pola pencemaran air secara otomatis (Ardana, 2025).

Efektivitas sistem klasifikasi sangat bergantung pada kemampuan model dalam mengenali karakteristik visual objek secara spesifik. Temuan pada jurnal (Artikel & Udjulawa, 2021) menyoroti bahwa pemilihan ekstraktor fitur yang mampu menangkap gradasi warna dan tekstur air secara mendalam merupakan faktor penentu keberhasilan klasifikasi. Secara keseluruhan, literatur tersebut menunjukkan bahwa meskipun metode cerdas telah mulai diterapkan, integrasi model ekstraksi fitur yang canggih dengan algoritma klasifikasi yang tangguh

tetap menjadi kunci utama untuk menghasilkan sistem pemantauan kualitas air yang presisi dan reliabel.

Sebagai solusi untuk memperkuat tahap klasifikasi, metode *Support Vector Machine (SVM)* dapat diintegrasikan karena kemampuannya yang sangat baik dalam memisahkan kelas data berdasarkan *hyperplane* optimal. Kombinasi antara *ResNet50* sebagai penyedia fitur dan *SVM* sebagai pengklasifikasi (*classifier*) membentuk sebuah pendekatan *hybrid* yang secara teoretis dapat meningkatkan performa sistem secara signifikan dibandingkan hanya menggunakan satu metode saja. Dari penggabungan kedua metode ini pada objek spesifik citra air belum banyak dieksplorasi secara mendalam. Dibutuhkan sebuah pengujian empiris untuk memastikan bahwa model *hybrid* ini tetap stabil dan akurat ketika dihadapkan pada variasi citra air di lapangan (Alzoubi et al., 2026).

Berdasarkan urgensi tersebut, penelitian ini diusulkan untuk mengembangkan sebuah sistem klasifikasi cerdas melalui judul Analisis Klasifikasi Tingkat Kekeruhan Air Berbasis Citra Menggunakan *Hybrid ResNet50* dan *Support Vector Machine*. Penelitian ini akan berfokus pada penerapan model *hybrid ResNet50-SVM* (Wijaya et al., 2025) dalam mengolah dataset citra air untuk mengenali tingkat kekeruhan secara otomatis. Masalah yang kemudian perlu dijawab adalah sejauh mana performa akurasi yang dapat dihasilkan oleh model ini dalam mengategorikan berbagai tingkat kondisi air secara presisi dan konsisten (Vishal et al., 2025).

Pada tahap akhir, penelitian ini diharapkan dapat mengklasifikasikan citra air ke dalam tiga kategori utama, yaitu Air Jernih, Air Keruh, Dan Air Kotor Evaluasi menyeluruh akan dilakukan menggunakan metrik *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score* untuk membuktikan keandalan sistem. Dengan selesainya penelitian ini, diharapkan tercipta sebuah solusi teknologi yang mampu mempermudah proses pemantauan kualitas air bagi masyarakat dan instansi terkait secara lebih praktis, cepat, dan akurat secara ilmiah.

B. Rumusan Masalah

Berdasarkan permasalahan yang telah dipaparkan diatas, permasalahan pokok yang dihadapi adalah:

1. Bagaimana model *hybrid ResNet50* dan *Support Vector Machine (SVM)* dalam melakukan klasifikasi tingkat kekeruhan air berbasis citra?
2. Bagaimana performa model *hybrid ResNet50* dan *Support Vector Machine (SVM)* dalam mengklasifikasikan tingkat kekeruhan air berdasarkan citra yang digunakan?

C. Tujuan Penelitian

Berdasarkan uraian rumusan masalah yang telah dipaparkan, tujuan penelitian ini dirumuskan untuk menjawab pertanyaan penelitian, yaitu:

1. Menguji model *hybrid ResNet50* dan *Support Vector Machine (SVM)* untuk mengklasifikasikan tingkat kekeruhan air berbasis citra melalui tahapan preprocessing citra, ekstraksi fitur menggunakan *ResNet50*, serta klasifikasi menggunakan *Support Vector Machine (SVM)*.
2. Menganalisis performa dan efektivitas model *hybrid ResNet50-SVM* dalam mengkategorikan citra air ke dalam tiga tingkat kekeruhan, yaitu Air Jernih, Air Keruh, Dan Air Kotor.

D. Manfaat Penelitian

Manfaat dari studi ini meliputi beragam aspek yang diharapkan mampu memberikan kontribusi bagi berbagai pihak, antara lain:

1. Bagi Peneliti

Penelitian ini diharapkan dapat memberikan pemahaman kepada penulis dalam memperluas wawasan di bidang informatika, khususnya implementasi kecerdasan buatan (*Artificial Intelligence*). Secara praktis, peneliti dapat mengasah keahlian dalam menerapkan arsitektur *Deep Neural Network* melalui *ResNet50* yang digabungkan dengan *Support Vector Machine (SVM)* untuk menyelesaikan permasalahan lingkungan hidup, yaitu monitoring kualitas air secara digital

2. Bagi Institusi Akademik

Secara praktis, penelitian ini diharapkan dapat menjadi referensi ilmiah dan studi kasus dalam pengembangan model klasifikasi berbasis *computer vision* di Program Studi Informatika. Model *hybrid ResNet50* dan *Support Vector Machine (SVM)* yang dibangun dapat dijadikan acuan untuk penelitian lanjutan dalam bidang pengolahan citra digital (*image processing*) maupun pengembangan sistem otomasi pemantauan sumber daya alam berbasis teknologi informasi.

3. Bagi Masyarakat

Penelitian ini memberikan kontribusi nyata dalam penyediaan alternatif teknologi pemantauan kualitas air yang lebih efisien dan ekonomis dibandingkan alat konvensional seperti turbidimeter. Model klasifikasi ini dapat digunakan sebagai landasan dalam membangun sistem peringatan dini (*early warning system*) terhadap pencemaran air. Dengan adanya kategori klasifikasi yang jelas (Air Jernih, Air Keruh, Air Kotor,), hasil penelitian ini dapat mendukung pengambilan keputusan terkait kebijakan pengolahan sumber daya air yang lebih terarah dan berbasis data komprehensif.

E. Ruang Lingkup Penelitian

Adapun Batasan dalam suatu penelitian agar menjadi terarah dengan baik, maka ruang lingkup penelitian dalam penelitian ini Adalah sebagai berikut:

1. Data Penelitian yang digunakan terbatas pada data citra digital air yang dikategorikan ke dalam tiga tingkat kekeruhan, yaitu: Air Jernih, Air Keruh, Dan, Air Kotor. Data citra diperoleh melalui pengambilan gambar secara langsung menggunakan kamera.
2. Metode yang diimplementasikan menggunakan pendekatan *hybrid* yang menggabungkan arsitektur *ResNet50* sebagai pemroses ekstraksi fitur visual dan *Support Vector Machine (SVM)* sebagai algoritma pengklasifikasi.
3. Model hanya memproses variabel berbasis citra (visual) untuk mengekstraksi fitur seperti warna, tekstur, dan pola visual yang berkaitan dengan tingkat kekeruhan air.

F. Sistematika Penulisan

Sistematika penulisan proposal penelitian ini dirancang dalam tiga bab komprehensif sebagai berikut:

BAB I PENDAHULUAN

Bab ini menerangkan secara singkat dan jelas dasar ilmiah dilaksanakannya penelitian. Mencakup latar belakang penulisan penelitian, rumusan masalah, tujuan dan manfaat, batasan permasalahan metodologi yang digunakan dan sistematikan penulisan.

BAB II TINJAUAN PUSTAKA

Pada bab ini membahas tentang teori-teori yang melandasi penulis dalam melaksanakan penelitian seperti metode dan algoritma yang terkait dengan penelitian ini. Pada bab ini juga berisi penjelasan dari penelitian sebelumnya yang relevan dengan penelitian ini.

BAB III METODE PENELITIAN

Pada bab ini membahas dengan detail tentang tahapan pelaksanaan penelitian, metode yang digunakan dalam melakukan penelitian, waktu dan tempat penelitian, alat dan bahan penelitian, rancangan sistem penelitian dan teknik analisis data.

BAB IV HASIL DAN PEMBAHASAN

Pada bab ini pemaparan hasil penelitian yang dilakukan dituangkan secara sistematis baik hasil analisis, dan juga perhitungan manual model.

BAB V KESIMPULAN

Berisi Kesimpulan yang ditarik dari rumusan masalah dan hasil yang telah diperoleh pada bab IV.

BAB II

TINJAUAN PUSTAKA

A. Landasan Teori

1. Kualitas Air Dan Kekeruhan Air

Air merupakan komponen esensial dalam kehidupan manusia dan ekosistem, sehingga kualitasnya menjadi aspek yang sangat penting untuk dijaga. Kualitas air didefinisikan sebagai kondisi fisik, kimia, dan biologis air yang menentukan kelayakannya untuk digunakan dalam berbagai kebutuhan, seperti konsumsi, pertanian, industri, maupun ekosistem perairan. Dalam praktiknya, kualitas air tidak hanya dinilai dari kejernihan secara visual, tetapi juga berdasarkan parameter terukur yang telah ditetapkan oleh standar nasional maupun internasional, seperti Peraturan Menteri Kesehatan dan *World Health Organization (WHO)* (Majapahit, 2019).

Salah satu parameter fisik utama dalam menentukan kualitas air adalah tingkat kekeruhan atau *turbidity*. Kekeruhan merupakan ukuran yang menggambarkan sejauh mana partikel tersuspensi dalam air menghambat penetrasi cahaya. Semakin tinggi tingkat kekeruhan, maka semakin besar jumlah partikel yang terkandung dalam air tersebut. Partikel-partikel ini dapat berupa material organik seperti *plankton* dan sisa makhluk hidup, maupun material anorganik seperti lumpur, pasir halus, dan sedimen lainnya (Rikanto, 2021).

Kekeruhan air tidak hanya mempengaruhi aspek estetika, tetapi juga memiliki dampak signifikan terhadap kesehatan manusia. Air yang keruh sering kali menjadi indikator adanya kontaminasi mikroorganisme patogen seperti bakteri, virus, dan parasit yang dapat menyebabkan penyakit. Selain itu, kekeruhan juga dapat mengganggu proses desinfeksi, karena partikel tersuspensi dapat melindungi mikroorganisme dari paparan bahan kimia seperti klorin (Rikanto, 2021).

Secara ilmiah, pengukuran kekeruhan dilakukan menggunakan alat yang disebut turbidimeter. Alat ini bekerja berdasarkan prinsip *nephelometry*, yaitu dengan mengukur intensitas cahaya yang dipantulkan oleh partikel dalam air pada sudut tertentu, biasanya 90 derajat. Hasil pengukuran dinyatakan dalam satuan

Nephelometric Turbidity Unit (NTU). Namun demikian, penggunaan alat ini memiliki keterbatasan, terutama dari segi biaya dan kebutuhan tenaga ahli untuk operasionalnya.

Dalam konteks masyarakat umum, penilaian kekeruhan air masih sering dilakukan secara visual, yang bersifat subjektif dan tidak konsisten. Hal ini membuka peluang untuk pengembangan metode alternatif berbasis teknologi, seperti pengolahan citra digital. Dengan memanfaatkan citra air, sistem komputer dapat dilatih untuk mengenali pola visual yang berkaitan dengan tingkat kekeruhan dan mengklasifikasikannya ke dalam kategori tertentu, seperti air jernih, air keruh, dan air kotor. (Majapahit, 2019). Pendekatan ini menawarkan solusi yang lebih praktis, cepat, dan dapat diimplementasikan secara luas, terutama di daerah dengan keterbatasan alat ukur konvensional.

2. Kategori Tingkat Kekeruhan Air

1. Air Jernih

Air jernih adalah air yang memiliki tingkat kekeruhan sangat rendah sehingga tampak bening dan tembus pandang. Pada citra digital, air jernih umumnya memiliki warna yang relatif seragam dengan sedikit partikel yang terlihat secara visual.

2. Air Keruh

Air keruh adalah 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 kotor adalah 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..

3. Pengolahan Citra Digital

Pengolahan citra digital (*digital image processing*) merupakan bidang ilmu yang berfokus pada manipulasi dan analisis citra menggunakan komputer untuk memperoleh informasi yang lebih bermakna. Dalam konteks modern, pengolahan citra menjadi bagian penting dari *computer vision*, yang memungkinkan komputer untuk “melihat” dan memahami informasi visual layaknya manusia.

Secara matematis, citra digital dapat direpresentasikan sebagai fungsi dua dimensi $f(x,y)$, di mana x dan y adalah koordinat piksel, sedangkan nilai fungsi tersebut menunjukkan intensitas cahaya atau warna pada titik tersebut. Dalam citra berwarna, setiap piksel biasanya terdiri dari tiga kanal utama, yaitu merah (*Red*), hijau (*Green*), dan biru (*Blue*) atau dikenal sebagai *RGB* (Pradifta et al., 2025).

Dalam penelitian klasifikasi kekeruhan air, citra diperoleh melalui kamera digital sebagai data *input* utama. Namun, citra mentah yang dihasilkan sering kali tidak ideal karena dipengaruhi oleh berbagai faktor, seperti pencahayaan yang tidak merata, bayangan, dan noise dari sensor kamera. Oleh karena itu, diperlukan tahapan *preprocessing* untuk meningkatkan kualitas citra sebelum digunakan dalam proses analisis.

Tahapan *preprocessing* meliputi beberapa langkah penting. Pertama, *resize image*, yaitu mengubah ukuran citra agar sesuai dengan kebutuhan model, misalnya menjadi 224×224 piksel untuk kompatibilitas dengan arsitektur tertentu seperti *ResNet50*. Kedua, normalisasi piksel, yaitu mengubah rentang nilai piksel dari 0–255 menjadi 0–1 agar proses pembelajaran model menjadi lebih stabil dan cepat. Ketiga, dapat dilakukan teknik tambahan seperti *noise reduction*, *contrast enhancement*, dan data *augmentation* untuk meningkatkan variasi data (Pradifta et al., 2025).

Selain itu, ekstraksi fitur menjadi bagian penting dalam pengolahan citra. Fitur yang dapat diekstraksi dari citra meliputi warna, tekstur, dan pola distribusi intensitas. Dalam konteks kekeruhan air, tekstur dan distribusi warna menjadi indikator utama, karena air yang keruh cenderung memiliki variasi warna dan pola yang lebih kompleks dibandingkan air jernih. Dengan perkembangan teknologi *deep learning*, proses ekstraksi fitur kini dapat dilakukan secara otomatis tanpa

perlu perancangan fitur manual. Hal ini memungkinkan sistem untuk menemukan pola-pola kompleks yang sulit dideteksi oleh metode konvensional, sehingga meningkatkan akurasi dalam klasifikasi citra.

4. *Deep Learning*

Deep Learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk mempelajari representasi data secara hierarkis. Dalam bidang pengolahan citra, salah satu arsitektur yang paling populer dan efektif adalah *Convolutional Neural Network (CNN)*. *CNN* dirancang khusus untuk menangani data berbentuk grid seperti citra. Keunggulan utama *CNN* dibandingkan jaringan saraf tradisional adalah kemampuannya dalam mempertahankan hubungan spasial antar piksel melalui operasi konvolusi. Hal ini memungkinkan *CNN* untuk mendeteksi pola lokal seperti tepi, sudut, dan tekstur, yang kemudian dikombinasikan menjadi fitur yang lebih kompleks pada lapisan yang lebih dalam (Abdullah et al., 2024).


Arsitektur *CNN* terdiri dari beberapa jenis lapisan utama. Lapisan pertama adalah *convolutional layer*, yang berfungsi untuk mengekstraksi fitur dari citra menggunakan filter atau kernel. Setiap filter akan menghasilkan *feature map* yang merepresentasikan pola tertentu dalam citra. Selanjutnya, *pooling layer* digunakan untuk mengurangi dimensi *feature map*, sehingga mengurangi kompleksitas komputasi dan membantu mencegah *overfitting* (Nkuna et al., 2025). Jenis *pooling* yang umum digunakan adalah *max pooling*. Lapisan terakhir adalah *fully connected layer*, yang berfungsi untuk melakukan klasifikasi berdasarkan fitur yang telah diekstraksi. Pada tahap ini, fitur yang telah dipelajari oleh *CNN* akan diubah menjadi vektor satu dimensi dan diproses untuk menentukan kelas *output*.

Dalam konteks klasifikasi kekeruhan air, *CNN* memiliki peran penting dalam mengenali pola visual yang kompleks. Misalnya, perbedaan antara air jernih dan air sedikit keruh mungkin tidak terlihat jelas secara kasat mata, tetapi *CNN* mampu menangkap perbedaan kecil dalam distribusi warna dan tekstur. Dengan

demikian, *CNN* menjadi solusi yang efektif untuk meningkatkan akurasi klasifikasi berbasis citra (Ramadhan & Riwurohi, 2024).

5. *ResNet50*

ResNet50 merupakan salah satu arsitektur *CNN* yang sangat populer dan telah terbukti memiliki performa tinggi dalam berbagai tugas klasifikasi citra. Arsitektur ini diperkenalkan untuk mengatasi permasalahan *vanishing gradient* yang sering terjadi pada jaringan saraf yang sangat dalam. Masalah *vanishing gradient* terjadi ketika nilai gradien menjadi sangat kecil selama proses pelatihan, sehingga bobot pada lapisan awal tidak mengalami pembaruan yang signifikan. Akibatnya, model sulit untuk belajar secara optimal. *ResNet50* mengatasi masalah ini dengan memperkenalkan konsep *residual learning* melalui *shortcut connection* atau *identity mapping* (Chen et al., 2024). Berikut Adalah ilustrasi dari *Resnet50* yang di lampirkan pada gambar 1 berikut ini.



Gambar 1. Ilustrasi *Resnet50* pada klasifikasi air

Konsep utama dari *residual learning* adalah memungkinkan input dari suatu lapisan untuk dilewatkan langsung ke lapisan berikutnya tanpa melalui transformasi. Hal ini direpresentasikan dalam persamaan berikut:

$$y = F(x, \{W_i\}) + x \dots\dots\dots (1)$$

Dengan adanya penambahan langsung antara *input* dan *output*, jaringan dapat mempertahankan informasi penting dari lapisan sebelumnya, sehingga mempercepat proses pelatihan dan meningkatkan akurasi model. *ResNet50* terdiri dari 50 lapisan yang menggunakan struktur *bottleneck*, yaitu kombinasi beberapa lapisan konvolusi dengan ukuran filter yang berbeda. Struktur ini memungkinkan model untuk menjadi lebih dalam tanpa meningkatkan kompleksitas secara signifikan (Hossain et al., 2022).

Dalam penelitian ini, *ResNet50* digunakan sebagai *feature extractor*. Hal ini karena kemampuannya dalam mengekstraksi fitur tingkat tinggi dari citra, seperti tekstur dan pola kompleks yang berkaitan dengan kekeruhan air. Dengan fitur yang lebih representatif, proses klasifikasi dapat dilakukan dengan lebih akurat. Adapun arsitektur pembangun *Resnet50* diantaranya.

a. *Convolution layer*

Convolution layer merupakan lapisan utama dalam *CNN* yang berfungsi untuk mengekstraksi fitur dari citra seperti tepi, tekstur, dan pola. Proses ini dilakukan dengan cara menggeser kernel (*filter*) pada citra *input* untuk menghasilkan *feature map*. Dengan rumus sebagai berikut.

$$y(i, j) = \sum_m \sum_{mn} x(i + m, j + n).w(m, n) \dots\dots\dots (2)$$

b. *Activation Function (ReLU)*

ReLU (Rectified Linear Unit) digunakan untuk memberikan sifat *non-linear* pada model sehingga mampu mempelajari pola kompleks. Fungsi ini hanya mengambil nilai positif dan mengubah nilai negatif menjadi nol.

$$f(x) = \max(0, x) \dots\dots\dots (3)$$

c. *Batch Normalization*

Batch Normalization berfungsi untuk menstabilkan distribusi data pada setiap layer sehingga mempercepat proses pelatihan dan meningkatkan performa model.

$$\hat{x} = \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} \dots \dots \dots (4)$$

d. *Pooling Layer*

Pooling layer digunakan untuk mengurangi dimensi *feature map* sehingga mempercepat komputasi dan mengurangi *overfitting*. Umumnya digunakan *max pooling*. dimana rumus *max pooling*.

$$y = \max(x_{region}) \dots \dots \dots (5)$$

e. *Residual connection*

Komponen utama *ResNet50* adalah *residual connection* yang memungkinkan *input* langsung ditambahkan ke *output layer* tertentu. Hal ini membantu mengatasi masalah *vanishing gradient*.

$$H(x) = F(x) + x \dots \dots \dots (6)$$

f. *Global Average Pooling*

Lapisan ini mengubah *feature map* menjadi *vector* dengan cara mengambil rata-rata dari setiap *channel*.

$$y_k = \frac{1}{n} \sum_{i=1}^N x_i \dots \dots \dots (7)$$


g. *Fully Connected Layer*

Lapisan ini mengubah fitur menjadi representasi numerik (*feature vector*) yang siap digunakan untuk klasifikasi.

$$y = w \cdot x + b \dots \dots \dots (8)$$

6. *Support Vector Machine (SVM)*

Support Vector Machine (SVM) merupakan algoritma supervised learning yang digunakan untuk tugas klasifikasi. Dalam konteks ini, SVM bekerja dengan mencari hyperplane optimal yang memisahkan data dari dua kelas atau lebih dengan margin maksimum. Konsep utama dalam SVM adalah menemukan garis atau bidang pemisah yang memiliki jarak terbesar terhadap titik data terdekat dari masing-masing kelas, yang disebut sebagai support vectors (Fan et al., 2023), berikut ini Adalah ilustrasi metode Support Vector Machine gambar 2.



Gambar 2. Ilustrasi *SVM* pada klasifikasi air

Dengan margin yang lebih besar, model diharapkan memiliki kemampuan generalisasi yang lebih baik terhadap data baru. Secara matematis, fungsi keputusan *SVM* dapat dituliskan sebagai berikut.

$$f(x) = \text{sign}(w \cdot x + b) \dots\dots\dots (9)$$

Di mana w adalah vektor bobot, x adalah data *input*, dan b adalah bias. Fungsi ini akan menentukan kelas dari suatu data berdasarkan posisi relatifnya terhadap *hyperplane*.

Untuk kasus di mana data tidak dapat dipisahkan secara linier, *SVM* menggunakan teknik yang disebut *kernel trick*. Teknik ini memetakan data ke ruang dimensi yang lebih tinggi sehingga menjadi *linier separable*. Beberapa jenis kernel yang umum digunakan antara lain *linear kernel*, *polynomial kernel*, dan *Radial Basis Function (RBF)*. Dalam penelitian ini, *SVM* digunakan sebagai *classifier* karena kemampuannya dalam menangani data berdimensi tinggi dan batas keputusan yang kompleks (Pandey et al., 2023). Ketika dikombinasikan dengan fitur

yang dihasilkan oleh *ResNet50*, *SVM* dapat memberikan performa klasifikasi yang optimal. Adapun arsitektur pembangun metode *SVM* Adalah sebagai berikut.

a. *Input feature vector*

SVM menerima *input* berupa vektor fitur (hasil ekstraksi dari *ResNet50*) yang merepresentasikan karakteristik citra.

b. *Hyperlane*

Hyperlane merupakan garis atau bidang yang digunakan untuk memisahkan data ke dalam kelas yang berbeda. Rumusnya diapaparkan sebagai berikut

$$w \cdot x + b = 0 \dots\dots\dots(10)$$

c. *Margin*

Margin adalah jarak antara *hyperlane* dengan titik data terdekat dari masing-masing kelas. *SVM* berusaha memaksimalkan margin ini.

$$\text{Margin} = \frac{2}{\|w\|} \dots\dots\dots(11)$$

d. Fungsi keputusan

Fungsi ini digunakan untuk menentukan kelas suatu data berdasarkan posisinya terhadap *hyperplane*.

$$f(x) = \text{sign}(w \cdot x + b) \dots\dots\dots(12)$$

e. Fungsi objektif

SVM bertujuan untuk mencari *hyperplane* terbaik dengan meminimalkan nilai bobot, rumusnya yaitu.

$$\text{Min } \frac{1}{2} \|w\|^2 \dots\dots\dots(13)$$

Dengan *constraint*.

$$y_i(w \cdot x_i + b) \geq 1 \dots\dots\dots(14)$$

f. *Kernel trick*


Jika data tidak dapat dipisahkan secara linear, digunakan kernel untuk memetakan data ke ruang dimensi lebih tinggi. Contoh kernel *RBF*.

$$K(x_i, x_j) = \exp \left(-\gamma \|x_i - x_j\|^2 \right) \dots\dots\dots(15)$$

7. Hybrid ResNet50-SVM

Pendekatan *hybrid* merupakan strategi yang menggabungkan dua atau lebih metode untuk memanfaatkan keunggulan masing-masing. Dalam penelitian ini, digunakan kombinasi antara *ResNet50* dan *SVM* untuk meningkatkan performa klasifikasi kekeruhan air. *ResNet50* digunakan sebagai *feature extractor*, sementara *SVM* digunakan sebagai *classifier* (Abdullah et al., 2024). Dalam implementasinya, lapisan *fully connected* pada *ResNet50* dihapus, sehingga *output* yang dihasilkan berupa vektor fitur. Vektor ini kemudian digunakan sebagai input untuk model *SVM*.

Alur kerja sistem *hybrid* ini dimulai dari tahap *preprocessing* citra, dilanjutkan dengan ekstraksi fitur menggunakan *ResNet50*, dan diakhiri dengan klasifikasi menggunakan *SVM*. Pendekatan ini memanfaatkan kemampuan *ResNet50* dalam memahami representasi visual yang kompleks, serta keunggulan *SVM* dalam menentukan batas keputusan yang optimal (Ozdemir et al., 2025). Adapun ilustrasinya diapaprkkan pada gambar 3 sebagai berikut.



Gambar 3. Ilustrasi *hybrid ResNet50 dan SVM*

Keunggulan utama dari pendekatan ini adalah peningkatan akurasi dan efisiensi. *ResNet50* mampu menghasilkan fitur yang kaya informasi, sementara *SVM* mampu melakukan klasifikasi dengan baik meskipun jumlah data terbatas. Kombinasi ini sangat cocok untuk kasus klasifikasi kekeruhan air yang memiliki

variasi visual yang tinggi. Sehingga digunakan kedua metode agar dapat mengintegrasikan *hybrid* diantaranya.

Untuk *resnet50* menggunakan *feature extraction*,

$$f = \text{ResNet50}(x) \dots \dots \dots (16)$$

Kedua, menggunakan fungsi SVM yakni,

$$y = \text{sign}(w.f + b) \dots \dots \dots (17)$$

Sehingga menghasilkan intergrasi *hybrid*

$$y = \text{sign}(w.\text{ResNet50}(x) + b) \dots \dots \dots (18)$$

8. Evaluasi Model *Confusion Matrix*

Confusion matrix merupakan sebuah fungsi yang digunakan untuk mengevaluasi peforma model klasifikasi dengan memberikan perbandingan antara hasil prediksi model dengan nilai nyata pada data uji. Matrix memiliki peran penting dalam menganalisis karena memberikan Gambaran yang detail terhadap jenis kesalahan yang dilakukan saat pemodelan (Riehl et al., 2023).

Penjelasan menurut penelitian juga menjelaskan bahwa *confusion matrix* Adalah table 4 kombinasi berbeda dari nilai prediksi dan aktual yang memberikan informasi perbandingan klasifikasi dan yang dilakukan oleh model.

Dalam *confusion matrix* terdapat empat struktur yang menjadi tumpuan dalam proses klasifikasi diantaranya.

- a. *True Positif (TP)* yang merupakan data aktual positif yang di prediksi benar sebagai positif.
- b. *True Negatif (TN)* merupakan data aktual yang di prediksi benar sebagai negatif.
- c. *False Positif (FP)* merupakan data aktual negatif yang salah di prediksi sebagai positif
- d. *False Negatif (FN)* merupakan data aktual positif yang salah di prediksi sebagai negatif.

Berdasarkan prosesnya rumus evaluasi dalam *confusion matrix* dapat dihitung dengan menggunakan rumus sebagai berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (19)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \dots\dots\dots (20)$$

$$\text{Recall} = \frac{TP}{TP+FN} \dots\dots\dots (21)$$

$$\text{F1-Score} = 2X \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \dots\dots\dots (22)$$

B. Penelitian Terkait

Beberapa penelitian sebelumnya telah menyoroti penerapan metode *machine learning* dan *deep learning* dalam klasifikasi kualitas air berbasis citra dengan berbagai pendekatan. Dengan menganalisis metode yang digunakan Sistem ini memanfaatkan citra air untuk mengidentifikasi karakteristik visual seperti warna dan tekstur guna menentukan kategori air, yaitu jernih, keruh, dan, kotor. Rangkuman beberapa penelitian terdahulu yang relevan ditampilkan pada Tabel 1.

Tabel 1. Penelitian terdahulu


Penelitian sebelumnya	Metode	Hasil
<i>Advanced machine learning models for accurate water quality classification and WQI prediction</i> (Hridoy et al., 2025)	Menggunakan model <i>ML</i> (<i>LightGBM</i> , <i>XGBoost</i> , <i>Random Forest</i> , <i>SVM</i>) dengan <i>hyperparameter</i> tuning dan analisis <i>SHAP</i>	<i>LightGBM</i> & <i>XGBoost</i> mencapai akurasi hingga 99,65% dan R^2 hingga 0,9685; parameter DO dan BOD paling berpengaruh.
<i>A hybrid machine learning approach for imbalanced irrigation water quality classification</i> (Mustapha et al., 2025)	<i>Ensemble learning</i> , <i>AMSVM</i> , <i>ADASYN</i> , dan <i>class weighting</i> untuk menangani data tidak seimbang	Akurasi terbaik 98,5% (ensemble), <i>ADASYN</i> 97,5%, <i>AMSVM</i> 86,8%; metode efektif untuk klasifikasi <i>IWQI</i>

Penelitian sebelumnya	Metode	Hasil
<i>Enhancing breast cancer diagnosis with ResNet50 and Salp Swarm-Based feature reduction</i> (Alzoubi et al., 2026)	<i>ResNet50</i> untuk ekstraksi fitur + <i>Salp Swarm Algorithm (SSA)</i> untuk reduksi fitur + klasifier <i>ML (SVM, RF, KNN, DT)</i>	<i>SVM</i> terbaik dengan akurasi hingga 96,45%; meningkatkan kecepatan dan akurasi diagnosis kanker payudara
<i>Enhanced Small Object Detection in Remotely Sensed Images using Hybrid ResNet50 and FPN</i> (Vishal et al., 2025)	Model <i>deep learning ResNet50 + Feature Pyramid Network (FPN)</i>	Akurasi 84,12%, <i>precision</i> 84,52%, <i>recall</i> 85,69%, <i>F1-score</i> 85,10%; efektif untuk deteksi objek kecil
<i>Identification of maize leaf diseases using CNN and ResNet50 models</i> (Nkuna et al., 2025)	Perbandingan <i>CNN</i> dan <i>ResNet50</i> pada citra <i>RGB</i> daun jagung	<i>ResNet50</i> lebih unggul dengan akurasi 78,76% dibanding <i>CNN</i> 71,01%

C. Kerangka Berpikir

Kerangka berpikir merupakan model konseptual yang menjelaskan hubungan antara teori dengan faktor-faktor yang telah diidentifikasi dalam suatu permasalahan penelitian. Kerangka berpikir pada penelitian ini disusun berdasarkan permasalahan dalam proses identifikasi tingkat kekeruhan air yang masih dilakukan secara visual dan bersifat subjektif. Sebagai solusi, penelitian ini menerapkan teknologi *Computer Vision* dengan pendekatan *Hybrid ResNet50* dan *Support Vector Machine (SVM)* untuk melakukan klasifikasi tingkat kekeruhan air. Selanjutnya, penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan dataset, praproses citra, ekstraksi fitur menggunakan *ResNet50*, pelatihan model *SVM*, serta evaluasi kinerja model berdasarkan beberapa metrik pengujian. Dari tahapan tersebut diharapkan diperoleh model *Hybrid ResNet50-SVM* yang mampu

melakukan klasifikasi tingkat kekeruhan air secara otomatis dan akurat. Ilustrasi kerangka berpikir penelitian ini dapat dilihat pada Gambar 4 sebagai berikut.



Gambar 4. Kerangka pikir

BAB III

METODE PENELITIAN

A. Tempat dan waktu penelitian

Penelitian ini dilakukan secara mandiri dengan memanfaatkan *Device* yang mampu mengambil gambar secara baik sebagai media utama pengolahan data dan Pengembangan model. Pengambilan *dataset* citra air dilakukan melalui sumber data terbuka di lapangan yang diperoleh dari lingkungan sekitar sebagai objek dari penelitian yang dilakukan.

B. Alat dan bahan

Adapun alat dan bahan yang akan digunakan dalam penelitian ini, yaitu:


1. Kebutuhan *hardware* (perangkat keras)
 - a. Laptop Lenovo
 - b. Ram 8 atau lebih dengan *storage* 512 atau lebih
2. Kebutuhan *software* (perangkat lunak)
 - a. Sistem operasi: windows 11
 - b. Lingkungan pengembangan: *visual studio code*
 - c. Bahasa pemrograman *python* yang menjadi Bahasa pemrograman utama
 - d. Pustaka yang digunakan,
 - 1) *Numpy*, digunakan untuk melakukan komputasi numerik dan manipulasi *array* multidimensi.
 - 2) *Pandas*, sebagai Pustaka yang berfungsi untuk membaca, membersihkan dan memanipulasi data tabular (kolom dan baris)
 - 3) *Matplotlib* dan *Seaborn*, sebagai pilihan utama dalam proses visualisasi data dan hasil analisis model.
 - 4) *Scikit-learn*, digunakan untuk *preprocessing* data, split dataset dan menjalankan model *SVM*, serta mengevaluasi model dengan metrik (*confusion matrix*).
 - 5) *Tensorflow* dan Keras, Pustaka yang digunakan untuk menjalankan model *Resnet50* sebagai *feature extractor*.

C. Perancangan system

Perancangan sistem klasifikasi tingkat kekeruhan air berbasis citra dalam penelitian ini menggunakan pendekatan *Hybrid ResNet50* dan *Support Vector Machine (SVM)*. Sistem dirancang untuk mengolah citra air sebagai input dan menghasilkan klasifikasi tingkat kekeruhan yang terdiri dari tiga kelas yaitu jernih, keruh, dan kotor.

Arsitektur sistem secara umum menggambarkan alur mulai dari proses input citra, *preprocessing*, ekstraksi fitur menggunakan *ResNet50*, hingga klasifikasi menggunakan *SVM*. Proses ini divisualisasikan dalam bentuk *flowchart* sistem.

Sedangkan *flowchart* desain sistem utama ditampilkan pada gambar 5 sebagai berikut.



Gambar 5. *Flowchart* sistem klasifikasi Air *Resnet50* dan *SVM*

1. Mulai

Tahap awal sistem dimulai. Tidak ada proses khusus, hanya sebagai penanda bahwa alur dimulai.

2. Input Dataset Citra Air

Sistem menerima dataset berupa gambar air, Dataset ini berisi berbagai kondisi air:

- a. Air Jernih
- b. Air Keruh
- c. Air Kotor

3. *Preprocessing* Data

Tujuan dari *preprocessing* data yaitu:

- a. Membersihkan data
- b. Menyamakan format
- c. Meningkatkan kualitas citra

4. *Resize Image*

Resize image dilakukan agar:

- a. Menyesuaikan dengan input model *ResNet50*
- b. Mempercepat proses komputasi

5. Normalisasi Pixel

Tujuan Normalisasi pixel adalah sebagai berikut:

- a. Mempercepat proses training
- b. Membuat model lebih stabil
- c. Menghindari bias karena nilai besar

6. Split Dataset

Dataset ini dibagi menjadi 2 bagian yaitu:

- a. Data training: untuk melatih model
- b. Data testing: untuk menguji model

7. Data Training Dan Testing

Tujuan data training dan testing

- a. Training digunakan untuk belajar pola
- b. Testing digunakan untuk evaluasi performa

8. Ekstraksi Fitur

Fungsi peran *deep learning* yaitu Mengambil fitur penting dari gambar contohnya tekstur air, warna, dan pola kekeruhan.

9. Training *SVM*

Fitur dari *ResNet50* dimasukkan ke *SVM* kemudian *SVM* belajar membuat batas antar kelas dengan memisahkan antara Air jernih, Air keruh, Dan Air kotor.

10. Prediksi Menggunakan *SVM*

Data testing dimasukkan kemudian *SVM* melakukan prediksi berdasarkan hasil *training*.

11. *Output* Klasifikasi

Diharapkan model *hybrid* ini memberikan hasil akhir berupa pembacaan model terhadap citra air yang di klasifikasikan ke dalam 3 kategori yakni, Air jernih, Air keruh, Dan Air kotor.

12. Evaluasi Model (*Confusion Matrix*)

Setelah proses prediksi dilakukan, tahap selanjutnya adalah evaluasi model untuk mengetahui kinerja sistem dalam mengklasifikasikan citra air. Hasil prediksi dibandingkan dengan label asli menggunakan *confusion matrix* untuk melihat jumlah prediksi yang benar dan salah.

13. Selesai

D. Teknik pengujian system

Teknik pengujian sistem dilakukan untuk mengevaluasi kinerja model *hybrid ResNet50-SVM* dalam mengklasifikasikan tingkat kekeruhan air. Pengujian dilakukan menggunakan data testing yang tidak digunakan dalam proses pelatihan. Evaluasi model dilakukan menggunakan *confusion matrix* untuk menghitung beberapa metrik evaluasi, yaitu.

1. *Accuracy*, tingkat ketepatan prediksi
2. *Precision*, tingkat ketepatan prediksi positif
3. *Recall*, kemampuan model menemukan data positif
4. *F1-Score*, keseimbangan antara *precision* dan *recall*

Dengan metode ini, dapat diketahui seberapa baik model dalam mengklasifikasikan citra air ke dalam kategori yang tepat.

E. Teknik analisis data

Analisis data dalam penelitian ini bertujuan untuk mengevaluasi efektivitas dan juga keandalan model *hybrid resnet50* dan *SVM* dalam mengklasifikasikan tingkat kekeruhan air secara konsisten. Tahapan analisis data yang dirancang meliputi.

1. Preprocessing Data

Data citra diproses melalui tahap *resize* dan normalisasi untuk memastikan data memiliki format yang seragam sebelum digunakan dalam pelatihan model.

2. Ekstraksi fitur menggunakan Resnet50

Model dilatih menggunakan data Citra menjadi feature vector menggunakan *ResNet50*, sehingga data dapat digunakan oleh algoritma *SVM*.

3. Pelatihan model SVM

Model *SVM* dilatih menggunakan feature vector dari data training untuk menemukan pola klasifikasi terbaik.

4. Evaluasi Kinerja Model

Setelah proses pelatihan, model diuji pada testing untuk melihat kemampuan generalisasi. Kemudian menggunakan *confusion matrix* yang memungkinkan analisis kesalahan prediksi secara detail beserta perhitungan metriknya yang terdiri dari akurasi, presisi, *recall* dan juga *F1-score*.

5. Interpretasi hasil

Hasil evaluasi dianalisis untuk mengetahui tingkat keberhasilan model dalam mengklasifikasikan citra air.

BAB IV

HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Tahap pengumpulan data merupakan langkah awal yang sangat penting dalam penelitian ini karena kualitas dataset yang digunakan akan berpengaruh secara langsung terhadap kemampuan model dalam melakukan proses pembelajaran (*learning*) dan menghasilkan klasifikasi yang akurat. Pada tahap ini dilakukan proses pengumpulan citra air yang merepresentasikan berbagai tingkat kondisi kekeruhan sebagai data utama yang akan digunakan dalam pengembangan model klasifikasi menggunakan metode *Hybrid ResNet50-SVM*.


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, yaitu:

1. Air Jernih sebanyak 150 citra
2. Air Keruh sebanyak 150 citra
3. Air Kotor sebanyak 150 citra.

Distribusi jumlah citra pada masing-masing kelas 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. Dengan distribusi data yang seimbang, model diharapkan mampu mempelajari karakteristik setiap kelas secara proporsional sehingga menghasilkan performa klasifikasi yang lebih objektif dan memiliki kemampuan generalisasi yang lebih baik terhadap data baru. Visualisasi distribusi jumlah citra pada setiap kelas dapat dilihat pada Gambar 6.




Gambar 6. Distribusi jumlah gambar tiap kelas

Berdasarkan Gambar 6 dapat diketahui bahwa ketiga kelas memiliki jumlah citra yang identik, yaitu masing-masing sebanyak 150 citra. Hal ini menunjukkan bahwa dataset yang digunakan dalam penelitian telah memenuhi prinsip keseimbangan kelas (*balanced dataset*), sehingga tidak terdapat dominasi jumlah data pada salah satu kategori. Kondisi tersebut diharapkan dapat meningkatkan stabilitas proses pelatihan model *Hybrid ResNet50-SVM* serta menghasilkan proses klasifikasi yang lebih akurat dan tidak bias terhadap kelas tertentu.

Selain memperhatikan jumlah data, penelitian ini juga memperhatikan karakteristik visual dari masing-masing kelas. Setiap kategori memiliki ciri-ciri visual yang berbeda sehingga dapat digunakan sebagai dasar pembelajaran oleh model deep learning. Perbedaan tersebut terlihat pada tingkat kejernihan air, intensitas warna, tingkat transmisi cahaya, serta jumlah partikel tersuspensi yang tampak pada citra. Variasi karakteristik visual inilah yang nantinya akan dipelajari oleh arsitektur *ResNet50* sebagai proses ekstraksi fitur (*feature extraction*),

kemudian fitur yang dihasilkan akan digunakan oleh algoritma *Support Vector Machine (SVM)* untuk membentuk batas pemisah (*decision boundary*) yang optimal antar kelas. Sebagai ilustrasi mengenai karakteristik visual dari dataset yang digunakan, ditampilkan beberapa contoh citra pada masing-masing kategori tingkat kekeruhan sebagaimana diperlihatkan pada Gambar 7.



Gambar 7. Sampel data tiap kategori

Berdasarkan Gambar 7 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.

Perbedaan karakteristik visual tersebut menjadi informasi penting yang dimanfaatkan oleh model *Hybrid ResNet50-SVM* dalam proses pembelajaran. Arsitektur *ResNet50* akan mengekstraksi fitur-fitur visual yang membedakan setiap kategori, sedangkan *SVM* akan mengklasifikasikan fitur tersebut ke dalam kelas yang sesuai. Dengan demikian, kualitas dan keseimbangan dataset yang digunakan pada penelitian ini diharapkan mampu mendukung terbentuknya model klasifikasi yang memiliki tingkat akurasi, presisi, dan kemampuan generalisasi yang baik dalam mengidentifikasi tingkat kekeruhan air.

B. Preprocessing Data

Tahap *preprocessing* merupakan proses awal yang dilakukan untuk mempersiapkan citra sebelum memasuki tahap ekstraksi fitur menggunakan model *ResNet50*. Tahap ini berperan penting dalam memastikan bahwa seluruh citra memiliki format yang seragam, kualitas yang sesuai dengan kebutuhan model, serta mampu merepresentasikan berbagai kondisi pengambilan gambar yang mungkin terjadi di lapangan. Dengan melakukan *preprocessing*, data yang digunakan pada proses pelatihan dan pengujian menjadi lebih konsisten sehingga model dapat mempelajari karakteristik visual setiap kategori air secara optimal. Pada penelitian ini, proses *preprocessing* terdiri atas dua tahapan utama, yaitu penyesuaian ukuran citra (*resize*) dan simulasi degradasi citra (*image degradation*).

1. Penyesuaian Ukuran Citra (*Resize*)

Tahap pertama pada proses *preprocessing* adalah melakukan penyesuaian ukuran (*resize*) terhadap seluruh citra pada dataset. Citra yang diperoleh dari proses pengambilan data memiliki dimensi yang bervariasi karena dipengaruhi oleh resolusi kamera, jarak pengambilan gambar, maupun pengaturan perangkat yang digunakan. Perbedaan ukuran tersebut menyebabkan citra tidak dapat langsung diproses oleh model *ResNet50*, karena model ini mensyaratkan seluruh data masukan memiliki ukuran yang sama.


Untuk memenuhi kebutuhan tersebut, seluruh citra diubah ukurannya menjadi 224×224 piksel, yang merupakan ukuran *input* standar pada arsitektur *ResNet50*.

Penyeragaman ukuran ini bertujuan agar setiap citra memiliki dimensi yang identik sehingga proses ekstraksi fitur dapat dilakukan secara konsisten pada seluruh data.

Proses *resize* dilakukan tanpa menghilangkan karakteristik visual utama yang terdapat pada citra. Informasi penting seperti distribusi warna, tingkat kecerahan, tekstur permukaan air, pola kekeruhan, serta karakteristik visual lainnya tetap dipertahankan sehingga citra masih mampu merepresentasikan kondisi air yang sebenarnya. Dengan demikian, perubahan yang dilakukan hanya pada dimensi citra, sedangkan informasi visual yang menjadi dasar proses klasifikasi tetap terjaga.

Selain memenuhi kebutuhan arsitektur *ResNet50*, proses *resize* juga memberikan keuntungan dari sisi komputasi. Penggunaan ukuran citra yang seragam dapat mengurangi kompleksitas perhitungan selama proses pelatihan dan pengujian, mempercepat waktu pemrosesan, serta meningkatkan kestabilan model dalam melakukan ekstraksi fitur. Hal ini memungkinkan model menghasilkan representasi fitur yang lebih konsisten sehingga dapat meningkatkan performa klasifikasi.

Hasil proses *resize* ditunjukkan pada Gambar 8 yang memperlihatkan perbandingan antara citra asli dan citra setelah dilakukan penyesuaian ukuran menjadi 224×224 piksel. Berdasarkan gambar tersebut, dapat diamati bahwa ukuran citra telah berhasil diseragamkan tanpa menghilangkan karakteristik visual air, sehingga citra siap digunakan sebagai masukan pada tahap ekstraksi fitur menggunakan model *ResNet50*.



Gambar 8. perbandingan sebelum dan sesudah *resize*

2. Simulasi Degradasi Citra (*Image Degradation*)

Setelah seluruh citra memiliki ukuran yang seragam, tahap selanjutnya adalah melakukan simulasi degradasi citra (*image degradation*). Tahap ini bertujuan untuk meningkatkan kemampuan model dalam mengenali karakteristik visual air pada kondisi pengambilan gambar yang tidak selalu ideal. Dalam penerapan di lapangan, kualitas citra dapat dipengaruhi oleh berbagai faktor, seperti keterbatasan resolusi kamera, kondisi pencahayaan yang kurang memadai, gangguan pada sensor kamera, maupun pergerakan kamera saat proses pengambilan gambar berlangsung. Kondisi tersebut dapat menyebabkan penurunan kualitas citra yang berpotensi memengaruhi hasil klasifikasi apabila model hanya dilatih menggunakan citra dengan kualitas yang baik.


Oleh karena itu, penelitian ini menerapkan simulasi degradasi citra agar model tidak hanya mempelajari karakteristik visual dari citra berkualitas tinggi, tetapi juga mampu mengenali pola visual pada citra yang mengalami penurunan kualitas. Pendekatan ini diharapkan dapat meningkatkan kemampuan model dalam melakukan generalisasi terhadap data baru yang memiliki kondisi berbeda dengan data pelatihan.

Simulasi degradasi dilakukan melalui tiga perlakuan, yaitu penurunan resolusi (*downscale*), penambahan *noise*, dan pemberian efek blur. Penurunan resolusi digunakan untuk mensimulasikan citra yang dihasilkan oleh kamera dengan kualitas resolusi rendah sehingga detail visual menjadi berkurang. Penambahan *noise* bertujuan merepresentasikan gangguan pada sensor kamera yang umumnya terjadi akibat kondisi pencahayaan yang kurang baik atau kualitas perangkat yang terbatas. Sementara itu, efek blur diberikan untuk mensimulasikan kondisi citra yang kurang fokus atau mengalami guncangan saat proses pengambilan gambar berlangsung, misalnya akibat pergerakan kamera atau riak pada permukaan air.

Penerapan ketiga teknik degradasi tersebut bertujuan untuk meningkatkan *robustness* model, yaitu kemampuan model dalam mempertahankan performa

klasifikasi meskipun citra masukan mengalami penurunan kualitas. Dengan adanya variasi kualitas citra selama proses pelatihan, model diharapkan mampu menghasilkan performa yang lebih stabil dan tidak bergantung pada citra dengan kondisi ideal saja. Hal ini menjadikan model lebih siap untuk diterapkan pada kondisi nyata, di mana kualitas citra yang diperoleh sering kali dipengaruhi oleh berbagai faktor lingkungan dan perangkat pengambilan gambar.

Hasil simulasi degradasi citra ditampilkan pada Gambar 9 yang memperlihatkan perbandingan antara citra hasil *resize* dan citra setelah diberikan proses degradasi. Melalui gambar tersebut dapat diamati perubahan kualitas citra akibat proses *downscale*, penambahan *noise*, dan efek blur, sementara karakteristik visual utama air masih tetap dapat dikenali oleh model pada tahap ekstraksi fitur.



Gambar 9. perbandingan hasil resize dan hasil degradasi

C. 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.

Pada penelitian ini, proses ekstraksi fitur dilakukan menggunakan arsitektur *Deep Learning ResNet50* yang telah dilatih sebelumnya (*pre-trained model*) menggunakan dataset berskala besar, yaitu *ImageNet*. Penggunaan model *pre-trained* tersebut menerapkan konsep *Transfer Learning*, yaitu memanfaatkan pengetahuan yang telah dipelajari oleh model pada dataset *ImageNet* untuk mengenali karakteristik visual citra air tanpa harus melakukan proses pelatihan model dari awal (*training from scratch*). Dengan pendekatan ini, proses ekstraksi fitur menjadi lebih efisien serta mampu menghasilkan representasi fitur yang lebih baik untuk proses klasifikasi.

Berdasarkan implementasi yang dilakukan pada sistem, model *ResNet50* dikonfigurasi secara khusus agar hanya berfungsi sebagai pengekstraksi fitur (*feature extractor*). Konfigurasi tersebut dilakukan melalui beberapa penyesuaian pada arsitektur *ResNet50* sehingga keluaran model bukan lagi berupa hasil klasifikasi, melainkan representasi fitur yang akan digunakan sebagai masukan pada algoritma *SVM*.

1. Ekstraksi Fitur *Resnet50*

a. Penghapusan Lapisan Klasifikasi Utama dan Pembekuan Bobot

Pada tahap ini, lapisan klasifikasi bawaan *ResNet50* yang terdiri atas *Fully Connected Layer* dan fungsi aktivasi *Softmax* dihilangkan dengan menggunakan parameter *include_top=False*. Penghapusan lapisan tersebut dilakukan karena lapisan klasifikasi asli *ResNet50* dirancang untuk mengklasifikasikan 1.000 kategori objek pada dataset *ImageNet*, sehingga tidak sesuai dengan kebutuhan penelitian ini yang hanya memiliki tiga kategori kualitas air, yaitu jernih, keruh, dan kotor.

Selanjutnya, seluruh lapisan konvolusi pada *ResNet50* dibekukan (*freeze*) menggunakan parameter *trainable=False*. Pembekuan bobot bertujuan agar seluruh bobot hasil pelatihan pada dataset *ImageNet* tetap dipertahankan selama proses

ekstraksi fitur. Dengan demikian, *ResNet50* hanya berfungsi untuk mengekstraksi karakteristik visual dari citra air tanpa melakukan pembaruan bobot (*weight update*) selama proses pelatihan model.

Sesuai dengan arsitektur dasarnya, proses ekstraksi fitur pada *ResNet50* dilakukan melalui serangkaian *Residual Block* yang menerapkan mekanisme *Skip Connection*. Mekanisme ini memungkinkan informasi dari lapisan sebelumnya diteruskan secara langsung ke lapisan berikutnya sehingga informasi penting yang terdapat pada citra tetap dapat dipertahankan selama proses ekstraksi fitur berlangsung. Secara matematis, proses pada setiap *Residual Block* dirumuskan sebagai berikut.

$$y = F(x, \{W_i\}) + x$$

Dengan:

- x merupakan citra masukan (*input feature map*) pada suatu lapisan,
- $F(x, \{W_i\})$ merupakan hasil transformasi konvolusi menggunakan bobot $\{W_i\}$
- y merupakan *feature map* keluaran (*output feature map*).

Berdasarkan persamaan tersebut, keluaran suatu *Residual Block* diperoleh dari hasil penjumlahan antara transformasi konvolusi dan citra masukan sebelumnya. Proses ini dilakukan secara berulang pada setiap blok konvolusi sehingga model mampu mempelajari karakteristik visual citra secara lebih efektif.

Selama proses ekstraksi fitur berlangsung, dimensi spasial citra secara bertahap mengalami reduksi, sedangkan jumlah saluran (*channel*) semakin bertambah. Citra masukan yang semula berukuran 224×224 piksel akhirnya menghasilkan *feature map* berdimensi 7×7 piksel dengan 2048 saluran (*channels*) pada bagian akhir jaringan *ResNet50*. *Feature map* inilah yang selanjutnya digunakan sebagai masukan pada tahap *Global Average Pooling* untuk menghasilkan representasi fitur dalam bentuk vektor.

b. Penerapan *Global Average Pooling* dan Perhitungan Manual Ekstraksi Fitur

Sebagai pengganti lapisan klasifikasi yang telah dihilangkan, penelitian ini menambahkan lapisan *Global Average Pooling* 2D (*GAP*) melalui parameter *pooling=avg*. Lapisan ini bertugas mereduksi dimensi spasial dari setiap *feature map* menjadi satu nilai representatif untuk setiap saluran (*channel*), sehingga keluaran *ResNet50* dapat digunakan sebagai vektor fitur pada proses klasifikasi.

Berdasarkan prinsip kerjanya, *Global Average Pooling* menghitung nilai rata-rata dari seluruh piksel aktivasi yang terdapat pada setiap *feature map*. Karena keluaran *ResNet50* memiliki dimensi $7 \times 7 \times 2048$, maka setiap saluran terdiri atas 49 nilai piksel aktivasi yang kemudian dirata-ratakan menjadi satu nilai representatif. Proses ini dilakukan terhadap seluruh 2048 saluran, sehingga menghasilkan sebuah vektor fitur berdimensi 2048. Secara matematis, proses perhitungan *Global Average Pooling* pada saluran ke- k dirumuskan sebagai berikut.

Dengan:

- GAP_k merupakan nilai rata-rata keluaran (*output feature*) pada saluran ke- k ,
- H merupakan tinggi (*Height*) dari *feature map*,
- W merupakan lebar (*Width*) dari *feature map*,
- $f_k(i, j)$ merupakan nilai aktivasi piksel pada koordinat (i, j) di dalam *feature map* ke- k .

Karena dimensi *feature map* yang dihasilkan *ResNet50* adalah 7×7 , maka jumlah elemen yang dihitung pada setiap saluran adalah sebanyak 49 nilai aktivasi.

mengenai proses perhitungan yang dilakukan oleh *Global Average Pooling*, berikut disajikan ilustrasi perhitungan manual pada saluran pertama ($k=1$) Matriks konvolusi pada saluran pertama memiliki ukuran 7×7 , sehingga terdiri atas 49 nilai piksel aktivasi. Berdasarkan hasil pembacaan pola citra air, total penjumlahan seluruh nilai aktivasi pada saluran pertama $\sum f_1(i, j)$ sebesar 65,85. Dengan menggunakan Persamaan (4.x), maka nilai representasi fitur pada saluran pertama dihitung sebagai berikut.

$$GAP_1 = \frac{65.85}{49} = 1.343$$

Hasil perhitungan sebesar 1,343 merupakan representasi fitur pada saluran pertama (GAP_1). Selanjutnya, proses perhitungan yang sama dilakukan secara otomatis oleh sistem terhadap seluruh saluran, mulai dari saluran ke-2 (GAP_2), saluran ke-3 (GAP_3), hingga saluran terakhir (GAP_{2048}). Dengan demikian, setiap saluran menghasilkan satu nilai representatif yang kemudian disusun menjadi sebuah vektor fitur berdimensi satu (*one-dimensional feature vector*). Representasi akhir dari proses tersebut dapat dituliskan sebagai berikut.

$$\text{Vektor Fitur} = [1.343, 0.412, 2.051, \dots, 0.089]$$

Vektor fitur tersebut berisi 2048 nilai numerik yang merepresentasikan karakteristik visual citra air, seperti pola tekstur, distribusi warna, serta karakteristik visual lainnya yang berhasil dipelajari oleh *ResNet50* selama proses ekstraksi fitur. Vektor inilah yang selanjutnya digunakan sebagai data masukan pada algoritma *Support Vector Machine (SVM)* untuk membangun model klasifikasi kualitas air.

c. Hasil Ekstraksi Fitur

Keberhasilan proses ekstraksi fitur dibuktikan melalui keluaran (*output*) program yang dihasilkan selama proses pengolahan data latih dan data uji. Berdasarkan keluaran program, seluruh citra terlebih dahulu berhasil diubah ukurannya menjadi 224×224 piksel, kemudian diproses oleh *ResNet50* untuk menghasilkan representasi fitur sebanyak 2048 fitur pada setiap citra.

Mengekstraksi fitur data LATIH... mohon tunggu.

--- Info Resize Gambar ---

[Keruh] Contoh resize: 3468x4624 -> 224x224

[Kotor] Contoh resize: 3468x4624 -> 224x224

[Jernih] Contoh resize: 4624x3468 -> 224x224

Target size: 224x224 (standard input ResNet50)

Selesai

Selesai dalam 308.0 detik.

Mengekstraksi fitur data UJI...

--- Info Resize Gambar ---

[Kotor] Contoh resize: 3468x4624 -> 224x224

[Jernih] Contoh resize: 4624x3468 -> 224x224

[Keruh] Contoh resize: 3468x4624 -> 224x224

Target size: 224x224 (standard input ResNet50)

Selesai

Selesai dalam 76.3 detik.

Dimensi fitur data latih: (360, 2048)

Dimensi fitur data uji: (90, 2048)

Jumlah label latih: (360,)

Jumlah label uji: (90,)

Berdasarkan output program tersebut, dapat diketahui bahwa proses ekstraksi fitur telah berjalan dengan baik. Sebanyak 360 citra data latih berhasil diekstraksi menjadi matriks fitur berdimensi (360, 2048) dalam waktu 308,0 detik, sedangkan 90 citra data uji berhasil diekstraksi menjadi matriks berdimensi (90, 2048) dalam waktu 76,3 detik. Setiap baris pada matriks merepresentasikan satu citra, sedangkan setiap kolom merepresentasikan satu fitur hasil ekstraksi *ResNet50*. Matriks fitur berdimensi 2048 tersebut kemudian digunakan sebagai data masukan (*input*) pada algoritma *Support Vector Machine (SVM)* untuk membangun model klasifikasi kualitas air ke dalam tiga kategori, yaitu jernih, keruh, dan kotor.

2. Pelatihan Model *Support Vector Machine (SVM)*

Setelah proses ekstraksi fitur menggunakan *ResNet50* selesai dilakukan, setiap citra air telah direpresentasikan dalam bentuk vektor fitur berdimensi 2048. Vektor fitur tersebut selanjutnya digunakan sebagai data masukan (*input*) pada tahap pelatihan model klasifikasi menggunakan algoritma *Support Vector Machine (SVM)*. Pada penelitian ini, *SVM* dipilih karena memiliki kemampuan yang baik dalam melakukan klasifikasi pada data berdimensi tinggi (*high-dimensional data*), sehingga sesuai untuk mengolah hasil ekstraksi fitur yang dihasilkan oleh *ResNet50*.

Agar model yang dibangun mampu menghasilkan performa klasifikasi yang optimal, proses pelatihan tidak menggunakan parameter bawaan (default parameter). Sebaliknya, penelitian ini menerapkan metode *GridSearchCV* untuk melakukan pencarian kombinasi parameter terbaik secara sistematis. Melalui pendekatan ini, setiap kombinasi parameter yang telah ditentukan akan diuji secara otomatis sehingga dapat diperoleh konfigurasi yang memberikan performa terbaik terhadap data pelatihan.

Untuk mengurangi kemungkinan terjadinya *overfitting* serta memastikan model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat (*unseen data*), proses pencarian parameter terbaik dikombinasikan dengan metode *5-Fold Cross Validation*. Pada metode ini, data pelatihan dibagi menjadi lima bagian (*fold*) dengan proporsi yang sama. Pada setiap iterasi, empat bagian digunakan sebagai data pelatihan (*training set*), sedangkan satu bagian lainnya digunakan sebagai data validasi (*validation set*). Proses tersebut dilakukan secara bergantian hingga seluruh *fold* memperoleh kesempatan menjadi data validasi. Nilai akurasi dari setiap iterasi kemudian dirata-ratakan untuk menentukan performa dari setiap kombinasi parameter yang diuji.

Berdasarkan implementasi pada sistem, proses *GridSearchCV* melakukan pengujian terhadap 24 kombinasi parameter yang telah ditentukan sebelumnya. Karena setiap kombinasi divalidasi menggunakan *5-Fold Cross Validation*, maka sistem melakukan total 120 proses pelatihan (*fits*) sebelum menentukan konfigurasi parameter terbaik. Hasil proses pelatihan menggunakan *GridSearchCV* ditunjukkan pada keluaran program berikut.

Melatih SVM dengan GridSearchCV (5-fold)... mohon tunggu.

Fitting 5 folds for each of 24 candidates, totalling 120 fits

Pelatihan selesai dalam 56.5 detik.

Parameter terbaik :

```
{'svm__C': 0.1,  
'svm__gamma': 'scale',  
'svm__kernel': 'linear'}
```

Akurasi CV terbaik : 0.9028

Berdasarkan keluaran program tersebut, proses pelatihan model berhasil dilakukan dengan baik. Seluruh kombinasi parameter yang telah ditentukan berhasil diuji menggunakan metode *GridSearchCV* dengan *5-Fold Cross Validation*, sehingga sistem dapat menentukan konfigurasi parameter yang memberikan performa terbaik terhadap data pelatihan.

Berdasarkan hasil komputasi, proses pencarian parameter terbaik yang terdiri atas 120 proses pelatihan berhasil diselesaikan dalam waktu 56,5 detik. Waktu komputasi tersebut menunjukkan bahwa algoritma *SVM* memiliki efisiensi yang cukup baik dalam mengolah data hasil ekstraksi fitur *ResNet50*. Meskipun setiap citra direpresentasikan oleh 2048 fitur, proses pelatihan tetap dapat dilakukan dalam waktu yang relatif singkat sehingga metode yang digunakan dinilai cukup efisien untuk diterapkan pada penelitian ini. Hasil *GridSearchCV* menunjukkan bahwa konfigurasi parameter terbaik diperoleh pada kombinasi yakni *Kernel = Linear*, $C = 0,1$, *Gamma = scale*. Nilai parameter $C = 0,1$ menunjukkan bahwa model menggunakan tingkat regularisasi yang relatif tinggi sehingga proses pembentukan *hyperplane* lebih mengutamakan kemampuan generalisasi dibandingkan hanya menyesuaikan seluruh data pelatihan. Dengan demikian, model menjadi lebih stabil dan memiliki peluang yang lebih kecil mengalami *overfitting*. Parameter *gamma = scale* dipilih secara otomatis oleh pustaka *Scikit-learn* sebagai mekanisme penyesuaian nilai gamma berdasarkan karakteristik data yang digunakan. Meskipun pada konfigurasi terbaik digunakan *kernel linear*, parameter tersebut tetap menjadi bagian dari konfigurasi model yang dihasilkan oleh *GridSearchCV*.

Fitur-fitur visual yang dihasilkan oleh *ResNet50* mampu merepresentasikan perbedaan karakteristik antara kategori air jernih, air keruh, dan air kotor secara jelas, sehingga ketiga kategori tersebut telah memiliki pemisahan (*separation*) yang cukup baik di dalam ruang fitur berdimensi 2048. Akibatnya, proses klasifikasi tidak lagi memerlukan fungsi pemetaan nonlinier seperti yang digunakan pada kernel *Radial Basis Function (RBF)* maupun *Polynomial*, karena batas pemisah (*decision boundary*) berbentuk linear sudah mampu memberikan performa terbaik terhadap data.

Konfigurasi parameter terbaik yang diperoleh melalui proses *GridSearchCV* menghasilkan nilai *Cross Validation Accuracy* sebesar 0,9028 atau 90,28%. Nilai tersebut merupakan rata-rata akurasi yang diperoleh dari lima proses validasi pada metode *5-Fold Cross Validation*, sehingga dapat menggambarkan performa model secara lebih objektif dibandingkan apabila hanya menggunakan satu kali pembagian data pelatihan dan data validasi.

Perolehan akurasi 90,28% menunjukkan bahwa kombinasi parameter yang dipilih memiliki kemampuan yang baik dalam mengenali pola pada data pelatihan serta mampu mempertahankan performa yang konsisten pada data validasi. Dengan demikian, model yang dihasilkan memiliki kemampuan generalisasi yang baik dan layak digunakan untuk memasuki tahap pengujian menggunakan data uji (*testing data*) yang belum pernah dilihat sebelumnya.

3. Evaluasi Model *Hybrid Resnet50* Dan *Support Vector Machine (SVM)*

Tahap evaluasi model bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan data yang belum pernah digunakan selama proses pelatihan (*unseen data*). Evaluasi ini penting untuk mengetahui sejauh mana model mampu mempertahankan performanya ketika dihadapkan pada variasi data baru, termasuk citra yang telah mengalami degradasi kualitas seperti penambahan noise, blur, maupun penurunan resolusi (*downscale*). Pada penelitian ini, evaluasi dilakukan menggunakan 20% data uji (*test set*) dari keseluruhan dataset yang telah dipisahkan pada tahap sebelumnya.

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*. *Accuracy* menunjukkan proporsi prediksi yang benar terhadap seluruh data uji, *Precision* mengukur ketepatan prediksi pada setiap kelas, *Recall* menunjukkan kemampuan model dalam mengenali seluruh anggota suatu kelas, sedangkan *F1-Score* merupakan rata-rata harmonik antara *Precision* dan *Recall* sehingga mampu memberikan gambaran performa model secara lebih seimbang. Hasil pengujian model secara keseluruhan disajikan pada Tabel 2 berikut.


Tabel 2. 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 2, 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. Kedekatan nilai ketiga metrik tersebut mengindikasikan bahwa model tidak hanya memiliki tingkat ketepatan prediksi yang baik, tetapi juga mampu mempertahankan sensitivitas dalam mengenali masing-masing kelas tanpa menunjukkan kecenderungan bias yang besar terhadap kelas tertentu. Hasil ini menunjukkan bahwa fitur yang diekstraksi oleh *ResNet50* cukup representatif untuk

membedakan karakteristik visual kualitas air, sedangkan *SVM* mampu membentuk batas keputusan (*decision boundary*) yang efektif dalam proses 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 10 berikut.



Gambar 10. Visualisasi *Confusion matrix*

Gambar 10 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.

Secara umum, nilai terbesar berada pada diagonal utama matriks yang menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan benar. Sebaliknya, nilai di luar diagonal utama menunjukkan terjadinya kesalahan klasifikasi (*misclassification*). Hal ini mengindikasikan bahwa model memiliki kemampuan klasifikasi yang baik pada sebagian besar data uji.

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.

Hasil tersebut menunjukkan bahwa Air Keruh merupakan kelas yang paling sulit diklasifikasikan karena memiliki karakteristik visual yang berada di antara Air Jernih dan Air Kotor. Selain itu, degradasi citra berupa noise, blur, dan penurunan resolusi dapat mengurangi informasi visual sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi.

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. Interpretasi ilmiah dari masing masing sel *Confusion matrix* di paparkan pada table 3.

Tabel 3. Interpretasi ilmiah


Jumlah	Aktual, Prediksi	Parameter	Penjelasan
1	Air Jernih, Air Jernih	True Positive	Mayoritas citra berhasil dikenali dengan benar, dengan tingkat keberhasilan sebesar 93,3%.
2	Air Jernih, Air Keruh	False Negative	Terjadi kesalahan klasifikasi karena sebagian citra

Jumlah	Aktual, Prediksi	Parameter	Penjelasan
			memiliki karakteristik visual yang mirip dengan kelas air keruh.
3	Air Keruh, Air Jernih	False Negative	Merupakan jumlah kesalahan prediksi terbesar. Hal ini menunjukkan adanya kemiripan fitur visual antara kelas air keruh dan air jernih sehingga model mengalami kesulitan dalam membedakannya.
4	Air Keruh, Air Keruh	True Positive	Sebagian besar citra berhasil diklasifikasikan dengan benar (76,7%), meskipun nilai ini merupakan akurasi terendah dibandingkan dua kelas lainnya.

Jumlah	Aktual, Prediksi	Parameter	Penjelasan
5	Air Keruh, Air Kotor	False Negative	Kesalahan klasifikasi sangat sedikit, menandakan hanya sebagian kecil citra air keruh yang memiliki karakteristik menyerupai air kotor.
6	Air Kotor, Air Jernih	False Negative	Kesalahan prediksi kemungkinan disebabkan oleh penurunan kualitas citra, seperti noise atau blur, yang mengurangi kejelasan ciri khas air kotor.
7	Air Kotor, Air Kotor	True Positive	Mayoritas citra berhasil dikenali dengan benar, dengan tingkat keberhasilan mencapai 90,0%, sehingga

Jumlah	Aktual, Prediksi	Parameter	Penjelasan
			menunjukkan
			performa model
			yang sangat baik
			pada kelas air
			kotor.

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 11 berikut.



Gambar 11. Visualisasi Nilai Tiap Kelas

Gambar 11 menyajikan evaluasi menyeluruh model *Hybrid ResNet50-SVM* yang meliputi *Confusion Matrix* dalam bentuk jumlah dan persentase, grafik *Precision*, *Recall*, dan *F1-Score* untuk setiap kelas, serta distribusi *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Hasil *Confusion Matrix* menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, yang menandakan model mampu mengklasifikasikan mayoritas data uji dengan benar. Kelas Air Jernih berhasil dikenali sebanyak 28 dari 30 sampel (93,3%), kelas Air Keruh sebanyak 23 sampel (76,7%), dan kelas Air Kotor sebanyak 27 sampel (90,0%). Sebagian besar kesalahan klasifikasi terjadi pada kelas Air Keruh yang lebih sering diprediksi sebagai Air Jernih, sehingga

mengindikasikan bahwa kelas tersebut memiliki karakteristik visual yang paling sulit dibedakan dibandingkan dua kelas lainnya.

Grafik metrik evaluasi menunjukkan bahwa kelas Air Kotor memiliki performa terbaik dengan nilai *Precision* sebesar 0,96, *Recall* sebesar 0,90, dan *F1-Score* sebesar 0,93, yang didukung oleh nilai *False Positive* terendah, yaitu satu sampel. Sebaliknya, kelas Air Jernih memiliki nilai *Recall* tertinggi sebesar 0,93, namun *Precision* lebih rendah, yaitu 0,76, karena masih terdapat sembilan sampel *False Positive*. Sementara itu, kelas Air Keruh memiliki *Recall* terendah sebesar 0,77 dan *False Negative* tertinggi sebanyak tujuh sampel, yang menunjukkan bahwa sebagian citra Air Keruh masih diprediksi sebagai kelas lain, terutama Air Jernih. Secara keseluruhan, hasil evaluasi konsisten dengan nilai *Accuracy* sebesar 86,67%, *Precision (weighted)* sebesar 88,03%, *Recall (weighted)* sebesar 86,67%, dan *F1-Score (weighted)* sebesar 86,77%. Hasil tersebut menunjukkan bahwa model *Hybrid ResNet50-SVM* memiliki kemampuan klasifikasi yang baik dan stabil, meskipun masih terdapat tantangan dalam membedakan kelas Air Keruh yang memiliki karakteristik visual transisi antara Air Jernih dan Air Kotor. Untuk lebih rinci dipaparkan detailnya pada table 4.

Tabel 4 Distribusi Nilai 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.

Secara keseluruhan, sistem *Hybrid ResNet50-SVM* terbukti tangguh dan efektif dengan pencapaian *Accuracy* sebesar 86,67% dan *F1-Score* sebesar 86,77%. Penggunaan *ResNet50* sebagai pengekstraksi fitur dikombinasikan dengan batas

klasifikasi *SVM* terbukti menghasilkan performa yang optimal. Meskipun masih terdapat sebagian kecil kesalahan prediksi pada kelas dengan ambiguitas visual yang tinggi, hasil evaluasi ini menegaskan bahwa model memiliki kemampuan generalisasi yang andal dan sangat layak diterapkan untuk mendeteksi kualitas air, bahkan pada citra yang telah mengalami berbagai bentuk degradasi.

D. Pelatihan Model *Resenet50* Sebagai *Baseline*

1. Tahap Pelatihan Model *Resnet50*

Pada tahap ini dilakukan pelatihan model menggunakan arsitektur *ResNet50* dengan lapisan klasifikasi berbasis *Softmax* sebagai model dasar (*baseline*). Model ini digunakan untuk mengetahui kemampuan *ResNet50* dalam melakukan klasifikasi citra kualitas air sebelum dibandingkan dengan pendekatan *Hybrid ResNet50-SVM*. Setelah proses ekstraksi fitur oleh *ResNet50*, representasi fitur diteruskan ke lapisan klasifikasi yang terdiri atas dua lapisan *Dense* masing-masing berukuran 256 dan 64 *neuron*, disertai lapisan *Dropout* sebagai mekanisme regularisasi. Lapisan keluaran menggunakan tiga neuron dengan fungsi aktivasi *Softmax* yang disesuaikan dengan jumlah kelas penelitian, yaitu Air Jernih, Air Keruh, dan Air Kotor.

Berdasarkan hasil pelatihan, lapisan *Dense* pertama memiliki jumlah parameter terbesar, yaitu 524.544 parameter. Hal ini menunjukkan bahwa sebagian besar proses pembelajaran pada bagian klasifikasi terjadi pada lapisan tersebut. Lapisan ini berfungsi mentransformasikan fitur yang telah diekstraksi oleh *ResNet50* ke dalam representasi yang lebih sesuai untuk proses klasifikasi. Selanjutnya, lapisan *Dense* kedua dengan 64 *neuron* melakukan penyederhanaan representasi fitur sehingga informasi yang dipertahankan merupakan karakteristik yang paling relevan sebelum dilakukan klasifikasi akhir. Struktur bertingkat tersebut memungkinkan model mempelajari hubungan nonlinier antarfitur secara bertahap sehingga keputusan klasifikasi dapat dilakukan secara lebih efektif.

Di antara kedua lapisan *Dense* diterapkan lapisan *Dropout* yang tidak memiliki parameter untuk dipelajari. Fungsi utama lapisan ini adalah melakukan regularisasi dengan menonaktifkan sebagian *neuron* secara acak selama proses pelatihan. Teknik tersebut bertujuan untuk mengurangi ketergantungan model

terhadap *neuron* tertentu sehingga kemampuan generalisasi model terhadap data baru dapat ditingkatkan dan risiko overfitting dapat diminimalkan.

Pada lapisan keluaran digunakan fungsi aktivasi *Softmax* yang menghasilkan distribusi probabilitas untuk setiap kelas. Berbeda dengan fungsi aktivasi biner, *Softmax* memungkinkan model memberikan nilai probabilitas pada seluruh kelas secara bersamaan dengan jumlah total probabilitas sebesar satu. Kelas dengan probabilitas tertinggi kemudian dipilih sebagai hasil prediksi model. Penggunaan *Softmax* pada penelitian ini sesuai dengan karakteristik permasalahan yang melibatkan tiga kelas klasifikasi yang bersifat saling eksklusif (*multiclass classification*).


Secara keseluruhan, lapisan klasifikasi yang dibangun memiliki total 541.187 parameter yang dapat dilatih (*trainable parameters*). Seluruh parameter tersebut diperbarui selama proses pelatihan menggunakan algoritma optimasi berbasis *backpropagation* untuk meminimalkan nilai fungsi kerugian (*loss function*). Jumlah parameter tersebut menunjukkan bahwa model memiliki kapasitas pembelajaran yang cukup besar untuk mempelajari hubungan antara fitur citra dan kelas kualitas air, namun tetap relatif ringan dari sisi kebutuhan memori karena hanya memerlukan sekitar 2,06 MB pada bagian klasifikasi.

Arsitektur *ResNet50* dengan *Softmax* pada penelitian ini digunakan sebagai model acuan (*baseline*) sebelum menerapkan pendekatan *Hybrid ResNet50-SVM*. Dengan demikian, hasil pelatihan model ini menjadi dasar untuk mengevaluasi apakah penggantian lapisan klasifikasi *Softmax* dengan algoritma *Support Vector Machine* mampu meningkatkan performa klasifikasi, khususnya pada citra kualitas air yang telah mengalami degradasi seperti penambahan noise, blur, dan penurunan resolusi.

2. Pengukuran dan Evaluasi Model *Resnet50*

Tahap pelatihan dan evaluasi bertujuan untuk mengetahui kemampuan model *ResNet50* dengan pengklasifikasi *Softmax* dalam mempelajari karakteristik citra kualitas air serta mengukur kemampuan generalisasinya terhadap data yang belum pernah digunakan selama proses pelatihan (*unseen data*). Selama proses pelatihan, perkembangan nilai *loss* dan *accuracy* diamati untuk mengevaluasi

proses konvergensi model, sedangkan tahap evaluasi dilakukan menggunakan data uji yang terdiri atas tiga kategori kualitas air, yaitu Air Jernih, Air Keruh, dan Air Kotor. Performa model diukur menggunakan metrik Accuracy, Precision, Recall, dan F1-Score, kemudian dianalisis lebih lanjut melalui Confusion Matrix serta distribusi True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN).



Gambar 12. *Learning Curve*

Gambar 12 memvisualisasikan perkembangan nilai *loss* dan *accuracy* selama proses pelatihan model *ResNet50* dengan pengklasifikasi *Softmax* selama 15 *epoch*. Kurva ini digunakan untuk mengevaluasi proses pembelajaran, tingkat konvergensi, serta kemampuan generalisasi model terhadap data validasi. Pada grafik *loss*, *training loss* menurun secara signifikan dari sekitar 1,35 menjadi 0,20, sedangkan *validation loss* juga mengalami penurunan dan kemudian stabil pada kisaran 0,25–0,30. Jarak kedua kurva yang relatif kecil menunjukkan bahwa model mampu mempelajari pola data dengan baik tanpa mengalami *overfitting* yang berlebihan.

Grafik *accuracy* menunjukkan peningkatan yang konsisten, di mana *training accuracy* mencapai lebih dari 92% dan *validation accuracy* sekitar 89% pada akhir pelatihan. Meskipun terdapat fluktuasi kecil pada *validation accuracy*, pola kedua kurva tetap sejalan dan mulai stabil pada *epoch* akhir, yang mengindikasikan bahwa model telah mencapai kondisi konvergen. Hasil ini menunjukkan bahwa proses optimasi berlangsung dengan baik dan penambahan *epoch* diperkirakan tidak akan memberikan peningkatan performa yang signifikan.

Hasil kurva pelatihan tersebut selaras dengan evaluasi pada data uji yang menghasilkan *Accuracy* sebesar 83,33%, *Precision* sebesar 84,02%, *Recall* sebesar 83,33%, dan *F1-Score* sebesar 83,53%. Meskipun performa pada data uji sedikit lebih rendah dibandingkan data pelatihan dan validasi, hal ini menunjukkan bahwa model masih mampu melakukan generalisasi dengan baik terhadap data baru. Namun demikian, hasil *Confusion Matrix* memperlihatkan bahwa sebagian besar kesalahan klasifikasi terjadi antara kelas Air Jernih dan Air Keruh, sehingga mengindikasikan bahwa ResNet50 telah berhasil mempelajari pola utama citra, tetapi masih memiliki keterbatasan dalam membedakan kelas-kelas yang memiliki karakteristik visual yang saling berdekatan akibat degradasi citra.


3. Evaluasi Model *Resnet50*

Tahap evaluasi dilakukan untuk mengukur kemampuan model ResNet50 dengan pengklasifikasi *Softmax* dalam mengklasifikasikan citra kualitas air pada data uji yang tidak digunakan selama proses pelatihan. Evaluasi ini bertujuan untuk mengetahui kemampuan generalisasi model terhadap data baru yang memiliki variasi karakteristik visual akibat proses degradasi citra, seperti *noise*, *blur*, dan penurunan resolusi. Performa model dianalisis menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Selanjutnya, dilakukan analisis yang lebih mendalam melalui *Confusion Matrix*, metrik evaluasi pada setiap kelas, serta distribusi *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Kombinasi seluruh analisis tersebut memberikan gambaran yang lebih komprehensif mengenai tingkat keberhasilan model sekaligus sumber kesalahan klasifikasi yang masih terjadi. Performa model *Resnet50* secara detail di paparkan pada tabel 6 berikut

Tabel 6. Ringkasan Performa Model ResNet50

Metrik	Nilai
Accuracy	83,33%
Precision (Weighted)	84,02%
Recall (Weighted)	83,33%
F1-Score (Weighted)	83,53%

Tabel 6 menunjukkan bahwa model ResNet50 dengan pengklasifikasi *Softmax* memperoleh *Accuracy* sebesar 83,33%, *Precision* sebesar 84,02%, *Recall* sebesar 83,33%, dan *F1-Score* sebesar 83,53%. Nilai keempat metrik yang relatif berdekatan menunjukkan bahwa model memiliki performa klasifikasi yang cukup seimbang, sehingga mampu mengenali ketiga kategori kualitas air dengan tingkat konsistensi yang baik. Meskipun demikian, nilai *Accuracy* yang belum mencapai 90% mengindikasikan bahwa masih terdapat sejumlah kesalahan klasifikasi yang perlu dianalisis lebih lanjut melalui *Confusion Matrix* dan evaluasi pada masing-masing kelas. Untuk mengetahui distribusi prediksi yang benar maupun salah pada setiap kategori kualitas air, dilakukan analisis menggunakan *Confusion Matrix*. Visualisasi ini disajikan dalam dua bentuk, yaitu berdasarkan jumlah sampel dan persentase. Penyajian kedua bentuk tersebut bertujuan untuk memberikan gambaran mengenai banyaknya prediksi pada setiap kelas sekaligus tingkat keberhasilan klasifikasi secara proporsional pada gambar 13 berikut.



Gambar 13. *Confusion Matrix ResNet50*

Gambar 13 memperlihatkan bahwa sebagian besar prediksi berada pada diagonal utama matriks, yang menunjukkan bahwa mayoritas citra berhasil diklasifikasikan sesuai kelas sebenarnya. Pada kelas Air Jernih, model berhasil mengklasifikasikan 25 dari 30 sampel (83,3%), sedangkan 5 sampel (16,7%) diprediksi sebagai Air Keruh. Pada kelas Air Keruh, sebanyak 24 sampel (80,0%) dikenali dengan benar, sementara 5 sampel diprediksi sebagai Air Jernih dan 1 sampel sebagai Air Kotor. Adapun kelas Air Kotor memperoleh hasil terbaik

dengan 26 dari 30 sampel (86,7%) berhasil diprediksi secara benar, sedangkan 3 sampel diprediksi sebagai Air Jernih dan 1 sampel sebagai Air Keruh. Pola tersebut menunjukkan bahwa sebagian besar kesalahan terjadi antara Air Jernih dan Air Keruh, yang mengindikasikan bahwa kedua kelas memiliki karakteristik visual yang lebih mirip dibandingkan Air Kotor. Sebaliknya, Air Kotor memiliki karakteristik visual yang lebih konsisten sehingga lebih mudah dikenali oleh model. Terkait distribusi prediksi model berdasarkan aktual dipaparkan pada tabel 7.

Tabel 7. *Confusion Matrix ResNet50*

Aktual	Prediksi Air		
	Jernih	Keruh	Kotor
Air Jernih	25	5	0
Air Keruh	5	24	1
Air Kotor	3	1	26

Tabel 7 memperlihatkan distribusi prediksi model berdasarkan kelas aktual. Kesalahan klasifikasi paling banyak terjadi antara Air Jernih dan Air Keruh, sedangkan kesalahan yang melibatkan Air Kotor relatif lebih sedikit. Hal ini menunjukkan bahwa model telah mampu mempelajari karakteristik visual utama setiap kelas, namun masih mengalami keterbatasan dalam membedakan kelas yang memiliki kemiripan tekstur, warna, dan tingkat kekeruhan.

Selain mengevaluasi performa model secara keseluruhan, analisis juga dilakukan pada setiap kelas menggunakan metrik *Precision*, *Recall*, dan *F1-Score*. Analisis ini bertujuan untuk mengetahui kelas mana yang paling mudah dikenali oleh model serta kelas yang masih menjadi sumber utama kesalahan klasifikasi. Hal tersebut divisualisasikan pada gambar 14.




Gambar 14. Metrik per kelas

Gambar 14 menunjukkan performa model berbeda pada setiap kelas. Air Kotor memperoleh hasil terbaik dengan *Precision* sebesar 0,96, *Recall* sebesar 0,87, dan *F1-Score* sebesar 0,91, yang menunjukkan bahwa model mampu mengenali kelas tersebut secara konsisten dengan tingkat kesalahan yang rendah. Air Keruh memiliki nilai *Precision*, *Recall*, dan *F1-Score* yang sama, yaitu 0,80, sehingga menunjukkan performa yang cukup seimbang meskipun masih terdapat sejumlah sampel yang gagal dikenali. Sementara itu, Air Jernih memiliki *Recall* sebesar 0,83 namun *Precision* hanya sebesar 0,76. Kondisi ini menunjukkan bahwa sebagian prediksi Air Jernih berasal dari kelas lain, sehingga ketepatan prediksi pada kelas tersebut masih lebih rendah dibandingkan kelas lainnya seperti yang ditampilkan pada tabel 8 berikut.

Tabel 8. Metrik Evaluasi per Kelas

Kelas	Precision	Recall	F1-Score	Accuracy
Air Jernih	0,7576	0,8333	0,7937	0,8556
Air Keruh	0,8000	0,8000	0,8000	0,8667
Air Kotor	0,9630	0,8667	0,9123	0,9444

Tabel 8 menjelaskan bahwa Air Kotor merupakan kelas dengan performa terbaik berdasarkan seluruh metrik evaluasi. Sebaliknya, Air Jernih memiliki nilai *Precision* terendah akibat masih cukup banyak prediksi positif yang keliru, sedangkan Air Keruh menunjukkan performa yang relatif seimbang namun belum mencapai tingkat akurasi seperti Air Kotor. Hasil ini memperkuat bahwa Air Kotor memiliki karakteristik visual yang lebih mudah dipelajari oleh model. Untuk memperoleh pemahaman yang lebih rinci mengenai sumber kesalahan klasifikasi, dilakukan analisis terhadap nilai TP, TN, FP, dan FN pada setiap kelas. Analisis ini membantu menjelaskan mengapa suatu kelas memiliki nilai *Precision* atau *Recall* yang lebih tinggi maupun lebih rendah dibandingkan kelas lainnya. Visualisasi dari TP, TN, FP, dan FN di tampilkan pada gambar 15.



Gambar 15. Grafik TP, TN, FP, dan FN per Kelas

Gambar 15 menjelaskan Air Kotor memiliki jumlah *True Positive* dan *True Negative* tertinggi serta *False Positive* terendah, sehingga menghasilkan *Precision* yang paling tinggi. Sebaliknya, Air Jernih memiliki *False Positive* tertinggi, yang menunjukkan bahwa model masih cukup sering mengelompokkan sampel dari kelas lain sebagai Air Jernih. Sementara itu, Air Keruh memiliki jumlah *False Negative* yang relatif tinggi, yang mengindikasikan bahwa sebagian citra Air Keruh lebih sering diprediksi sebagai Air Jernih. Temuan ini konsisten dengan hasil *Confusion Matrix* yang menunjukkan bahwa tantangan utama model terletak pada pemisahan kelas Air Jernih dan Air Keruh yang memiliki karakteristik visual saling berdekatan. Adapun detail nilai dari TP, TN, FP, dan FN di paparkan pada tabel 9 dibawah.

Tabel 9. Detail nilai TP, TN, FP, dan FN

Kelas	TP	TN	FP	FN
Air Jernih	25	52	8	5
Air Keruh	24	54	6	6
Air Kotor	26	59	1	4

Nilai pada tabel 9 menunjukkan Air Kotor memiliki kombinasi TP dan TN tertinggi serta FP terendah, sehingga menjadi kelas dengan performa klasifikasi paling baik. Sebaliknya, Air Jernih menghasilkan FP tertinggi dan Air Keruh memiliki FN yang relatif tinggi, yang menunjukkan bahwa sebagian besar kesalahan model masih berasal dari kesulitan membedakan kedua kelas tersebut. Secara keseluruhan, hasil analisis TP, TN, FP, dan FN memperkuat temuan pada *Confusion Matrix* dan metrik evaluasi bahwa model *ResNet50* murni telah mampu mengklasifikasikan sebagian besar citra dengan benar, namun kemampuan diskriminatifnya masih terbatas pada kelas yang memiliki kemiripan karakteristik visual.

E. Pelatihan Model *Support Vector Machine* sebagai *Baseline*

Sebagai model pembandingan (*baseline model*), penelitian ini mengevaluasi metode *Support Vector Machine (SVM)* yang menggunakan fitur histogram warna tanpa melibatkan proses ekstraksi fitur mendalam (*deep feature extraction*). Penggunaan model ini bertujuan untuk mengetahui sejauh mana fitur histogram mampu merepresentasikan karakteristik visual kualitas air, sekaligus menjadi dasar perbandingan terhadap model hibrida *ResNet50-SVM* yang diusulkan dalam penelitian.

Fitur histogram merepresentasikan distribusi intensitas warna pada setiap citra sehingga informasi yang digunakan hanya berasal dari karakteristik warna secara global. Berbeda dengan fitur yang dihasilkan oleh jaringan *Convolutional Neural Network (CNN)*, histogram tidak mempertimbangkan hubungan spasial antar piksel maupun pola tekstur pada objek. Oleh karena itu, kemampuan model dalam membedakan citra yang memiliki distribusi warna serupa cenderung lebih

terbatas, terutama ketika citra mengalami variasi pencahayaan, noise, blur, maupun perubahan kualitas citra lainnya.

Pada tahap pelatihan, setiap citra diekstraksi menjadi vektor fitur histogram yang terdiri atas 160 fitur. Dataset dibagi menjadi 360 data latih dan 90 data uji. Selanjutnya dilakukan optimasi parameter menggunakan metode *GridSearchCV* dengan skema *5-Fold Cross Validation* untuk memperoleh kombinasi parameter terbaik. Hasil optimasi menunjukkan bahwa konfigurasi terbaik menggunakan kernel *Radial Basis Function (RBF)*, nilai $C = 100$, dan $\gamma = 0,001$, dengan nilai akurasi *cross-validation* sebesar 72,50%. Konfigurasi pelatihan tersebut ada pada Tabel 10.


Tabel 10. Pelatihan model *SVM*

Parameter	Nilai
Dimensi Data Latih	360×160
Dimensi Data Uji	90×160
Kernel	RBF
Nilai C	100
Nilai Gamma	0,001
Akurasi Cross Validation	72,50%

Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji yang terdiri atas tiga kategori kualitas air, yaitu Air Jernih, Air Keruh, dan Air Kotor. Berdasarkan hasil pengujian diperoleh nilai *Accuracy* sebesar 74,44%, *Precision* sebesar 73,58%, *Recall* sebesar 74,44%, serta *F1-Score* sebesar 73,49%. Hasil tersebut menunjukkan bahwa fitur histogram masih mampu merepresentasikan karakteristik dasar kualitas air, namun kemampuannya dalam membedakan kelas yang memiliki kemiripan visual masih relatif terbatas. Oleh karena itu, analisis lebih lanjut dilakukan melalui *Confusion Matrix*, distribusi TP–TN–FP–FN, serta metrik evaluasi pada masing-masing kelas.

a. Analisis *Confusion Matrix*

Untuk mengetahui pola keberhasilan dan kesalahan klasifikasi pada setiap kategori kualitas air, dilakukan analisis menggunakan *Confusion Matrix*. Analisis ini memberikan informasi mengenai jumlah prediksi yang benar maupun salah, sekaligus menunjukkan pasangan kelas yang paling sering mengalami kesalahan klasifikasi. Berikut gambar 16 *Confusion matrix* model *SVM* yang di lampirkan dibawah.



Gambar 16. *Confusion Matrix* Model *SVM*

Sebagai pendukung visualisasi tersebut, rincian hasil klasifikasi di lampirkan pada Tabel 11 berikut.

Tabel 11. Hasil *Confusion Matrix* model *SVM*

Aktual	Air Jernih	Air Keruh	Air Kotor
Air Jernih	26	4	0
Air Keruh	6	15	9
Air Kotor	0	4	26


Berdasarkan Gambar 16 dan Tabel 11, terlihat bahwa model mampu mengklasifikasikan kelas Air Jernih dan Air Kotor dengan baik. Masing-masing kelas berhasil dikenali sebanyak 26 dari 30 sampel, sehingga memperoleh tingkat keberhasilan sebesar 86,67%. Sebaliknya, performa terendah terjadi pada kelas Air

Keruh, di mana hanya 15 dari 30 sampel yang berhasil diklasifikasikan dengan benar atau sebesar 50,00%.

Kesalahan klasifikasi pada kelas Air Keruh paling banyak terjadi ketika sampel diprediksi sebagai Air Jernih sebanyak 6 sampel dan sebagai Air Kotor sebanyak 9 sampel. Hasil tersebut menunjukkan bahwa karakteristik visual Air Keruh berada pada kondisi transisi sehingga distribusi histogram warnanya memiliki kemiripan dengan kedua kelas lainnya. Menariknya, tidak ditemukan kesalahan klasifikasi secara langsung antara kelas Air Jernih dan Air Kotor. Hal ini menunjukkan bahwa distribusi warna kedua kelas tersebut masih cukup berbeda sehingga lebih mudah dipisahkan oleh model *SVM* berbasis histogram.

b. Analisis *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN)

Untuk memperoleh gambaran yang lebih rinci mengenai performa model pada setiap kategori, dilakukan analisis berdasarkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Analisis ini membantu mengidentifikasi jumlah prediksi yang benar serta jenis kesalahan yang dilakukan model pada masing-masing kelas. Berikut lampiran table distribusi TP, TN, FP, dan FN. Berikut gambar 17 Distribusi TP, TN, FP, dan FN Model *SVM* yang di lampirkan dibawah.



Gambar 17. Distribusi TP, TN, FP, dan FN Model *SVM*

Tabel 12. Distribusi TP, TN, FP, dan FN


Kelas	TP	TN	FP	FN
Air Jernih	26	54	6	4
Air Keruh	15	52	8	15
Air Kotor	26	51	9	4

Berdasarkan Gambar 17 Dan Tabel 12, kelas Air Keruh memiliki nilai *False Negative* tertinggi, yaitu sebanyak 15 sampel. Hal tersebut menunjukkan bahwa separuh citra Air Keruh gagal dikenali sebagai kelas sebenarnya dan lebih sering diprediksi menjadi Air Jernih maupun Air Kotor. Sebaliknya, kelas Air Jernih dan Air Kotor memiliki nilai *True Positive* yang tinggi, sehingga sebagian besar sampelnya berhasil dikenali dengan benar.

Di sisi lain, kelas Air Kotor masih memiliki 9 *False Positive*, yang menunjukkan adanya sejumlah citra dari kelas lain yang diprediksi sebagai Air Kotor. Secara keseluruhan, hasil ini mengindikasikan bahwa fitur histogram cukup efektif dalam mengenali kelas yang memiliki karakteristik warna dominan, namun masih mengalami kesulitan ketika membedakan kelas dengan distribusi warna yang saling berdekatan.

c. Analisis Matrix Evaluasi Per Kelas

Selain menggunakan metrik evaluasi secara keseluruhan, performa model juga dianalisis pada masing-masing kelas menggunakan nilai *Precision*, *Recall*, *F1-Score*, dan *Accuracy*. Analisis ini bertujuan untuk mengetahui konsistensi kemampuan model dalam mengklasifikasikan setiap kategori kualitas air. Berikut lampiran gambar 18. Matrix Evaluasi Per Kelas.



Gambar 18. Matrix Evaluasi Per Kelas

Rincian hasil evaluasi model *SVM* per kelas dilampirkan pada Tabel 13 berikut.

Tabel 13. Matrik Evaluasi Per Kelas.

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
Air Jernih	0,8125	0,8667	0,8387	0,8889
Air Keruh	0,6522	0,5000	0,5660	0,7444
Air Kotor	0,7429	0,8667	0,8000	0,8556

Berdasarkan Gambar 18 dan Tabel 13, kelas Air Jernih memperoleh performa terbaik dengan *F1-Score* sebesar 0,8387, yang menunjukkan keseimbangan antara nilai *Precision* dan *Recall*. Kelas Air Kotor juga menunjukkan kemampuan klasifikasi yang baik dengan nilai *Recall* sebesar 0,8667, meskipun nilai *Precision* sedikit lebih rendah akibat masih terdapat sejumlah *False Positive*.

Sementara itu, kelas Air Keruh menjadi kelas dengan performa terendah, ditunjukkan oleh nilai *Recall* sebesar 0,5000 dan *F1-Score* sebesar 0,5660. Hasil tersebut menunjukkan bahwa fitur histogram belum mampu merepresentasikan karakteristik visual Air Keruh secara konsisten. Kemiripan distribusi warna antara

Air Keruh dengan dua kelas lainnya menyebabkan model lebih sering mengalami kesalahan klasifikasi pada kategori tersebut.

F. 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 pembanding (*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 14 berikut.

Tabel 14. Perbandingan Performa Keseluruhan Antar Model

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

Berdasarkan Tabel 14, 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 19 perbandingan confusion matrix dari ketiga model yang dilampirkan.




Gambar 19. Perbandingan Confusion Matrix *SVM*, *Resnet50*, dan *Hybrid*

Perbandingan *Confusion Matrix* 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 Keruh, yang hanya berhasil dikenali sebanyak 50,00% dari seluruh sampel pada kelas tersebut. Sebagian besar citra Air Keruh 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 Keruh berkurang secara signifikan. Model mampu mengenali sekitar 80% sampel Air Keruh 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 20 perbandingan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Ketiga Model yang dilampirkan.



Gambar 20. 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 15 Analisis Peningkatan Performa Antar Model.

Tabel 15. Analisis Peningkatan Performa Antar Model.

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

Berdasarkan Tabel 15, peningkatan performa terbesar berasal dari proses ekstraksi fitur. Perbandingan antara *Hybrid ResNet50–SVM* dan *SVM Murni* menunjukkan peningkatan akurasi sebesar 12,22%. Hasil ini mengindikasikan bahwa fitur mendalam yang dihasilkan *ResNet50* mampu merepresentasikan karakteristik citra secara lebih komprehensif dibandingkan fitur histogram. Berbeda dengan histogram yang hanya menggambarkan distribusi intensitas warna, fitur *ResNet50* mampu menangkap informasi tekstur, bentuk objek, serta hubungan spasial antar piksel sehingga proses klasifikasi menjadi lebih akurat, terutama pada citra yang mengalami degradasi visual.

Selain itu, penggantian lapisan klasifikasi Softmax dengan *SVM* juga memberikan peningkatan akurasi sebesar 3,33%. Meskipun peningkatannya tidak sebesar kontribusi ekstraksi fitur, hasil tersebut menunjukkan bahwa *SVM* mampu memanfaatkan representasi fitur *ResNet50* secara lebih optimal. Hal ini sejalan dengan prinsip kerja *SVM* yang membangun batas keputusan (*decision boundary*) dengan margin maksimum, sehingga lebih efektif dalam memisahkan kelas-kelas yang memiliki karakteristik visual saling berdekatan.

Secara keseluruhan, hasil analisis komparatif menunjukkan bahwa kedua komponen yang digunakan pada model *Hybrid* memberikan kontribusi yang saling melengkapi. *ResNet50* menghasilkan representasi fitur yang lebih kaya dan lebih stabil terhadap variasi kualitas citra, sedangkan *SVM* meningkatkan kemampuan klasifikasi melalui pembentukan batas keputusan yang lebih optimal. Kombinasi keduanya menghasilkan performa terbaik pada seluruh metrik evaluasi, sehingga mendukung hipotesis penelitian bahwa integrasi ekstraksi fitur mendalam menggunakan *ResNet50* dengan klasifikasi berbasis *SVM* lebih efektif dibandingkan penggunaan masing-masing metode secara terpisah dalam klasifikasi kualitas air berbasis citra.

G. Hasil Pengujian Prediksi Pada *Hybrid Resnet50 Dan SVM*

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 21 sebagai berikut.




Gambar 21. Sampel Hasil Pengujian Prediksi model *Hybrid ResNet50 SVM*

Berdasarkan visualisasi hasil prediksi, model menunjukkan kapabilitas generalisasi yang sangat kuat dalam mengenali karakteristik visual masing-masing kelas kualitas air di lingkungan terbuka. Pada sampel citra Air Jernih, model

mampu memprediksi dengan tingkat keyakinan yang tinggi, yakni mencapai 94.1% dan 75.6%. Fitur konvolusional terbukti efektif mengabaikan variasi pantulan cahaya maupun riak gelombang di permukaan air jernih. Demikian pula pada tiga sampel citra Air Keruh, model berhasil mengidentifikasi secara tepat dengan konsistensi probabilitas keyakinan yang sangat dominan, yaitu di atas 97.8% (97.8%, 98.2%, dan 98.7%). Angka keyakinan yang mendekati mutlak ini membuktikan bahwa arsitektur *ResNet50* mampu menangkap pola tekstur mikro dan suspensi partikel koloid yang menjadi ciri penentu kelas air keruh, sekaligus mengonfirmasi bahwa model *hybrid* dalam memecahkan masalah kelas transisi yang sebelumnya hasilnya kurang maksimal oleh model *baseline* SVM Murni.

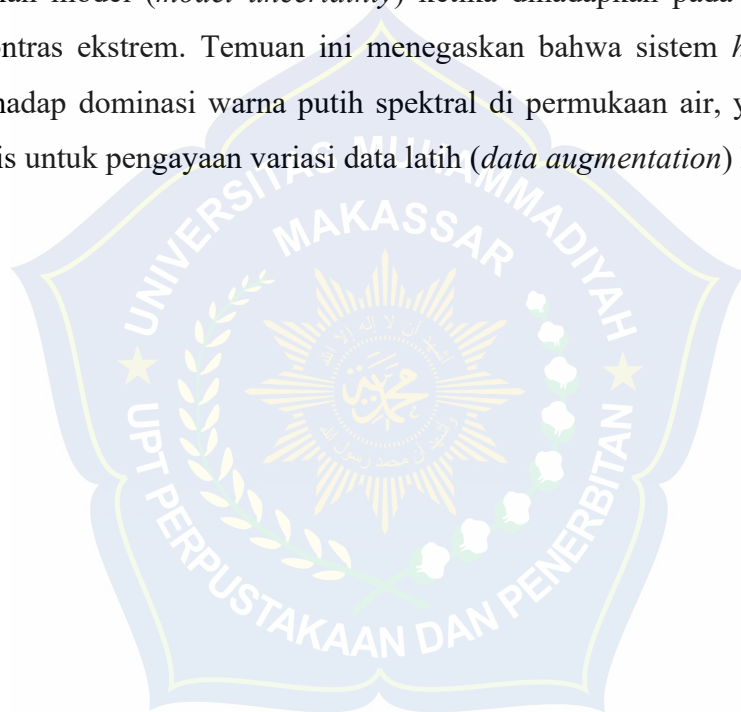
Adapun visualisasi terkait tingkat keyakinan model dalam proses klasifikasi pada data citra air untuk masing masing kelas dipaparkan pada gambar 22 dibawah.



Gambar 22. Distribusi Probabilitas Keyakinan pada Klasifikasi

Meskipun model *hybrid* mencatatkan akurasi keseluruhan tertinggi sebesar 86.67%, evaluasi mendalam terhadap kasus kesalahan prediksi (*misclassification*) tetap diperlukan guna memahami batasan pemrosesan fitur visual sistem. Gambar diatas membedah sebuah sampel aktual Air Kotor yang keliru diprediksi oleh model sebagai Air Jernih. Pada grafik distribusi tingkat keyakinan, model mengeluarkan probabilitas sebesar 47.1% untuk Air Jernih, diikuti oleh 33.4% untuk Air Kotor, dan 19.4% untuk Air Keruh.

Fenomena *False Positive* ini memiliki penjelasan ilmiah yang didasarkan pada komposisi visual citra itu sendiri. Citra air kotor pada sampel tersebut didominasi oleh gumpalan busa tebal berwarna putih terang yang menutupi area perairan yang gelap dan tercemar. Secara matematis, lapisan konvolusi *ResNet50* terdistorsi oleh pola geometris intensitas cerah berfrekuensi tinggi dari busa putih tersebut, yang menyerupai representasi fitur semantik dari air jernih dengan pantulan cahaya tinggi. Selisih probabilitas keyakinan yang relatif tipis antara prediksi Air Jernih (47.1%) dan target aktual Air Kotor (33.4%) mencerminkan ketidakpastian model (*model uncertainty*) ketika dihadapkan pada citra dengan anomali kontras ekstrem. Temuan ini menegaskan bahwa sistem *hybrid* sangat sensitif terhadap dominasi warna putih spektral di permukaan air, yang menjadi catatan kritis untuk pengayaan variasi data latih (*data augmentation*) kedepannya.



BAB V

KESIMPULAN

A. KESIMPULAN

Berdasarkan hasil perancangan sistem, pengujian empiris, dan analisis komparatif terhadap model *Hybrid ResNet50-SVM* dalam melakukan klasifikasi tingkat kekeruhan air berbasis citra digital, maka dapat ditarik kesimpulan yang selaras dengan tujuan penelitian sebagai berikut.

1. Penelitian ini berhasil merancang dan menguji pendekatan *hybrid* yang mengintegrasikan arsitektur *Deep Convolutional Neural Network (ResNet50)* sebagai pengestraksi fitur visual dan *Support Vector Machine (SVM)* sebagai pengklasifikasi akhir. Melalui tahapan *preprocessing* citra (*resize* 224×224 piksel dan normalisasi piksel) serta simulasi degradasi visual (*noise*, *blur*, dan *downscale*), *ResNet50* (dengan memanfaatkan *Transfer Learning ImageNet*) terbukti sangat efektif mengekstraksi karakteristik warna, tekstur mikro, dan pola kekeruhan menjadi vektor fitur berdimensi 2048. Vektor fitur representatif tersebut kemudian berhasil diolah secara optimal oleh algoritma *SVM* berkernel *Linear* ($C = 0,1$) menggunakan metode *GridSearchCV* dan *5-Fold Cross Validation*, yang mencapai akurasi validasi silang (*cross-validation accuracy*) terbaik sebesar 90,28%.
2. Hasil evaluasi kinerja pada data uji menunjukkan bahwa model *Hybrid ResNet50-SVM* menghasilkan performa yang sangat baik, konsisten, dan unggul dalam mengategorikan citra air ke dalam tiga tingkat kekeruhan (Air Jernih, Air Keruh, dan Air Kotor). Ditinjau dari metrik evaluasi keseluruhan, model mencapai *Accuracy* sebesar 86,67%, *Precision* sebesar 88,03%, *Recall* sebesar 86,67%, dan *F1-Score* sebesar 86,77%, di mana keseimbangan angka tersebut membuktikan bahwa model memiliki ketepatan prediksi yang tinggi dan tidak menunjukkan kecenderungan bias terhadap kelas tertentu. Secara spesifik per kelas, model mencatatkan kinerja terbaik pada kelas ekstrem, yaitu Air Kotor (*Precision* 96,43%, *Recall* 90,00%, *F1-Score* 93,10%) dan Air Jernih (*Precision* 75,68%, *Recall* 93,33%, *F1-Score* 83,58%). Sementara itu, pada kelas transisi

yaitu Air Keruh (*Precision* 92,00%, *Recall* 76,67%, *F1-Score* 83,64%), model tetap mampu menunjukkan ketepatan prediksi yang tinggi meskipun menjadi kelas dengan tingkat kompleksitas visual paling sulit akibat kemiripan fiturnya dengan air jernih. Lebih lanjut, analisis keunggulan komparatif memperlihatkan bahwa model *Hybrid ResNet50-SVM* (86,67%) terbukti lebih unggul dibandingkan model *baseline ResNet50* Murni berbasis pengklasifikasi *Softmax* yang memperoleh akurasi 83,33% (peningkatan performa sebesar +3,34%). Selain itu, model *hybrid* mengungguli secara telak metode pembandingan *SVM* Murni berbasis fitur histogram statis yang hanya memperoleh akurasi 74,44% dengan peningkatan signifikan sebesar +12,23%. Hal ini membuktikan bahwa kombinasi representasi fitur mendalam dari *ResNet50* dan maksimasi margin *SVM* memberikan solusi klasifikasi yang jauh lebih tangguh, presisi, dan andal untuk sistem peringatan dini (*early warning system*) kualitas air.

B. SARAN

Berdasarkan hasil penelitian dan analisis terhadap kendala klasifikasi yang masih ditemui, saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya adalah.

1. Pengayaan dan Augmentasi Dataset Spesifik Pada kelas transisi (Air Keruh) dan kondisi citra dengan anomali kontras ekstrem (misalnya air kotor dengan dominasi buih/busa putih pekat), sistem rentan mengalami keliru klasifikasi (*False Positive/False Negative*). Disarankan untuk memperbanyak variasi data latih (*dataset*) khususnya pada fase peralihan kejernihan air serta menerapkan teknik *Data Augmentasi* yang lebih beragam agar ketahanan (*robustness*) model semakin meningkat.
2. Pengembangan Sistem Real-Time Berbasis IoT Untuk merealisasikan manfaat praktis bagi masyarakat dan instansi terkait secara langsung, model *Hybrid ResNet50-SVM* yang telah dilatih ini disarankan agar diintegrasikan ke dalam perangkat keras *Internet of Things* (IoT) seperti mikrokontroler dengan kamera portabel atau aplikasi seluler pintar (*smartphone*), sehingga pemantauan kualitas air dapat dilakukan secara *real-time* di lapangan.

3. Penelitian selanjutnya disarankan untuk mengembangkan sistem klasifikasi tingkat kekeruhan air dengan mengintegrasikan analisis citra dan parameter kualitas air, seperti pH, *Total Dissolved Solids (TDS)*, *Dissolved Oxygen (DO)*, *Biological Oxygen Demand (BOD)*, maupun nilai kekeruhan (NTU) yang diperoleh melalui sensor. Integrasi antara data visual dan data hasil pengukuran diharapkan dapat menghasilkan sistem yang tidak hanya mampu mengklasifikasikan kondisi air berdasarkan tampilan citra, tetapi juga memberikan informasi kualitas air yang lebih akurat, komprehensif, dan mendukung pengambilan keputusan dalam pemantauan kualitas air.



DAFTAR PUSTAKA

- Abdullah, M., Abrha, F. berhe, Kedir, B., & Tamirat Tagesse, T. (2024). A Hybrid Deep Learning CNN model for COVID-19 detection from chest X-rays. *Heliyon*, 10(5), e26938. <https://doi.org/10.1016/j.heliyon.2024.e26938>
- Alzoubi, H., Amin, M., Aljehani, A. M., Alhatamleh, S., Madain, R., Madae'en, S., Serhan, H. A., & Alomani, A. A. (2026). Enhancing breast cancer diagnosis with ResNet50 and Salp Swarm-Based feature reduction on BreakHis dataset. *Biomedical Signal Processing and Control*, 114(November 2025), 109319. <https://doi.org/10.1016/j.bspc.2025.109319>
- Ardana, W. M. (2025). *Optimization of Convolutional Neural Network Algorithm with Efficientnet-B0 and Resnet-50 Architecture for Waste Type Classification* Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah. 5(October), 1274–1286.
- Artikel, R., & Udjulawa, D. (2021). *Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network- Support Vector Machine*. 7(April), 192–205.
- Buah, J. (2023). *JTIM: Jurnal Teknologi Informasi dan Multimedia Hybrid Algoritma Vgg16-Net dengan Support Vector Machine*. 5(2), 56–65.
- Chen, Y., Wang, L., Ding, B., Shi, J., Wen, T., Huang, J., & Ye, Y. (2024). Automated Alzheimer's disease classification using deep learning models with Soft-NMS and improved ResNet50 integration. *Journal of Radiation Research and Applied Sciences*, 17(1), 100782. <https://doi.org/10.1016/j.jrras.2023.100782>
- Fan, C., Lai, X., Wen, H., & Yang, L. (2023). Coal and gas outburst prediction model based on principal component analysis and improved support vector machine. *Geohazard Mechanics*, 1(4), 319–324. <https://doi.org/10.1016/j.ghm.2023.11.003>
- Hossain, M. B., Iqbal, S. M. H. S., Islam, M. M., Akhtar, M. N., & Sarker, I. H. (2022). Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images. *Informatics in Medicine Unlocked*, 30(March), 100916. <https://doi.org/10.1016/j.imu.2022.100916>
- Hridoy, M. A. A. M., Shawkat, A. I., Bordin, C., Acharjee, M. R., Masood, A., Baki, A. O., & Al Mamun, M. A. (2025). Advanced machine learning models for accurate water quality classification and WQI prediction: Implications for aquatic disease risk management. *Science of the Total Environment*, 1008(November), 180965. <https://doi.org/10.1016/j.scitotenv.2025.180965>
- Kusumawati, R., Santoso, I. B., Info, A., Detection, M., Learning, T., & Machine, S. V. (2023). *Hybrid Model Transfer Learning ResNet50 and Support Vector Machine for Face Mask Detection*. 4(2), 125–134. <https://doi.org/10.25008/ijadis.v4i2.1297>

- Majapahit, K. J. (2019). *Sistem Monitoring Kekerusuhan Air*. 5(1), 25–34.
- Mugunthan, J. S., Duguay, C. R., & Zakharova, E. (2023). Machine learning based classification of lake ice and open water from Sentinel-3 SAR altimetry waveforms. *Remote Sensing of Environment*, 299(April), 113891. <https://doi.org/10.1016/j.rse.2023.113891>
- Mustapha, M., Zineddine, M., Kaufman, E., Friedman, L., Gmira, M., Majikumna, K. U., & Alaoui, A. E. H. (2025). A hybrid machine learning approach for imbalanced irrigation water quality classification. *Desalination and Water Treatment*, 321(November 2024), 100910. <https://doi.org/10.1016/j.dwt.2024.100910>
- Nkuna, B. L., Abutaleb, K., Chirima, J. G., Newete, S. W., van der Walt, A. J., & Nyamugama, A. (2025). Identification of maize leaf diseases using red, green, blue-based images with convolutional neural network (CNN) and residual network (ResNet50) models. *Smart Agricultural Technology*, 12(July), 101226. <https://doi.org/10.1016/j.atech.2025.101226>
- Ozdemir, B., Aslan, E., & Pacal, I. (2025). Attention Enhanced InceptionNeXt-Based Hybrid Deep Learning Model for Lung Cancer Detection. *IEEE Access*, 13(February), 27050–27069. <https://doi.org/10.1109/ACCESS.2025.3539122>
- Pandey, A. K., Saxena, R., Awasthi, A., & Sunil, M. P. (2023). Privacy preserved data sharing using blockchain and support vector machine for industrial IOT applications. *Measurement: Sensors*, 29(June), 100891. <https://doi.org/10.1016/j.measen.2023.100891>
- Pradifta, R. A., Murti, W., Rusman, F. F., Ikhsani, N., Wijayono, A., Nurazizah, V., Studi, P., Pembuatan, T., Studi, P., Pembuatan, T., Tenun, K., Studi, P., & Pembuatan, T. (2025). *S i l i t e k*. 05(01), 363–373.
- Ramadhan, F. M., & Riwurohi, J. E. (2024). Perbandingan Optimizer, Batch Size Dan Epoch Pada Metode Convolution Neural Network. *JSiI (Jurnal Sistem Informasi)*, 11(2), 134–138. <https://doi.org/10.30656/jsii.v11i2.9249>
- Riehl, K., Neunteufel, M., & Hemberg, M. (2023). Hierarchical confusion matrix for classification performance evaluation. *Journal of the Royal Statistical Society. Series C: Applied Statistics*, 72(5), 1394–1412. <https://doi.org/10.1093/jrssc/qlad057>
- Rikanto, T. (2021). Sistem Monitoring Kualitas Kekerusuhan Air Berbasis Internet Of Thing. *Jurnal Fasikom*, 11(2), 87–90. <https://doi.org/10.37859/jf.v11i2.2714>
- Salama, W. M., & Aly, M. H. (2026). Brain tumor segmentation and classification: A CVAE-UNETR-ResNet50-VGG16 hybrid deep learning approach. *Alexandria Engineering Journal*, 135(September 2025), 433–449. <https://doi.org/10.1016/j.aej.2026.01.003>
- Syaukani, I., Zarina, S., Mohd, B., Uttraphan, C., & Kan, E. (2025). *Classification of Beef and Pork Using a Hybrid Model of ResNet-50 and Support Vector*

Machine (SVM). 4(1), 65–70. <https://doi.org/10.56566/amplitudo.v4i1.193>

Vishal, K. S., Srinidhi, S. K., Shashank, U. S., & Singh, R. P. (2025). Enhanced Small Object Detection in Remotely Sensed Images using Hybrid ResNet50 and Feature Pyramid Network. *Procedia Computer Science*, 258(2024), 1813–1822. <https://doi.org/10.1016/j.procs.2025.04.433>


Wijaya, F. K., Sugijono, T. C., Setiawan, R., & Rumagit, R. Y. (2025). Comparative Analysis of Machine Learning Random Forest, Naïve Bayes and SVM for Flight Delay Classification. *Procedia Computer Science*, 269, 1546–1555. <https://doi.org/10.1016/j.procs.2025.09.096>




LAMPIRAN

LAMPIRAN 1. Dataset Air Jernih ,Keruh, Dan Kotor

JERNIH



KERUH



KOTOR



LAMPIRAN 2. Source Code


```
import os
import warnings
import glob
import ctypes # This import is no longer needed after removing _aktifkan_pustaka_cuda
warnings.filterwarnings("ignore")
os.environ["TF_CPP_MIN_LOG_LEVEL"] = "2" # kurangi log TensorFlow

# The _aktifkan_pustaka_cuda function is removed as it was causing a TypeError
# and is generally not needed in Colab for GPU detection.

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from PIL import Image

import tensorflow as tf
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.applications.resnet50 import preprocess_input
from tensorflow.keras.preprocessing.image import img_to_array, load_img

from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.preprocessing import StandardScaler, LabelEncoder
from sklearn.pipeline import Pipeline
from sklearn.svm import SVC
from sklearn.metrics import (
    confusion_matrix,
    classification_report,
```



```

# Pipeline: standarisasi fitur -> SVM
pipa_svm = Pipeline([
    ("scaler", StandardScaler()),
    ("svm", SVC(probability=True, random_state=SEED)),
])

# Ruang pencarian hyperparameter
param_grid = {
    "svm__C": [0.1, 1, 10, 100],
    "svm__gamma": ["scale", 0.01, 0.001],
    "svm__kernel": ["rbf", "linear"],
}

grid = GridSearchCV(
    pipa_svm,
    param_grid,
    cv=5,
    scoring="accuracy",
    n_jobs=-1,
    verbose=1,
)

print("Melatih SVM dengan GridSearchCV (5-fold)... mohon tunggu.")
t0 = time.time()
grid.fit(X_train, y_train)
print(f"Pelatihan selesai dalam {time.time() - t0:.1f} detik.\n")

print("Parameter terbaik :", grid.best_params_)

```

```

# TN: semua selain baris & kolom kelas ini
tn = cm.sum() - (tp + fn + fp)

hasil.append({
    "Kelas": label_tampil[kelas_list[idx]],
    "TP (True Positive)": int(tp),
    "TN (True Negative)": int(tn),
    "FP (False Positive)": int(fp),
    "FN (False Negative)": int(fn),
    "Total Aktual": int(tp + fn),
    "Total Prediksi": int(tp + fp),
})

return pd.DataFrame(hasil)

# Hitung untuk data uji
df_tp_tn = hitung_tp_tn_fn(y_test, y_pred, le.classes_, LABEL_TAMPIL)
print("==== DETAIL TP, TN, FP, FN PER KELAS ==== \n")
print(df_tp_tn.to_string(index=False))

# Tampilkan penjelasan
print("\n==== PENJELASAN =====")
print("TP (True Positive) : Diprediksi BENAR sebagai kelas tersebut")
print("TN (True Negative) : Diprediksi BENAR BUKAN kelas tersebut")
print("FP (False Positive) : Diprediksi SALAH sebagai kelas tersebut (padahal bukan)")
print("FN (False Negative) : Diprediksi SALAH bukan kelas tersebut (padahal iya)")
print("\nTotal Aktual = TP + FN (jumlah sampel yang sebenarnya kelas tersebut)")
print("Total Prediksi = TP + FP (jumlah sampel yang diprediksi sebagai kelas tersebut)")

```



MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
UPT PERPUSTAKAAN DAN PENERBITAN

Alamat kantor: Jl. Sultan Alauddin NO.259 Makassar 90221 Tlp.(0411) 866972,881593, Fax.(0411) 865588

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

SURAT KETERANGAN BEBAS PLAGIAT

UPT Perpustakaan dan Penerbitan Universitas Muhammadiyah Makassar,
Menerangkan bahwa mahasiswa yang tersebut namanya di bawah ini:

Nama : Tegar Surya Prayoga

Nim : 105841106222

Program Studi : Teknik Informatika

Dengan nilai:

No	Bab	Nilai	Ambang Batas
1	Bab 1	7%	10 %
2	Bab 2	10%	25 %
3	Bab 3	7%	10 %
4	Bab 4	0%	10 %
5	Bab 5	3%	5 %

Dinyatakan telah lulus cek plagiat yang diadakan oleh UPT- Perpustakaan dan Penerbitan Universitas Muhammadiyah Makassar Menggunakan Aplikasi Turnitin.

Demikian surat keterangan ini diberikan kepada yang bersangkutan untuk dipergunakan
seperlunya.

Makassar, 13 Agustus 2026

Mengetahui,

Kepala Tata Usaha UPT- Perpustakaan dan
Penerbitan,



Ida Aryani, S.Sos
NBM. 886 771

BAB I Tegar Surya Prayoga 105841106222.

by Tahap Tutup



Submission date: 10-Aug-2026 02:52PM (UTC+0700)

Submission ID: 3010633663

File name: BAB_I_30.docx (242.27K)

Word count: 1759

Character count: 11929

BAB I Tegar Surya Prayoga 105841106222.

ORIGINALITY REPORT

7%

SIMILARITY INDEX

2%

INTERNET SOURCES

8%

STUDENT PAPERS

PRIMARY SOURCES

1

Submitted to Universitas Muhammadiyah Makassar
Student Paper

7%



Exclude quotes

On

Exclude matches

-2%

Exclude bibliography

On



BAB II Tegar Surya Prayoga 105841106222.
by Tahap Tutup



Submission date: 10-Aug-2026 12:52PM (UTC+0700)
Submission ID: 3010582708
File name: BAB_II_32.docx (1.49M)
Word count: 2604
Character count: 16977

BAB II Tegar Surya Prayoga 105841106222.

ORIGINALITY REPORT

10%
SIMILARITY INDEX

3%
INTERNET SOURCES

2%
PUBLICATIONS




PRIMARY SOURCES

1 Submitted to Universitas Muhammadiyah Makassar
Student Paper

8%

2 Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI :
MENGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN
ARSITEKTUR MOBILNETV2". Jurnal Informatika dan Teknik Elektro Terapan, 2026
Publication

2%



Exclude quotes
Exclude bibliography

Can
Can

Exclude matches
= 2%



BAB III Tegar Surya Prayoga 105841106222
by Tahan Putup



Submission date: 12-Aug-2026 12:14PM (UTC+0700)
Submission ID: 3011438038
File name: BAB_III_39.docx (296.04K)
Word count: 823
Character count: 5238

BAB III Tegar Surya Prayoga 105841106222

ORIGINALITY REPORT

7%
SIMILARITY INDEX

2%
INTERNET SOURCES

2%
PUBLICATION

6%
STUDENT PAPERS



MATCH ALL SOURCES (ONLY SELECTED SOURCE PRINTED)

2%
★ Submitted to Telkom University
Student Paper:

Exclude quotes
Exclude bibliography

On
On

Exclude matches
< 2%



BAB IV Tegar Surya Prayoga 105841106222.

by Tahap Tutup



Submission date: 10-Aug-2026 12:55PM (UTC+0700)

Submission ID: 3010584781

File name: BAB_IV_31.docx (4.51M)

Word count: 8809

Character count: 58629

BAB IV Tegar Surya Prayoga 105841106222.

ORIGINALITY REPORT

0%

SIMILARITY INDEX

0%


INTERNET SOURCES



0%

STUDENT PAPERS

PRIMARY SOURCES



Exclude quotes

ON

Exclude matches

4/28

Exclude bibliography

ON



BAB V Tegar Surya Prayoga 105841106222.

by Tahap Tutup



Submission date: 10-Aug-2026 12:56PM (UTC+0700)
Submission ID: 3010585183
File name: BAB_V_56.docx (226.09K)
Word count: 1391
Character count: 9468

BAB V Tegar Surya Prayoga 105841106222.

ORIGINALITY REPORT

3%

SIMILARITY INDEX

3%

INTERNET SOURCES



0%

STUDENT PAPERS

PRIMARY SOURCES

1

diglibadmin.unismuh.ac.id
Internet Source

turnitin

3%

Exclude quotes

Exclude bibliography

0%

0%

Exclude matches

0.2%

