



Pengembangan Model Hybrid Deep Learning dan CatBoost untuk Analisis Kelayakan Oli Mesin melalui Objek Dipstick pada PT Telkom Infrastruktur Indonesia

PT Telkom Infrastruktur Indonesia Territory 3 Surabaya
Telkom Landmark Tower Surabaya, Lt 10, Jl. Dr. Ir. H. Soekarno
No.175, Klampis Ngasem, Kec. Sukolilo, Surabaya, Jawa Timur
Periode: 5 Januari 2026 - 2 April 2026

Oleh:

Miskiyah 5025231119
Hikmia Sofia Nur Izzati 5025231147

Pembimbing Jurusan

Dr. Kelly Rossa Sungkono, S.Kom.,M.Kom

Pembimbing Lapangan

Hanif Kuncahyo Adi

DEPARTEMEN TEKNIK INFORMATIKA
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2026



KERJA PRAKTIK - IF184801

Pengembangan Model Hybrid Deep Learning dan CatBoost untuk Analisis Kelayakan Oli Mesin melalui Objek Dipstick pada PT TIF Territory 3 Surabaya

PT Telkom Infrastruktur Indonesia Territory 3 Surabaya
Telkom Landmark Tower Surabaya, Lt 10, Jl. Dr. Ir. H. Soekarno
No.175, Klampis Ngasem, Kec. Sukolilo, Surabaya, Jawa Timur
Periode: 5 Januari 2026 - 2 April 2026

Oleh:

Miskiyah 5025231119

Hikmia Sofia Nur Izzati 5025231147

Pembimbing Jurusan

Dr. Kelly Rossa Sungkono, S.Kom., M.Kom.

Pembimbing Lapangan

Hanif Kuncahyo Adi

DEPARTEMEN TEKNIK INFORMATIKA

Fakultas Teknologi Elektro dan Informatika Cerdas

Institut Teknologi Sepuluh Nopember

Surabaya 2026

DAFTAR ISI

DAFTAR ISI	iii
DAFTAR GAMBAR	vii
DAFTAR TABEL	ix
LEMBAR PENGESAHAN	xi
KATA PENGANTAR	xv
BAB I	
PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Tujuan	2
1.3. Manfaat	2
1.4. Rumusan Masalah	2
1.5. Lokasi dan Waktu Kerja Praktik	3
1.6. Metodologi Kerja Praktik	3
1.6.1. Perumusan Masalah	3
1.6.2. Studi Literatur	3
1.6.3. Analisis dan Perancangan Sistem	4
1.6.4. Implementasi Sistem	4
1.6.5. Pengujian dan Evaluasi	4
1.6.6. Kesimpulan dan Saran	4
1.7. Sistematika Laporan	5
1.7.1. Bab I Pendahuluan	5
1.7.2. Bab II Profil Perusahaan	5
1.7.3. Bab III Tinjauan Pustaka	5
1.7.4. Bab IV Analisis dan Perancangan Infrastruktur Sistem	5
1.7.5. Bab V Implementasi Sistem	5
1.7.6. Bab VI Pengujian dan Evaluasi	5

1.7.7. Bab VII Kesimpulan dan Saran	5
BAB II	
PROFIL PERUSAHAAN	7
2.1. Profil TELKOM Infrastruktur Indonesia	7
2.2. Lokasi	7
BAB III	
TINJAUAN PUSTAKA	9
3.1. Artificial Intelligence	9
3.2. Computer Vision	9
3.3. You Only Look Once (YOLO)	10
3.4. CatBoost	10
3.5. Gamma Correction	11
3.6. Ruang Warna HSV (Hue, Saturation, Value)	11
3.7. Erosion	12
3.8. Precision-Recall Curve	12
BAB IV	
ANALISIS DAN PERANCANGAN INFRASTRUKTUR SISTEM	15
4.1. Analisis Arsitektur YOLOv11	15
4.1.1. Jalur Instance Segmentation	15
4.1.2. Jalur Analisis Fitur dan Klasifikasi (CatBoost)	15
4.2. Tahap Pemahaman Data	16
4.2.1. Pengumpulan dan Pembersihan Data (Filtering)	16
4.2.2. Anotasi Bertingkat (Multi-stage Annotation)	16
4.2.3. Distribusi Dataset	17
4.3. Pengembangan Model 1 Dipstick Object Detection	18
4.4. Pengembangan Model 2: Oil Component Segmentation	19

4.5. Pengembangan Model 2: Oil Component Segmentation	21
4.5.1. Pra-pemrosesan Data	22
4.5.2. Rekayasa Fitur (Feature Extraction)	23
4.5.3. Pelatihan Model Klasifikasi CatBoost	23
BAB V	
PENGUJIAN DAN EVALUASI	27
5.1. Tujuan Pengujian	27
5.2. Kriteria Pengujian	27
5.3. Skenario Pengujian	28
5.4. Evaluasi Pengujian	30
BAB VI	
KESIMPULAN DAN SARAN	33
6.1. Kesimpulan	33
6.2. Saran	33
DAFTAR PUSTAKA	35
BIODATA PENULIS	37

[Halaman ini sengaja dikosongkan]

DAFTAR GAMBAR

Kode Sumber 4.1 Parameter Augmentasi Model 1	19
Kode Sumber 4.2 Parameter Pelatihan Model 1	19
Kode Sumber 4.3 Parameter Augmentasi Model 2	20
Kode Sumber 4.4 Parameter Pelatihan Model 2	21
Kode Sumber 4.5 Gamma Correction	22
Kode Sumber 4.6 <i>Handling Imbalance</i>	22
Kode Sumber 4.7 Fungsi <i>get_robust_stat</i> untuk Mendapat Nilai Interkuartil, Erosi, dan HSV	24
Kode Sumber 4.8 Fungsi <i>extract_features_v3</i> untuk Ekstraksi Fitur	25
Kode Sumber 4.9 Rekayasa Fitur	26
Kode Sumber 4.10 Parameter Pelatihan Model 3	26

**LEMBAR PENGESAHAN
KERJA PRAKTIK**

**Pengembangan Model Hybrid Deep Learning dan
CatBoost untuk Analisis Kelayakan Oli Mesin melalui
Objek Dipstick pada PT Telkom Infrastruktur Indonesia**

Oleh:

Miskiyah
Hikmia Sofia Nur Izzati

5025231119
5025231147

Disetujui oleh Pembimbing Kerja Praktik:

1. Dr. Kelly Rossa Sungkono,
S.Kom., M.Kom.
NIP. 1994201912088

[TTD]



(Pembimbing Departemen)

2. Hanif Kuncahyo Adi
NIK. 940323

[TTD]



(Pembimbing Lapangan)

[Halaman ini sengaja dikosongkan]

DAFTAR TABEL

Tabel 4.1. Distribusi Dataset	17
Tabel 5.1 Hasil Pengujian Model YOLOv8 dan YOLOv11	30
Tabel 5.2 Hasil Pengujian Model Machine Learning	31

[Halaman ini sengaja dikosongkan]

[Halaman ini sengaja dikosongkan]

Pengembangan Model Hybrid Deep Learning dan CatBoost untuk Analisis Kelayakan Oli Mesin melalui Objek Dipstick pada PT Telkom Infrastruktur Indonesia

Nama Mahasiswa : Miskiyah
NRP : 5025231119
Nama Mahasiswa : Hikmia Sofia Nur Izzati
NRP : 5025231147
Departemen : Teknik Informatika FTEIC-ITS
Pembimbing Departemen : Dr. Kelly Rossa Sungkono, S.Kom.,
M.Kom.
Pembimbing Lapangan : Hanif Kuncahyo Adi

ABSTRAK

Pengecekan kualitas oli mesin secara manual melalui dipstick merupakan proses yang bersifat repetitif dan memerlukan ketelitian visual yang tinggi. Kondisi ini menyebabkan inspeksi menjadi subjektif dan rentan terhadap kesalahan manusia (human error), terutama saat menghadapi beban kerja yang tinggi. Penelitian ini bertujuan untuk mengotomatisasi proses klasifikasi kualitas oli menggunakan teknologi Computer Vision dan Machine Learning. Metode yang diusulkan menggabungkan arsitektur YOLOv11 untuk instance segmentation area oli dan algoritma CatBoost Classifier untuk analisis fitur warna secara objektif. Melalui penerapan Gamma Correction dan ruang warna HSV, sistem mampu mempertahankan konsistensi deteksi pada berbagai kondisi pencahayaan. Hasil pengujian menunjukkan bahwa YOLOv11 memperoleh precision 0,8570 dan recall 0,9333, sedangkan CatBoost mencapai akurasi klasifikasi sebesar 83%,

sehingga mampu menghasilkan penilaian kualitas oli yang lebih konsisten dan efisien.

Kata Kunci: CatBoost, Computer Vision, Instance, Kualitas Oli, Segmentation, YOLOv11

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Allah SWT atas penyertaan dan karunia-Nya sehingga penulis dapat menyelesaikan salah satu kewajiban penulis sebagai mahasiswa Departemen Teknik Informatika ITS yaitu Kerja Praktik yang berjudul: **Pengembangan Model Hybrid Deep Learning dan CatBoost untuk Analisis Kelayakan Oli Mesin melalui Objek Dipstick pada PT Telkom Infrastruktur Indonesia.**

Penulis menyadari bahwa masih banyak kekurangan baik dalam melaksanakan kerja praktik maupun penyusunan buku laporan kerja praktik ini. Namun penulis berharap buku laporan ini dapat menambah wawasan pembaca dan dapat menjadi sumber referensi.

Melalui buku laporan ini penulis juga ingin menyampaikan rasa terima kasih kepada orang-orang yang telah membantu menyusun laporan kerja praktik baik secara langsung maupun tidak langsung antara lain:

1. Kedua orang tua penulis.
2. Dr. Kelly Rossa Sungkono, S.Kom., M.Kom. selaku dosen pembimbing kerja praktik.
3. Mas Hanif Kuncahyo Adi selaku pembimbing lapangan selama kerja praktik berlangsung.
4. Teman-teman penulis yang senantiasa memberikan semangat ketika penulis melaksanakan KP.

Surabaya, 10 April 2026
Miskiyah dan Hikmia Sofia Nur Izzati

[Halaman ini sengaja dikosongkan]

BAB 1 PENDAHULUAN

1.1. Latar Belakang

Generator set (genset) berperan penting dalam menjaga kontinuitas operasional jaringan pada Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia. Salah satu aktivitas pemeliharaan rutin yang dilakukan adalah pengecekan kondisi oli mesin melalui objek *dipstick*, dengan parameter utama berupa warna oli.

Proses pengecekan tersebut saat ini masih dilakukan secara manual melalui inspeksi visual. Meskipun relatif sederhana, metode manual menjadi kurang efisien ketika dilakukan secara berulang pada banyak unit genset. Selain itu, variasi kondisi pencahayaan, posisi *dipstick*, dan sudut pandang menyebabkan proses inspeksi sulit untuk distandardisasi dan berpotensi menurunkan konsistensi hasil pengecekan.

Perkembangan teknologi pengolahan citra dan kecerdasan buatan membuka peluang untuk mengotomatisasi proses inspeksi visual tersebut. Pendekatan berbasis deteksi objek dapat digunakan untuk melokalisasi area *dipstick* secara konsisten, sementara metode machine learning dapat dimanfaatkan untuk mengklasifikasikan kondisi oli berdasarkan fitur visual yang diperoleh. Dengan pendekatan ini, proses pengecekan diharapkan menjadi lebih efisien, objektif, dan mudah diterapkan tanpa bergantung pada inspeksi manual secara penuh.

Berdasarkan permasalahan tersebut, diperlukan suatu sistem yang mampu mendukung proses pengecekan kondisi oli generator secara otomatis dan terstandarisasi guna meningkatkan efisiensi pemeliharaan pada Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia.

1.2. Tujuan

Tujuan kerja praktik ini adalah menyelesaikan kewajiban nilai kerja praktik sebesar 4 SKS, serta membantu Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia dalam meningkatkan efisiensi proses pengecekan kondisi oli generator.

1.3. Manfaat

Manfaat yang diperoleh dengan adanya pelaksanaan kerja praktik ini adalah memberikan kontribusi dalam meningkatkan efisiensi dan konsistensi proses pengecekan kondisi oli generator pada Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia. Melalui penerapan sistem pendukung pengecekan berbasis pengolahan citra, proses inspeksi yang sebelumnya dilakukan secara manual dapat dilakukan dengan lebih cepat, terstandarisasi, dan terdokumentasi dengan baik. Selain itu, kerja praktik ini juga menjadi sarana penerapan pengetahuan akademik dalam menyelesaikan permasalahan nyata di lingkungan industri, khususnya dalam pemanfaatan teknologi kecerdasan buatan untuk mendukung kegiatan pemeliharaan operasional.

1.4. Rumusan Masalah

Rumusan masalah dari kerja praktik ini adalah sebagai berikut:

1. Bagaimana meningkatkan efisiensi proses pengecekan kondisi oli generator yang selama ini masih dilakukan secara manual melalui inspeksi visual pada objek *dipstick* di Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia?

2. Bagaimana merancang sistem pendukung pengecekan kondisi oli generator yang mampu menghasilkan hasil pemeriksaan yang lebih konsisten dan terstandarisasi berdasarkan parameter warna oli?

1.5. Lokasi dan Waktu Kerja Praktik

Pengerjaan kerja praktik ini lakukan secara *on-site*. Adapun kerja praktik dimulai pada tanggal 5 Januari 2026 hingga 2 April 2026.

1.6. Metodologi Kerja Praktik

Metodologi dalam pembuatan buku kerja praktik meliputi:

1.6.1. Perumusan Masalah

Tahap perumusan masalah dilakukan berdasarkan penjelasan dan arahan dari pembimbing kerja praktik di Divisi Regional Network Operation PT Telkom Infrastruktur Indonesia. Berdasarkan penjelasan tersebut, diketahui bahwa proses pengecekan kondisi oli generator, yang meliputi pengecekan warna oli melalui objek *dipstick*, masih dilakukan secara manual. Pihak pembimbing menyampaikan kebutuhan akan sistem pendukung yang dapat mengotomatisasi proses pengecekan tersebut guna meningkatkan efisiensi dan konsistensi hasil inspeksi. Dari informasi yang diperoleh, dirumuskan permasalahan dan kebutuhan sistem yang menjadi dasar pelaksanaan kerja praktik ini.

1.6.2. Studi Literatur

Setelah permasalahan dipahami, dilakukan studi literatur untuk memperoleh referensi yang relevan dengan topik kerja praktik. Studi literatur meliputi konsep dasar pengolahan citra, object detection, machine learning, serta penelitian-penelitian terdahulu yang berkaitan dengan

analisis visual berbasis citra. Tahap ini bertujuan sebagai landasan teori dalam perancangan sistem yang akan dikembangkan.

1.6.3. Analisis dan Perancangan Sistem

Pada tahap ini dilakukan analisis terhadap kebutuhan sistem berdasarkan permasalahan yang telah dirumuskan. Selanjutnya disusun perancangan alur sistem pengecekan kondisi oli, mulai dari pengambilan citra *dipstick*, proses deteksi objek, ekstraksi fitur visual, hingga klasifikasi kondisi oli berdasarkan parameter warna oli. Perancangan ini bertujuan untuk memastikan sistem yang dikembangkan sesuai dengan kebutuhan dan dapat diimplementasikan secara efektif.

1.6.4. Implementasi Sistem

Tahap implementasi merupakan realisasi dari hasil perancangan sistem. Pada tahap ini dilakukan pengembangan sistem pengecekan kondisi oli generator sesuai dengan alur yang telah dirancang, termasuk proses pengolahan citra dan penerapan metode klasifikasi untuk menentukan kondisi oli. Implementasi dilakukan dengan menyesuaikan kondisi dan data yang tersedia di lingkungan kerja praktik.

1.6.5. Pengujian dan Evaluasi

Setelah sistem diimplementasikan, dilakukan pengujian untuk mengetahui apakah sistem dapat berjalan sesuai dengan tujuan yang diharapkan. Pengujian meliputi evaluasi hasil deteksi objek *dipstick* serta hasil klasifikasi kondisi oli. Dari tahap ini dapat diketahui tingkat kesesuaian sistem dengan kebutuhan di lapangan serta potensi perbaikan yang diperlukan.

1.6.6. Kesimpulan dan Saran

Berdasarkan hasil pengujian dan evaluasi yang dilakukan, sistem yang dikembangkan mampu mendukung proses pengecekan kondisi oli generator dengan lebih efisien. Pada tahap ini juga disusun kesimpulan serta saran

sebagai bahan pertimbangan untuk pengembangan sistem lebih lanjut di masa mendatang.

1.7. Sistematika Laporan

1.7.1. Bab I Pendahuluan

Bab ini berisi latar belakang, tujuan, manfaat, rumusan masalah, lokasi dan waktu kerja praktik, metodologi, dan sistematika laporan.

1.7.2. Bab II Profil Perusahaan

Bab ini berisi gambaran umum PT Telkom Infrastruktur Indonesia mulai dari profil, lokasi perusahaan.

1.7.3. Bab III Tinjauan Pustaka

Bab ini berisi dasar teori dari teknologi yang digunakan dalam menyelesaikan proyek kerja praktik.

1.7.4. Bab IV Analisis dan Perancangan Infrastruktur Sistem

Bab ini berisi mengenai tahap analisis sistem aplikasi dalam menyelesaikan proyek kerja praktik.

1.7.5. Bab V Implementasi Sistem

Bab ini berisi uraian tahap-tahap yang dilakukan untuk proses implementasi aplikasi.

1.7.6. Bab VI Pengujian dan Evaluasi

Bab ini berisi hasil uji coba dan evaluasi dari aplikasi yang telah dikembangkan selama pelaksanaan kerja praktik.

1.7.7. Bab VII Kesimpulan dan Saran

Bab ini berisi kesimpulan dan saran yang didapat dari proses pelaksanaan kerja praktik.

[Halaman ini sengaja dikosongkan]

BAB 2

PROFIL PERUSAHAAN

2.1. Profil TELKOM Infrastruktur Indonesia

PT Telkom Infrastruktur Indonesia (TIF) merupakan anak perusahaan dari PT Telkom Indonesia (Persero) Tbk yang difokuskan sebagai entitas pemisahan (*spin-off*) untuk mengelola infrastruktur jaringan telekomunikasi secara terpusat. Dengan identitas baru yang dikenal sebagai Infranexia, perusahaan ini memosisikan diri sebagai penyedia konektivitas fiber (*Wholesale Fiber Connectivity*) terbesar di Indonesia.

2.2. Lokasi

TELKOM Landmark Tower Surabaya, Lt 10 Jl. Dr. Ir. H. Soekarno No.175, Klampis Ngasem, Kec. Sukolilo, Surabaya, Jawa Timur 60116

[Halaman ini sengaja dikosongkan]

BAB III

TINJAUAN PUSTAKA

3.1. *Artificial Intelligence*

Kecerdasan Buatan atau *Artificial Intelligence* (AI) merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang mampu meniru kemampuan kognitif manusia, seperti pembelajaran, penalaran, pengambilan keputusan, serta pengenalan pola (Luger, 2021). AI memanfaatkan berbagai pendekatan, mulai dari metode berbasis aturan (*rule-based*) hingga teknik pembelajaran mesin (*machine learning*) dan pembelajaran mendalam (*deep learning*), untuk memungkinkan sistem memproses data dalam jumlah besar dan menghasilkan prediksi atau rekomendasi secara otomatis. Dengan kemampuan tersebut, AI dapat difungsikan sebagai alat bantu sekaligus sebagai sistem yang adaptif terhadap perubahan data dan lingkungan.

Dalam perkembangannya, AI menjadi standar baru transformasi digital di berbagai sektor industri, termasuk kesehatan, pendidikan, manufaktur, dan layanan keuangan. Implementasi AI dapat meningkatkan efisiensi operasional, optimalisasi proses bisnis, serta pengambilan keputusan yang lebih akurat berbasis data.

3.2. *Computer Vision*

Computer Vision merupakan salah satu cabang Kecerdasan Buatan yang mempelajari bagaimana sistem komputer memahami dan menafsirkan data visual, seperti gambar dan video (Szeliski, 2022). Melalui teknik pemrosesan citra dan pembelajaran mesin, sistem dapat mengekstrak informasi yang bermakna, mengenali objek, mendeteksi pola, serta mengidentifikasi peristiwa tertentu

dalam suatu adegan. Teknologi ini banyak diterapkan pada sistem pengenalan wajah, kendaraan otonom, pengawasan keamanan, hingga analisis medis berbasis citra.

3.3. *You Only Look Once (YOLO)*

Salah satu pendekatan yang banyak digunakan dalam tugas deteksi objek pada bidang Computer Vision adalah keluarga algoritma *You Only Look Once* (YOLO), terutama YOLOv11. YOLOv11 merupakan iterasi terbaru yang dikembangkan oleh Ultralytics dan dirancang untuk meningkatkan efisiensi parameter serta akurasi deteksi dibandingkan versi-versi sebelumnya (Ultralytics, 2024).

Secara umum, arsitektur YOLO bekerja dengan melakukan prediksi lokasi dan kelas objek secara simultan dalam satu kali proses inferensi, sehingga mampu mencapai kinerja real-time (Redmon et al., 2016). Pada versi terbarunya, YOLOv11 juga mendukung fitur *Instance Segmentation*, sehingga sistem tidak hanya mendeteksi keberadaan objek, tetapi juga mengidentifikasi batas objek secara lebih rinci hingga tingkat piksel.

3.4. **CatBoost**

CatBoost merupakan algoritma *gradient boosting* yang dikembangkan oleh Yandex dan dirancang untuk menghasilkan performa tinggi pada data tabular (Hancock & Khoshgoftaar, 2021). Algoritma ini membangun model secara iteratif dengan menggabungkan sejumlah *decision tree* untuk meminimalkan kesalahan prediksi melalui pendekatan *gradient boosting*. Meskipun dikenal unggul dalam menangani fitur kategorikal, CatBoost juga menunjukkan kinerja yang kompetitif pada dataset dengan fitur numerik murni.

CatBoost mampu mempelajari pola kompleks dari variabel numerik untuk memetakan data ke dalam kelas-kelas tertentu secara akurat. Selain itu, penerapan teknik *ordered boosting* membantu mengurangi risiko overfitting dan meningkatkan stabilitas model.

3.5. *Gamma Correction*

Gamma correction adalah teknik pemrosesan citra non-linear yang digunakan untuk mengatur kecerahan (*luminance*) suatu gambar. Dalam pengolahan citra digital, hubungan antara input dan output intensitas cahaya didefinisikan melalui fungsi pangkat berikut.

$$V_{out} = A \cdot V_{in}^{\gamma} \quad (3.1)$$

Pada Persamaan (3.1), (V_{in}) merupakan intensitas piksel input, (V_{out}) merupakan intensitas piksel output, (A) adalah konstanta skala, sedangkan (γ) merupakan parameter yang mengatur tingkat kecerahan citra, di mana nilai ($\gamma < 1$) mencerahkan citra dan ($\gamma > 1$) menggelapkan citra.

Teknik ini penting dalam menormalkan gambar yang diambil dalam kondisi pencahayaan yang ekstrem (terlalu gelap atau terlalu terang) agar fitur warna tetap konsisten saat diekstraksi (Gonzalez & Woods, 2024).

3.6. *Ruang Warna Hue, Saturation, Value (HSV)*

Ruang warna *Hue, Saturation, Value* (HSV) merupakan model representasi warna yang disusun berdasarkan persepsi visual manusia. Berbeda dengan ruang warna RGB yang merepresentasikan warna sebagai kombinasi komponen merah, hijau, dan biru dalam satu ruang intensitas, HSV memisahkan informasi jenis warna

dari tingkat kecerahan dan kejenuhan. Komponen *Hue* merepresentasikan jenis warna dalam spektrum, *Saturation* menunjukkan tingkat kemurnian atau intensitas warna, sedangkan *Value* menggambarkan tingkat kecerahan (Szeliski, 2022). Pemisahan ini menjadikan HSV lebih intuitif dalam analisis warna karena perubahan pencahayaan tidak secara langsung mengubah identitas warna pada komponen Hue.

Dalam pemrosesan citra dan analisis kualitas cairan, penggunaan HSV dinilai lebih robust terhadap variasi iluminasi, bayangan, dan pantulan cahaya dibandingkan RGB (Gonzalez & Woods, 2018; Szeliski, 2022).

3.7. *Erosion*

Erosi merupakan salah satu operasi dasar dalam morfologi citra yang digunakan untuk mengurangi atau mengikis bagian tepi objek pada citra biner (masker). Operasi ini bekerja dengan menggeser elemen struktur atau *structuring element* di atas citra, kemudian menentukan nilai piksel pusat berdasarkan nilai minimum pada area yang dicakup elemen tersebut (Sarker, 2021). Akibatnya, piksel-piksel pada batas objek yang tidak sepenuhnya didukung oleh lingkungan sekitarnya akan dihilangkan, sehingga ukuran objek cenderung mengecil.

Dalam praktik pemrosesan citra, erosi sering dimanfaatkan untuk mengurangi derau, memisahkan objek yang saling terhubung tipis, serta memperhalus batas hasil segmentasi (Gonzalez & Woods, 2018).

3.8. *Precision-Recall Curve*

Precision-Recall (PR) Curve merupakan metrik evaluasi yang digunakan untuk menilai performa model

klasifikasi, terutama pada dataset dengan distribusi kelas yang tidak seimbang (*imbalanced data*). Precision mengukur proporsi prediksi positif yang benar dibandingkan seluruh prediksi positif yang dihasilkan model, sedangkan recall mengukur kemampuan model dalam mengidentifikasi seluruh data yang benar-benar termasuk dalam kelas positif (Hancock & Khoshgoftaar, 2021). Nilai precision dan recall dapat dihitung menggunakan Persamaan (3.2) dan Persamaan (3.3).

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

Pada Persamaan (3.2) dan Persamaan (3.3), TP (*True Positive*) menyatakan jumlah data positif yang berhasil diklasifikasikan dengan benar, FP (*False Positive*) merupakan jumlah data negatif yang salah diklasifikasikan sebagai positif, sedangkan FN (*False Negative*) adalah jumlah data positif yang salah diklasifikasikan sebagai negatif.

Berbeda dengan akurasi yang dapat memberikan gambaran menyesatkan pada data tidak seimbang, kurva PR menunjukkan hubungan antara *precision* dan *recall* pada berbagai nilai ambang keputusan (*threshold*). Pendekatan ini memungkinkan evaluasi yang lebih informatif terhadap performa model dalam mendeteksi kelas minoritas secara konsisten (Brownlee, 2021).

[Halaman ini sengaja dikosongkan]

BAB IV

ANALISIS DAN PERANCANGAN INFRASTRUKTUR SISTEM

4.1. Analisis Arsitektur YOLOv11

Arsitektur YOLOv11 melakukan proses deteksi objek dan segmentasi instansi dalam satu jalur pemrosesan tunggal (*single-stage detector*) yang memungkinkan ekstraksi informasi secara *real-time*. Pada sistem ini, model bekerja dengan membagi citra input ke dalam format grid dan memprediksi probabilitas kelas serta koordinat poligon secara simultan untuk setiap sel grid tersebut. Berbeda dengan deteksi objek konvensional yang hanya menghasilkan kotak pembatas (*bounding box*), YOLOv11 menggunakan *segmentation head* untuk menghasilkan masker piksel yang presisi sesuai dengan kontur fisik objek (Ultralytics, 2024).

4.1.1. Jalur Instance Segmentation

Konsep utama pada jalur segmentasi ini adalah menghasilkan masker biner yang memisahkan area *wet oil* (oli basah) dan *dry stick* (stik kering). Proses ini menggunakan backbone *Cross-Stage Partial Darknet* (CSPDarknet) yang telah dioptimalkan untuk menangkap fitur spasial yang rumit. Dengan menghasilkan masker setingkat piksel, sistem dapat mengabaikan informasi yang tidak relevan di luar area target. Teknik ini penting karena memungkinkan tahap ekstraksi fitur berikutnya hanya fokus pada piksel yang benar-benar merepresentasikan pelumas, sehingga menghindari bias warna dari komponen mesin di sekitarnya (Jocher et al., 2024).

4.1.2. Jalur Analisis Fitur dan Klasifikasi (CatBoost)

Setelah area objek berhasil dipisahkan melalui masker segmentasi, sistem melanjutkan proses pada jalur analisis fitur numerik menggunakan algoritma CatBoost. Jalur ini

berfungsi untuk mengolah statistik deskriptif dari piksel yang telah tersegmentasi, seperti nilai median pada ruang warna HSV dan tekstur berbasis Interquartile Range (IQR). CatBoost dipilih karena kemampuannya dalam menangani pola non-linear pada data tabular secara efisien tanpa memerlukan proses *feature scaling* yang rumit (Hancock & Khoshgoftaar, 2021).

4.2. Tahap Pemahaman Data

Pada penelitian ini, data dikumpulkan melalui pengambilan citra dipstick di lapangan. Proses persiapan data dilakukan melalui beberapa tahapan untuk memastikan kualitas dataset yang digunakan dalam pengembangan model.

4.2.1. Pengumpulan dan Pembersihan Data (*Filtering*)

Dataset awal yang berhasil dikumpulkan berjumlah 1.902 citra. Mengingat pengambilan data dilakukan oleh operator di lapangan, ditemukan beberapa kendala teknis seperti gambar yang tidak fokus (blur) atau posisi dipstick yang tidak masuk dalam bingkai kamera. Oleh karena itu, dilakukan proses seleksi manual untuk memisahkan data yang valid. Hasil dari tahap ini menghasilkan 1.564 citra valid yang siap untuk diproses lebih lanjut.

4.2.2. Anotasi Bertingkat (*Multi-stage Annotation*)

Proses anotasi dilakukan secara bertingkat untuk melatih tiga model berbeda dalam satu sistem *hybrid*.

1. Model 1 (*Dipstick Detection*), menggunakan 1.564 citra untuk melatih deteksi objek dipstick secara utuh. Tahap ini bertujuan agar sistem dapat menemukan lokasi alat ukur di dalam gambar.
2. Model 2 (*Component Segmentation*), pada citra yang sudah teridentifikasi sebagai dipstick valid, dilakukan anotasi lebih rinci pada komponen-komponen utama, yaitu area oli (*Oil*) dan area batas aman (*Valid Min-Max*). Anotasi ini berjumlah 1.164 pada masing-

masing label untuk melatih pemahaman kualitatif sistem terhadap kondisi fisik oli.

3. Model 3 (Kualitas Kategori), berdasarkan fitur yang berhasil disegmentasi oleh Model 2, data kemudian diklasifikasikan ke dalam dua kategori kualitas menggunakan algoritma CatBoost, yaitu *Clear* (739 data) dan *Brown* (425 data).

4.2.3. Distribusi Dataset

Setelah melalui tahap pembersihan, dataset sebanyak 1.564 citra tersebut dibagi ke dalam tiga subset untuk kebutuhan eksperimen.

Tabel 4.1. Distribusi Dataset

Kategori Data	Jumlah	Persentase	Tujuan Penggunaan
Data Latih (Train)	1.094	70%	Digunakan untuk melatih bobot internal model (<i>Deep Learning & Machine Learning</i>).
Data Validasi (Val)	313	20%	Digunakan untuk optimasi parameter (<i>hyperparameter tuning</i>) selama proses pelatihan.
Data Uji (Test)	157	10%	Digunakan untuk mengevaluasi performa akhir sistem pada data yang belum pernah dilihat sebelumnya.

Total Valid Data	1.564	100%	Data yang telah melalui tahap pembersihan (tidak blur).
------------------	-------	------	---

4.3. Pengembangan Model 1: *Dipstick Object Detection*

Model 1 dikembangkan sebagai tahap awal dalam pipeline otomatisasi untuk melakukan deteksi objek *dipstick* secara utuh. Fokus utama dari model ini adalah klasifikasi keberadaan objek dan lokalisasi guna memisahkan data citra yang valid dari data yang tidak relevan atau *noisy*. Dalam implementasi di lapangan, sering ditemukan kendala berupa citra yang tidak memuat objek sasaran akibat kesalahan sudut pengambilan gambar oleh operator. Oleh karena itu, Model 1 berfungsi sebagai filter otomatis yang memastikan hanya citra berkualitas yang diteruskan ke tahap segmentasi.

Pengembangan model ini menggunakan arsitektur YOLOv11 Nano (`yolo11n.pt`). Pemilihan varian Nano didasarkan pada kebutuhan efisiensi komputasi agar model dapat berjalan secara responsif pada perangkat dengan spesifikasi terbatas. Hasil dari Model 1 ini berupa koordinat kotak pembatas yang membungkus seluruh area *dipstick*, yang kemudian menjadi landasan bagi Model 2 untuk melakukan segmentasi komponen internal secara lebih mendetail.

```

# Augmentation parameters
augmentation_params = {
    'hsv_h': 0.015, # Hue augmentation
    'hsv_s': 0.7, # Saturation augmentation
    'hsv_v': 0.4, # Value augmentation
    'degrees': 10.0, # Rotation degrees
    'translate': 0.1, # Translation
    'scale': 0.5, # Scaling factor
    'shear': 0.0, # Shear
    'perspective': 0.0, # Perspective
    'flipud': 0.5, # Vertical flip probability
    'fliplr': 0.5, # Horizontal flip probability
    'mosaic': 1.0, # Mosaic augmentation probability
    'mixup': 0.1, # Mixup augmentation probability
    'copy_paste': 0.1 # Copy-paste augmentation
}

```

Kode Sumber 4.1 Parameter Augmentasi Model 1

```

model_v11 = YOLO('yolo11n-seg.pt')

results_v11 = model_v11.train(
    data='/kaggle/input/oil-dataset/data.yaml',
    epochs=100,
    batch=32,
    imgsz=640,
    patience=20,
    workers=8,
    device=0 if torch.cuda.is_available() else 'cpu',
    project='runs/segment',
    name='yolo11n-dipstick',
    exist_ok=True,
    pretrained=True,
    optimizer='AdamW',
    verbose=True,
    seed=42,
    deterministic=True,
    plots=True,
    amp=True,
    **augmentation_params
)

```

Kode Sumber 4.2 Parameter Pelatihan Model 1

4.4. Pengembangan Model 2: *Oil Component Segmentation*

Setelah citra dinyatakan valid oleh Model 1, sistem melanjutkan ke tahap Model 2 dengan fokus segmentasi

komponen internal *dipstick*. Sama seperti model pertama, Model 2 juga menggunakan arsitektur YOLOv11 *Instance Segmentation*, namun dilatih secara khusus untuk mengenali kelas-kelas yang lebih spesifik di dalam area *dipstick*.

Model 2 dilatih untuk mengenali tiga kelas utama: area oli (Oil) dan batas indikator aman (Valid Min-Max). Masker dari area Oil menjadi input utama bagi tahap ekstraksi fitur warna untuk Model 3.

```
TRAIN_ARGS = {
    'lr0': 1e-4,
    'lrf': 0.01,
    'cos_lr': True,
    'close_mosaic': 10
}

augmentation_params = {
    'hsv_h': 0.015,
    'hsv_s': 0.7,
    'hsv_v': 0.5,
    'degrees': 15.0,
    'translate': 0.1,
    'scale': 0.6,

    # --- GEOMETRY ---
    'shear': 0.0,
    'perspective': 0.0,
    'flipud': 0.5,
    'fliplr': 0.5,

    # --- COMPOSITION ---
    'mosaic': 1.0,
    'mixup': 0.0,
    'copy_paste': 0.3
}
```

Kode Sumber 4.3 Parameter Augmentasi Model 2

```

model_seg = YOLO('yolo11n-seg.pt')

# Train
results_seg = model_seg.train(
    data=str(yaml_path),
    epochs=200,
    batch=32,
    imgsz=1024,
    patience=20,
    workers=8,
    device=0 if torch.cuda.is_available() else 'cpu',
    project=str(OUT_PATH / 'runs' / 'segment'),
    name='dipstick-seg',
    exist_ok=True,
    pretrained=True,
    optimizer='AdamW',
    verbose=True,
    seed=42,
    deterministic=True,
    plots=True,
    amp=True,
    overlap_mask=True,
    **TRAIN_ARGS,

    # Add augmentations
    **augmentation_params
)

```

Kode Sumber 4.4 Parameter Pelatihan Model 2

4.5. Pengembangan Model 2: Oil Component Segmentation

Model 3 merupakan tahap akhir dalam sistem pipeline yang berfungsi sebagai pengambil keputusan klasifikasi kualitas pelumas. Berbeda dengan dua model sebelumnya yang berbasis Computer Vision, Model 3 menggunakan algoritma Machine Learning CatBoost Classifier. Model ini menerima input berupa fitur-fitur numerik hasil ekstraksi citra untuk memprediksi apakah oli masuk dalam kategori *Clear* (Bersih) atau *Brown* (Kotor).

4.5.1. Pra-pemrosesan Data

Sebelum data dimasukkan ke dalam model CatBoost, dilakukan beberapa langkah pra-pemrosesan untuk memastikan validitas data.

1. Erosi Masker. Sebelum ekstraksi fitur, masker segmentasi dikikis (*erode*) sebanyak 1 iterasi menggunakan OpenCV untuk memastikan piksel yang diambil murni berasal dari gumpalan oli, bukan dari tepi besi *dipstick*.
2. *Gamma Correction*. Penyesuaian nilai gamma dilakukan pada citra asli untuk menormalkan tingkat kecerahan, sehingga fitur warna yang diekstraksi tetap konsisten meskipun foto diambil di lingkungan yang gelap.

```
def adjust_gamma(image, gamma=1.0):
    """
    Apply gamma correction to brighten/darken image.
    gamma > 1.0 -> darken
    gamma < 1.0 -> brighten
    """
    # Build a lookup table mapping pixel values [0, 255] to adjusted gamma values
    inv_gamma = 1.0 / gamma
    table = np.array([((i / 255.0) ** inv_gamma) * 255 for i in np.arange(0, 256)]).
    astype("uint8")

    # Apply gamma correction using the lookup table
    return cv2.LUT(image, table)
```

Kode Sumber 4.5 Gamma Correction

3. *Handling Imbalanced Data*. Mengingat jumlah data *Clear* lebih banyak daripada *Brown*, pada saat inisialisasi model digunakan parameter `class_weight='balanced'` untuk memberikan bobot lebih pada kelas minoritas agar hasil klasifikasi tidak bias.

```
# Calculate Class Weights to handle imbalance
classes = np.unique(y_train)
weights = compute_class_weight(class_weight='balanced', classes=classes, y=y_train)
class_weights_dict = dict(zip(classes, weights))
```

Kode Sumber 4.6 *Handling Imbalance*

4.5.2. Rekayasa Fitur (*Feature Extraction*)

Tahap ini adalah proses mengubah informasi visual dari masker segmentasi menjadi data angka. Fitur-fitur yang diekstraksi dirancang khusus untuk menangkap perbedaan karakteristik fisik antara oli baru dan oli bekas.

1. Statistik *Robust* (Median & IQR). Dibandingkan menggunakan rata-rata (mean), sistem menggunakan nilai Median pada saluran HSV untuk menghindari pengaruh pantulan cahaya (*glare*). Selain itu, *Interquartile Range* (IQR) digunakan untuk mengukur variasi tekstur warna pada permukaan oli.
2. *Brown Index* untuk membedakan warna kuning emas (S tinggi, V tinggi) dengan warna coklat tua (S tinggi, V rendah).
3. *Relative Darkness*, yaitu rasio kecerahan antara area oli basah dibandingkan dengan area besi dipstick yang kering.
4. *Contrast Difference*, yaitu selisih nilai saturasi dan nilai kecerahan antara area oil dan dry stick untuk mendeteksi tingkat kepekatan kontaminan.

4.5.3. Pelatihan Model Klasifikasi CatBoost

Tahap pelatihan Model 3 berfokus pada pengembangan pengambil keputusan berbasis data tabular. Setelah fitur numerik berhasil diekstraksi dari hasil segmentasi Model 2, data tersebut disusun ke dalam sebuah Dataframe yang terdiri dari variabel bebas (fitur warna dan tekstur) dan variabel terikat (label kualitas oli).

```

def get_robust_stats(image, mask):
    """
    Extracts stats using IQR (Interquartile Range) to ignore glare/outliers,
    and Erosion to ignore messy edge pixels.
    """
    if mask is None: return None

    # A. EROSION
    # Shrink the mask by 1 iteration to ignore messy edges where background bleeds in
    kernel = np.ones((3,3), np.uint8)
    mask_eroded = cv2.erode(mask, kernel, iterations=1)

    # Safety: If erosion kills the mask (tiny area), revert to original
    if np.count_nonzero(mask_eroded) < 10:
        mask_to_use = mask
    else:
        mask_to_use = mask_eroded

    masked_pixels = image[mask_to_use > 0]
    if len(masked_pixels) < 10: return None

    # Convert to HSV
    pixels_hsv = cv2.cvtColor(masked_pixels.reshape(-1, 1, 3), cv2.COLOR_BGR2HSV)
    pixels_hsv = pixels_hsv.reshape(-1, 3)

    # Extract channels
    h, s, v = pixels_hsv[:, 0], pixels_hsv[:, 1], pixels_hsv[:, 2]

    # B. ROBUST TEXTURE
    # Use IQR (75th - 25th percentile) instead of StdDev.
    # This measures "roughness" without being thrown off by one bright reflection.
    iqr_s = np.percentile(s, 75) - np.percentile(s, 25)
    iqr_v = np.percentile(v, 75) - np.percentile(v, 25)

    return {
        'H': np.median(h),
        'S': np.median(s),
        'V': np.median(v),
        'iqr_S': iqr_s,
        'iqr_V': iqr_v
    }

```

Kode Sumber 4.7 Fungsi *get_robust_stat* untuk Mendapat Nilai Interkuartil, Erosi, dan HSV

```

def extract_features_v3(img_path, model_stick, model_oil):
    """
    Extracts features designed to solve the "Golden Oil" vs "Dirty Brown" confusion.
    """
    img = cv2.imread(str(img_path))
    if img is None: return None
    h, w = img.shape[:2]

    # 1. Stick Detection
    res_stick = model_stick(img, verbose=False, conf=0.15)
    mask_stick = np.zeros((h, w), dtype=np.uint8)
    if res_stick[0].masks:
        for seg in res_stick[0].masks.xy:
            cv2.fillPoly(mask_stick, [np.array(seg, dtype=np.int32)], 255)
    elif len(res_stick[0].boxes) > 0:
        box = res_stick[0].boxes[0].xyxy[0].cpu().numpy().astype(int)
        cv2.rectangle(mask_stick, (box[0], box[1]), (box[2], box[3]), 255, -1)
    else:
        return None

    # 2. Oil Detection
    res_oil = model_oil(img, verbose=False, conf=0.15)
    mask_wet = np.zeros((h, w), dtype=np.uint8)
    found_oil = False
    if res_oil[0].masks:
        found_oil = True
        for seg in res_oil[0].masks.xy:
            cv2.fillPoly(mask_wet, [np.array(seg, dtype=np.int32)], 255)

    if not found_oil:
        return None

    # 3. Dry = Stick - Wet
    mask_dry = cv2.bitwise_and(mask_stick, cv2.bitwise_not(mask_wet))
    wet = get_robust_stats(img, mask_wet)
    dry = get_robust_stats(img, mask_dry)
    if wet is None or dry is None: return None

```

Kode Sumber 4.8 Fungsi *extract_features_v3* untuk Ekstraksi Fitur

```

# Feature engineering
eps = 1e-5
features = {
    # 1. Basic Colors (Median)
    'wet_H': wet['H'],
    'wet_S': wet['S'],
    'wet_V': wet['V'],
    'dry_V': dry['V'],

    # 2. Robust Texture (IQR)
    'wet_iqr_V': wet['iqr_V'],
    'wet_iqr_S': wet['iqr_S'],

    # 3. Contrast (Difference)
    'diff_V': dry['V'] - wet['V'],
    'diff_S': wet['S'] - dry['S'],

    # 4. INTERACTION FEATURES (The "Smart" Ratios)
    # Brown Index: Differentiates Golden (Fresh) from Brown (Dirty)
    'brown_index': wet['S'] / (wet['V'] + 10.0),
    # Relative Darkness: How dark is the oil relative to the stick?
    'rel_darkness': wet['V'] / (dry['V'] + 10.0),
    # Saturation Boost: How much color does the oil ADD to the metal?
    'sat_boost': wet['S'] / (dry['S'] + 10.0)
}

```

Kode Sumber 4.9 Reayasa Fitur

```

cb_model = CatBoostClassifier(
    iterations=1500,
    learning_rate=0.02,
    depth=5,
    l2_leaf_reg=7,
    loss_function='Logloss',
    eval_metric='F1',
    class_weights=class_weights_dict,
    early_stopping_rounds=100,
    verbose=200,
    random_seed=42
)

cb_model.fit(
    X_train, y_train,
    eval_set=(X_val, y_val),
    use_best_model=True
)

```

Kode Sumber 4.10 Parameter Pelatihan Model 3

BAB V

PENGUJIAN DAN EVALUASI

Bab ini akan menjelaskan tahapan pengujian dan evaluasi model YOLO untuk deteksi objek dipstick oli serta model *machine learning* untuk klasifikasi kondisi oli berdasarkan warna oli terhadap data citra dipstick oli generator.

5.1. Tujuan Pengujian

Pengujian ini bertujuan untuk menguji keakuratan model YOLO dalam melakukan deteksi objek dipstick oli serta model *machine learning* dalam melakukan klasifikasi kondisi warna oli pada data citra dipstick oli generator. Adapun kelas pada tahap deteksi objek terdiri dari dipstick terdeteksi (kelas 1) dan dipstick tidak terdeteksi (kelas 0). Selanjutnya, pada tahap klasifikasi kondisi oli, kelas yang digunakan adalah warna oli normal/layak (kelas 1) dan warna oli tidak normal/tidak layak (kelas 0).

5.2. Kriteria Pengujian

Kriteria pengujian digunakan untuk menilai kinerja model dalam menjalankan tugas yang telah ditentukan. Pada kerja praktik ini, kriteria pengujian dibedakan berdasarkan jenis model yang digunakan, yaitu model deteksi objek dan model klasifikasi warna oli.

5.2.1. Deteksi Objek Dipstick Oli

Kinerja model deteksi objek dipstick oli dievaluasi menggunakan beberapa metrik evaluasi yang umum digunakan pada tugas object detection dan segmentation. Metrik yang digunakan meliputi mean Average Precision (mAP) pada nilai mAP50 dan mAP50–95, baik untuk bounding box maupun mask. Selain itu, digunakan pula

metrik precision dan recall untuk menilai ketepatan dan kelengkapan model dalam mendeteksi objek dipstick oli.

5.2.2. Klasifikasi Warna Oli

Kinerja model *machine learning* dalam mengklasifikasikan kondisi warna oli dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi dilakukan untuk masing-masing kelas, yaitu kondisi oli layak (*healthy*) dan tidak layak (*unhealthy*).

5.3. Skenario Pengujian

Skenario pengujian pada kerja praktik ini dibagi menjadi dua bagian, yaitu pengujian deteksi objek dipstick oli dan pengujian klasifikasi warna oli. Setiap pengujian dilakukan dengan membandingkan dua model yang berbeda menggunakan dataset dan skenario pengujian yang sama.

5.3.1. Skenario Pengujian Deteksi Objek Menggunakan YOLOv8

Pada skenario ini, model YOLOv8 digunakan untuk melakukan deteksi objek dipstick oli pada data citra uji. Pengujian dilakukan dengan menggunakan dataset yang sama dan parameter pengujian yang seragam. Hasil deteksi berupa bounding box dan mask objek dipstick kemudian dievaluasi menggunakan metrik evaluasi yang telah ditentukan untuk menilai performa model.

5.3.2. Skenario Pengujian Deteksi Objek Menggunakan YOLOv11

Pada skenario ini, model YOLOv11 digunakan sebagai pembanding terhadap YOLOv8. Pengujian dilakukan menggunakan dataset, alur pengujian, dan

metrik evaluasi yang sama. Perbandingan hasil pengujian difokuskan pada performa deteksi objek dipstick oli yang dihasilkan oleh masing-masing model.

5.3.3. Skenario Pengujian Klasifikasi Warna Oli Menggunakan Random Forest

Pada skenario ini, algoritma Random Forest digunakan untuk melakukan klasifikasi kondisi warna oli menjadi kategori healthy dan unhealthy. Pengujian dilakukan menggunakan data uji dan fitur yang sama dengan skenario pengujian lainnya. Hasil pengujian digunakan untuk mengevaluasi kemampuan Random Forest dalam mengklasifikasikan kondisi warna oli berdasarkan data citra dipstick.

5.3.4. Skenario Pengujian Klasifikasi Warna Oli Menggunakan Gradient Boosting

Pada skenario ini, algoritma Gradient Boosting digunakan untuk melakukan klasifikasi kondisi warna oli menjadi kategori healthy dan unhealthy. Pengujian dilakukan menggunakan data uji dan fitur yang sama seperti pada skenario Random Forest. Hasil pengujian dibandingkan untuk mengetahui perbedaan performa antara metode Gradient Boosting dan Random Forest dalam klasifikasi kondisi warna oli.

5.3.5. Skenario Pengujian Klasifikasi Warna Oli Menggunakan CatBoost

Pada skenario ini, algoritma CatBoost digunakan untuk melakukan klasifikasi kondisi warna oli menjadi kategori healthy dan unhealthy. Pengujian dilakukan menggunakan data uji dan fitur yang sama seperti pada skenario sebelumnya. Hasil klasifikasi CatBoost dibandingkan dengan Random Forest dan Gradient

Boosting untuk mengetahui perbedaan performa dalam mengklasifikasikan kondisi warna oli.

5.4. Evaluasi Pengujian

5.4.1. Perbandingan YOLOv8 dan YOLOv11

Berdasarkan hasil pengujian yang telah dilakukan, diperoleh perbandingan kinerja antara model YOLOv8 dan YOLOv11 dalam mendeteksi objek dipstick oli pada citra generator. Evaluasi dilakukan menggunakan metrik deteksi objek, yaitu precision, dan recall.

Tabel 5.1 Hasil Pengujian Model YOLOv8 dan YOLOv11

	YOLOv8	YOLOv11
Precision	0,8557	0,8570
Recall	0,9185	0,9333

Hasil pengujian menunjukkan bahwa model YOLOv11 memiliki performa yang lebih baik dibandingkan YOLOv8 dalam mendeteksi objek dipstick oli. YOLOv11 mampu memberikan nilai presisi dan recall yang lebih tinggi. Dengan demikian, YOLOv11 dinilai lebih optimal untuk digunakan pada tahap deteksi objek dipstick oli dan selanjutnya dipilih sebagai model deteksi pada sistem yang dikembangkan.

5.4.2. Perbandingan Random Forest, CatBoost, dan Gradient Boosting

Setelah objek dipstick dan area oli berhasil terdeteksi, tahap selanjutnya adalah klasifikasi kondisi oli berdasarkan warna. Pada tahap ini dilakukan perbandingan antara algoritma Random Forest dan CatBoost. Evaluasi

klasifikasi dilakukan menggunakan metrik *precision*, *recall*, *F1-score*, dan *accuracy*.

Tabel 5.2 Hasil Pengujian Model Machine Learning

Model		Random Forest	Gradient Boost	Cat Boost
Precision	Healthy	0,82	0,80	0,86
	Unhealthy	0,74	0,68	0,77
Recall	Healthy	0,86	0,83	0,88
	Unhealthy	0,66	0,66	0,75
F1 Score	Healthy	0,84	0,81	0,87
	Unhealthy	0,70	0,66	0,76
Accuracy		0,79	0,76	0,83

Berdasarkan hasil evaluasi, model CatBoost menunjukkan performa yang lebih baik dibandingkan Random Forest dan Gradient Boosting dalam mengklasifikasikan kondisi oli menjadi kategori healthy dan unhealthy. CatBoost menghasilkan nilai akurasi dan F1-score yang lebih tinggi pada data uji, sehingga dinilai lebih optimal untuk digunakan pada proses klasifikasi kondisi oli.

Performa CatBoost yang lebih baik tidak dapat dijelaskan hanya berdasarkan penggunaan pendekatan boosting, mengingat algoritma Gradient Boosting yang menerapkan paradigma serupa justru menghasilkan performa yang lebih rendah pada pengujian ini. Hal tersebut menunjukkan bahwa keunggulan CatBoost lebih berkaitan dengan mekanisme pembelajaran internal yang digunakan dalam proses pembentukan model.

Mekanisme tersebut memungkinkan CatBoost memodelkan hubungan antar fitur warna secara lebih konsisten, sehingga mampu membedakan kondisi oli healthy dan unhealthy dengan lebih baik. Selain itu, CatBoost menunjukkan keseimbangan yang lebih baik antara nilai precision dan recall pada kedua kelas, khususnya pada kelas unhealthy, yang berdampak pada peningkatan nilai F1-score dan akurasi secara keseluruhan.

BAB 5

KESIMPULAN DAN SARAN

6.1. Kesimpulan

Berdasarkan hasil perancangan, implementasi, dan pengujian sistem pengembangan model hybrid Deep Learning dan CatBoost untuk analisis kelayakan oli mesin di PT Telkom Infrastruktur Indonesia, diperoleh kesimpulan sebagai berikut:

1. Proses pengecekan kondisi oli generator yang sebelumnya dilakukan secara manual melalui inspeksi visual berhasil ditingkatkan efisiensinya melalui sistem berbasis *Computer Vision* dan *Machine Learning*. Sistem mampu melakukan deteksi *objek dipstick*, segmentasi area oli, serta klasifikasi kondisi oli secara otomatis sehingga mengurangi ketergantungan terhadap inspeksi manual dan meminimalkan potensi *human error*.
2. Sistem pendukung pengecekan kondisi oli berhasil dirancang untuk menghasilkan proses pemeriksaan yang lebih konsisten dan terstandarisasi berdasarkan parameter warna oli. Berdasarkan hasil pengujian, arsitektur YOLOv11 memberikan performa deteksi objek yang lebih baik dibandingkan YOLOv8, sedangkan algoritma CatBoost memberikan performa klasifikasi terbaik dibandingkan Random Forest dan Gradient Boosting. Kombinasi kedua metode tersebut menghasilkan sistem yang mampu melakukan pengecekan kondisi oli secara objektif dan mendukung kegiatan pemeliharaan generator di PT Telkom Infrastruktur Indonesia.

6.2. Saran

Berdasarkan hasil perancangan dan evaluasi sistem klasifikasi kualitas oli PT Telkom Infrastruktur

Indonesia, terdapat beberapa saran yang dapat diterapkan untuk pengembangan selanjutnya.

- a. Aplikasi pengambilan gambar sebaiknya dilengkapi fitur *focus lock* guna meminimalisir data yang terbuang akibat efek *blur*.
- b. Perlu dilakukan konversi model YOLOv11 dan CatBoost ke format yang lebih ringan seperti TFLite atau ONNX dengan teknik *quantization*.
- c. Disarankan menambahkan tahap *edge enhancement* pada proses pra-pemrosesan citra sebelum segmentasi Model 2 dilakukan.

DAFTAR PUSTAKA

- [1] J. Brownlee, *Probability for Machine Learning: Discover How To Harness Uncertainty With Python*, Vermont: Machine Learning Mastery, 2021.
- [2] S. S. Chai, *Fundamentals of Machine Learning*, Boca Raton: CRC Press, 2021.
- [3] R. C. Gonzalez dan R. E. Woods, *Digital Image Processing*, Edisi ke-5, New Jersey: Pearson Education, 2024.
- [4] I. Goodfellow, Y. Bengio, dan A. Courville, *Deep Learning (Adaptive Computation and Machine Learning series)*, Cambridge: MIT Press, 2021.
- [5] J. T. Hancock dan T. M. Khoshgoftaar, "CatBoost for big data: an interdisciplinary review," *Journal of Big Data*, vol. 8, no. 1, hlm. 1-45, 2021.
- [6] G. F. Luger, *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*, Edisi ke-7, New York: Pearson, 2021.
- [7] J. Redmon, S. Divvala, R. Girshick, dan A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," dalam *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 2016. (Tetap dimasukkan karena merupakan paper fundamental YOLO).
- [8] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Computer Science*, vol. 2, no. 160, 2021.
- [9] R. Szeliski, *Computer Vision: Algorithms and Applications*, Edisi ke-2, Washington: Springer Nature, 2022.
- [10] Ultralytics, "YOLOv11: Real-time Object Detection and Instance Segmentation," [Online]. Available: <https://docs.ultralytics.com/models/yolo11/>. [Diakses: 13-Feb-2026].

[Halaman ini sengaja dikosongkan]

BIODATA PENULIS I

Nama : Miskiyah
Tempat, Tanggal Lahir : Salatiga, 21 Juli 2005
Jenis Kelamin : Perempuan
Telepon : +6289658857422
Email : 5025231119@student.its.ac.id

AKADEMIS

Kuliah : Departemen Teknik Informatika –
FTEIC , ITS
Angkatan : 2023
Semester : 6 (Enam)

BIODATA PENULIS II

Nama : Hikmia Sofia Nur Izzati
Tempat, Tanggal Lahir : Sidoarjo, 29 Juli 2025
Jenis Kelamin : Perempuan
Telepon : +6281357036414
Email : hikmiasofia37@gmail.com

AKADEMIS

Kuliah : Departemen Teknik Informatika –
FTEIC , ITS
Angkatan : 2023
Semester : 6 (Enam)