

## Komparasi Kinerja Model U-Net dan DeepLab V3+ pada Segmentasi Pipa Korosi

I Dewa Gede Mahesta Parawangsa<sup>1</sup>, Putu Zasya Eka Satya Nugraha<sup>2</sup>, Anggie Ananda<sup>3</sup>

<sup>1</sup>Program Studi Sistem Informasi, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha

<sup>2,3</sup>PT. Dago Engineering

[<sup>1</sup>](mailto:mahesta@undiksha.ac.id), [<sup>2</sup>](mailto:dendi.ms@undiksha.ac.id), [<sup>3</sup>](mailto:zasya@dagoeng.co.id), [<sup>4</sup>](mailto:anggie.ananda@dagoeng.co.id)

### Abstrak

*Inspeksi integritas pipa pada industri vital seperti minyak dan gas saat ini masih bergantung pada metode manual yang kurang efisien dan berisiko tinggi. Permasalahan utama seperti korosi dapat menyebabkan kebocoran dan kerusakan lingkungan jika tidak terdeteksi secara dini dan akurat. Sebagai solusinya, teknologi deep learning menawarkan berbagai pendekatan, mulai dari klasifikasi hingga deteksi objek. Namun, pendekatan segmentasi semantik dipilih karena kemampuannya menawarkan potensi otomatisasi penuh untuk identifikasi area korosi secara presisi piksel-demi-piksel. Penelitian ini melakukan analisis komparatif antara kinerja arsitektur U-Net standar dengan DeepLabV3+ yang menggunakan backbone ResNet50. Kinerja kedua model dievaluasi pada 108 gambar asli, yang diproses melalui augmentasi menjadi total 1.261 data latih dan validasi. Perbandingan difokuskan pada dua tugas terpisah: segmentasi aset pipa utuh dan segmentasi korosi. Penilaian Intersection over Union (mIoU) menunjukkan DeepLabV3+ secara signifikan mengungguli U-Net dalam segmentasi aset dengan nilai 0.862 berbanding 0.735. Sebaliknya, U-Net menunjukkan keterunggulan tipis pada segmentasi korosi dengan mIoU 0.779 berbanding 0.701. Secara komputasi, DeepLabV3+ dengan waktu rata-rata 0.44 detik terbukti jauh lebih efisien daripada U-Net dengan rata-rata 1.24 detik. Dengan demikian, DeepLabV3+ menawarkan keseimbangan terbaik antara akurasi segmentasi aset yang superior dan efisiensi tinggi, menjadikannya kandidat model yang robust untuk pengembangan sistem inspeksi visual otomatis di lapangan.*

Kata kunci: Segmentasi Semantik, Korosi Pipa, Deep Learning, U-Net, DeepLabV3+

### 1. Latar Belakang

Dalam industri minyak dan gas, pipa merupakan infrastruktur vital untuk mengalirkan fluida melintasi jarak yang jauh. Saat ini, industri minyak dan gas di Indonesia sedang menghadapi isu serius terkait keselamatan dan keandalan sistem perpipaan [1]. Berbagai insiden telah menyoroti besarnya risiko ini, seperti terdapat sebuah studi kasus mengenai operasional bongkar muat BBM di Pelabuhan Tanjung Wangi, misalnya mengidentifikasi kebocoran yang disebabkan oleh korosi akibat air laut dan kegagalan paking pada sambungan pipa [2]. Ancaman paling signifikan terhadap integritas infrastruktur ini memang korosi, sebuah proses degradasi material alami yang jika tidak terdeteksi dapat menipiskan dinding pipa dan menyebabkan kegagalan.

Secara historis, deteksi korosi bergantung pada inspeksi visual manual dan pengukuran ketebalan secara periodik. Metode tradisional ini memiliki keterbatasan yang signifikan: sangat subjektif, memakan proses yang lama, padat karya, dan tidak efisien untuk diterapkan pada jaringan pipa yang luas [3]. Keterbatasan ini mendorong perlunya adopsi teknologi yang lebih canggih untuk pemantauan kondisi pipa.

Kemajuan dalam *computer vision*, yang didukung oleh *deep learning*, telah membuka peluang baru untuk otomatisasi inspeksi [4]. Secara khusus, teknik segmentasi semantik telah muncul sebagai solusi yang kuat. Berbeda dengan deteksi objek, segmentasi semantik mengklasifikasikan setiap piksel dalam gambar [5]. Kemampuan ini memungkinkan identifikasi dan kuantifikasi area korosi secara presisi, yang sangat penting untuk penilaian tingkat kerusakan.

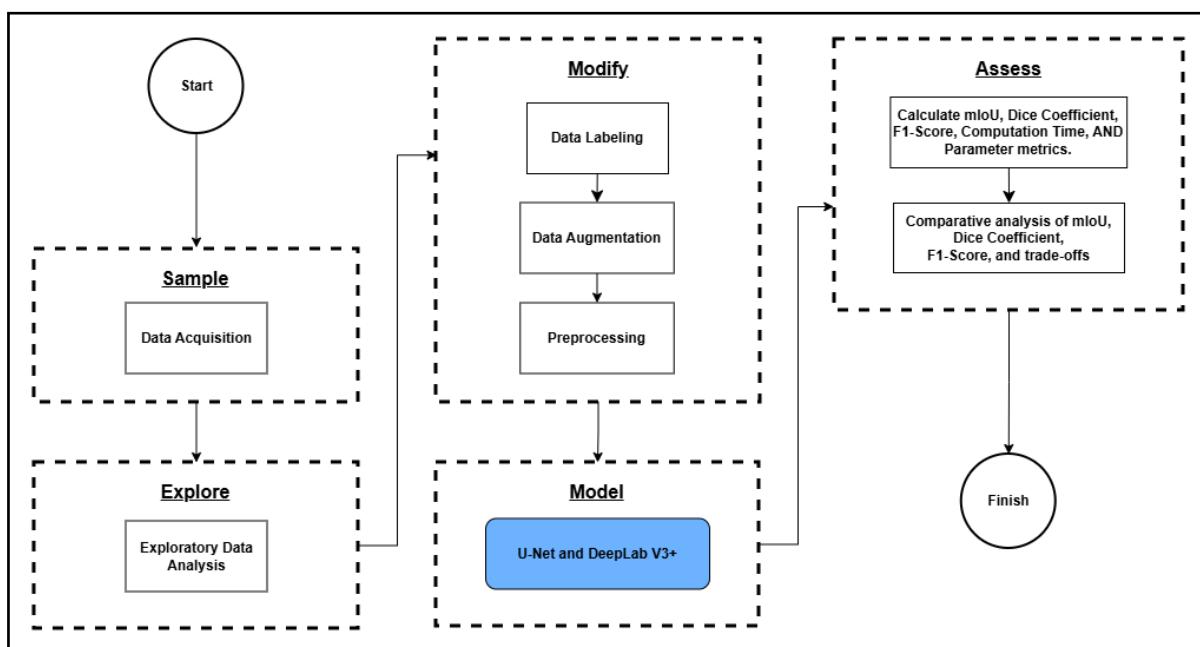
Dalam ranah segmentasi semantik, berbagai arsitektur deep learning telah dikembangkan. Arsitektur ini secara fundamental berbeda dari metode computer vision tradisional yang bergantung pada fitur hand-crafted, atau model klasifikasi CNN standar yang hanya memberikan satu label untuk keseluruhan gambar [6], [7]. Arsitektur pelopor

seperti FCN (*Fully Convolutional Network*) dan SegNet dirancang khusus untuk menghasilkan output berupa pixel-map yang padat. Terdapat dua model yang sering menjadi benchmark utama adalah U-Net dan DeepLabV3+ [8], [9]. U-Net, dengan arsitektur *encoder-decoder* simetris dan *skip-connections*, dikenal unggul dalam lokalisasi presisi dan merekonstruksi batas-batas objek yang halus [10], [11]. DeepLabV3+, di sisi lain, memanfaatkan *Atrous Spatial Pyramid Pooling* (ASPP) dan *backbone pre-trained* yang kuat untuk menangkap informasi kontekstual multi-skala secara efektif.

Untuk menjawab tantangan keterbatasan inspeksi manual yang subjektif dan kurang efisien tersebut, diperlukan model segmentasi otomatis yang tidak hanya akurat dalam melokalisasi korosi, tetapi juga efisien secara komputasi untuk penerapan di lapangan. Meskipun U-Net dan DeepLabV3+ telah menjadi benchmark dalam segmentasi semantik, kinerja empirisnya dapat bervariasi. Segmentasi korosi menghadirkan tantangan unik karena teksturnya yang tidak teratur dan batas area yang seringkali tidak jelas. Oleh karena itu, penelitian ini bertujuan untuk melakukan analisis komparatif yang ketat antara U-Net dan DeepLabV3+ untuk tugas spesifik segmentasi pipa korosi. Penelitian ini sengaja membandingkan arsitektur U-Net standar dengan DeepLabV3+ yang mengandalkan backbone pre-trained (ResNet50) untuk mengevaluasi *trade-off* antara kesederhanaan arsitektur dan kekuatan transfer learning [12]. Evaluasi ini krusial untuk menentukan arsitektur mana yang paling optimal sebagai solusi praktis untuk tugas inspeksi pipa korosi, dengan fokus komparasi pada metrik akurasi (mIoU dan F1-Score) dan efisiensi waktu komputasi.

## **2. Metode Penelitian**

Penelitian ini mengadopsi alur kerja metodologi data mining SEMMA, yang merupakan singkatan dari *Sample, Explore, Modify, Model, dan Assess*. Alur ini memastikan proses yang sistematis dari persiapan data hingga evaluasi model [13]. Ilustrasi metode penelitian dapat dilihat pada Gambar 1 berikut.



Gambar 1. Metode Penelitian

## 2.1. Sample

Tahap awal melibatkan pengumpulan data. Dataset sekunder untuk penelitian ini terdiri dari 108 gambar RGB yang relevan. Dataset ini merupakan dataset publik yang sudah ada dan diperoleh langsung dari repositori Roboflow. Sampel ini dipilih karena telah merepresentasikan berbagai kondisi pipa, termasuk area pipa utuh dan area yang terdampak korosi dalam berbagai tingkat keparahan.

## 2.2. Explore

Pada tahap eksplorasi, dataset mentah dianalisis untuk memahami karakteristiknya. Proses ini mencakup visualisasi data untuk mengidentifikasi variasi pencahayaan, tekstur korosi, dan skala objek. Ditemukan bahwa gambar memiliki resolusi yang beragam. Untuk menstandarisasi input model, semua gambar termasuk ground truth diubah ukurannya menjadi resolusi seragam 256x256 piksel. Dataset kemudian dibagi secara proporsional menjadi tiga himpunan: 80% data pelatihan, 10% data validasi, dan 10% data test.

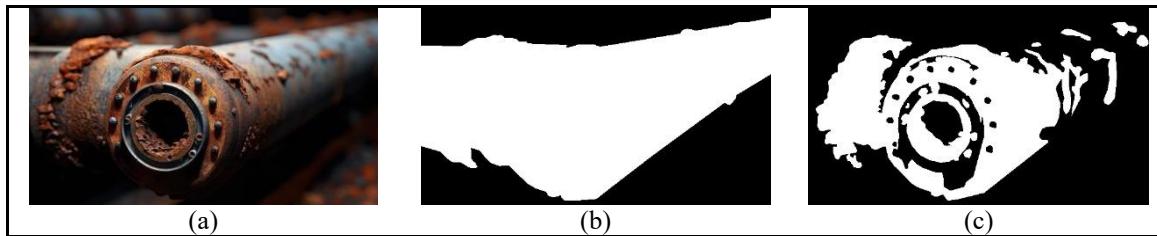
## 2.3. Modify

Tahap modifikasi adalah tahap persiapan data intensif untuk pemodelan. Berikut merupakan tahap-tahap modify.

### 2.3.1 Data Labelling

Proses ini melibatkan pembuatan *mask* segmentasi biner secara manual menggunakan Adobe Photoshop. Proses ini sangat penting untuk *supervised learning*. Dua set *mask* terpisah dibuat untuk setiap gambar asli:

- Ground Truth Pipa: Menandai area yang merepresentasikan aset (piksel putih) terhadap latar belakang (piksel hitam).
- Ground Truth Korosi: Menandai area yang secara spesifik teridentifikasi sebagai korosi (piksel putih) terhadap latar belakang (piksel hitam). Pemisahan ini sangat penting untuk melatih model pada dua tugas segmentasi yang berbeda.

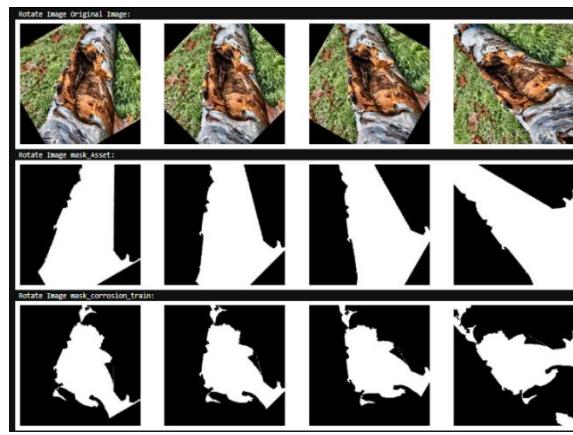


Gambar 2. Label Pipa dan Korosi

Gambar 2 mengilustrasikan proses *data labelling*. (a) adalah citra asli pipa berkarat, (b) merupakan *ground truth* biner yang menandai aset pipa utuh, dan (c) merupakan *ground truth* biner untuk area korosi.

### 2.3.2 Augmentasi Data

Untuk mengatasi jumlah sampel data yang relatif kecil dan meningkatkan kemampuan generalisasi model, teknik augmentasi data diterapkan secara ekstensif pada himpunan data *train* dan *validation*. Augmentasi yang dilakukan meliputi Rotasi, Flip Horizontal dan Vertikal, dan penyesuaian Hue serta Saturation. Berikut merupakan tampilan dari Augmentasi Gambar yang dilakukan.



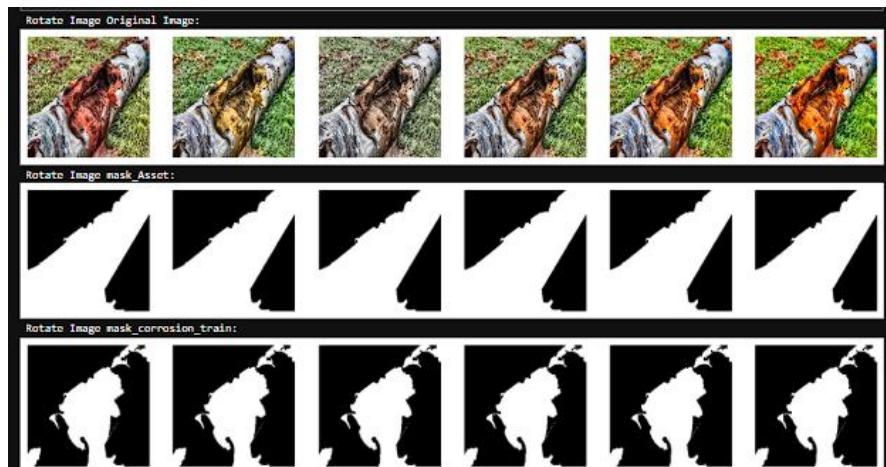
Gambar 3. Augmentasi Rotasi

Bisa dilihat pada gambar 3 yang menampilkan proses augmentasi rotasi yang diterapkan secara konsisten pada gambar asli, mask asset, dan mask korosi. Teknik ini memutar gambar dan mask secara bersamaan dengan berbagai sudut diantara nya  $30^\circ$ ,  $45^\circ$ ,  $60^\circ$ , dan  $90^\circ$  untuk meningkatkan variasi data *train*.



Gambar 4. Augmentasi Flip

Bisa dilihat pada gambar 4. menampilkan proses augmentasi *flip* yang diterapkan secara konsisten pada gambar asli, *mask* aset, dan *mask* korosi. Teknik ini membalik gambar dan *mask* secara bersamaan, baik secara horizontal maupun vertikal, untuk meningkatkan variasi data *train*.



Gambar 5. Augmentasi Saturasi dan Hue

Bisa dilihat pada gambar 5. menampilkan proses augmentasi saturasi dan hue yang diterapkan hanya pada gambar asli, sementara mask aset dan mask korosi tetap tidak berubah. Teknik ini mengubah properti warna gambar dengan berbagai nilai, seperti penyesuaian hue sebesar +10 dan -10 dan faktor saturasi 0.5, 1.0, 1.5, dan 2.0, untuk meningkatkan variasi data *train*.

### 2.3.3 Preprocessing

Tahap pra-pemrosesan data merupakan langkah krusial dalam fase Modify untuk memastikan kualitas, konsistensi, dan keseragaman data sebelum dilatih ke model. Proses ini sangat penting untuk mengoptimalkan kinerja arsitektur deep learning. Langkah-langkah utama yang dilakukan dalam pra-pemrosesan dijabarkan sebagai berikut ini.

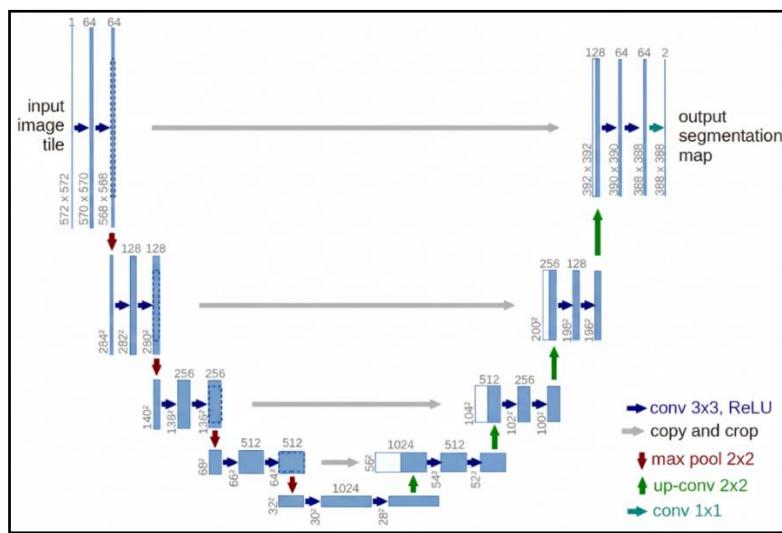
- Normalisasi Nilai Piksel: Nilai piksel pada gambar asli (RGB) dinormalisasi ke dalam rentang [0, 1]. Hal ini dicapai dengan membagi setiap nilai intensitas piksel (yang awalnya dalam rentang [0, 255]) dengan 255. Normalisasi ini merupakan langkah standar untuk menstabilkan dan mempercepat konvergensi selama proses pelatihan model.
- Standarisasi Format File: Untuk menjamin kompatibilitas dan keseragaman dataset, semua file gambar dan mask dikonversi dan disimpan dalam format .jpg. Proses konversi ini dilakukan secara terprogram menggunakan library shutil.
- One-Hot Encoding: Sebagai langkah akhir dalam persiapan label, mask biner yang telah diproses kemudian dikonversi menggunakan one-hot encoding. Ini dilakukan untuk mengubah representasi label menjadi format yang sesuai dengan arsitektur output model dan fungsi loss yang digunakan.

## 2.4 Model

Pada tahap ini, dilakukan pembangunan dan pelatihan dua arsitektur *deep learning*. Pemilihan kedua arsitektur ini didasarkan pada studi kasus serupa dari penelitian terdahulu. Berikut adalah dua arsitektur yang digunakan.

### 2.4.1 U-Net

Model U-Net yang digunakan mengadopsi arsitektur *encoder-decoder* simetris standar. Arsitektur ini dirancang dengan *skip-connections* yang menggabungkan fitur resolusi tinggi dari *encoder* ke *decoder*, yang secara teoretis ideal untuk pemulihian detail spasial yang presisi [4].



Gambar 6. Arsitektur U-Net

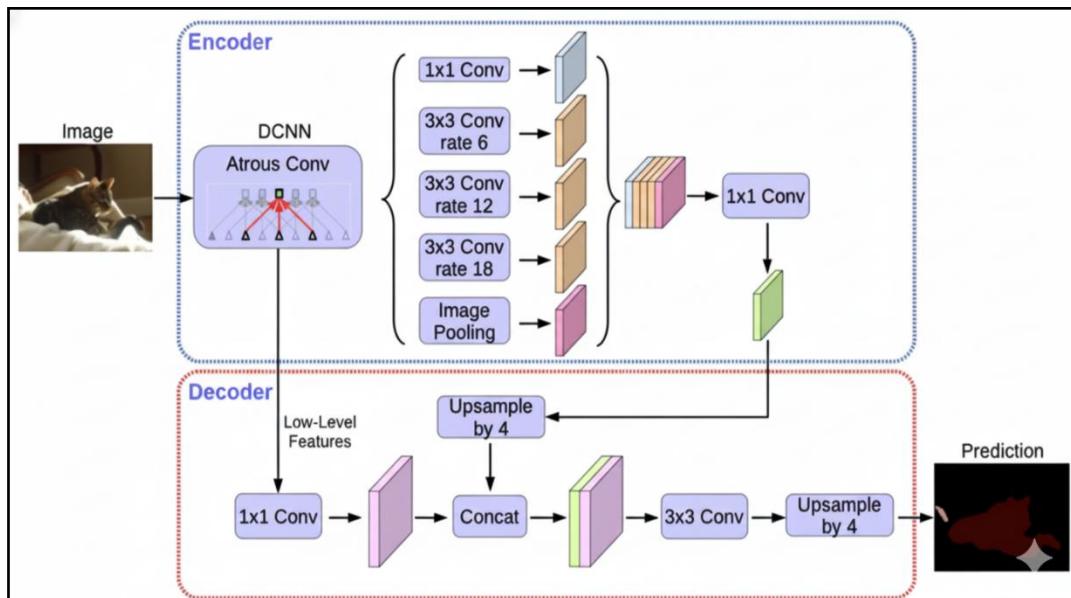
Implementasi dari arsitektur yang diilustrasikan pada Gambar 6 tersebut dikonfigurasi menggunakan serangkaian parameter spesifik selama proses pelatihan. Untuk Parameter tuning nya bisa dilihat pada Tabel 1 berikut.

Tabel 1. Parameter Model U-Net

Parameter	Deskripsi
Batch Size	8
Input Size	256x256
Optimizer	Adam
Learning Rate	0.0001
Activation Function	ReLU dan Sigmoid
Early Stopping	Val loss dengan 20 epoch
Kernel Size	3x3 dan 1x1 untuk output layer
Number of Filters	64, 128, 256, 512, 1024
Loss Function	Binary Cross-Entropy

#### 2.4.2 DeepLabV3+

Model DeepLabV3+ yang digunakan mengimplementasikan arsitektur yang lebih kompleks dengan *backbone* ResNet50 yang telah dilatih pada dataset ImageNet. Model ini memanfaatkan modul *Atrous Spatial Pyramid Pooling* (ASPP) untuk mengekstraksi fitur pada berbagai skala spasial, memungkinkannya menangkap konteks yang lebih baik [12].



Gambar 7. Ilustrasi Arsitektur Deeplab V3+

Arsitektur yang diilustrasikan pada Gambar 7 tersebut diimplementasikan menggunakan serangkaian parameter spesifik. Untuk Parameter tuning nya bisa dilihat pada Tabel 2 berikut.

Tabel 2. Parameter Model DeepLab V3+

Parameter	Deskripsi
Batch Size	8
Input Size	256x256
Optimizer	Adam
Learning Rate	0.0001
Activation Function	ReLU dan Sigmoid
Early Stopping	Val loss dengan 20 epoch
Kernel Size	1x1 dan 3x3
Number of Filters	ResNet50 (Backbone), 256 (ASSP), 48 (Fitur Low-Level)
Loss Function	Binary Cross-Entropy

#### 2.5 Assess

Tahap terakhir adalah penilaian kinerja model yang telah dilatih. Proses evaluasi ini sangat penting untuk mengukur seberapa baik performa model pada data test, yaitu data yang belum pernah dilihat oleh model selama proses pelatihan. Analisis performa model dilakukan dengan menggunakan beberapa metrik evaluasi.

Metrik pertama adalah Pixel Accuracy, yang menilai kinerja model dalam mengklasifikasikan setiap piksel secara tepat. Metrik ini mengukur akurasi piksel prediksi dengan membandingkannya langsung terhadap data ground truth. Perhitungan Pixel Accuracy ditampilkan pada persamaan (1).

$$Pixel\ Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Selanjutnya, Intersection over Union (IoU) digunakan sebagai metrik standar, khususnya pada kasus segmentasi citra. Metrik ini berfungsi untuk mengukur tingkat tumpang tindih (overlap) antara area piksel yang diprediksi oleh model dengan area ground truth yang sebenarnya. Perhitungan metrik IoU dapat dilihat pada persamaan (2).

$$IoU = \frac{TP}{TP + FP + FN} \quad (2)$$

Selain IoU, metrik F1-Score juga dimanfaatkan untuk mengukur performa model. Metrik ini menghitung rata-rata harmonik untuk menyeimbangkan antara nilai precision dan recall. Perhitungan dari metrik F1-Score ditunjukkan pada persamaan (3).

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (3)$$

Metrik berikutnya adalah Waktu Komputasi, yang dicatat dalam satuan detik. Metrik ini mengukur rata-rata waktu inferensi yang diperlukan oleh model untuk menghasilkan satu prediksi gambar. Ini berfungsi sebagai indikator penting untuk menilai efisiensi komputasi dari arsitektur model.

Terakhir, Parameter (Bobot Model) juga dihitung. Metrik ini merujuk pada jumlah total parameter (bobot) yang dapat dilatih di dalam model. Jumlah parameter sering digunakan sebagai proksi untuk mengukur kompleksitas dan ukuran model, yang berdampak pada kebutuhan memori dan kecepatan inferensi [14].

### 3. Hasil dan Diskusi

Bagian ini menyajikan hasil implementasi alur kerja dan evaluasi performa model. Eksperimen ini memanfaatkan total 1.272 data. Data ini dibagi menjadi tiga bagian fungsional: (1) Data *train* yang terdiri dari 1.118 data yang dihasilkan dari augmentasi, (2) Data *validation* yang terdiri dari 143 data setelah diaugmentasi, dan (3) Data *test* yang terdiri dari 11 data tanpa augmentasi untuk interpretasi pada data baru. Penggunaan data Test ini bertujuan untuk memastikan evaluasi akhir model dilakukan secara objektif terhadap data yang belum pernah diproses sebelumnya sehingga pada proses training ini dilakukan hanya dengan 1261 citra.

Pelatihan model dilakukan di Google Colaboratory menggunakan akselerator GPU NVIDIA Tesla T4 dengan 15 GB VRAM. *Training* dilakukan dengan menggunakan 100 epoch dengan menggunakan dua callback diantaranya *ReduceLROnPlateau* untuk penyesuaian learning rate dinamis dan *EarlyStopping* dengan patience 20 epoch. *EarlyStopping* menghentikan pelatihan jika *validation* loss tidak membaik, yang berfungsi untuk mencegah overfitting dan menyimpan model terbaik. Hasil evaluasi akurasi pada data test dirangkum dalam Tabel 3 sebagai berikut.

Tabel 3 Hasil komparasi U-Net & DeepLab V3+

Model	Kategori	Accuracy	mIoU	F1-Score	Waktu Komputasi (s)	Parameter
DeepLabV3+	Aset	<b>0.887</b>	<b>0.862</b>	<b>0.899</b>	<b>0.3738</b>	214500
U-Net	Aset	0.652	0.735	0.791	1.1864	<b>91120</b>
DeepLabV3+	Korosi	0.865	0.701	0.846	<b>0.5008</b>	214500
U-Net	Korosi	<b>0.879</b>	<b>0.779</b>	<b>0.857</b>	1.2982	<b>91120</b>

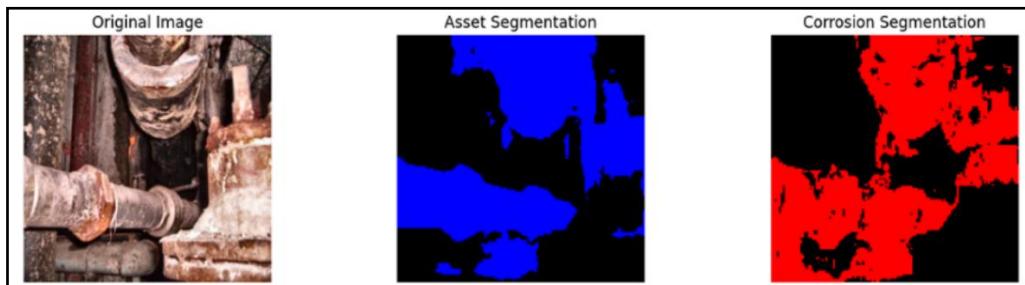
Hasil penilaian mengidentifikasi dua temuan utama yang menunjukkan kinerja kontras antara kedua model. Pada tugas segmentasi aset, DeepLabV3+ menunjukkan keunggulan kinerja yang sangat signifikan. Model ini melampaui U-Net dengan mIoU 0.862 berbanding 0.735, atau selisih ~17.3%. Keunggulan telak ini kemungkinan besar berasal dari backbone ResNet50 *pre-trained* yang digunakan oleh DeepLabV3+. Fitur-fitur yang dipelajari dari ImageNet memberikan pemahaman kontekstual yang lebih kaya tentang objek, yang membantu model mengidentifikasi struktur pipa (aset) secara lebih robust dan utuh.

Sebaliknya, situasinya berbalik pada tugas segmentasi pada korosi. U-Net menunjukkan kinerja yang sedikit lebih baik dengan mIoU 0.779 berbanding 0.701 dengan selisih 11.1%. Keunggulan tipis ini dapat diatribusikan pada kekuatan desain inti U-Net, yaitu skip-connections. Fitur ini sangat efektif dalam menggabungkan fitur spasial resolusi rendah dengan fitur resolusi tinggi, memungkinkan model merekonstruksi batas-batas area korosi yang bertekstur tidak teratur dengan presisi yang sedikit lebih baik.

Jika diposisikan dalam konteks *state-of-the-art* yang lebih luas, temuan ini menunjukkan kinerja yang relevan dan kompetitif. Keunggulan tipis U-Net pada segmentasi korosi dengan mIoU 0.779 sejalan dengan kekuatan U-Net dalam literatur untuk tugas presisi spasial tinggi, seperti ditunjukkan pada penelitian [8], [10], [11] untuk segmentasi objek berbatas kompleks. Hal ini mendukung temuan kami bahwa desain *skip-connections* U-Net efektif merekonstruksi detail batas korosi yang tidak teratur. Di sisi lain, superioritas signifikan DeepLabV3+ pada segmentasi aset dengan mIoU 0.862 menunjukkan kekuatan *backbone pre-trained* dalam memahami konteks gambar yang lebih luas, sebuah pendekatan yang konsisten dengan tren segmentasi area berskala besar seperti pada penelitian [9]. Dengan demikian, metrik yang dicapai dalam penelitian ini dapat dianggap sebagai *benchmark* yang solid untuk tugas spesifik segmentasi pipa korosi, menyoroti keunggulan DeepLabV3+ untuk konteks objek dan U-Net untuk lokalisasi detail.

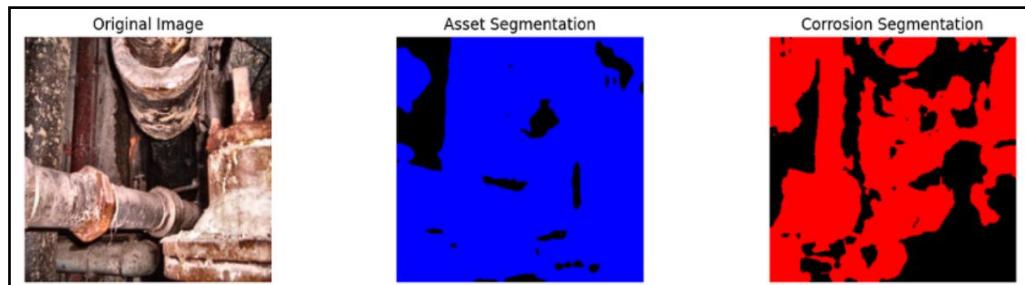
Selain akurasi, faktor efisiensi komputasi menjadi pembeda utama. Model U-Net membutuhkan waktu rata-rata sekitar 1.24 detik per gambar, sementara DeepLabV3+ secara signifikan lebih cepat dengan waktu inferensi rata-rata hanya 0.44 detik. Hal ini menjadikan DeepLabV3+ sekitar 2.8 kali lebih efisien. Temuan ini menarik karena U-Net memiliki parameter yang jauh lebih sedikit dengan jumlah 91.120 dibandingkan DeepLabV3+ yang memiliki 214.500 parameter. Kinerja yang kontra-intuitif ini disebabkan oleh arsitektur *backbone* ResNet50 pada DeepLabV3+ yang sangat teroptimasi untuk operasi GPU, sementara operasi *skip-connection* pada U-Net standar menimbulkan *overhead* komputasi.

Selanjutnya dilakukan interpretasi dengan Data Test. Untuk memudahkan interpretasi visual dan pembedaan antara segmentasi aset dan korosi, skema warna visualisasi *ground truth* diubah. *Mask* yang awalnya menggunakan format *binary* standar yaitu putih dan hitam, kini disesuaikan untuk mempermudah analisis. Pada hasil interpretasi ini, *mask* untuk korosi diberi warna merah dan *mask* untuk aset pipa diberi warna biru. Berikut merupakan gambar hasil interpretasi pada Gambar 8 dan 9.



Gambar 8. Hasil Interpretasi Segmentasi Pipa Korosi dengan U-Net

Gambar 8 menunjukkan hasil segmentasi U-Net, di mana mask aset berhasil menangkap struktur pipa utama meskipun ada beberapa area yang terlewat atau terputus. Segmentasi korosi mendekripsi sebagian besar area berkarat, menampilkan hasil yang menjanjikan, namun terlihat kurang presisi dan cenderung menyatu di beberapa bagian.



Gambar 9. Hasil Interpretasi Segmentasi Pipa Korosi dengan DeepLab V3+

Gambar 9 menunjukkan hasil DeepLabV3+, di mana segmentasi aset dengan warna biru berhasil mengidentifikasi struktur pipa utama dengan sangat baik, menghasilkan *mask* yang lebih utuh dan presisi. Segmentasi korosi warna merah juga tampak detail dan akurat dalam melokalisasi area berkarat, dengan batas-batas yang lebih tajam dan lebih sedikit *noise*.

Analisis komparatif ini mengungkapkan *trade-off* yang jelas: DeepLabV3+ terbukti superior dalam mengidentifikasi struktur aset secara utuh, sementara U-Net standar sedikit lebih presisi dalam melokalisasi korosi bertekstur tidak teratur. Namun, keunggulan tipis dari U-Net tersebut dikesampingkan oleh kinerjanya yang jauh lebih rendah pada segmentasi aset dan waktu inferensi yang jauh lebih lambat. Ketika semua faktor dievaluasi, DeepLabV3+ secara jelas menawarkan profil kinerja yang lebih seimbang dan praktis. Model ini berhasil menggabungkan akurasi identifikasi aset yang superior dengan efisiensi komputasi yang tinggi, menjadikannya pilihan yang lebih *robust* secara keseluruhan.

#### 4. Kesimpulan

Penelitian ini telah menganalisis secara komparatif arsitektur U-Net standar dan DeepLabV3+ dengan backbone ResNet50 untuk tugas segmentasi semantik pipa korosi. Tahap penilaian menunjukkan bahwa tidak ada satu model yang unggul di semua metrik, melainkan terdapat trade-off yang jelas. DeepLabV3+ terbukti secara signifikan lebih unggul dalam segmentasi aset dengan mIoU 0.862 dan secara drastis lebih efisien dengan waktu komputasi rata-rata sekitar 0.44 detik. Sementara itu, U-Net arsitektur standar menunjukkan keunggulan tipis dalam lokalisasi presisi untuk segmentasi korosi dengan mIoU 0.779, namun dengan waktu komputasi yang jauh lebih tinggi yaitu sekitar 1.24 detik. Berdasarkan temuan ini, DeepLabV3+ direkomendasikan sebagai arsitektur yang lebih superior secara keseluruhan. Model ini menawarkan keseimbangan terbaik antara akurasi segmentasi aset yang tinggi, akurasi korosi yang kompetitif, dan efisiensi inferensi yang sangat cepat. Hal ini menjadikannya pilihan yang lebih praktis dan robust untuk pengembangan sistem deteksi korosi di masa depan. Berdasarkan keterbatasan dalam penelitian ini, beberapa arah penelitian di masa depan dapat disarankan. Pertama, untuk penerapan praktis di industri, studi selanjutnya dapat menerapkan analisis *cost-benefit* yang menyeimbangkan kriteria *cost*, seperti komputasi dan *hardware*, dengan kriteria *benefit*, seperti metrik *confusion matrix* yang krusial, khususnya *precision*, *recall*, dan *F1-score*. Selanjutnya, disarankan melakukan perbandingan yang lebih seimbang dengan menguji U-Net yang juga menggunakan *backbone pre-trained*, contohnya ResNet50. Hal ini bertujuan untuk mengisolasi dampak murni dari desain *decoder*, yaitu perbandingan antara *skip-connections* U-Net dan modul ASPP DeepLabV3+. Terakhir, eksplorasi model segmentasi multi-kelas tunggal yang mencakup kelas Latar Belakang, Aset Pipa, dan Korosi, dapat dipertimbangkan untuk menyederhanakan alur kerja inferensi dan berpotensi meningkatkan kinerja model secara holistik.

#### Referensi

- [1] Hendrik, “Diduga Karena Korosi Pipa Minyak PT Pertamina EP Adera Field Kembali Bocor,” 2025. Accessed: Oct. 26, 2025. [Online]. Available: <https://linksumsel.com/diduga-karena-korosi-pipa-minyak-pt-pertamina-ep-adera-field-kembali-bocor/>
- [2] D. Fatmawaty, “Analisis Pertanggungjawaban Pencemaran Lingkungan Akibat Tumpahan Minyak (Studi Kasus: Kebocoran Pipa Minyak di Teluk Balikpapan),” *Bumi Lestari Journal of Environment*, vol. 20, no. 1, p. 14, Feb. 2020, doi: 10.24843/blje.2020.v20.i01.p03.
- [3] V. Tuninetti *et al.*, “Evaluating Pipeline Inspection Technologies for Enhanced Corrosion Detection in Mining Water Transport Systems,” *Applied Sciences*, vol. 15, no. 3, p. 1316, Jan. 2025, doi: 10.3390/app15031316.
- [4] I. B. M. Y. Wirawan, I. M. G. Sunarya, and I. M. D. Maysanjaya, “Semantic Segmentation of Rice Field Bund on Unmanned Aerial Vehicle Image using UNet,” in *2022 14th International Conference on Information Technology and Electrical Engineering (ICITEE)*, IEEE, Oct. 2022, pp. 211–216. doi: 10.1109/ICITEE56407.2022.9954091.
- [5] A. Sanjay Kumar, S. Manoj Kumar, and R. Kiran Kumar, “Optimized Deep Learning Framework for Detecting Pitting Corrosion based on Image Segmentation,” *International Journal of Performativity Engineering*, vol. 17, no. 7, p. 627, 2021, doi: 10.23940/ijpe.21.07.p7.627637.
- [6] R. Rokhana *et al.*, “Convolutional Neural Network untuk Pendekripsi Patah Tulang Femur pada Citra Ultrasonik B-Mode,” 2019.
- [7] I. K. H. T. Jaya, M. W. A. Kesiman, and I. M. G. Sunarya, “Detecting the Same Pattern in Choreography Balinese Dance Using Convolutional Neural Network and Analysis Suffix Tree,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 8, no. 3, p. 410, Oct. 2022, doi: 10.26555/jiteki.v8i3.24461.
- [8] I. M. Dendi Maysanjaya, K. Suwis, S. Atmaja, I. Made, and G. Sunarya, “Segmentasi Soft Exudate Pada Citra Fundus Retina Pasien Diabetic Retinopathy Berbasis U-NET,” *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 2, 2023.
- [9] N. P. K. Dewi, P. H. Suputra, A. A. G. Y. Paramartha, L. J. E. Dewi, P. Varnakovida, and K. Y. E. Aryanto, “River Area Segmentation Using Sentinel-1 SAR Imagery with Deep-Learning Approach,” *Geomatics and Environmental Engineering*, vol. 19, no. 4, pp. 39–63, Jul. 2025, doi: 10.7494/geom.2025.19.4.39.
- [10] I. Made, A. Darma Putra, M. Dendi Maysanjaya, M. Windu, and A. Kesiman, “Pendekatan Berbasis U-NET Untuk Segmentasi Hard Exudate Dalam Citra Fundus Retina,” *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 1, 2023.

- [11] P. Z. E. S. Nugraha, I. M. G. Sunarya, and I. M. D. Maysanjaya, "Binary Semantic Segmentation of Dolphin on UAV Image Using U-Net," in *2023 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, IEEE, Jul. 2023, pp. 728–733. doi: 10.1109/ISITIA59021.2023.10221152.
- [12] P. A. Widiantara, N. W. Marti, and P. H. Suputra, "Segmentasi Semantik Berbasis Deeplabv3+ Untuk Pemantauan Pencemaran Sampah di Perairan Sungai," *Jutisi : Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 2, p. 809, Aug. 2025, doi: 10.35889/jutisi.v14i2.2962.
- [13] H. J. G. Palacios, R. A. J. Toledo, G. A. H. Pantoja, and Á. A. M. Navarro, "A comparative between CRISP-DM and SEMMA through the construction of a MODIS repository for studies of land use and cover change," *Advances in Science, Technology and Engineering Systems*, vol. 2, no. 3, pp. 598–604, 2017, doi: 10.25046/aj020376.
- [14] I. M. A. Wirawan, R. Wardoyo, D. Lelono, and S. Kusrohmaniah, "Continuous Capsule Network Method for Improving Electroencephalogram-Based Emotion Recognition," *Emerging Science Journal*, vol. 7, no. 1, pp. 116–134, Feb. 2023, doi: 10.28991/ESJ-2023-07-01-09.