



**Analisis Pengaruh Inhibitor (Ampas  
Kopi dan Ekstrak Ampas Kopi) Terhadap  
Laju Korosi Besi Dengan Menggunakan  
Teknologi Citra Gambar**

**Tugas Akhir**

**Oleh:**

**Hari Mukti (4212201092)**

**Muhammad Ilyas (4212201020)**

**Muhammad Nasir (4212201084)**

**M Padli Sandi (4212201085)**

**Program Studi Teknik Mekatronika**

**Jurusan Teknik Elektro**

**Politeknik Negeri Batam**

**2025**

## Pernyataan Keaslian Tugas Akhir

Saya yang bertandatangan dibawah ini menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya yang berjudul : "Analisis Pengaruh Inhibitor (Ampas Kopi dan Ekstrak Ampas Kopi) Terhadap Laju Korosi Besi Dengan Menggunakan Teknologi Citra Gambar" adalah hasil karya sendiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan, dan bukan merupakan karya dari pihak lain yang saya akui sebagai karya sendiri. Semua referensi yang dikutip atau dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan saya ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Batam, 29 Juni 2026



---

Muhammad Ilyas  
NIM : 4212201020

Batam, 29 Juni 2026



---

M Padli Sardi  
NIM : 4212201085

Batam, 29 Juni 2026



---

Muhammad Nasir  
NIM : 4212201084

Batam, 29 Juni 2026



---

Hari Mukti  
NIM : 4212201092

# Lembar Pengesahan

**Tugas Akhir disusun untuk memenuhi salah satu syarat memperoleh gelar  
Sarjana Terapan Teknik (S.Tr.T)  
di  
Politeknik Negeri Batam**

Oleh:

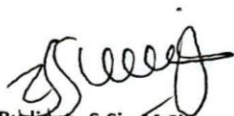
**Hari Mukti (4212201092)  
Muhammad Ilyas (4212201020)  
Muhammad Nasir (4212201084)  
M Padli Sandi (4212201085)**

**Tanggal Sidang: 28 Februari 2025**

Disetujui oleh:



**Diono, S.Tr.T., M.Sc.  
NIK: 120243**



**Budiana, S.Si., M.Si.  
NIK: 117194**



**Nadhras Wivanius S.Si., M.Si.  
NIK: 115141**

# Analisis Pengaruh Inhibitor (Ampas Kopi dan Ekstrak Ampas Kopi) Terhadap Laju Korosi Besi Dengan Menggunakan Teknologi Citra Gambar

## Abstrak

Bahan logam termasuk material yang sering dipakai pada era modern. Contohnya adalah besi S45C. Namun bahan tersebut memiliki kelemahan mudah mengalami korosi. Untuk mengatasi masalah ini, diperlukan inhibitor yang mampu menghambat laju korosi. Ampas kopi dapat menjadi inhibitor alami yang sangat ramah terhadap lingkungan. Riset ini melibatkan pembuatan alat yang berfungsi untuk pengambilan data sampel, diikuti dengan analisis kekuatan rangka alat tersebut. Hasil analisis *von mises* menunjukkan tegangan maksimum sebesar 9,775 MPa dan perpindahan total (*resultant displacement*) maksimum 0,081 cm, sementara nilai *equivalent strain* yang diperoleh sangat kecil, yaitu sekitar 0,000037. Penelitian ini menggunakan tiga model yaitu *SegNet*, *HRNet*, dan *U-Net* yang akan dibandingkan dalam mendeteksi pengaruh limbah ampas kopi terhadap laju korosi besi. Riset ini juga berfokus untuk meningkatkan sistem pendeteksi pengaruh limbah ampas kopi terhadap laju korosi dengan kecerdasan buatan. Riset ini berpotensi memberikan peran dalam meningkatkan teknologi inhibitor alami. Berdasarkan pengujian pada dataset citra korosi, model *U-Net* memberikan hasil paling akurat dengan rata-rata *IoU* sebesar 55,63% dan *Dice Coefficient* sebesar 69,51%. Hasil tersebut menunjukkan model dapat melakukan segmentasi gambar dengan baik.

Kata kunci: *Machine Learning*, *Inhibitor*, Korosi, Besi, *Image Processing*, *Convolutional Neural Network (CNN)*

# ***Analysis of the Effect of Inhibitors (Coffee grounds and Coffee grounds Extract) on the Corrosion Rate of Iron Using Image Technology***

## ***Abstract***

*Metal materials are among the most commonly used materials in the modern era. An example is S45C iron. However, this material has the disadvantage of being easily corroded. To overcome this problem, an inhibitor is needed that can inhibit the corrosion rate. Coffee grounds can be a natural inhibitor that is very friendly to the environment. This research involved the construction of a tool that serves for sample data collection, followed by an analysis of the strength of the tool frame. The von mises analysis showed a maximum stress of 9.775 MPa and a maximum resultant displacement of 0.081 cm, while the equivalent strain value obtained was very small, around 0.000037. This research utilizes three models namely SegNet, HRNet, and U-Net which will be compared in detecting the effect of coffee grounds waste on iron corrosion rate. This research also focuses on improving the detection system of the effect of coffee grounds waste on corrosion rate with artificial intelligence. This research has the potential to play a role in improving natural inhibitor technology. Based on testing on the corrosion image dataset, the U-Net model provides the most accurate results with an average IoU of 55.63% and Dice Coefficient of 69.51%. These results show that the model can segment the image well.*

*Keywords: Machine Learning, inhibitor, Corrosion, Iron, Image Processing, Convolutional Neural Network (CNN)*

## Kata Pengantar

Puji serta syukur kami panjatkan kepada Tuhan pencipta alam berkat kasih dan karunianya yang telah memberikan kelapangan dalam berfikir sehingga Laporan Tugas Akhir ini bisa kami selesaikan dengan judul "*Analisis Pengaruh Inhibitor (Ampas Kopi dan Ekstrak Ampas Kopi) Terhadap Laju Korosi Besi Dengan Menggunakan Teknologi Citra Gambar*".

Tugas akhir ini dilaksanakan menggunakan pendanaan dari Program Kreativitas Mahasiswa (PKM) pada tahun 2024. Tugas akhir disusun sebagai syarat untuk kelulusan di jurusan Teknik Elektro program studi D-IV Teknik Mekatronika Politeknik Negeri Batam. Di momen ini, kami ingin mengucapkan ribuan terimakasih atas segala dukungan maupun bantuan yang telah diberikan selama proses pengerjaan dan penyusunan tugas akhir ini, kepada:

1. Tuhan Yang Maha Esa atas semua kasih, nikmat dan karunia-Nya.
2. Orang tua dan keluarga yang telah mendoakan, memotivasi dan membantu penulis.
3. Kemendikbudristek, dan Dit. APTV yang telah memberikan dukungan pendanaan.
4. Politeknik Negeri Batam yang telah memfasilitasi selama Penelitian.

Batam, 28 Februari 2025



Muhammad Ilyas

Batam, 28 Februari 2025



M Padli Sandi

Batam, 28 Februari 2025



Muhammad Nasir

Batam, 28 Februari 2025



Hari Mukti

# Daftar Isi

Abstrak .....	iii
<i>Abstract</i> .....	iv
Kata Pengantar .....	v
Daftar Isi .....	vi
Daftar Gambar .....	viii
Daftar Tabel .....	ix
Bab 1. Pendahuluan .....	1
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah .....	1
1.3. Tujuan .....	2
1.4. Manfaat .....	2
1.5. Batasan .....	3
1.6. <i>Work Breakdown Structure</i> .....	3
Bab 2. Tinjauan Pustaka .....	4
2.1. Penelitian Terkait .....	4
2.1.1. Korosi .....	4
2.1.2. Inhibitor .....	6
2.1.3. <i>Image Processing</i> .....	7
2.2. Simulasi <i>Solidwork</i> .....	8
2.2.1. <i>SolidWorks</i> sebagai Perangkat Simulasi Teknik .....	8
2.2.2. Simulasi Struktural dalam Analisis Teknik .....	9
2.3. <i>Machine Learning</i> .....	9
2.4. <i>Deep Learning</i> .....	10
2.5. <i>Convolution Neural Network (CNN)</i> .....	10
2.5.1. <i>Convolution Layer</i> .....	11
2.5.2. <i>Pooling Layer</i> .....	12
2.5.3. <i>Fully Connected Layer</i> .....	12
2.6. <i>U-Net</i> .....	13
2.7. <i>High-Resolution Network (HRNet)</i> .....	14
2.8. <i>Segmented Neural Network (SegNet)</i> .....	14
Bab 3. Metode Riset .....	16
3.1. Perancangan .....	16
3.1.1. Perancangan Penelitian .....	16
3.1.2. Perancangan Mekanikal .....	16
3.1.3. Perancangan Sistem .....	19
3.2. Alat dan Bahan .....	22
3.3. Pengujian .....	22
3.3.1. Pengujian Perancangan Sistem .....	23

3.3.2. Pengujian Sistem Dengan Model <i>SegNet</i> .....	25
3.3.3. Pengujian Sistem Dengan Model <i>HRNet</i> .....	25
3.3.4. Pengujian Sistem Dengan Model <i>U-Net</i> .....	26
Bab 4. Hasil dan Pembahasan .....	27
4.1. Proses Alur Kerja Sistem .....	27
4.2. Hasil Pengujian .....	28
4.2.1. Hasil Pengujian Perancangan Sistem .....	28
4.2.2. Hasil Pengujian Model <i>Segnet</i> .....	30
4.2.3. Hasil Pengujian Model <i>HRNet</i> .....	34
4.2.4. Hasil Pengujian Model <i>U-Net</i> .....	39
4.3. Pembahasan .....	43
Bab 5. Kesimpulan dan Saran .....	47
5.1. Kesimpulan .....	47
5.2. Saran .....	48
Daftar Pustaka .....	49
Lampiran .....	53

## Daftar Gambar

Gambar 1. Ilustrasi <i>Deep Learning</i> [20] .....	10
Gambar 2. Proses <i>Convolution Neural Network</i> [22].....	11
Gambar 3. Contoh Operasi Konvolusi [24] .....	11
Gambar 4. <i>Polling</i> dengan <i>Max-Pool</i> [23].....	12
Gambar 5. Arsitektur <i>U-Net</i> [26] .....	13
Gambar 6. Arsitektur <i>HRNet</i> [28] .....	14
Gambar 7. Arsitektur <i>SegNet</i> [30] .....	15
Gambar 8. <i>Flowchart</i> Perancangan Penelitian .....	16
Gambar 9. <i>Flowchart</i> Perancangan Mekanikal.....	17
Gambar 10. Model 3D Desain .....	17
Gambar 11. Desain Rangka .....	18
Gambar 12. Diagram Alir Perancangan Sistem.....	19
Gambar 13. Tahapan Pra-Proses Data.....	20
Gambar 14. Tahapan Augmentasi Data.....	20
Gambar 15. Tahapan Evaluasi .....	21
Gambar 16. <i>Upload</i> dan <i>preprocessing data</i> .....	27
Gambar 17. Simulasi <i>Von Mises</i> .....	28
Gambar 18. Simulasi <i>Resultant Displacement</i> .....	29
Gambar 19. Simulasi <i>Equivalent Strain</i> .....	29
Gambar 20. <i>Model Summary</i> Arsitektur <i>SegNet Basic</i> .....	30
Gambar 21. Grafik Pelatihan Arsitektur <i>SegNet Basic</i> .....	33
Gambar 22. Hasil Pengujian Arsitektur <i>SegNet Basic</i> Pada Sampel .....	33
Gambar 23. <i>Model Summary</i> Arsitektur <i>HRNetV2-W48</i> .....	35
Gambar 24. Grafik Pelatihan Arsitektur <i>HRNetV2-W48</i> .....	37
Gambar 25. Hasil Pengujian Arsitektur <i>HRNetV2-W48</i> Pada Sampel.....	38
Gambar 26. <i>Model Summary</i> Arsitektur <i>U-Net</i> .....	39
Gambar 27. Grafik Pelatihan Arsitektur <i>U-Net</i> .....	42
Gambar 28. Hasil Pengujian Arsitektur <i>U-Net</i> Pada Sampel.....	42
Gambar 29. Grafik <i>IoU</i> dan <i>Dice Coefficient</i> model <i>SegNet</i> .....	43
Gambar 30. Grafik <i>IoU</i> dan <i>Dice Coefficient</i> model <i>HRNetV2-W48</i> .....	44
Gambar 31. Grafik <i>IoU</i> dan <i>Dice Coefficient</i> model <i>U-Net</i> .....	44
Gambar 32. Grafik perbandingan <i>Mean IoU</i> pada model .....	45
Gambar 33. Grafik perbandingan <i>Mean Dice Coefficient</i> pada model .....	46
Gambar 34. Hasil Analisa plagiarisme (9%) .....	53

## Daftar Tabel

Tabel 1. <i>Work Breakdown Structure</i> .....	3
Tabel 2. Penelitian Mengenai Korosi Pada Material Logam .....	4
Tabel 3. Penelitian Mengenai Inhibitor .....	6
Tabel 4. Penelitian Teknologi Citra Gambar sebagai Identifikasi Korosi.....	7
Tabel 5. Layout Pengujian Metrik Evaluasi .....	23
Tabel 6. Beban Statis .....	24
Tabel 7. Contoh dan Jumlah Citra.....	27
Tabel 8. <i>Hyperparameter Training</i> .....	28
Tabel 9. Hasil Pelatihan Arsitektur <i>SegNet Basic</i> .....	31
Tabel 10. Hasil Pelatihan Arsitektur <i>HRNetV2-W48</i> .....	35
Tabel 11. Hasil Pelatihan Arsitektur <i>U-Net</i> .....	40
Tabel 12. Hasil Metrik Evaluasi .....	45

# Bab 1. Pendahuluan

## 1.1. Latar Belakang

Indonesia merupakan salah satu diantara negara yang beriklim tropis serta memiliki banyak pulau yang dipisahkan oleh lautan. Oleh karena itu wilayah Indonesia memiliki tingkat curah hujan dan kelembapan yang cukup tinggi. Sebagai negara yang mendukung perkembangan, terdapat banyak sekali industri yang dapat berpengaruh terhadap kondisi lingkungan. Material seperti logam memiliki ikatan erat dengan fenomena alam dari segi sistem dan proses, ikatan yang dimaksud ialah proses kerusakan atau yang lebih dikenal dengan karat [1].

Karat merupakan suatu proses alami pada logam yang diakibatkan karena adanya reaksi kimia antara logam dengan zat-zat korosif yang ada pada lingkungan sekitarnya. Peristiwa korosi muncul ketika logam berinteraksi secara langsung dengan air ataupun udara [2]. Material logam sering dipakai sebagai bahan peralatan dalam suatu industri. Ketika terjadinya proses korosi, permukaan logam akan mengalami kerusakan secara perlahan dan terlepas dari logam utama sehingga mempengaruhi kinerja dan kualitas dari peralatan tersebut. Korosi tidak dapat dicegah atau dihentikan, tetapi dapat dikendalikan dengan menghambat laju dari proses korosi tersebut dengan menggunakan zat yang disebut dengan inhibitor [3].

## 1.2. Rumusan Masalah

Riset ini berfokus untuk mengembangkan sistem pendeteksi pengaruh limbah ampas kopi pada laju korosi besi. Dalam upaya mencapai hal ini, tiga model pengolahan citra gambar, yaitu *U-Net*, *HRNet* dan *SegNet* dibandingkan untuk menentukan metode yang memberikan hasil terbaik.

Kajian-kajian mengenai penggunaan teknologi pengolahan citra gambar dengan topik korosi telah dilakukan diantaranya adalah mencari tingkat karat pada insulator menggunakan metode *decision tree* [4], dan menerapkan metode *image processing* untuk mengecek hasil pelapisan pada lambung kapal [5]. Kajian-kajian yang telah dilakukan telah melakukan elaborasi terhadap penggunaan teknologi citra gambar. Namun, kajian yang telah dilakukan belum optimal untuk pengembangan penggunaan teknologi citra gambar dalam melakukan identifikasi proses korosi pada medium yang berbeda.

Penelitian korosi yang lain adalah penelitian yang mempelajari penggunaan inhibitor alami sebagai penghambat laju korosi. Contoh inhibitor yang dapat

digunakan adalah ekstrak ampas kopi dan larutannya. Terdapat beberapa penelitian yang mempelajari korosi dengan menggunakan kopi seperti pemanfaatan inhibitor alami dari ekstrak kafein pada ampas kopi [6], dan identifikasi pengaruh jumlah ekstrak ampas kopi terhadap laju korosi pada logam [7]. Berdasarkan penelitian yang dilakukan, ekstrak ampas dapat memperlambat laju korosi. Penelitian yang dilakukan belum melakukan optimalisasi kajian atas komparasi ampas kopi sebagai inhibitor dengan ekstrak ampas kopi sebagai inhibitor. Sehingga komparasi dua variabel ini sangat berpotensi untuk dikembangkan pada penelitian ini. Selanjutnya, melalui pendekatan kecerdasan buatan, sistem akan dilatih untuk mengenali dan memproses data citra korosi yang diperoleh dari *action cam*. Metode *U-Net*, *HRNet* dan *SegNet* akan digunakan sebagai algoritma klasifikasi dalam riset ini.

Melalui perbandingan antara *U-Net*, *HRNet* dan *SegNet*, penelitian ini memiliki tujuan untuk menentukan metode mana yang memiliki akurasi terbaik dalam mendeteksi korosi pada besi. Dengan mengimplementasikan ketiga metode tersebut, tahapan seperti *preprocessing*, ekstraksi fitur, *training*, dan *testing* akan dilakukan untuk mengevaluasi dan membandingkan performa keduanya.

Dengan mengembangkan sistem pendeteksi pengaruh limbah ampas kopi terhadap laju korosi besi dan melibatkan kecerdasan buatan, diharapkan penelitian ini dapat berperan dalam mengembangkan teknologi inhibitor alami. Hasil dari perbandingan antara *U-Net*, *HRNet* dan *SegNet* diharapkan akan memberikan wawasan yang berharga untuk menentukan metode yang paling efektif dan akurat dalam mengenali korosi serta meningkatkan pengetahuan tentang bahan inhibitor korosi pada besi yang alami.

### 1.3. Tujuan

Riset ini bertujuan untuk mengetahui pengaruh limbah ampas kopi terhadap laju korosi besi menggunakan metode *U-Net*, *HRNet* dan *SegNet*.

### 1.4. Manfaat

Riset ini memiliki manfaat yang signifikan dalam mengatasi masalah korosi pada besi. Beberapa manfaat dari riset ini antara lain:

1. Memanfaatkan limbah ampas kopi sebagai zat inhibitor korosi alami dan ramah lingkungan.
2. Menggunakan metode *U-Net*, *HRNet* dan *SegNet* untuk mengidentifikasi dan mengklasifikasi tingkat korosi pada besi, yang dapat membantu dalam mengetahui tingkat korosi yang lebih akurat dan efisien.

3. Mengembangkan bahan penghambat korosi alami yang lebih efektif dan ramah lingkungan, yang dapat mengurangi penggunaan bahan kimia berbahaya dalam penghambat korosi.

## 1.5. Batasan

Pada penelitian ini terdapat beberapa batasan masalah, antara lain adalah:

1. Proses akuisisi citra baik saat proses *training* maupun *testing* tidak dilakukan secara *real time*.
2. Akuisisi citra korosi berupa objek 2 dimensi.
3. Kondisi cahaya terang saat akuisisi citra korosi dengan nilai intensitas cahaya ruangan yaitu 75-300 *lux*, dan proses penyebaran cahaya tidak merata.

## 1.6. Work Breakdown Structure

Tabel 1. Work Breakdown Structure

No	Nama	Tugas dan Tanggung Jawab dalam Tim
1	Hari Mukti	Mekanikal
2	Muhammad Ilyas	Metode <i>SegNet</i>
3	Muhammad Nasir	Metode <i>HRNetV2-W48</i>
4	M Padli Sandi	Metode <i>U-Net</i>

## Bab 2. Tinjauan Pustaka

### 2.1. Penelitian Terkait

#### 2.1.1. Korosi

Korosi ialah suatu proses yang dapat merusak suatu logam karena adanya reaksi kimia atau elektrokimia yang berada pada lingkungan sekitarnya. Proses korosi tidak dapat kita cegah, Namun kita bisa menghambatnya. Banyak cara yang telah dilakukan untuk menghambat laju korosi. Zat inhibitor salah satu zat yang digunakan untuk menghambat korosi [8].

**Tabel 2. Penelitian Mengenai Korosi Pada Material Logam**

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
1	Affandi, et al. [9]	Proses Terjadinya Korosi Pada Material Baja Karbon Rendah Dan Dilakukan Di kecamatan Medan Belawan	Hasil yang di dapat ialah, pengukuran tingkat korosi atmosfer pada 3 daerah dengan rata-rata 0,573 mpy untuk daerah A, 0,604 mpy untuk daerah B, dan 0,358 mpy di daerah C. Kekurangannya yaitu diperlukan adanya penelitian lebih lanjut untuk mengukur laju korosi yang lebih lama, dan wilayah yang lebih luas agar dapat dilakukan pemetaan tingkat korosi atmosferik.

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
2	Miranda dan Rahmawati.[8]	Tentang tingkat korosi Pada bahan Logam dengan Penerapan <i>Dip-Coating</i>	Laju proses korosi pada material logam akan tinggi apabila terjadi nya perendaman material tanpa menggunakan metode <i>dip-coating electrolyte</i> ini. Dari penelitian tersebut dapat diketahui bahwa nilai laju korosi semakin tinggi maka material akan mudah rusak. Kekurangannya yaitu tidak adanya hasil nilai penghambat laju korosi yang jelas.
3	Yeni Stiadi, et al. [10]	Menghambat Korosi Pada Baja Ringan Dengan Media Asam Klorida	Terdapat banyak senyawa organik yang memiliki potensi untuk memperlambat laju korosi pada baja. Senyawa yang mengandung unsur N, S dan O pada struktur kerangkanya lebih baik dalam memperlambat proses laju korosi. Adapun kekurangannya yaitu tidak adanya nilai hasil korosi yang terdapat pada objeknya/sampel, hanya terdapat beberapa senyawa yang bisa dipakai sebagai inhibitor.

### 2.1.2. Inhibitor

Inhibitor merupakan suatu zat yang dimana jika diimplementasikan pada suatu lingkungan korosif maka akan memperlambat pertumbuhan laju korosi. Terdapat beberapa jenis zat inhibitor salah satunya adalah inhibitor organik. Inhibitor organik merupakan senyawa organik yang mampu memperlambat proses korosi yang tidak dikategorikan sebagai katodik dan anodik [6].

**Tabel 3. Penelitian Mengenai Inhibitor**

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
1	Farha az zahra, et al.[6]	Penggunaan Ekstrak Kafein Ampas Kopi Sebagai Bahan Inhibitor(penghambat korosi) Alami Pada Baja Murni Dengan Media $H_2SO_4$	Tingkat efisiensi dari penggunaan inhibitor tersebut adalah 30,407%. Dengan menggunakan media $H_2SO_4$ 3% dalam 2 hari perendaman. Adapun kekurangannya adalah diperlukannya penelitian lanjutan dan mempertimbangkan faktor eksternal yang mempengaruhi laju korosi
2	Yanty Maryanty, et al.[11]	Efisiensi inhibitor pada Baja dengan Media Larutan Asam Sulfat Dan Biosolar	Kopi ialah inhibitor terbaik dengan efisiensi 80% dalam perendaman $H_2SO_4$ 12% pada baja, dengan nilai ppm yaitu 2100,793 ppm dan tingkat laju korosinya pada hari pertama yaitu $84,7 \times 10^{-4} g/cm^2$ , setelah 10 hari sebesar $75,5 \times 10^{-4} g/cm^2$ . Kekurangannya yaitu minimnya informasi

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
			hasil nilai inhibisi laju korosi dan diperlukan penelitian lanjutan yang pengukurannya bulanan.
3	Desi Afrilia , et al. [7]	Ekstrak Kopi Sebagai Inhibitor terhadap Laju Korosi pada Baja	Diperoleh efisiensi inhibitor ekstrak kopi yaitu 6,06%. Adapun kekurangannya adalah hasil nilai inhibisi laju korosi diperoleh hanya dengan metode berat, sehingga nilai yang dihasilkan belum maksimal dan akurat.

### 2.1.3. Image Processing

*Image Processing* merupakan teknik mengubah citra yang ditransformasikan menjadi citra lain agar hasilnya memiliki kualitas yang lebih bagus. Pengolahan citra berperan penting dalam memperbaiki kualitas citra supaya menjadi mudah ketika manusia dan mesin dalam menginterpretasinya [12]. Seiring dengan perkembangan zaman, teknik pengolahan citra semakin banyak digunakan dalam melakukan penelitian karena dapat membantu dalam mengolah data secara efisien dan akurat.

**Tabel 4. Penelitian Teknologi Citra Gambar sebagai Identifikasi Korosi**

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
1	Rinaldi Munir. [12]	Pengantar Pengolahan Citra	Kualitas citra dapat diperbaiki dengan teknik memanipulasi parameter-parameter citra. Parameter-parameter tersebut yaitu resolusi dan warna.

No	Nama Penulis	Topik Penelitian	Hasil Yang Diperoleh
2	Danita Wardani, et al.[5]	Karakterisasi Hasil Pelapisan Lambung Kapal dengan Image Processing	Pengujian menampilkan data yang diperoleh bahwasanya ia mampu mengenali kondisi yang dimana perlu atau tidak perlunya pengecatan ulang. Adapaun kekurangannya adalah hanya menampilkan hasil bagus tidaknya suatu permukaan, dan tidak ada hasil yang menjelaskan mengenai tingkat korosi pada permukaan lambung kapal.
3	Muhammad Alfitrah Chakra Wardana, et al.[4]	Analisa Tingkat Korosi dengan Metode Decision Tree	Hasil yang didapatkan adalah sistem dapat mengenali derajat kerusakan yang diakibatkan oleh korosi pada isolator dalam kategori rendah, sedang, dan tinggi, sesuai dengan rentang rasio yang telah diperoleh dari halaman pelatihan sebelumnya. Adapun kekurangannya adalah, tidak menampilkan hasil dari pengolahan citra yang jelas melainkan hanya menunjukkan tingkat korosi pada insulator.

## 2.2. Simulasi *Solidwork*

### 2.2.1. *SolidWorks* sebagai Perangkat Simulasi Teknik

*SolidWorks* merupakan perangkat lunak berbasis *Computer-Aided Design (CAD)* yang banyak digunakan dalam berbagai bidang teknik untuk pemodelan tiga dimensi dan simulasi [13]. *SolidWorks* memiliki berbagai modul simulasi yang dapat digunakan untuk analisis teknik, seperti *SolidWorks Flow Simulation* untuk memodelkan aliran fluida dan perpindahan panas [14]. Dan *SolidWorks Simulation* untuk menganalisis kekuatan struktur dan tegangan mekanis [15].

### 2.2.2. Simulasi Struktural dalam Analisis Teknik

Simulasi struktural digunakan untuk mengevaluasi kekuatan suatu komponen terhadap beban eksternal. Dengan mengaplikasikan metode *Finite Element Method (FEM)*, *SolidWorks* dapat memprediksi distribusi tegangan, regangan, dan deformasi suatu struktur dengan akurasi tinggi. Penelitian yang dilakukan oleh Pratama membuktikan bahwa *FEM* dalam perangkat lunak *SolidWorks 2020* dapat digunakan untuk menganalisis distribusi tegangan pada alat uji bending pipa dalam skala laboratorium. Dalam penelitian tersebut, variasi pembebanan sebesar 700 N, 500 N, dan 100 N menunjukkan hasil yang sangat mendekati data eksperimen. Hal ini menegaskan bahwa pendekatan berbasis *FEM* mampu memberikan prediksi yang cukup akurat, sehingga dapat diandalkan dalam perhitungan tegangan pada berbagai struktur mekanis [16].

Salah satu aplikasi dari simulasi ini adalah analisis kekokohan rangka dari alat pemberi pakan ikan secara otomatis. Penggunaan *FEM* dilakukan untuk menilai ketahanan rangka terhadap beban operasional dan berat pakan. Hasil simulasi menunjukkan tegangan *von Mises* terbesar sebesar 5,04 MPa pada *horizontal frame 4*, deformasi total maksimum sebesar 0,01 mm pada *linear actuator support*, serta faktor keamanan minimum sebesar 62,5. Dengan demikian, rangka mesin dinyatakan cukup kuat untuk menahan beban yang terjadi, menunjukkan efektivitas metode *FEM* dalam mengevaluasi kekuatan struktur [17].

### 2.3. Machine Learning


*Machine learning* merupakan cabang kecerdasan buatan yang dimana ia bisa belajar dan mendapatkan solusi yang optimal dengan cara pengenalan pola. Dengan *machine learning* komputer mampu menemukan solusi data yang optimal secara otomatis. *Machine Learning* juga dapat dianggap sebagai salah satu aplikasi atau struktur algoritma matematika yang dimana ia dapat mempelajari suatu data serta dapat memprediksi berdasarkan data tersebut. Adapun hasil dari prediksi tersebut nantinya dapat dipakai untuk menentukan *output* dari data *input*. Terdapat 3 jenis *Machine Learning* yaitu *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning* [18].

*Supervised Learning* merupakan teknik pengelompokan menggunakan banyak data dimana data tersebut akan diberi label atau tanda untuk mengelompokkan kelas yang tidak dikenal. *Machine* akan mempelajari ciri atau *feature* khusus pada setiap label sehingga *machine* mampu membuat model matematisnya. Sedangkan *Unsupervised Learning* merupakan metode yang tidak akan diberikan label khusus terlebih dahulu pada objek atau sering disebut juga dengan *cluster*. Sehingga *machine* tidak akan melakukan pembelajaran dari *feature-feature* khusus objek dan hasilnya *machine* tidak dapat mengidentifikasi kelas yang ditentukan. *Reinforcement Learning* biasanya letak keberadaannya terdapat di antara *Supervised Learning* dan *Unsupervised Learning*, di mana jenis ini mempelajari

sistem pengambilan keputusan oleh *machine* setelah melakukan latihan pada data yang diberikan [19].

## 2.4. Deep Learning

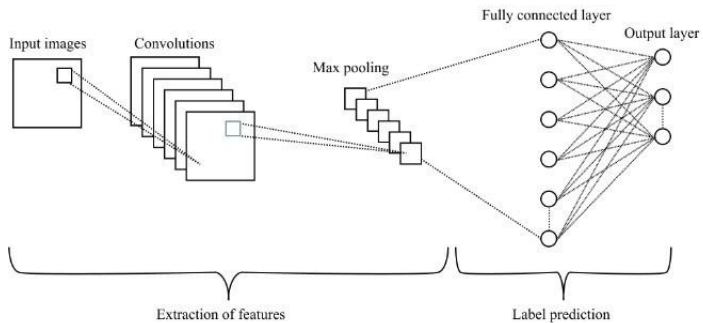
*Deep Learning* dapat didefinisikan sebagai jaringan syaraf tiruan yang terdiri dari berbagai lapisan, di mana setiap lapisan terdiri dari sejumlah *node*. *Node* memiliki fungsi sebagai tempat perhitungan. Tahapannya, *node input* yang masuk dikombinasikan dengan bobot (*weight*), kemudian hasilnya akan melewati tahap yang disebut fungsi *activation node*. Fungsi *activation node* akan menentukan sejauh mana sinyal dapat diteruskan ke jaringan berikutnya, sehingga akan mempengaruhi hasil akhirnya [20].



Gambar 1. Ilustrasi *Deep Learning* [20]

## 2.5. Convolution Neural Network (CNN)

*Convolution Neural Network (CNN)* adalah perluasan dari arsitektur *Multilayer Perceptron (MLP)* yang dikembangkan khusus agar dapat memproses suatu data dalam bentuk dua dimensi. Algoritma *CNN* banyak digunakan untuk mengolah gambar karena *CNN* dapat mengekstrak fitur-fitur pada gambar dengan cara *otomatis* melalui lapisan konvolusi, sehingga metode ini sangat cocok serta efektif untuk pengerjaan seperti mengklasifikasi, deteksi objek, dan segmentasi gambar. Karena memiliki struktur jaringan yang mendalam, *CNN* dikategorikan sebagai bagian dari *Deep Neural Network* dan sering diimplementasikan dalam pengolahan citra. Sebelum dikenal dengan nama *CNN*, konsep awal dari algoritma ini pertama kali dipopulerkan dengan nama *NeoCognitron* oleh peneliti asal Jepang yaitu Kunihiko Fukushima dari *NHK Broadcasting Science Research Laboratories* yang berbasis di Kinuta, Setagaya, Tokyo, Jepang [21].




**Gambar 2. Proses Convolution Neural Network [22]**

Gambar 2 menampilkan *Convolution layer*, *pooling layer*, dan *fully connected layer* yang merupakan lapisan pada arsitektur CNN pada umumnya. Namun, ada juga arsitektur yang menggunakan *ReLU layer* sebagai tambahan.

### 2.5.1. Convolution Layer

Lapisan konvolusi adalah *neuron* yang diatur sedemikian rupa, maka dari itu terbentuklah suatu filter dengan ukuran panjang dan tinggi (piksel). Adapun proses konvolusi mengimplementasikan *kernel* dan *stride*, prosedur ini merupakan kombinasi dari dua matriks berbeda agar menghasilkan matriks dengan nilai yang sudah diperbarui. Pada proses pengolahan citra, tahapan konvolusi bertujuan untuk menerapkan sebuah *kernel* (kotak hijau) pada bagian citra yang berada di semua *offset* yang bisa dilakukan, contohnya ditunjukkan oleh gambar 3 dibawah ini[23].



**Gambar 3. Contoh Operasi Konvolusi [24]**


Gambar kiri adalah contoh *kernel* yang akan diterapkan proses konvolusi. *Kernel* diproses pertama dari kolom satu baris satu hingga kolom terakhir dan baris akhir. Hasil konvolusi dari gambar 3 dapat dilihat dari gambar di sebelah kanan. Hasil dari proses konvolusi dapat kita hitung dengan menggunakan persamaan (1) berikut.

$$c_{i,j} = \left( \sum_{u=0}^{n-1} \sum_{v=0}^{n-1} a_{u+i,v+j} \times k_{i+1,j+1} \right) + b_q \quad (1)$$

Dengan keterangan  $i$  adalah baris,  $j$  merupakan kolom *output matriks*,  $n$  merupakan ukuran tinggi *kernel*,  $c_{i,j}$  adalah matriks *input*,  $k_{i,j}$  merupakan matriks *kernel*, dan  $b_q$  adalah bias yang digunakan *kernel* ke- $q$  [25].

### 2.5.2. Pooling Layer

*Pooling layer* adalah lapisan dalam arsitektur *CNN* yang digunakan untuk memangkas ukuran dimensi spasial dari peta fitur keluaran yang terdapat pada lapisan konvolusi sebelumnya. Jaringan *pooling* dijalankan pada setiap lapisan *feature map* serta bertugas untuk melakukan pemangkasan dimensinya. Adapun bentuk umum dari lapisan *pooling* biasanya memakai *filter* dengan ukuran  $2 \times 2$ . Filter ini akan diimplementasikan dengan tahap sebanyak dua langkah serta dilakukan pada setiap irisan dari *input* nya [23].



Gambar 4. Polling dengan Max-Pool [23]

Gambar 4 merupakan salah satu contoh dari *max pooling* dengan *filter*  $2 \times 2$ . Adapun kotak-kotak berwarna merah, kuning, biru serta hijau yang berada pada *kernel* sebelah kiri adalah sekelompok kotak yang akan ditargetkan nilai maksimumnya. Oleh karena itu *output* dari proses *pooling* bisa kita lihat pada kotak disebelah kanan.


### 2.5.3. Fully Connected Layer

*Fully connected layer* biasa disebut juga dengan *dense layer*, merupakan jaringan-jaringan dari semua lapisan *neuron* aktivitas sebelumnya yang terkoneksi dengan sistem pada lapisan selanjutnya. dimana jaringan ini membentuk sel syaraf tiruan seperti pada manusia [23]. Proses ini bertujuan untuk menghubungkan

representasi fitur yang diekstraksi oleh lapisan konvolusi dan *pooling* ke lapisan keluaran, terutama untuk tugas klasifikasi.

## 2.6. U-Net

*U-Net* adalah salah satu dari beberapa arsitektur *Convolutional Neural Network (CNN)* yang dimana ia dibuat khusus untuk pengerjaan segmentasi gambar. Arsitektur *U-Net* tersusun dari dua bagian utama yaitu **encoder** dan **decoder** dimana arsitektur ini memiliki bentuk seperti huruf “U”. **encoder** berperan untuk mengambil informasi fitur citra dari data *input* serta melakukan pemiminalisiran dimensi pada bentuk citra *input*, adapun jalur **decoder** berfungsi untuk mengambil informasi fitur dari hasil **encoder** serta digunakan untuk *output* segmentasi gambar [25].




Gambar 5. Arsitektur *U-Net* [26]

Gambar 5 merupakan contoh bentuk arsitektur berbasis *U-Net* yang dimana ia tersusun dari 2 jalur yaitu jalur **encoder** yang berada sebelah kiri serta jalur **decoder** yang berada di sebelah kanan. Pada bagian **encoder** dimulai dengan melakukan *double conv 3x3* dan menggunakan fungsi aktivasi *ReLU*, setelah itu dilanjutkan dengan melakukan *maxpooling* yang berukuran *2x2*. Setelah itu dilanjutkan sampai blok kelima yang berfungsi untuk menghubungkan jalur **encoder** dan **decoder**. Selanjutnya jalur **decoder** dimulai dengan proses *upsampling 2x2*, dan diteruskan dengan melakukan proses seperti blok pertama tanpa melakukan *max pooling*. Adapun tahapan terakhir pada jalur ini adalah melakukan *convolution layer 1x1* serta fungsi aktivasi *sigmoid* yang dipakai untuk memberikan output yang tersegmentasi.

## 2.7. High-Resolution Network (HRNet)

*High-Resolution Network (HRNet)* adalah arsitektur jaringan saraf *convolutional* yang dirancang untuk mempertahankan representasi resolusi tinggi sepanjang seluruh proses ekstraksi fitur. Berbeda dengan arsitektur konvensional yang mengurangi resolusi secara bertahap melalui lapisan *pooling* atau *convolutional stride*, *HRNet* mempertahankan resolusi tinggi dengan menghubungkan beberapa sub-jaringan yang beroperasi pada resolusi berbeda secara paralel. Setiap sub-jaringan bertukar informasi dengan yang lain, sehingga detail spasial yang penting tidak hilang selama proses ekstraksi fitur. *HRNet* sangat efektif untuk tugas-tugas *computer vision* yang memerlukan presisi spasial tinggi, seperti *pose estimation*, segmentasi semantik, dan deteksi objek [27].




Gambar 6. Arsitektur *HRNet* [28]

Gambar 6 merupakan contoh arsitektur *HRNet* yang dimulai dengan menginisiasi *conv 3x3* dengan *BatchNorm* dan *ReLU* yang ditunjukkan oleh blok kuning. Kemudian dilanjutkan dengan *BottleNeck Block* yang ditunjukkan oleh blok hijau. Setelah itu dilanjutkan dengan *csAG Block* yang ditunjukkan oleh blok ungu. Langkah selanjutnya *csAG Fusion* yang ditunjukkan oleh blok biru. Kemudian tahap akhir transpose menggunakan filter 3x3.

## 2.8. Segmented Neural Network (SegNet)

*Segmented Neural Network (SegNet)* merupakan salah satu arsitektur lapisan saraf konvolusional (*CNN*) yang dimana ia dibuat untuk segmentasi gambar. Dalam konteks analisis korosi, *SegNet* digunakan untuk mendeteksi dan mengidentifikasi area korosi pada permukaan logam dengan membedakan piksel yang mengalami korosi dan yang tidak. Arsitektur ini memanfaatkan proses *encoder* dan *decoder*

untuk menghasilkan peta segmentasi yang presisi. Dengan kemampuannya melakukan segmentasi pada level piksel. *SegNet* menjadi alat yang andal dalam memantau dan mengevaluasi kerusakan akibat korosi secara otomatis [29].



**Gambar 7. Arsitektur SegNet [30]**

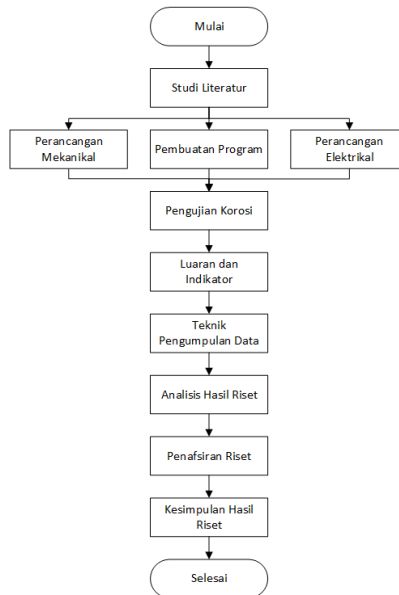
Gambar 7 merupakan contoh arsitektur *SegNet* yang tersusun dari 2 bagian penting yaitu **encoder** dan **decoder** yang kemudian dilanjutkan *Softmax Layer* sebagai hasil akhir. Bagian **encoder** berisi 2 blok yaitu blok biru dan hijau, blok biru berisi lapisan dengan *Conv + BatchNorm + Relu* yang bertujuan untuk mengekstrak fitur dari input, sedangkan blok hijau berisi lapisan *pooling* yang bertujuan untuk mereduksi ukuran input. Bagian **decoder** berisi 2 blok yaitu blok merah dan blok biru, blok merah berisi lapisan *upsampling* dengan menggunakan teknik *max-unpooling*. Setelah itu sama seperti blok biru pada **encoder** namun pada **decoder** blok biru berfungsi untuk memperhalus hasil konstruksi.

## Bab 3. Metode Riset

### 3.1. Perancangan

#### 3.1.1. Perancangan Penelitian

Perancangan penelitian ini dijelaskan secara sistematis dalam bentuk *flowchart*, yang tertampil pada Gambar 8. *flowchart* tersebut menggambarkan tahapan-tahapan utama dalam proses penelitian ini, mulai dari perencanaan awal hingga analisis hasil yang diperoleh.




Gambar 8. *Flowchart* Perancangan Penelitian

#### 3.1.2. Perancangan Mekanikal

Perancangan mekanikal ini bertujuan untuk membuat desain 3D model alat yang diharapkan dapat bekerja dengan baik karena struktur rangka yang kuat, untuk mendapatkan struktur rangka yang kuat di butuhkan proses analisis kekuatan rangka. Analisis ini dilakukan menggunakan *software solidwork 2022* untuk mendapatkan hasil berupa kekuatan struktur rangka terhadap tegangan (*von mises*), regangan maksimal (*equivalent strain*), perpindahan total (*resultant*


*displacement*) akibat pemberian beban. Detail mengenai alur analisis dijelaskan dalam bentuk *flowchart* yang tertampil pada Gambar 9.



**Gambar 9. Flowchart Perancangan Mekanikal**

#### 1. Perancangan Model 3D


Proses pembuatan desain model 3D dilakukan menggunakan *software SolidWork 2022*. Model tersebut terdiri dari beberapa material, seperti *Aluminium Alloy 6063-T5*, *Besi ASTM A36*, dan beberapa material lainnya. Pada Gambar 10 dibawah menunjukkan model 3D tersebut.



**Gambar 10. Model 3D Desain**

Dalam gambar tersebut, terdapat beberapa bagian (*part*), namun penelitian ini hanya berfokus pada analisis rangka sebagai objek utama. Rangka tersebut

menggunakan besi *hollow* 4x4 , Besi siku 4x4 serta *Aluminium Profile v-slot*. Material pada besi *hollow* dan besi siku menggunakan ASTM A36 sedangkan *Aluminium Profile* menggunakan *aluminium alloy* 6063-T5, dengan panjang total 1.074 mm dengan lebar 550 mm, dan memiliki ketinggian yaitu 200 mm. penjelasan detail mengenai desain dari rangka tersebut ditampilkan oleh Gambar 11.



**Gambar 11. Desain Rangka**

## 2. Penentuan Material

Pemilihan material merupakan tahap krusial dalam proses perancangan dan fabrikasi suatu alat, karena dapat mempengaruhi kinerja, daya tahan, biaya produksi, serta kesesuaian dengan aplikasi yang dituju. Pada desain yang dikembangkan, beberapa material dipilih berdasarkan analisis sifat mekanis, dan ketersediaan material di pasar. Material yang digunakan pada alat yang dirancang terdiri dari :

### a. Besi ASTM A36

ASTM A36 merupakan baja karbon struktural serbaguna yang banyak diaplikasikan dalam konstruksi dan rekayasa mekanik. Pada rancangan yang telah dibuat, material ini terdapat pada komponen rangka utama, yaitu besi siku 4x4 dan besi *hollow* 4x4, keduanya dengan ketebalan 4 mm. Rangka ini berfungsi sebagai penopang beban statis dari seluruh sistem, sehingga memerlukan material dengan kekuatan dan ketahanan yang tinggi, serta kemudahan pengelasan.

### b. *Aluminium Alloy* 6063-T5

Pada desain ini, material ini terdapat pada *aluminium profile* V-slot. *Aluminium Profile* tersebut berfungsi sebagai rel linear (*linear guide*) untuk pergerakan mesin. *Aluminium profile* ini harus mampu menahan beban dinamis.

### c. Akrilik

Akrilik dipilih sebagai penutup mesin dan alas akuarium karena sifatnya yang ringan, tahan air. Selain itu, akrilik mudah dipotong dan dibentuk dengan laser

cutting atau CNC, sehingga cocok untuk komponen custom seperti penutup mesin, dan sebagai cover untuk melindungi rangkaian elektrikal.

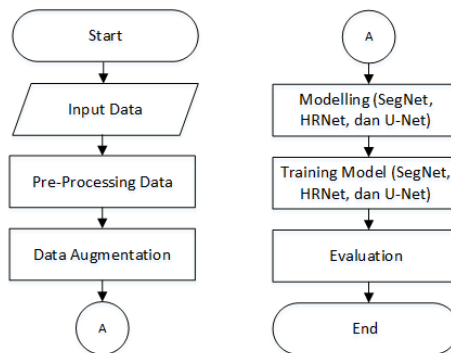
d. Kaca

Pada desain ini kaca dipilih sebagai material untuk dinding akuarium . Kaca ini memiliki ketebalan 5 mm. Akuarium dibuat sebanyak 21 dengan total ukuran 102mm x 44mm x 15mm. Akuarium tersebut digunakan sebagai wadah untuk meletakkan sampel dan media korosif.

e. Filament PLA

PLA adalah material yang biasa digunakan untuk mencetak komponen custom melalui mesin 3D Printer. Pada perancangan mekanik yang telah dibuat beberapa komponen menggunakan 3D printing untuk mencetak desain 3D seperti base slider untuk meletakkan kamera, dan cover samping mesin untuk melindungi komponen-komponen elektrikal.

### 3.1.3. Perancangan Sistem



Gambar 12. Diagram Alir Perancangan Sistem


Gambar 12 menunjukkan diagram alir yang menggambarkan alur kerja sistem secara keseluruhan. Proses dimulai dari tahap *input* data, dilanjutkan dengan pra-pemrosesan dan augmentasi data. Selanjutnya, data yang telah diproses digunakan dalam tahap pemodelan dengan tiga arsitektur *deep learning*, yaitu *SegNet*, *HRNet*, dan *U-Net*. Setelah pemodelan, sistem menjalani proses pelatihan model hingga mencapai tahap evaluasi akhir. Secara rinci, tahapan alur kerja sistem yaitu:

1. *Input Data*

Tahapan awal yang dilakukan dengan memasukkan data ke dalam sistem untuk dilakukan proses selanjutnya. Data yang digunakan berupa citra korosi

beserta label yang sesuai. Citra korosi ini akan menjadi dasar untuk pelatihan dan pengujian model, sementara label berfungsi sebagai acuan kebenaran (*ground truth*) yang diperlukan dalam proses pelatihan model.


## 2. *Data Pre-processing* (Pra-Proses Data)



**Gambar 13. Tahapan Pra-Proses Data**

Gambar 13 adalah tahapan *pre-processing* data yaitu melakukan penyeragaman ukuran citra dan normalisasi pada data. Pada tahap ini, citra korosi dan label yang digunakan sebagai *ground truth* diproses agar memiliki ukuran yang seragam dan nilai piksel yang terstandarisasi.

## 3. *Data Augmentation* (Augmentasi Data)



**Gambar 14. Tahapan Augmentasi Data**

Gambar 14 merupakan tahapan dalam proses augmentasi data. Pada tahap ini, data diubah menggunakan berbagai teknik augmentasi, seperti *horizontal flip*, *vertical flip*, dan *rotation*. Penerapan teknik ini bertujuan untuk memperbanyak

variasi data, sehingga dapat memiliki model yang lebih baik dalam mengenali pola serta mengurangi kemungkinan *overfitting*.


#### 4. *Modelling* (Pemodelan arsitektur *SegNet*, *HRNet* & *U-Net*)

Tahap pemodelan adalah tahap di mana metode *deep learning* ditentukan, termasuk pemilihan arsitektur model, algoritma yang digunakan, dan penentuan *hyperparameter* yang sesuai. Tahap ini bertujuan untuk merancang model agar mampu menangkap pola kompleks dalam data dan menghasilkan performa yang optimal. Pada pemodelan ini, digunakan tiga arsitektur *deep learning* untuk tugas segmentasi citra, yaitu *Segmentation Network (SegNet)*, *High-Resolution Network (HRNet)* dan *U-Net*. Masing-masing arsitektur memiliki karakteristik unik yang membedakannya dalam hal algoritma, struktur, akurasi, dan efisiensi komputasi.

#### 5. *Training model* (*SegNet*, *HRNet* & *UNet*)

Proses *training* model adalah tahap di mana model *deep learning* belajar dari data yang diberikan. Pada tahap ini, model akan menyesuaikan parameter-parameternya untuk meminimalkan fungsi *loss* dan meningkatkan akurasi. Tujuan utama dari *training* adalah untuk mengoptimalkan parameter model sehingga dapat memprediksi *output* yang akurat pada data baru.

#### 6. *Evaluation* (Evaluasi)



**Gambar 15. Tahapan Evaluasi**

Gambar 15 menggambarkan tahapan dalam proses evaluasi hasil *deep learning* yang digunakan pada model yang sudah dibangun sebelumnya. Tahap ini dimulai dengan penggunaan data uji yang telah dipisahkan untuk menguji model. Model yang telah dilatih seperti *SegNet*, *HRNet*, dan *U-Net* menghasilkan prediksi segmentasi, yang kemudian dibandingkan dengan *ground truth* menggunakan

metrik evaluasi *intersection over union (IoU)* dan *dice coefficient*. Metrik ini mengukur seberapa akurat model dalam memprediksi area terkorosi, dengan *IoU* menghitung *overlap* antara gambar prediksi dan gambar *ground truth*, sedangkan *dice coefficient* mengukur kesamaan antara keduanya. Hasil evaluasi ini dikembalikan dan dianalisis untuk menentukan performa model, memastikan bahwa model memenuhi kriteria yang diharapkan dalam segmentasi citra korosi.

### 3.2. Alat dan Bahan

Alat dan bahan diperoleh dengan menggunakan pendanaan dari Program Kreativitas Mahasiswa (PKM) pada tahun 2024. Detail mengenai anggaran belanja dijabarkan pada lampiran.

### 3.3. Pengujian

Setelah dilaksanakan perancangan pada sistem, tahap berikutnya ialah melakukan pengujian untuk melihat kinerja dari Perancangan Simulasi dan menganalisis kekuatan struktur rangka terhadap tegangan (*von mises*), regangan maksimal (*equivalent strain*), perpindahan total (*resultant displacement*) akibat pemberian beban. Analisis ini dilakukan melalui simulasi menggunakan *software solidwork 2022*. Dalam melakukan simulasi tersebut diperlukan beberapa tahapan, tahapan-tahapan tersebut di deskripsikan pada *flowchart* yang tertera pada gambar 9.

Selain itu, pengujian juga dilakukan untuk melihat kinerja dari model hasil pelatihan menggunakan *Segmentation Network (SegNet)*, *High-Resolution Network (HRNet)* dan *U-Net* dalam menganalisis segmentasi area terkorosi. Pada penelitian ini, ketiga arsitektur model tersebut digunakan untuk mengolah dan mengevaluasi data sampel korosi yang telah disiapkan. Proses pengujian mencakup perbandingan metrik evaluasi yang khusus digunakan untuk segmentasi, yaitu *Intersection over Union (IoU)* dan *Dice Coefficient*. Dengan menggunakan metrik tersebut, kami dapat membandingkan performa ketiga arsitektur model (*SegNet*, *HRNet*, dan *U-Net*) dan menentukan model mana yang paling efektif dalam melakukan segmentasi area terkorosi.

#### 1. *Intersection over Union (IoU)*

*IoU* dapat dihitung dengan persamaan (2) berikut:

$$\begin{aligned} \text{Intersection of Union} &= \frac{\text{Area of Intersection}}{\text{Area of Union}} \\ &= \frac{A \cap B}{A \cup B} \end{aligned} \tag{2}$$

Dimana,

*Area of Intersection* ( $A \cap B$ ) = Luas area yang merupakan irisan antara prediksi dan *ground truth* (tumpang tindih).

*Area of Union* ( $A \cup B$ ) = Luas gabungan antara area prediksi dan *ground truth* secara keseluruhan.

## 2. *Dice coefficient*

*Dice Coefficient* dapat dihitung dengan persamaan (3) berikut.

$$\begin{aligned}
 \text{Dice} &= \frac{2 \times \text{Area of Overlap}}{\text{Total Area of prediction} + \text{Total Area of Ground Truth}} \\
 &= \frac{2 \times (A \cap B)}{|A| + |B|}
 \end{aligned} \tag{3}$$

Dimana,

*Area of Overlap* ( $A \cap B$ ) = Luas area di mana prediksi (A) dan *ground truth* (B) saling tumpang tindih.

*Area of Prediction* ( $|A|$ ) = Total area yang diprediksi oleh model.

*Area of Ground Truth* ( $|B|$ ) = Total area pada *ground truth*.

Berikut merupakan tabel hasil pengujian segmentasi area terkorosi dengan menggunakan metrik evaluasi *Intersection over Union (IoU)* dan *Dice Coefficient*.

**Tabel 5. Layout Pengujian Metrik Evaluasi**

No	Model	Jumlah Data	<i>Mean IoU</i>	<i>Mean Dice Coefficient</i>
1	SegNet	70		
2	HRNetV2-W48	70		
3	U-Net	70		

### 3.3.1. Pengujian Perancangan Sistem

Dalam melakukan pengujian terdapat beberapa tahapan seperti yang telah di tampilkan pada gambar 9. Yang mencakup:

#### 1. Persiapan Model dan Penentuan Material

Langkah pertama dalam pengujian adalah menyiapkan model yang akan dianalisis. Seperti yang telah dijabarkan pada Bab 3.1.2 Perancangan Model 3D. Analisis yang dilakukan hanya berfokus pada kekuatan struktur rangka seperti yang ditampilkan pada gambar 11.

Setelah model selesai, material yang digunakan dalam simulasi ditentukan berdasarkan spesifikasi yang telah dibahas pada Bab 3.1.2 Penentuan Material. Setiap material memiliki karakteristik mekanis yang telah ditetapkan, seperti

modulus elastisitas, kekuatan luluh (*yield strength*), dan kepadatan, yang akan menjadi input dalam simulasi.

## 2. Penentuan Beban

Setelah model disiapkan, langkah berikutnya adalah menentukan beban yang akan diberikan pada struktur. Beban yang dianalisis meliputi beban statis dan beban dinamis, beban dinamis adalah berat mesin yaitu 6 kg, sedangkan beban statis dijabarkan dalam tabel 7 dibawah.

**Tabel 6. Beban Statis**

Keterangan	Berat(Kg)
Berat Akuarium	16
Media Korosif	30,6
Berat Sampel	4,2
<b>Total</b>	<b>50,8</b>

Beban berat mesin dan akuarium diperoleh dengan menimbang menggunakan timbangan berat badan, sedangkan sampel ditimbang menggunakan neraca analitik. Sementara itu, berat media korosif (air garam) dihitung berdasarkan volume air yang mengisi setengah dari akuarium. Langkah- langkah perhitungan seperti dibawah ini;

Volume Akuarium dapat dihitung menggunakan persamaan (4) sebagai berikut:

$$\begin{aligned}
 V_{total} &= P_{dalam} \times L_{dalam} \times T_{dalam} \\
 V_{total} &= 14 \times 14 \times 14,5 \\
 V_{total} &= 2842 \text{ cm}^3
 \end{aligned}
 \tag{4}$$

Karena air garam hanya mengisi setengah dari akuarium, maka:

$$\begin{aligned}
 V_{air} &= \frac{V_{total}}{2} \\
 V_{air} &= \frac{2842}{2} = 1421 \text{ cm}^3
 \end{aligned}
 \tag{5}$$

Jika dikonversikan ke liter menjadi 1,421 liter. Setelah didapat volume air kemudian kita konversi agar mendapatkan berat dari air tersebut, menggunakan persamaan (6) berikut:

$$W = V \times \rho
 \tag{6}$$

$W$  = berat air

$V$  = Volume air

$\rho$  = Massa Jenis air garam (1,025 kg/L).

$$\begin{aligned} W &= 1,421 \times 1,025 \\ W &= 1,457 \text{ kg} \end{aligned} \tag{7}$$

Karena terdapat 21 akuarium, maka total berat air garam adalah:

$$\begin{aligned} W_{total} &= W \times n \\ W_{total} &= 30,6 \text{ kg} \end{aligned} \tag{8}$$

Jadi, total berat media korosif dalam 21 akuarium adalah 30,6 kg.

### 3. *Boundary Condition*

*Boundary condition* (kondisi batas) adalah kondisi atau batasan yang diterapkan pada suatu sistem fisik untuk mensimulasikan bagaimana objek atau struktur berinteraksi dengan lingkungan sekitarnya. Dalam analisis rekayasa, *boundary condition* digunakan untuk menentukan bagaimana beban, gaya, atau gerakan ditransmisikan pada suatu model, yang dapat mempengaruhi respons strukturalnya.

### 4. *Mesh*

Setelah menentukan *boundary condition*, langkah selanjutnya adalah pembuatan *mesh*. *Mesh* merupakan suatu proses pemecahan model menjadi elemen-elemen kecil yang disebut finite elements, yang memungkinkan simulasi berjalan lebih akurat dengan mendiskretisasi struktur menjadi bagian-bagian yang lebih kecil.

## 3.3.2. Pengujian Sistem Dengan Model *SegNet*

Pengujian sistem dengan model *SegNet* dilakukan dengan menggunakan arsitektur *SegNet Basic*, yang dirancang untuk segmentasi gambar secara efisien. Model ini bekerja dengan mengekstraksi fitur melalui **encoder** dan merekonstruksi peta segmentasi melalui **decoder**, sambil mempertahankan informasi spasial yang penting menggunakan teknik *up-sampling*. Tujuan dari pengujian ini adalah untuk mengevaluasi performa klasifikasi dan segmentasi objek menggunakan arsitektur *SegNet Basic* sebagai *encoder* dalam sistem. Hasil akhir pengujian berupa *Intersection Over Union (IoU)* dan *Dice Coefficient*, yang kemudian dibandingkan dengan model lain untuk menilai efektivitasnya.

## 3.3.3. Pengujian Sistem Dengan Model *HRNet*

Pengujian sistem dengan model *High-Resolution Network (HRNet)*, menggunakan arsitektur model *HRNetV2-W48*, yang dirancang untuk mempertahankan resolusi tinggi selama ekstraksi fitur. Model ini menggabungkan resolusi yang berbeda secara paralel, untuk mempertahankan detail spasial tanpa

kehilangan aspek penting. Tujuan dari pengujian ini adalah untuk mengevaluasi performa klasifikasi dan segmentasi objek menggunakan arsitektur model *HRNetV2-W48* dalam sistem. Hasil akhir pengujian berupa *Intersection over Union (IoU)* dan *Dice Coefficient*, yang kemudian dibandingkan dengan model lain untuk menilai efektivitasnya.

#### **3.3.4. Pengujian Sistem Dengan Model U-Net**



Uji coba dilakukan dengan menggunakan model arsitektur *U-Net + VGG16*, dimana *backbone VGG16* berfungsi sebagai **encoder** dan menambahkan **decoder** berbasis *U-Net*. **Decoder** menggunakan *upsampling* dan *concatenation* dengan fitur dari **encoder** untuk rekonstruksi spasial yang lebih baik. Pengujian ini bertujuan untuk mengetahui bagaimana hasil klasifikasi dan segmentasi objek bekerja dengan model yang digunakan pada sistem. Hasil akhir pengujian berupa *Intersection over Union (IoU)* dan *Dice Coefficient* akan dibandingkan dengan model lain untuk menilai efektivitasnya.

## Bab 4. Hasil dan Pembahasan

### 4.1. Proses Alur Kerja Sistem

Tahap pertama yaitu pengumpulan dataset. Proses pengumpulan dataset yaitu pengambilan citra korosi dari hasil pengujian dengan menggunakan *action cam*. Data yang terkumpul akan dipakai sebagai data *train*, data *validation*, dan data *test*. Dataset untuk data *train* dan *validation* yang didapatkan dari proses pengambilan gambar adalah sebanyak 560 gambar yang sudah melalui tahap augmentasi. Kemudian untuk data *test* memiliki 70 gambar, setiap data akan dibuat label (*ground truth*) dalam bentuk biner (0 dan 1), sehingga total label adalah sebanyak 630 gambar. Total keseluruhan dataset adalah 1260 gambar.

Tabel 7. Contoh dan Jumlah Citra

No	Nama	Contoh citra	Jumlah Citra
1	Citra asli		630
2	Citra label		630

Tabel 8 merupakan contoh dan jumlah citra yang digunakan sebagai dataset untuk setiap model. Proses selanjutnya adalah *upload* dataset untuk setiap masing-masing citra asli dan citra label.

```
load dataset

def load_data(image_dir, mask_dir, img_size=(256, 256)):
    images, masks = [], []
    image_files = sorted(os.listdir(image_dir))
    for img_file in image_files:
        img_path = os.path.join(image_dir, img_file)
        mask_path = os.path.join(mask_dir, img_file)

        img = cv2.imread(img_path)
        img = cv2.resize(img, img_size)
        img = img / 255.0

        mask = cv2.imread(mask_path, cv2.IMREAD_GRAYSCALE)
        mask = cv2.resize(mask, img_size)
        mask = np.expand_dims(mask, axis=-1) / 255.0
        images.append(img)
        masks.append(mask)

    return np.array(images), np.array(masks)

X, Y = load_data(image_dir, mask_dir)
print("Dataset citra asli: ", X.shape, "Dataset citra label : ", Y.shape)

Dataset citra asli : (560, 256, 256, 3) Dataset citra label : (560, 256, 256, 1)
```

Gambar 16. Upload dan *preprocessing data*

Gambar 16 merupakan proses upload data. Pada proses ini data yang sudah disimpan pada google drive diupload dan di *resize* menjadi ukuran 256 x 256. Citra asli berjumlah 560 dengan 3 *channel* warna (*RGB*), sedangkan citra label berjumlah 560 dengan 1 *channel* warna (biner). Kemudian, masing-masing citra asli dan citra label akan dibagi 90% data *training* dan 10% data *validation*.


**Tabel 8. Hyperparameter Training**

<b>Hyperparameter Training</b>	
<i>Split Data</i>	90% data <i>training</i> , 10% data <i>validation</i>
<i>Batch Size</i>	8
<i>Epoch</i>	50
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0.001

Tabel 9 merupakan tabel *hyperparameter* yang akan digunakan dalam proses *training*. Kemudian data dibagi menjadi data latih (*train*) serta data *validation* dengan rasio 90:10. *Batch size* yang digunakan sebanyak 8. Hal ini berarti, sebanyak **8 sampel** dari **citra asli** dan **citra label** akan diproses sekaligus dalam satu *batch*. Kemudian dengan menggunakan 50 *epoch* artinya model akan **melakukan 50 kali** siklus pelatihan menggunakan seluruh dataset *train* dan *validation*. Model menggunakan *optimizer Adam* dengan kecepatan pembelajaran default sebesar 0.001.


## 4.2. Hasil Pengujian

### 4.2.1. Hasil Pengujian Perancangan Sistem




**Gambar 17. Simulasi Von Mises**

Gambar 17 menampilkan hasil simulasi *von Mises* yang menunjukkan distribusi tegangan pada objek yang dianalisis. Berdasarkan hasil simulasi, nilai tegangan maksimum tercatat sebesar 9,775 MPa.



**Gambar 18. Simulasi *Resultant Displacement***

Gambar diatas menampilkan hasil simulasi *resultant displacement* yang menunjukkan variasi perpindahan pada objek yang dianalisis. Berdasarkan hasil simulasi, nilai *resultant displacement* maksimum tercatat sebesar 0,081 cm.



**Gambar 19. Simulasi *Equivalent Strain***

Hasil simulasi menunjukkan distribusi *equivalent strain* pada objek yang dianalisis. Berdasarkan hasil tersebut, nilai *equivalent strain* tertinggi tercatat sebesar 0,000037.

## 4.2.2. Hasil Pengujian Model Segnet

### 1. Model Summary Arsitektur SegNet Basic

Model: "functional\_3"

Layer (type)	Output Shape	Param #
input_layer_3 (InputLayer)	(None, 256, 256, 3)	0
conv2d_15 (Conv2D)	(None, 256, 256, 64)	1,792
max_pooling2d_12 (MaxPooling2D)	(None, 128, 128, 64)	0
conv2d_16 (Conv2D)	(None, 128, 128, 128)	73,856
max_pooling2d_13 (MaxPooling2D)	(None, 64, 64, 128)	0
conv2d_17 (Conv2D)	(None, 64, 64, 256)	295,168
max_pooling2d_14 (MaxPooling2D)	(None, 32, 32, 256)	0
conv2d_18 (Conv2D)	(None, 32, 32, 512)	1,180,160
max_pooling2d_15 (MaxPooling2D)	(None, 16, 16, 512)	0
up_sampling2d_12 (UpSampling2D)	(None, 32, 32, 512)	0
conv2d_transpose_12 (Conv2DTranspose)	(None, 32, 32, 512)	2,359,808
up_sampling2d_13 (UpSampling2D)	(None, 64, 64, 512)	0
conv2d_transpose_13 (Conv2DTranspose)	(None, 64, 64, 256)	1,179,904
up_sampling2d_14 (UpSampling2D)	(None, 128, 128, 256)	0
conv2d_transpose_14 (Conv2DTranspose)	(None, 128, 128, 128)	295,040
up_sampling2d_15 (UpSampling2D)	(None, 256, 256, 128)	0
conv2d_transpose_15 (Conv2DTranspose)	(None, 256, 256, 64)	73,792
conv2d_19 (Conv2D)	(None, 256, 256, 1)	65

Total params: 5,459,585 (20.83 MB)  
Trainable params: 5,459,585 (20.83 MB)  
Non-trainable params: 0 (0.00 B)

**Gambar 20. Model Summary Arsitektur SegNet Basic**

Model arsitektur diatas merupakan model berbasis *SegNet* untuk segmentasi gambar, yang terdiri dari bagian *encoder (downsampling)*. Model menerima *input* gambar berukuran 256x256 piksel dengan 3 *channel* warna (*RGB*). Pada tahap *encoder*, fitur diekstraksi menggunakan beberapa lapisan *Convolutional (Conv2D)* dengan fungsi aktivasi *ReLU*, yang secara bertahap meningkatkan jumlah *filter* dari 64 hingga 512. Operasi *max pooling* diterapkan setelah lapisan konvolusi yang bertujuan untuk mengurangi dimensi spasial hingga mencapai ukuran 16x16x512.

Selanjutnya, pada tahap *decoder* model melakukan *upsampling* untuk mengembalikan ukuran spasial menggunakan lapisan *Upsampling2D* dan *Conv2D Transpose*, yang secara bertahap mengembalikan dimensi hingga ukuran asli gambar, yaitu 256x256x1 sebagai *output* biner untuk segmentasi dan Model ini memiliki total 5.459.585 parameter.

## 2. Hasil Pelatihan Arsitektur *SegNet Basic*


**Tabel 9. Hasil Pelatihan Arsitektur *SegNet Basic***

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
1	0,7447	0,4545	0,6929	0,4784
2	0,8012	0,3668	0,6955	0,4438
3	0,8097	0,3389	0,6902	0,4021
4	0,8114	0,3346	0,6936	0,3933
5	0,8154	0,3219	0,7074	0,3802
6	0,8221	0,3018	0,7056	0,3849
7	0,8237	0,3039	0,7001	0,3853
8	0,8284	0,2862	0,7088	0,3514
9	0,8314	0,2785	0,7061	0,3669
10	0,8366	0,2633	0,7180	0,3538
11	0,8355	0,2643	0,7136	0,3545
12	0,8376	0,2602	0,7216	0,3352
13	0,8402	0,2546	0,7212	0,3419
14	0,8421	0,2477	0,7211	0,3293
15	0,8451	0,2398	0,7279	0,3330
16	0,8435	0,2428	0,7225	0,3266
17	0,8441	0,2421	0,7125	0,3414
18	0,8433	0,2449	0,7155	0,3389
19	0,8472	0,2349	0,7197	0,3260
20	0,8475	0,2312	0,7209	0,3347
21	0,8460	0,2366	0,7265	0,3197
22	0,8481	0,2322	0,7270	0,3208
23	0,8486	0,2315	0,7272	0,3216
24	0,8485	0,2318	0,7196	0,3258
25	0,8496	0,2289	0,7030	0,3499
26	0,8511	0,2239	0,7176	0,3304
27	0,8551	0,2115	0,7229	0,3164
28	0,8562	0,2087	0,7252	0,3134
29	0,8568	0,2073	0,7289	0,3089

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
30	0,8572	0,2068	0,7251	0,3115
31	0,8573	0,2060	0,7250	0,3119
32	0,8574	0,2057	0,7237	0,3128
33	0,8580	0,2045	0,7278	0,3066
34	0,8582	0,2040	0,7228	0,3143
35	0,8584	0,2034	0,7258	0,3098
36	0,8587	0,2026	0,7267	0,3089
37	0,8589	0,2023	0,7182	0,3216
38	0,8589	0,2021	0,7291	0,3084
39	0,8596	0,2007	0,7249	0,3108
40	0,8597	0,2001	0,7246	0,3110
41	0,8597	0,2000	0,7251	0,3105
42	0,8598	0,1999	0,7248	0,3110
43	0,8598	0,1998	0,7250	0,3107
44	0,8599	0,1996	0,7250	0,3107
45	0,8599	0,1996	0,7250	0,3107
46	0,8599	0,1995	0,7250	0,3108
47	0,8599	0,1995	0,7250	0,3107
48	0,8599	0,1995	0,7249	0,3109
49	0,8599	0,1995	0,7249	0,3109
50	0,8599	0,1995	0,7249	0,3109

Pada Tabel 10 dapat dilihat bahwa proses pelatihan model menggunakan arsitektur *SegNet* untuk segmentasi area korosi. Kinerja model mengalami peningkatan yang menunjukkan bahwa model terus belajar dan memperbaiki performanya. Hal ini terlihat dari peningkatan *validation accuray* yang mencapai sekitar 72,89% pada *epoch* ke –29. *Train loss* mengukur tingkat kesalahan model dalam memprediksi selama pelatihan dan bertujuan untuk dikurangi agar model dapat memberikan prediksi yang lebih akurat. *Validation Loss* merupakan ukuran rata-rata kesalahan model saat diuji dengan data validasi, yang memberikan representasi seberapa baik model dapat menggeneralisasi terhadap data validasi. *Train accuracy* menunjukkan tingkat prediksi yang benar yang dibuat oleh model pada data pelatihan, yang mencerminkan sejauh mana model berhasil mempelajari pola-pola dalam data latih. Sementara itu, *validation accuracy* mengukur tingkat prediksi benar model terhadap data validasi, yang menunjukkan kemampuan model dalam mengaplikasikan hasil latihannya terhadap data yang belum pernah dijumpai sebelumnya.


### 3. Grafik Pelatihan Arsitektur *SegNet Basic*



**Gambar 21. Grafik Pelatihan Arsitektur *SegNet Basic***

Pada gambar 21 merupakan grafik hasil *training* model *SegNet*. Berdasarkan grafik tersebut dapat dilihat bahwa *training loss* mengalami penurunan yang cukup signifikan seiring bertambahnya jumlah *epoch*. Namun, *validation loss* menunjukkan fluktuasi yang cukup tinggi, yang mengindikasikan adanya variasi dalam proses validasi. Sementara itu, *training accuracy* mengalami peningkatan yang cukup stabil dan mencapai nilai yang cukup tinggi. *Validation accuracy* juga menunjukkan peningkatan, meskipun terdapat fluktuasi yang lebih besar dibandingkan dengan *training accuracy*.

### 4. Hasil Pengujian Arsitektur *SegNet Basic* pada sampel



**Gambar 22. Hasil Pengujian Arsitektur *SegNet Basic* Pada Sampel**

Pada gambar 22 menunjukkan perbandingan antara gambar asli disebelah kiri, dengan hasil segmentasi korosi disebelah kanan. Gambar asli menampilkan objek dengan bentuk dan warna aslinya, sementara pada gambar segmentasi korosi, area yang terdeteksi sebagai korosi ditampilkan dalam warna putih, sedangkan area yang tidak mengalami korosi diklasifikasikan sebagai latar belakang dan ditampilkan dalam warna hitam.

### 4.2.3. Hasil Pengujian Model HRNet

#### 1. Model Summary Arsitektur HRNetV2-W48

model: "functional\_1"

Layer (type)	Output Shape	Param #	Connected to
input_layer_1 (InputLayer)	(None, 256, 256, 3)	0	-
conv2d_17 (Conv2D)	(None, 256, 256, 48)	1,344	input_layer_1[0][0]
batch_normalization_12 (BatchNormalization)	(None, 256, 256, 48)	192	conv2d_17[0][0]
re_lu_12 (ReLU)	(None, 256, 256, 48)	0	batch_normalization_12
conv2d_18 (Conv2D)	(None, 256, 256, 48)	20,784	re_lu_12[0][0]
batch_normalization_13 (BatchNormalization)	(None, 256, 256, 48)	192	conv2d_18[0][0]
re_lu_13 (ReLU)	(None, 256, 256, 48)	0	batch_normalization_13
conv2d_19 (Conv2D)	(None, 256, 256, 48)	20,784	re_lu_13[0][0]
batch_normalization_14 (BatchNormalization)	(None, 256, 256, 48)	192	conv2d_19[0][0]
add_4 (Add)	(None, 256, 256, 48)	0	re_lu_12[0][0], batch_normalization_14
re_lu_14 (ReLU)	(None, 256, 256, 48)	0	add_4[0][0]
conv2d_20 (Conv2D)	(None, 128, 128, 96)	41,568	re_lu_14[0][0]
batch_normalization_15 (BatchNormalization)	(None, 128, 128, 96)	384	conv2d_20[0][0]
re_lu_15 (ReLU)	(None, 128, 128, 96)	0	batch_normalization_15
conv2d_21 (Conv2D)	(None, 128, 128, 96)	83,040	re_lu_15[0][0]
batch_normalization_16 (BatchNormalization)	(None, 128, 128, 96)	384	conv2d_21[0][0]
re_lu_16 (ReLU)	(None, 128, 128, 96)	0	batch_normalization_16
conv2d_22 (Conv2D)	(None, 128, 128, 96)	83,040	re_lu_16[0][0]
batch_normalization_17 (BatchNormalization)	(None, 128, 128, 96)	384	conv2d_22[0][0]
add_5 (Add)	(None, 128, 128, 96)	0	re_lu_15[0][0], batch_normalization_17
re_lu_17 (ReLU)	(None, 128, 128, 96)	0	add_5[0][0]
conv2d_23 (Conv2D)	(None, 64, 64, 192)	166,800	re_lu_17[0][0]
batch_normalization_18 (BatchNormalization)	(None, 64, 64, 192)	768	conv2d_23[0][0]
re_lu_18 (ReLU)	(None, 64, 64, 192)	0	batch_normalization_18
conv2d_24 (Conv2D)	(None, 64, 64, 192)	331,968	re_lu_18[0][0]
batch_normalization_19 (BatchNormalization)	(None, 64, 64, 192)	768	conv2d_24[0][0]
re_lu_19 (ReLU)	(None, 64, 64, 192)	0	batch_normalization_19
conv2d_25 (Conv2D)	(None, 64, 64, 192)	331,968	re_lu_19[0][0]
batch_normalization_20 (BatchNormalization)	(None, 64, 64, 192)	768	conv2d_25[0][0]
add_6 (Add)	(None, 64, 64, 192)	0	re_lu_18[0][0], batch_normalization_20
re_lu_20 (ReLU)	(None, 64, 64, 192)	0	add_6[0][0]
conv2d_26 (Conv2D)	(None, 32, 32, 384)	663,936	re_lu_20[0][0]
batch_normalization_21 (BatchNormalization)	(None, 32, 32, 384)	1,536	conv2d_26[0][0]
re_lu_21 (ReLU)	(None, 32, 32, 384)	0	batch_normalization_21
conv2d_27 (Conv2D)	(None, 32, 32, 384)	1,327,488	re_lu_21[0][0]
batch_normalization_22 (BatchNormalization)	(None, 32, 32, 384)	1,536	conv2d_27[0][0]
re_lu_22 (ReLU)	(None, 32, 32, 384)	0	batch_normalization_22
conv2d_28 (Conv2D)	(None, 32, 32, 384)	1,327,488	re_lu_22[0][0]
batch_normalization_23 (BatchNormalization)	(None, 32, 32, 384)	1,536	conv2d_28[0][0]
add_7 (Add)	(None, 32, 32, 384)	0	re_lu_21[0][0], batch_normalization_23
re_lu_23 (ReLU)	(None, 32, 32, 384)	0	add_7[0][0]
conv2d_30 (Conv2D)	(None, 128, 128, 96)	9,312	re_lu_17[0][0]
conv2d_31 (Conv2D)	(None, 64, 64, 192)	37,056	re_lu_20[0][0]
conv2d_32 (Conv2D)	(None, 32, 32, 384)	147,040	re_lu_23[0][0]
conv2d_29 (Conv2D)	(None, 256, 256, 48)	2,352	re_lu_14[0][0]

re_lu_22 (ReLU)	(None, 32, 32, 384)	0	batch_normalization_2
conv2d_28 (conv2d)	(None, 32, 32, 384)	1,327,488	re_lu_22[0][0]
batch_normalization_23 (BatchNormalization)	(None, 32, 32, 384)	1,536	conv2d_28[0][0]
add_7 (Add)	(None, 32, 32, 384)	0	re_lu_21[0][0], batch_normalization_2
re_lu_23 (ReLU)	(None, 32, 32, 384)	0	add_7[0][0]
conv2d_30 (conv2d)	(None, 128, 128, 96)	9,312	re_lu_17[0][0]
conv2d_31 (conv2d)	(None, 64, 64, 192)	37,056	re_lu_20[0][0]
conv2d_32 (conv2d)	(None, 32, 32, 384)	147,840	re_lu_23[0][0]
conv2d_29 (conv2d)	(None, 256, 256, 48)	2,352	re_lu_14[0][0]
up_sampling2d_3 (upSampling2D)	(None, 256, 256, 96)	0	conv2d_30[0][0]
up_sampling2d_4 (upSampling2D)	(None, 256, 256, 192)	0	conv2d_31[0][0]
up_sampling2d_5 (upSampling2D)	(None, 256, 256, 384)	0	conv2d_32[0][0]
concatenate_1 (Concatenate)	(None, 256, 256, 720)	0	conv2d_29[0][0], up_sampling2d_3[0][0], up_sampling2d_4[0][0], up_sampling2d_5[0][0]
conv2d_33 (conv2d)	(None, 256, 256, 1)	720	concatenate_1[0][0]

Total params: 4,605,409 (17.57 MB)  
Trainable params: 4,602,059 (17.55 MB)  
Non-trainable params: 4,320 (16.88 KB)

**Gambar 23. Model Summary Arsitektur HRNetV2-W48**

Pada model arsitektur *HRNetV2-W48* diatas terdapat beberapa jenis *layer* (lapisan), yaitu *input layer* yang memiliki gambar berukuran 256x256 piksel, dengan 3 *channel* warna (*RGB*), yang kemudian diproses melalui serangkaian *convolutional layer* yang diikuti oleh *batch normalization* dan fungsi aktivasi *ReLU (Rectified Linear Unit)*. Jumlah filter bertambah secara bertahap sedangkan dimensi spasial gambar dikurangi. Dalam model ini, resolusi tinggi terus dipertahankan melalui *residual connection* dan melakukan *up-sampling* pada setiap cabang untuk mengembalikan resolusi ke 256x256, yang kemudian digabungkan melalui *Concatenate*. *output* akhir dihasilkan oleh *convolutional layer* dengan 1 filter dan menggunakan fungsi aktivasi sigmoid, yang menghasilkan gambar berukuran 256x256 dengan 1 *channel* warna (*binary*).

## 2. Hasil Pelatihan Arsitektur HRNetV2-W48

**Tabel 10. Hasil Pelatihan Arsitektur HRNetV2-W48**


<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
1	0,7958	0,3975	0,3603	4,7359
2	0,8270	0,2861	0,7111	0,3768
3	0,8330	0,2637	0,7260	0,3262
4	0,8413	0,2455	0,7352	0,3126
5	0,8491	0,2324	0,6330	0,4452
6	0,8494	0,2315	0,7215	0,3049
7	0,8529	0,2160	0,6078	0,5039
8	0,8539	0,2128	0,6174	0,4998

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
9	0,8612	0,1950	0,7418	0,2552
10	0,8611	0,1952	0,7322	0,2857
11	0,8640	0,1900	0,7351	0,2568
12	0,8613	0,1919	0,7155	0,3047
13	0,8661	0,1825	0,7415	0,2444
14	0,8623	0,1912	0,7486	0,2271
15	0,8665	0,1801	0,7413	0,2403
16	0,8681	0,1745	0,7033	0,3470
17	0,8709	0,1682	0,7455	0,2287
18	0,8667	0,1793	0,7572	0,2061
19	0,8681	0,1745	0,7337	0,2592
20	0,8665	0,1797	0,7400	0,2499
21	0,8677	0,1783	0,7492	0,2303
22	0,8704	0,1697	0,7520	0,2308
23	0,8718	0,1655	0,7464	0,2266
24	0,8763	0,1537	0,7524	0,2095
25	0,8778	0,1496	0,7561	0,2002
26	0,8789	0,1464	0,7527	0,2077
27	0,8787	0,1468	0,7547	0,2031
28	0,8788	0,1463	0,7531	0,2077
29	0,8797	0,1434	0,7535	0,2058
30	0,8805	0,1416	0,7547	0,2027
31	0,8802	0,1422	0,7530	0,2068
32	0,8809	0,1414	0,7519	0,2091
33	0,8805	0,1415	0,7518	0,2095
34	0,8795	0,1436	0,7515	0,2099
35	0,8800	0,1425	0,7514	0,2103
36	0,8804	0,1424	0,7516	0,2098
37	0,8803	0,1420	0,7516	0,2097
38	0,8803	0,1424	0,7515	0,2100
39	0,8806	0,1419	0,7515	0,2100
40	0,8802	0,1428	0,7515	0,2101
41	0,8804	0,1412	0,7517	0,2094
42	0,8805	0,1417	0,7517	0,2096
43	0,8809	0,1409	0,7517	0,2094
44	0,8813	0,1398	0,7516	0,2098
45	0,8800	0,1433	0,7518	0,2093

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
46	0,8807	0,1418	0,7517	0,2095
47	0,8803	0,1420	0,7517	0,2096
48	0,8798	0,1437	0,7518	0,2095
49	0,8805	0,1411	0,7518	0,2094
50	0,8811	0,1396	0,7517	0,2094

Tabel 11 menunjukkan pelatihan model pada arsitektur *HRNetV2-W48* dengan peningkatan kinerja signifikan, terlihat dari *validation accuracy* yang mencapai 75,61% pada *epoch* ke-25. *Train loss* sebesar 14,96% menunjukkan kesalahan prediksi selama pelatihan, sementara *validation loss* sebesar 20,02% mengukur kesalahan pada data *validation*. *Train accuracy* mencapai 87,78%, menunjukkan model berhasil mempelajari pola dari data *train*. *Validation accuracy* mencerminkan kinerja model pada data yang tidak dilihat saat pelatihan.


### 3. Grafik Pelatihan Arsitektur *HRNetV2-W48*



**Gambar 24. Grafik Pelatihan Arsitektur *HRNetV2-W48***

Pada Gambar 24 merupakan grafik hasil *training* model arsitektur *HRNetV2-W48*. Berdasarkan grafik tersebut dapat dilihat *train loss* menurun secara signifikan setiap penambahan *epochs*. Pada *validation loss*, grafik bergerak dengan beberapa fluktuasi tetapi menunjukkan penurunan secara signifikan, yang mengindikasikan bahwa model dapat melakukan generalisasi data dengan baik. Kemudian untuk grafik *train accuracy* meningkat secara stabil dan konsisten. Pada *validation accuracy* menunjukkan pergerakan yang cenderung meningkat meskipun terdapat beberapa fluktuasi, yang mengindikasikan peningkatan kinerja model secara bertahap.

#### 4. Hasil Pengujian Arsitektur *HRNetV2-W48* pada Sampel



**Gambar 25. Hasil Pengujian Arsitektur *HRNetV2-W48* Pada Sampel**

Pada Gambar 25 terdapat perbandingan antara gambar asli (*original image*) di sebelah kiri dan gambar prediksi (*corrosion image*) di sebelah kanan. Gambar asli menampilkan objek dalam bentuk dan warna aslinya, sedangkan gambar prediksi menunjukkan hasil pemrosesan model dengan arsitektur *HRNetV2-W48* pada sampel tersebut. Pada gambar prediksi, area yang terdeteksi sebagai korosi ditandai dengan warna putih, sementara area yang tidak terdeteksi sebagai korosi diklasifikasikan sebagai latar belakang dan ditampilkan dalam warna hitam.

## 4.2.4. Hasil Pengujian Model U-Net

### 1. Model Summary Arsitektur U-Net

Model: "functional"			
Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, 256, 256, 3)	0	-
conv2d (Conv2D)	(None, 256, 256, 64)	1,792	input_layer[0][0]
batch_normalization (BatchNormalization)	(None, 256, 256, 64)	256	conv2d[0][0]
conv2d_1 (Conv2D)	(None, 256, 256, 64)	36,928	batch_normalization[0]
batch_normalization_1 (BatchNormalization)	(None, 256, 256, 64)	256	conv2d_1[0][0]
max_pooling2d (MaxPooling2D)	(None, 128, 128, 64)	0	batch_normalization_1
dropout (Dropout)	(None, 128, 128, 64)	0	max_pooling2d[0][0]
conv2d_2 (Conv2D)	(None, 128, 128, 128)	73,856	dropout[0][0]
batch_normalization_2 (BatchNormalization)	(None, 128, 128, 128)	512	conv2d_2[0][0]
conv2d_3 (Conv2D)	(None, 128, 128, 128)	147,584	batch_normalization_2
batch_normalization_3 (BatchNormalization)	(None, 128, 128, 128)	512	conv2d_3[0][0]
max_pooling2d_1 (MaxPooling2D)	(None, 64, 64, 128)	0	batch_normalization_3
dropout_1 (Dropout)	(None, 64, 64, 128)	0	max_pooling2d_1[0][0]
conv2d_4 (Conv2D)	(None, 64, 64, 256)	399,168	dropout_1[0][0]
batch_normalization_4 (BatchNormalization)	(None, 64, 64, 256)	1,024	conv2d_4[0][0]
conv2d_5 (Conv2D)	(None, 64, 64, 256)	398,080	batch_normalization_4
batch_normalization_5 (BatchNormalization)	(None, 64, 64, 256)	1,024	conv2d_5[0][0]
max_pooling2d_2 (MaxPooling2D)	(None, 32, 32, 256)	0	batch_normalization_5
dropout_2 (Dropout)	(None, 32, 32, 256)	0	max_pooling2d_2[0][0]
conv2d_6 (Conv2D)	(None, 32, 32, 512)	1,180,160	dropout_2[0][0]
batch_normalization_6 (BatchNormalization)	(None, 32, 32, 512)	2,048	conv2d_6[0][0]
conv2d_7 (Conv2D)	(None, 32, 32, 512)	2,359,808	batch_normalization_6
batch_normalization_7 (BatchNormalization)	(None, 32, 32, 512)	2,048	conv2d_7[0][0]
dropout_3 (Dropout)	(None, 32, 32, 512)	0	batch_normalization_7
up_sampling2d (UpSampling2D)	(None, 64, 64, 512)	0	dropout_3[0][0]
concatenate (Concatenate)	(None, 64, 64, 768)	0	up_sampling2d[0][0], batch_normalization_3
conv2d_8 (Conv2D)	(None, 64, 64, 256)	1,769,728	concatenate[0][0]
batch_normalization_8 (BatchNormalization)	(None, 64, 64, 256)	1,024	conv2d_8[0][0]
conv2d_9 (Conv2D)	(None, 64, 64, 256)	398,080	batch_normalization_8
batch_normalization_9 (BatchNormalization)	(None, 64, 64, 256)	1,024	conv2d_9[0][0]
dropout_4 (Dropout)	(None, 64, 64, 256)	0	batch_normalization_9
up_sampling2d_1 (UpSampling2D)	(None, 128, 128, 256)	0	dropout_4[0][0]
concatenate_1 (Concatenate)	(None, 128, 128, 384)	0	up_sampling2d_1[0][0], batch_normalization_3
conv2d_10 (Conv2D)	(None, 128, 128, 128)	442,496	concatenate_1[0][0]
batch_normalization_10 (BatchNormalization)	(None, 128, 128, 128)	512	conv2d_10[0][0]
conv2d_11 (Conv2D)	(None, 128, 128, 128)	147,584	batch_normalization_10
batch_normalization_11 (BatchNormalization)	(None, 128, 128, 128)	512	conv2d_11[0][0]
dropout_5 (Dropout)	(None, 128, 128, 128)	0	batch_normalization_11
up_sampling2d_2 (UpSampling2D)	(None, 256, 256, 128)	0	dropout_5[0][0]
concatenate_2 (Concatenate)	(None, 256, 256, 192)	0	up_sampling2d_2[0][0], batch_normalization_3
conv2d_12 (Conv2D)	(None, 256, 256, 64)	118,656	concatenate_2[0][0]
batch_normalization_12 (BatchNormalization)	(None, 256, 256, 64)	256	conv2d_12[0][0]
conv2d_13 (Conv2D)	(None, 256, 256, 64)	36,928	batch_normalization_12
batch_normalization_13 (BatchNormalization)	(None, 256, 256, 64)	256	conv2d_13[0][0]
dropout_6 (Dropout)	(None, 256, 256, 64)	0	batch_normalization_13
conv2d_14 (Conv2D)	(None, 256, 256, 1)	63	dropout_6[0][0]

Total params: 7,794,177 (129.13 MB)  
 Trainable params: 7,788,545 (129.71 MB)  
 Non-trainable params: 5,632 (12.00 KB)

**Gambar 26. Model Summary Arsitektur U-Net**

Gambar 26 merupakan *model summary* dari model *Unet*. Pada model arsitektur *UNet* diatas terdapat beberapa jenis *layer* (lapisan) yaitu, *input layer*

yang memiliki gambar berukuran 256x256 piksel, dengan 3 *channel* warna (*RGB*), yang kemudian diproses melalui serangkaian *convolutional layer* yang merupakan bagian dari **Encoder** dan **Decoder**. *Output* akhir akan menghasilkan *convolutional layer* dengan 1 filter dan menggunakan fungsi aktivasi *sigmoid*, yang menghasilkan gambar berukuran 256x256 dengan 1 *channel* warna (*binary*).

## 2. Hasil Pelatihan Arsitektur *U-Net*


**Tabel 11. Hasil Pelatihan Arsitektur *U-Net***

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
1	0,7668	0,4263	0,7090	0,4060
2	0,8193	0,3141	0,7108	0,4047
3	0,8277	0,2881	0,7214	0,3272
4	0,8398	0,2609	0,7257	0,3171
5	0,8445	0,2453	0,7256	0,3313
6	0,8551	0,2202	0,7405	0,2843
7	0,8554	0,2155	0,7363	0,2814
8	0,8586	0,2101	0,7508	0,2433
9	0,8654	0,1919	0,7551	0,2394
10	0,8665	0,1880	0,7583	0,2285
11	0,8685	0,1811	0,7552	0,2288
12	0,8663	0,1881	0,7569	0,2318
13	0,8718	0,1712	0,7466	0,2328
14	0,8740	0,1645	0,7488	0,2281
15	0,8728	0,1669	0,7596	0,2096
16	0,8741	0,1647	0,7598	0,2091
17	0,8745	0,1628	0,7412	0,2302
18	0,8769	0,1541	0,7575	0,2151
19	0,8767	0,1548	0,7582	0,2094
20	0,8782	0,1508	0,7599	0,2099
21	0,8761	0,1570	0,7514	0,2119
22	0,8839	0,1344	0,7536	0,2059
23	0,8855	0,1302	0,7591	0,1962
24	0,8858	0,1291	0,7602	0,1960
25	0,8864	0,1278	0,7591	0,1968
26	0,8870	0,1261	0,7568	0,1986
27	0,8873	0,1249	0,7600	0,1944
28	0,8876	0,1239	0,7563	0,1988
29	0,8877	0,1235	0,7593	0,1960

<i>Epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
30	0,8879	0,1231	0,7593	0,1929
31	0,8883	0,1215	0,7555	0,1995
32	0,8886	0,1209	0,7581	0,1943
33	0,8890	0,1201	0,7566	0,1988
34	0,8893	0,1188	0,7609	0,1904
35	0,8897	0,1180	0,7605	0,1895
36	0,8902	0,1163	0,7575	0,1954
37	0,8902	0,1159	0,7649	0,1859
38	0,8908	0,1152	0,7558	0,1994
39	0,8907	0,1149	0,7609	0,1897
40	0,8910	0,1138	0,7569	0,1974
41	0,8913	0,1130	0,7648	0,1881
42	0,8910	0,1141	0,7598	0,1943
43	0,8925	0,1099	0,7612	0,1901
44	0,8931	0,1083	0,7620	0,1877
45	0,8932	0,1079	0,7634	0,1861
46	0,8933	0,1079	0,7621	0,1874
47	0,8932	0,1077	0,7635	0,1859
48	0,8932	0,1078	0,7619	0,1878
49	0,8933	0,1076	0,7629	0,1866
50	0,8933	0,1075	0,7621	0,1874

Tabel 12 Merupakan hasil *training* model *Unet* dengan jumlah *epoch* 50. Dari tabel hasil *training* terlihat bahwa *epoch* mendapatkan tingkat *accuracy* serta *loss* pada data pelatihan maupun data validasi. Tingkat *accuracy* menunjukkan seberapa baik model berhasil melakukan prediksi dengan benar. Sebaliknya, nilai *loss* mengukur besarnya kesalahan yang dihasilkan oleh jaringan, dan tujuan dari pelatihan model adalah untuk meminimalisir nilai *loss*. Berdasarkan tabel *training* diatas didapatkan performa *training* terbaik pada *epoch* 50 dengan nilai *training accuracy* mencapai 89,33% dan nilai *loss* 10,75%. Sedangkan untuk performa *validation* terbaik pada *epoch* 37 dengan nilai *validation accuracy* 76,49% dan nilai *validation loss* 18,59%


### 3. Grafik Pelatihan Arsitektur *U-Net*



**Gambar 27. Grafik Pelatihan Arsitektur *U-Net***

Gambar 27 merupakan grafik hasil *training* model *Unet*. Berdasarkan grafik tersebut dapat dilihat bahwa hasil *training loss* dan *validation loss* yang ditunjukkan pada gambar sebelah kiri mengalami penurunan yang cukup signifikan. Sedangkan untuk hasil *training accuracy* dan *validation accuracy* yang ditunjukkan pada gambar sebelah kanan mengalami kenaikan yang lebih signifikan. Berdasarkan hasil grafik tersebut bisa kita lihat bahwa model masih belum cukup stabil dalam memvalidasi data yang diberikan, hal ini ditunjukkan dengan grafik yang sering berfluktuasi.

### 4. Hasil Pengujian Arsitektur *U-Net* pada Sampel



**Gambar 28. Hasil Pengujian Arsitektur *U-Net* Pada Sampel**

Gambar 28 merupakan perbandingan antara gambar asli di sebelah kiri dengan gambar prediksi disebelah kanan. Gambar asli menampilkan objek dalam bentuk dan warna aslinya, sedangkan untuk gambar prediksi menunjukkan hasil pemrosesan model arsitektur *U-Net* pada sampel. Pada gambar prediksi, area

yang terdeteksi sebagai korosi ditampilkan dalam warna putih, sedangkan area yang tidak terdeteksi diklasifikasikan sebagai latar belakang ditampilkan dalam warna hitam.


### 4.3. Pembahasan

Hasil simulasi *Von Mises* menunjukkan nilai maksimum sebesar 9,775 MPa. Gambar 18. menggambarkan distribusi tegangan di seluruh struktur, di mana sebagian besar area tampil dengan warna biru (tegangan rendah) dan terdapat area dengan warna merah pada sambungan di bagian bawah rangka, yang menunjukkan konsentrasi tegangan tertinggi. Nilai tegangan tersebut masih jauh di bawah batas *yield strength* material, yaitu sekitar 250 Mpa untuk ASTM A36 [31]. dan 110 MPa untuk *Aluminium Alloy* 6063-T5 [32]. Dengan demikian, struktur tetap bekerja dalam batas elastis dan aman dari deformasi plastis.

Pada gambar 19 menunjukkan bahwa perpindahan maksimum pada struktur adalah 0,081 cm. Distribusi perpindahan menunjukkan bahwa pergerakan terbesar terjadi di daerah yang sama dengan konsentrasi tegangan tertinggi, terutama di bagian bawah rangka. Namun, nilai perpindahan yang sangat kecil ini mengindikasikan bahwa struktur tetap kaku dan mampu menahan beban tanpa terjadi deformasi signifikan.

Hasil simulasi *equivalent strain* pada gambar 20. menunjukkan nilai regangan maksimum yang cukup rendah sekitar 0,000037. Yang berarti material hanya mengalami deformasi minimal dalam batas elastis, sehingga tidak terjadi perubahan bentuk permanen. Dengan regangan yang sangat kecil, dapat disimpulkan bahwa struktur bekerja dalam kondisi yang sangat aman. Setelah dilakukan pengujian perancangan sistem, selanjutnya dilakukan pengujian menggunakan model *Segmentation Network (SegNet)*, *High-Resolution Network (HRNet)*, dan *U-Net* untuk mendapatkan hasil terbaik segmentasi citra korosi. Proses pengujian mencakup perbandingan metrik evaluasi yang khusus digunakan untuk segmentasi, yaitu *Intersection over Union (IoU)* dan *Dice Coefficient*. Hasil pengujian dapat dilihat pada grafik dibawah ini.


#### 1. Hasil *Intersection over Union (IoU)* dan *Dice Coefficient* Arsitektur model *SegNet*



Gambar 29. Grafik *IoU* dan *Dice Coefficient* model *SegNet*

Gambar 29 menunjukkan performa model *SegNet* dalam melakukan segmentasi berdasarkan dua metrik evaluasi yaitu, *IoU (Intersection over Union)* dan *Dice Coefficient*. Grafik tersebut menunjukkan nilai *IoU* dan *dice coefficient* yang bervariasi dan berfluktuasi yang cukup besar. Dengan nilai rata-rata *IoU* yang berada disekitar 0,3502 dan nilai rata-rata *Dice Coefficient* 0,5026.


2. Hasil *Intersection over Union (IoU)* dan *Dice Coefficient* Arsitektur model *HRNetV2-W48*



**Gambar 30. Grafik *IoU* dan *Dice Coefficient* model *HRNetV2-W48***

Gambar 30 menunjukkan performa model *HRNetV2-W48* dalam melakukan segmentasi berdasarkan dua metrik evaluasi, yaitu *IoU (Intersection over Union)* dan *dice coefficient*. Grafik tersebut memperlihatkan nilai *IoU* dan *dice coefficient* yang bervariasi dan mengalami fluktuasi pada beberapa gambar. Hasil grafik menunjukkan nilai rata-rata *IoU* sebesar 0,5060 dan rata-rata *Dice Coefficient* sebesar 0,6535.

5. Hasil *Intersection over Union (IoU)* dan *Dice Coefficient* Arsitektur model *U-Net*



**Gambar 31. Grafik *IoU* dan *Dice Coefficient* model *U-Net***

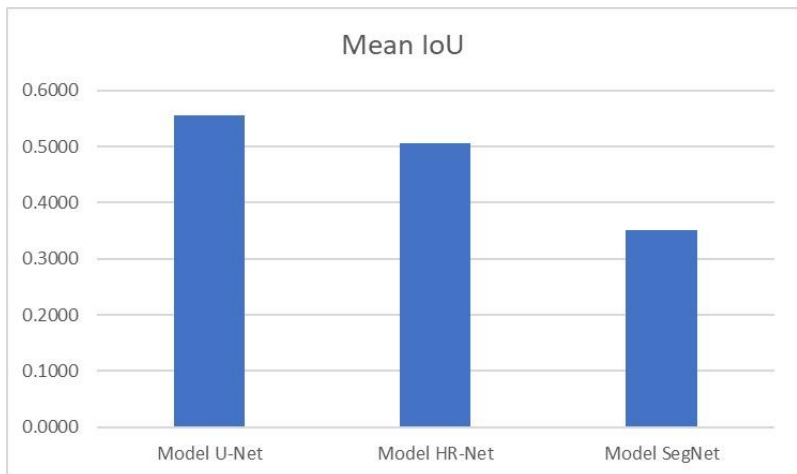
Gambar 31 menunjukkan performa model *U-Net*, pada grafik ini menunjukan hasil segmentasi berdasarkan dua metrik evaluasi yaitu, ***Intersection over Union (IoU)*** dan ***Dice Coefficient***. Grafik tersebut menunjukkan nilai *IoU* dan *dice coefficient* yang bervariasi dan berfluktuasi pada beberapa titik. Walaupun dengan hasil grafik yang kurang stabil, namun model *U-Net* memiliki performa yang lebih

baik dan lebih tinggi dalam segmentasi gambar. Dengan nilai rata-rata *IoU* dan *Dice Coefficient* yang berada disekitar 0,5563 dan 0,6951 menunjukkan bahwa model sudah cukup baik dalam menghasilkan segmentasi yang akurat.

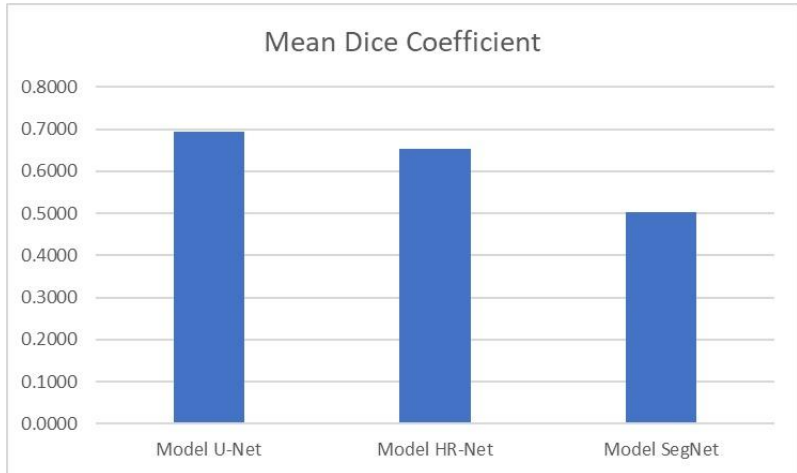
**Tabel 12. Hasil Metrik Evaluasi**

No	Model	Jumlah Data	Mean IoU	Mean Dice Coefficient
1	<i>SegNet</i>	70	0,3502	0,5026
2	<i>HRNetV2-W48</i>	70	0,5060	0,6535
3	<i>U-Net</i>	70	0,5563	0,6951

Tabel 13 menunjukkan hasil pengujian menggunakan tiga arsitektur model, yaitu *SegNet*, *HRNetV2-W48*, dan *U-Net*, pada 70 gambar asli. Arsitektur model *SegNet* memperoleh nilai *mean IoU* sebesar 0,3502 dan *mean Dice Coefficient* sebesar 0,5026. Selanjutnya, arsitektur model *HRNetV2-W48* mencapai nilai *mean IoU* sebesar 0,5060 dan *mean Dice Coefficient* sebesar 0,6535. Arsitektur model *U-Net* mencatat hasil tertinggi dengan nilai *mean IoU* sebesar 0,5563 dan *mean Dice Coefficient* sebesar 0,6951.



**Gambar 32. Grafik perbandingan Mean IoU pada model**



**Gambar 33. Grafik perbandingan *Mean Dice Coefficient* pada model**

## Bab 5. Kesimpulan dan Saran

### 5.1. Kesimpulan

Dari hasil simulasi model mekanik rangka tersebut, disimpulkan bahwa struktur yang menggunakan material ASTM A36 untuk rangka dan *Aluminium Alloy 6063-T5* untuk rel pergerakan mesin bekerja dalam kondisi aman. Hasil analisis tegangan *Von Mises* menunjukkan bahwa alat uji korosi memiliki nilai tegangan maksimum sebesar 9,775 MPa (di bawah batas luluh material), sehingga tidak terjadi deformasi plastis. *Resultant displacement* maksimum yang tercatat sebesar 0,081 cm menunjukkan bahwa struktur alat uji korosi memiliki tingkat kekakuan yang baik dan tidak mengalami deformasi signifikan. Selain itu, nilai *equivalent strain* yang sangat kecil yakni hanya 0,000037 mengindikasikan bahwa material hanya mengalami deformasi elastis dalam batas aman. Dengan demikian, desain ini dapat dikatakan telah memenuhi kriteria kekuatan dan kestabilan yang diharapkan. Penelitian ini juga bertujuan untuk mengetahui perbandingan 3 struktur model, yaitu *Segmentation Network (Segnet)*, *High-Resolution Network (HRNet)*, dan *U-Net*. Dengan tingkat akurasi pada model U-Net didapatkan nilai mean Intersection over Union (IoU) sebesar 55,63% dan nilai mean Dice Coefficient sebesar 69,51% sedangkan *HRNetV2-W48* didapatkan nilai *mean Intersection over Union (IoU)* sebesar 50,60% dan nilai *mean Dice Coefficient* sebesar 65,35% dan *SegNet* didapatkan nilai mean Intersection over Union (IoU) sebesar 35,02% dan nilai mean Dice Coefficient sebesar 50,26%. Berdasarkan tingkat akurasi tersebut model *U-Net* lebih efektif dalam mendeteksi objek yang terkena korosi dibandingkan dengan *SegNet* dan *HRNetV2-W48*.

## 5.2. Saran

Dari penelitian yang telah dilakukan, penulis memberikan beberapa saran untuk penelitian selanjutnya, yaitu:

1. diharapkan dilakukan pengujian eksperimental guna memvalidasi hasil simulasi dan memastikan kesesuaian dengan kondisi nyata.
2. Disarankan untuk mengoptimalkan desain struktur dengan mempertimbangkan analisis topologi guna mengurangi massa tanpa mengorbankan kekuatan.
3. Untuk penelitian selanjutnya dapat menerapkan arsitektur CNN dengan model lain dan hyperparameter yang berbeda.
4. Untuk penelitian selanjutnya disarankan untuk menambahkan dataset pada proses training untuk mendapatkan akurasi yang lebih baik lagi.
5. Untuk penelitian selanjutnya dapat menambahkan bentuk sampel yang lainnya.
6. Untuk penelitian selanjutnya diharapkan model dapat diakses dan dijalankan melalui aplikasi berbasis Web dan Android.
7. Untuk penelitian selanjutnya diharapkan lebih memperhatikan penyebaran cahaya pada sampel agar lebih stabil dan merata.

Untuk penelitian selanjutnya diharapkan model dapat digunakan secara *real-time* agar dapat memantau korosi pada bangunan-bangunan yang rentan terhadap korosi.

## Daftar Pustaka

- [1] E. B. Santoso, A. Taufik, and E. H. Herraprastanti, "Pengaruh Perbandingan NaCl dan Copper Sulphate Terhadap Material Hilang pada Perendaman Logam ST41," *J. Tek. Mesin*, vol. 6, no. 1, pp. 14–19, 2021.
- [2] Sumanto. and R. E. Maghfiroh, "Efek Temperatur Terhadap Laju Korosi," *J. Flywheel*, vol. 10, no. 1, pp. 26–32, 2019.
- [3] T. Setiawan, Z. Abidin, and C. Hendra, "Pembuatan Prototype Alat Electro Plating Untuk Home Industri," *J. Ilm. Teknol. Inf. Terap.*, vol. 8, no. 1, pp. 145–149, 2021.
- [4] M. A. C. Wardana, A. B. Setiawan, and A. Rabi, "Pengolahan Citra Untuk Mengetahui Derajat Korosi Pada Insulator Dengan Metode Decision Tree," *J. Tek. Mesin, Ind. Elektro dan Inform.*, vol. 2, no. 3, pp. 11–29, 2023.
- [5] D. Wardani *et al.*, "Penggunaan Metode Image Processing Sebagai Alat Karakterisasi Hasil Pelapisan pada Lambung Kapal," *J. Appl. Electr. Eng.*, vol. 7, no. 1, pp. 37–41, 2023.
- [6] F. az. Zahra, B. Aliyah, and N. L. Oktavian, "Ekstrak Kafein Ampas Kopi Sebagai Inhibitor Korosi Baja Murni Dalam Media H<sub>2</sub>SO<sub>4</sub>," *Sains dan Teknol.*, vol. 002, no. 2019, pp. 1–9, 2019.
- [7] D. Afrilia, S. Bahri, Jalaluddin, Masrulita, and Z. Nazrul, "Pengaruh Konsentrasi Ekstrak Kopi Sebagai Inhibitor Terhadap Laju Korosi Pada Baja," *Chem. Eng. J. Storage*, vol. 1, no. 4, pp. 111–120, 2022.
- [8] Miranda. and Rahmawati., "Analysis the rate of metal corrosion using dip - coating electrolyte solutions," *J. Ilm. Penelit. dan pembelajaran Fis.*, vol. 6, no. 2, pp. 98–101, 2020, doi: 10.30870/gravity.v6i2.6830.
- [9] Affandi. *et al.*, "Analisa Korosi Atmosferik Baja Karbon Rendah Di Kecamatan Medan Belawan," *J. Ilm.*, vol. 14, no. 2, pp. 80–88, 2020.
- [10] Y. Stiadi, S. Arief, H. Aziz, M. Efdi, and E. Emriadi, "Inhibisi Korosi Baja Ringan Menggunakan Bahan Alami Dalam Medium Asam Klorida: Review," *J. Ris. Kim.*, vol. 10, no. 1, pp. 51–65, 2019.
- [11] Y. Maryanty, A. D. Ifvournamasari, K. Widjajanti, D. R. Wulan, and N. I. Azkiya, "Pengaruh Ekstrak Kafein sebagai Inhibitor Laju Korosi dan Efisiensi Inhibisi pada Baja dalam Larutan Asam Sulfat dan Biosolar," *J. Rekayasa Proses*, vol. 17, no. 1, pp. 66–70, 2023.
- [12] R. Munir, "Pengantar Pengolahan Citra," *Pengolah. Citra Digit.*, no. Bagian 1, pp. 1–10, 2019, [Online]. Available: <http://rosni-gj.staff.gunadarma.ac.id/Downloads/files/15431/pendahuluan.pdf>
- [13] A. Prasetyo, A. Tiroy, P. Sihole, and M. D. Khairunisa, "Implementasi Software Solidworks dalam Perancangan Produksi Lemari untuk Efisiensi Waktu Produksi," vol. 8, no. 1, pp. 164–169, 2025.
- [14] A. Jonuskaite, "Flow Simulation with SolidWorks," pp. 1–52, 2017.

- [15] F. Fendi and F. Rhozman, "Analisa Simulasi Kekuatan Rangka Pada Mesin Brush Sander Menggunakan Aplikasi Solidwork," vol. 24, no. 1, pp. 1–5, 2024.
- [16] A. B. Pratama and I. Islahuddin, "Analisis Tegangan Alat Uji Bending Pipa Skala Laboratorium Menggunakan Finite Element Analysis," *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 3, no. 1, pp. 201–205, 2021, doi: 10.47233/jteksis.v3i1.214.
- [17] F. Dzil Ikram and S. Ali Rohman, "Simulasi Static Structural Kekuatan Rangka Mesin Pemberi Pakan Ikan Otomatis Menggunakan Metode Elemen Hingga," *Din. J. Ilm. Tek. Mesin*, vol. 14, no. 1, pp. 29–33, 2022, doi: 10.33772/DJITM.V14I1.28804.
- [18] B. Siswoyo, "MultiClass Decision Forest Machine Learning Artificial Intelligence," *J. Appl. Informatics Comput.*, vol. 4, no. 1, pp. 1–7, 2020, doi: 10.30871/jaic.v4i1.1155.
- [19] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *IJCIT (Indonesian J. Comput. Inf. Technol.)*, vol. 5, no. 1, pp. 75–82, 2020, doi: 10.31294/ijcit.v5i1.7951.
- [20] B. Nugroho and E. Y. Puspaningrum, "Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 3, pp. 533–538, 2021, doi: 10.25126/jtiik.2021834515.
- [21] S. H. Fani Nurona Cahya, Nila Hardi, Dwiza Riana, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Model Resnet-50," *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 1, no. 3, pp. 199–206, 2024, doi: 10.59407/jrsit.v1i3.529.
- [22] D. A. S. Mathew, N. D. Shree, and C. L. Chowdhary, "An Experimental Study on the Deviations in Performance of FNNS and CNNS in the Realm of Grayscale Adversarial Images," *J. Eng. Sci. Technol. Rev.*, vol. 16, no. 3, pp. 66–73, 2023, doi: 10.25103/jestr.163.09.
- [23] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [24] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [25] T. Anggardini, "Aplikasi Segmentasi Jantung Menggunakan Kecerdasan Buatan Dengan Visualisasi Berbasis Web," *AME (Aplikasi Mek. dan Energi) J. Ilm. Tek. Mesin*, no. Mi, pp. 5–24, 2023.
- [26] X. X. Yin, L. Sun, Y. Fu, R. Lu, and Y. Zhang, "U-Net-Based Medical Image Segmentation," *J. Healthc. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/4189781.
- [27] J. Wang *et al.*, "Deep High-Resolution Representation Learning for Visual Recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 43, no. 10, pp.

- 3349–3364, 2021, doi: 10.1109/TPAMI.2020.2983686.
- [28] S. Seong and J. Choi, "Semantic segmentation of urban buildings using a high-resolution network (Hrnet) with channel and spatial attention gates," *Remote Sens.*, vol. 13, no. 16, 2021, doi: 10.3390/rs13163087.
- [29] V. Badrinarayanan, A. Kendall, and R. Cipolla, "Segnet: A deep convolutional encoder-decoder architecture for image segmentation}," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 12, pp. 2481–2495, 2017, [Online]. Available: <https://arxiv.org/pdf/1511.00561.pdf>
- [30] V. Thesma and J. Mohammadpour Velni, "Plant Root Phenotyping Using Deep Conditional GANs and Binary Semantic Segmentation," *Sensors*, vol. 23, no. 1, pp. 1–16, 2023, doi: 10.3390/s23010309.
- [31] F. Restu, R. Hakim, and F. S. Anwar, "Analisa Kekuatan Material ASTM A36 pada Konstruksi Ragum terhadap Variasi Gaya Cekam dengan Menggunakan Software SolidWorks 2013," *J. Integr.*, vol. 9, no. 2, p. 113, 2017, doi: 10.30871/ji.v9i2.444.
- [32] J. Pearson, "Aluminium Alloy 6063 Data Sheet," 2021.

## Biodata



Nama : Muhammad Ilyas  
TTL : Batam, 25 September 2003  
Agama : Islam  
Alamat : Perumahan Taman Raya Tahap 5 Blok  
LV No.02 Rt 07, Batam Centre, Batam.  
Email : muhammadilyas0895@gmail.com  
Riwayat Pendidikan SMA/SMK : SMK Tahfidz An-Nasichah  
SMP : SMP Tahfidz An-Nasichah



Nama : Muhammad Nasir  
TTL : Sungai Sebesi, 08 Juni 2003  
Agama : Islam  
Alamat : Kavling Bida Kabil Blok Kenanga III No  
22, Rt 003 Rw 016, Kabil, Nongsa,  
Batam.  
Email : mn0543147@gmail.com  
Riwayat Pendidikan SMA/SMK : SMK Negeri Kundur  
SMP : MTS Negeri Kundur



Nama : M Padli Sandi  
TTL : Batam, 08 November 2004  
Agama : Islam  
Alamat : Tiban Lama Rt 02 Rw 04 No.16, Kel:  
Tiban Lama, Kec: Sekupang, Batam.  
Email : fadlisandi3@gmail.com  
Riwayat Pendidikan SMA/SMK : SMA Negeri 4 Batam  
SMP : SMP Negeri 25 Batam



Nama : Hari Mukti  
TTL : Batam, 10 April 2003  
Agama : Islam  
Alamat : Kampung Bagan Rt:02/Rw:09 No.14,  
Tanjung Piayu, Sei Beduk, Batam.  
Email : muktibtm@gmail.com  
Riwayat Pendidikan SMA/SMK : MAs Batamiyah Batam  
SMP : MTs Batamiyah Batam

# Lampiran

<https://drive.google.com/drive/u/0/folders/1uR3ML7e2DObghP4cMwPou3m3rvCzF5rQ>



**Gambar 34. Hasil Analisa plagiarism (9%)**