

SKRIPSI

DETEKSI RETAK PADA PERMUKAAN BETON MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*



**PATRICK NICHOLAS HADINATA
NPM : 2017410205**

PEMBIMBING: Dr. Djoni Simanta, Ir., M.T.

KO-PEMBIMBING: Liyanto Eddy, Ph.D.

**UNIVERSITAS KATOLIK PARAHYANGAN
FAKULTAS TEKNIK PROGRAM STUDI TEKNIK SIPIL
(Terakreditasi Berdasarkan SK BAN-PT Nomor: 227/SK/BAN-PT/Ak-XVI/S/XI/2013)
BANDUNG
JANUARI 2021**

SKRIPSI

DETEKSI RETAK PADA PERMUKAAN BETON MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*



PATRICK NICHOLAS HADINATA
NPM : 2017410205

PEMBIMBING: Dr. Djoni Simanta, Ir., M.T.

KO-PEMBIMBING: Liyanto Eddy, Ph.D.

UNIVERSITAS KATOLIK PARAHYANGAN
FAKULTAS TEKNIK PROGRAM STUDI TEKNIK SIPIL
(Terakreditasi Berdasarkan SK BAN-PT Nomor: 227/SK/BAN-PT/Ak-XVI/S/XI/2013)
BANDUNG
JANUARI 2021

SKRIPSI

DETEKSI RETAK PADA PERMUKAAN BETON MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK



**PATRICK NICHOLAS HADINATA
NPM : 2017410205**

BANDUNG, 21 JANUARI 2021

PEMBIMBING:

A blue ink signature of Dr. Djoni Simanta, Ir., M.T.

Dr. Djoni Simanta, Ir., M.T.

KO-PEMBIMBING:

A blue ink signature of Liyanto Eddy, Ph.D.

Liyanto Eddy, Ph.D.

**UNIVERSITAS KATOLIK PARAHYANGAN
FAKULTAS TEKNIK PROGRAM STUDI TEKNIK SIPIL
(Terakreditasi Berdasarkan SK BAN-PT Nomor: 227/SK/BAN-PT/Ak-XVI/S/XI/2013)
BANDUNG
JANUARI 2021**

PERNYATAAN

Yang bertandatangan di bawah ini, saya dengan data diri sebagai berikut:

Nama : Patrick Nicholas Hadinata

NPM : 2017410205

Program Studi : Teknik Sipil

Fakultas Teknik, Universitas Katolik Parahyangan

Menyatakan bahwa skripsi / tesis / disertasi*) dengan judul:

DETEKSI RETAK PADA PERMUKAAN BETON MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

adalah benar-benar karya saya sendiri di bawah bimbingan dosen pembimbing. Saya tidak melakukan penjiplakan atau pengutipan dengan cara-cara yang tidak sesuai dengan etika keilmuan yang berlaku dalam masyarakat keilmuan. Apabila di kemudian hari ditemukan adanya pelanggaran terhadap etika keilmuan dalam karya saya, atau jika ada tuntutan formal atau non formal dari pihak lain berkaitan dengan keaslian karya saya ini, saya siap menanggung segala resiko, akibat, dan/atau sanksi yang dijatuhkan kepada saya, termasuk pembatalan gelar akademik yang saya peroleh dari Universitas Katolik Parahyangan.

Dinyatakan: di Bandung

Tanggal: 27 Januari 2021



Patrick Nicholas Hadinata

2017410205

*) coret yang tidak perlu

DETEKSI RETAK PADA PERMUKAAN BETON MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

**Patrick Nicholas Hadinata
NPM: 2017410205**

**Pembimbing: Dr. Djoni Simanta, Ir., M.T.
Ko-Pembimbing: Liyanto Eddy, Ph.D.**

**UNIVERSITAS KATOLIK PARAHYANGAN
FAKULTAS TEKNIK PROGRAM STUDI TEKNIK SIPIL
(Terakreditasi Berdasarkan SK BAN-PT Nomor: 227/SK/BAN-PT/Ak-XVI/S/XI/2013)**

**BANDUNG
JANUARI 2021**

ABSTRAK

Kecerdasan buatan telah banyak berkembang dan digunakan untuk memecahkan masalah yang terkait dengan penglihatan komputer. Pada skripsi ini, *convolutional neural network* yang merupakan salah satu bagian dari kecerdasan buatan diimplementasikan untuk mendeteksi retak pada permukaan beton. *Semantic image segmentation* adalah proses pengklasifikasian setiap piksel pada gambar. *Semantic image segmentation* yang berbasis kecerdasan buatan dapat dilakukan menggunakan *convolutional neural network* dengan struktur *encoder-decoder*. Skripsi ini bertujuan untuk membandingkan dua arsitektur *semantic image segmentation* dalam bidang deteksi retak pada permukaan beton. Arsitektur yang akan digunakan dalam perbandingan adalah U-Net dan DeepLabV3+. U-Net telah terbukti performanya untuk segmentasi gambar biomedis, sedangkan DeepLabV3+ telah terbukti performanya untuk segmentasi gambar multiskala. Kedua arsitektur tersebut akan dibandingkan performanya menggunakan parameter akurasi, F1, *precision*, dan *recall*. Performa *neural network* sangat tergantung dari dataset pelatihan yang dipakai. Oleh karena itu, pengaruh berbagai variasi dataset pelatihan juga akan ditinjau dalam skripsi ini. *Neural network* dilatih menggunakan *cloud computing* dengan *Graphic Processing Unit* (GPU) NVIDIA Tesla V100 dan RAM 27,4 gigabyte. *Neural network* akan dievaluasi menggunakan gambar retak sederhana, retak berongga, dan retak kompleks. Hasil segmentasi retak akan dikuantifikasi dengan *medial axis transform* untuk mencari panjang retak dan lebar retak. Hasil pengujian memperlihatkan bahwa variasi dataset pelatihan sangat mempengaruhi performa *neural network*, sehingga diperlukan pemilihan kondisi lingkungan yang bervariasi untuk meningkatkan performa *neural network*. *Medial axis transform* juga bisa mengukur panjang retak dan lebar retak dengan akurat dalam satuan piksel.

Kata Kunci: Kecerdasan buatan, segmentasi gambar, deteksi retak, pemeliharaan infrastruktur

CRACK DETECTION ON CONCRETE SURFACES USING CONVOLUTIONAL NEURAL NETWORK

Patrick Nicholas Hadinata

NPM: 2017410205

Advisor: Dr. Djoni Simanta, Ir., M.T

Co-Advisor: Liyanto Eddy, Ph.D.

PARAHYANGAN CATHOLIC UNIVERSITY

FACULTY OF ENGINEERING DEPARTMENT OF CIVIL ENGINEERING

(Accreditated by SK BAN-PT Number: 227/SK/BAN-PT/Ak-XVI/S/XI/2013)

BANDUNG

JANUARY 2021

ABSTRACT

Artificial intelligence has shown its potential in the field of computer vision task. This study focuses on the application of convolutional neural network, which is a part of artificial intelligence, to detect cracks on concrete surfaces. Semantic segmentation is a computer vision task to label each pixel of an image to a specific class. It has been proven that artificial intelligence can improve the robustness of semantic image segmentation task. Semantic image segmentation based on artificial intelligence can be achieved using an encoder-decoder structured convolutional neural network. This research aims to benchmark two famous semantic image segmentation architectures, namely U-Net and DeepLabV3+. U-Net has shown its potential in biomedical image segmentation and DeepLabV3+ has shown its potential in multiscale image segmentation. Both architecture will be benchmarked based on four evaluation metrics encompassing accuracy, F1, precision, and recall. Neural network's performance is highly dependent on its training data. Therefore, three different types of training dataset will be used to further study its effect on neural network's performance. Neural network is trained using cloud computing with a high performance Graphic Processing Unit (GPU) NVIDIA Tesla V100 and 27,4 gigabyte of RAM. Neural network's performance will then be evaluated using three different types of crack, which are simple cracks, cracks with voids, and complex cracks. Segmentation result will also be quantified using medial axis transform to measure its length and width. Test results show that variation of training dataset greatly affects neural network's performance. Hence, a varied selection of training datasets is needed to further improve neural network's performance. Medial axis transform is also able to measure crack length and width accurately in pixels.

Keywords: Artificial intelligence, image segmentation, crack detection, maintenance of infrastructure

PRAKATA

Puji dan syukur penulis panjatkan kepada Tuhan Yesus Kristus atas kasih setia dan penyertaannya sehingga penulis dapat menyelesaikan skripsi yang berjudul *Deteksi Retak pada Permukaan Beton Menggunakan Convolutional Neural Network*. Skripsi ini dibuat dalam rangka untuk memenuhi salah satu syarat akademik untuk menyelesaikan studi di tingkat S-1 di Fakultas Teknik, Program Studi Teknik Sipil, Universitas Katolik Parahyangan.

Banyak hambatan dan kesulitan yang penulis rasakan dalam penulisan skripsi ini. Namun berkat dukungan, saran, serta kritik yang membangun dari berbagai pihak, maka skripsi ini dapat penulis selesaikan. Maka dari itu penulis ingin menyampaikan ucapan terima kasih kepada:

1. Oma Kiong dan Opa Kin Gwan yang senantiasa mendoakan penulis dari atas surga.
2. Papa, Mama, Opa Gwan, dan Oma Gwat yang telah memberikan banyak doa, motivasi, dan dukungan bagi penulis.
3. Papa yang sangat membantu penulis dengan membiayai penyewaan fasilitas *cloud computing* dan buku buku teori yang dibutuhkan.
4. Maria Hadinata selaku kakak kandung penulis yang sudah menginspirasi penulis dalam mengoreksi *mathematical description* untuk dasar teori.
5. Bapak Dr. Djoni Simanta, Ir., M.T. selaku dosen pembimbing yang telah mendukung dan membimbing penulis hingga skripsi ini dapat diselesaikan. Terima kasih telah mendukung penelitian ini sehingga penulis memiliki sebuah hobi dan *passion* baru.
6. Bapak Liyanto Eddy, Ph.D. selaku dosen ko-pembimbing yang telah mendedikasikan banyak waktunya untuk membimbing penulis dalam penyusunan skripsi ini. Terima kasih telah mengajari penulis tentang “cara berpikir” dalam riset dan memberikan penulis kesempatan untuk menulis *paper*. Kesempatan tersebut merupakan pengalaman berharga bagi penulis.
7. Bapak Prof. Bambang Suryoatmono, Ph.D. dan Bapak Helmy Hermawan Tjahjanto, Ph.D. selaku dosen penguji atas saran-saran dan masukannya dalam skripsi ini.

8. Seluruh dosen di Jurusan Teknik Sipil Unpar yang telah memberikan banyak ilmu dan dukungan selama masa perkuliahan.
9. Bapak Janto V. Sulungbudi, S.Si. yang sudah mengundang penulis untuk mengikuti kelas *deep learning* untuk fisikawan dan membantu penulis dalam mendalami aspek-aspek *deep learning*. Terima kasih telah mengajarkan pentingnya eksplorasi pada proses pembelajaran.
10. Bapak Reinard Primulando, Ph.D. yang sudah menginspirasi penulis dalam mendalami konsep-konsep dari *deep learning*. Terima kasih telah mengajarkan beberapa konsep *deep learning* secara sangat mendalam.
11. Tan Leonardo Yonatan selaku mayor jenderal PUBG dengan senjata M24nya yang senantiasa mengajak “dor” dimanapun penulis sedang merasa hidup tak lagi berguna.
12. Stephan Victor selaku teman seperjuangan skripsi yang senantiasa berbagi penderitaan dengan penulis.
13. Grup serdadu kolonel purnawarman (Tan, Chengpo) yang selalu memarahi penulis ketika penulis sedang tidak semangat.
14. Grup Olala (Jowi, Grisel, Regina, Echa, Jazlyn, Ferdinand, Ivaldy, Ryan, Eli, dan Kiel) yang senantiasa menemani selama seminar agar penulis tidak gugup.
15. Peanut dan Paris yang selalu mengingatkan penulis untuk selalu bergembira.

Penulis menyadari masih ada kekurangan dalam penyusunan skripsi ini. Oleh karena itu, penulis dengan terbuka menerima segala saran dan kritik yang membangun dari pembaca untuk penyempurnaan skripsi ini. Penulis berharap agar skripsi ini dapat bermanfaat dan memberikan inspirasi bagi pembaca.

Bandung, 1 Februari 2021



Patrick Nicholas

Hadinata

2017410205

DAFTAR ISI

ABSTRAK	i
ABSTRACT	ii
PRAKATA	iii
DAFTAR ISI	v
DAFTAR NOTASI	ix
DAFTAR GAMBAR	x
DAFTAR TABEL	xix
BAB 1 PENDAHULUAN	1-1
1.1 Latar Belakang	1-1
1.2 Inti Permasalahan	1-2
1.3 Tujuan Penulisan	1-4
1.4 Batasan Masalah	1-4
1.5 Metode Penelitian	1-5
1.6 Sistematika Penulisan	1-6
BAB 2 DASAR TEORI	2-1
2.1 Kecerdasan Buatan	2-1
2.2 Machine Learning	2-1
2.3 Deep Learning	2-1
2.4 Artificial Neural Network	2-1
2.4.1 Fungsi Aktivasi	2-4
2.4.2 Parameter Evaluasi	2-5
2.4.3 Fungsi <i>Loss</i>	2-6

2.4.4	<i>Optimizer</i> dan <i>gradient descent</i>	2-7
2.4.5	Algoritme <i>Backpropagation</i>	2-10
2.5	Convolutional Neural Network.....	2-11
2.5.1	<i>Convolution2D Layer</i>	2-11
2.5.2	<i>Maxpooling2D Layer</i>	2-12
2.5.3	<i>Transpose Convolution Layer</i>	2-13
2.5.4	<i>Depthwise Separable Convolution Layer</i>	2-13
2.5.5	<i>Atrous Convolution Layer (Dilated Convolution)</i>	2-15
2.5.6	<i>Batch Normalization Layer</i>	2-15
2.5.7	<i>Concatenate Layer</i>	2-16
2.5.8	<i>Add Layer</i>	2-16
2.5.9	<i>Dropout Layer</i>	2-17
2.5.10	<i>Upsampling2D Layer</i>	2-18
2.6	Hyperparameter Tuning, Regularisasi, dan Optimasi.....	2-18
2.7	Semantic Image Segmentation dengan CNN berstruktur Encoder-Decoder	2- 20
2.8	<i>Medial Axis Transform</i>	2-21
BAB 3	PEMODELAN <i>NEURAL NETWORK</i>	3-1
3.1	Arsitektur U-Net	3-1
3.2	Arsitektur DeepLabV3+	3-2
3.3	<i>Dataset Pelatihan Neural Network</i>	3-3
3.4	<i>Preprocessing</i> dataset pelatihan.....	3-5
3.5	Perangkat keras dan perangkat lunak untuk melatih neural network	3-5
3.6	Pembagian proporsi <i>dataset</i> untuk pelatihan dan validasi.....	3-5

3.7	Jumlah <i>Epoch</i>	3-5
3.8	<i>Learning rate</i> dan <i>batch size</i>	3-6
BAB 4	HASIL ANALISIS DAN PEMBAHASAN	4-1
4.1	Hyperparameter tuning.....	4-1
4.1.1.	Arsitektur U-Net dengan <i>dataset</i> pelatihan Yang et al (2018).....	4-1
4.1.2.	Arsitektur U-Net dengan <i>dataset</i> pribadi	4-7
4.1.3.	Arsitektur U-Net dengan <i>dataset</i> gabungan	4-12
4.1.4.	Arsitektur DeepLabV3+ dengan <i>dataset</i> Yang et al (2018)	4-19
4.1.5.	Arsitektur DeepLabV3+ dengan <i>dataset</i> pribadi	4-25
4.1.6.	Arsitektur DeepLabV3+ dengan <i>dataset</i> gabungan	4-32
4.1.7.	Rangkuman <i>hyperparameter</i>	4-39
4.1.8.	Rangkuman performa model dengan parameter evaluasi	4-40
4.2.	Tes kinerja <i>neural network</i>	4-41
4.2.1.	U-Net dengan <i>dataset</i> Yang et al (2018).....	4-41
4.2.2.	U-Net dengan <i>dataset</i> pribadi	4-45
4.2.3.	U-Net dengan <i>dataset</i> gabungan	4-48
4.2.4.	DeepLabV3+ dengan <i>dataset</i> Yang et al (2018).....	4-51
4.2.5.	DeepLabV3+dengan <i>dataset</i> pribadi	4-54
4.2.6.	DeepLabV3+dengan <i>dataset</i> gabungan	4-57
4.3.	Perhitungan panjang dan lebar retak menggunakan medial axis transform ..	4-60
BAB 5	KESIMPULAN DAN SARAN	5-1
5.1	Kesimpulan.....	5-1
5.2	Saran	5-2



DAFTAR NOTASI

- \mathcal{L} : *Loss*
 W : *Weight*
 b : *Bias*
 ϵ : *Learning rate*
 n : Dimensi *feature map* (piksel)
 f : Dimensi *kernel* (piksel)
 s : *Stride*
 P : *Precision*
 R : *Recall*
 y : *Groundtruth*
 \hat{y} : Prediksi *neural network*



DAFTAR GAMBAR

Gambar 1.1 <i>Artificial Neural Network</i>	1-2
Gambar 1.2 Arsitektur U-Net (Ronneberger, Fischer, & Brox, 2015).....	1-3
Gambar 1.3 Arsitektur DeepLabV3+ (Chen, Zhu, Papandreou, Schroff, & Adam, 2018).....	1-3
Gambar 1.4 Diagram Alir Penelitian.....	1-6
Gambar 2.1 Ilustrasi ANN dengan 2 <i>hidden layer</i>	2-2
Gambar 2.2 Ilustrasi komputasi dari suatu neuron	2-3
Gambar 2.3 Fungsi Aktivasi ReLu	2-4
Gambar 2.4 Fungsi aktivasi <i>sigmoid</i>	2-5
Gambar 2.5 <i>Confusion matrix</i> TP, TN, FP, dan FN	2-6
Gambar 2.6 Ilustrasi <i>gradient descent</i> 2 dimensi untuk parameter <i>weight</i>	2-9
Gambar 2.7 Salah satu kemungkinan kontur lembah <i>loss</i> pada <i>neural network</i>	2-10
Gambar 2.8 Algoritme <i>backpropagation</i>	2-10
Gambar 2.9 Proses <i>convolution</i> pada CNN.....	2-11
Gambar 2.10 Proses <i>maxpooling2D</i> pada CNN.....	2-12
Gambar 2.11 Transpose Convolution Layer.....	2-13
Gambar 2.12 <i>Depthwise separable convolution</i> (Chollet, 2017)	2-14
Gambar 2.13 <i>Atrous convolution</i> (Chen, Zhu, Papandreou, Schroff, & Adam, 2018) 2-15	2-15
Gambar 2.14 Proses <i>concatenate</i> pada CNN.....	2-16
Gambar 2.15 <i>Add Layer</i>	2-17
Gambar 2.16 Regularisasi <i>dropout</i> dengan nilai 0,25 pada <i>layer 1</i> dan <i>layer 2</i>	2-17
Gambar 2.17 <i>Upsampling2D Bilinear</i>	2-18
Gambar 2.18 Ilustrasi pengaruh <i>learning rate</i> pada proses pembelajaran <i>neural network</i>	2-19
Gambar 2.19 Fenomena <i>high bias</i> dan <i>high variance</i>	2-20
Gambar 2.20 CNN dengan struktur <i>Encoder-Decoder</i>	2-20
Gambar 2.21 <i>Medial axis transform</i>	2-21
Gambar 3.1 <i>Layer-layer</i> pada bagian <i>encoder</i> dan <i>decoder</i> U-Net.....	3-1

Gambar 3.2 <i>Layer-layer</i> pada bagian <i>encoder</i> dan <i>decoder</i> DeepLabV3+	3-2
Gambar 3.3 <i>Backbone modified xception</i> (Chen, Zhu, Papandreou, Schroff, & Adam, 2018)	3-3
Gambar 3.4 Contoh <i>dataset</i> yang bersumber dari Yang et al (2018).....	3-4
Gambar 3.5 Contoh <i>dataset</i> yang dibuat pribadi	3-4
Gambar 4.1 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 2	4-1
Gambar 4.2 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 2	4-2
Gambar 4.3 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 2	4-2
Gambar 4.4 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 2	4-3
Gambar 4.5 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 2e-4 dan <i>batch size</i> 2	4-4
Gambar 4.6 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 3e-4 dan <i>batch size</i> 2	4-4
Gambar 4.7 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 2	4-5
Gambar 4.8 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 2	4-5
Gambar 4.9 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 2	4-6
Gambar 4.10 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 4	4-6
Gambar 4.11 Kurva pembelajaran U-Net menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 8	4-7
Gambar 4.12 Kurva pembelajaran pada <i>dataset</i> pribadi yang menggunakan <i>batch size</i> berukuran kecil.....	4-8

Gambar 4.13 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 8	4-9
Gambar 4.14 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 8	4-9
Gambar 4.15 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 8	4-10
Gambar 4.16 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 8	4-10
Gambar 4.17 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 8	4-11
Gambar 4.18 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 8	4-11
Gambar 4.19 Kurva pembelajaran U-Net menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 7e-4 dan <i>batch size</i> 8	4-12
Gambar 4.20 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 2	4-13
Gambar 4.21 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 2	4-13
Gambar 4.22 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 2	4-14
Gambar 4.23 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 2	4-14
Gambar 4.24 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 2e-4 dan <i>batch size</i> 2	4-15
Gambar 4.25 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 3e-4 dan <i>batch size</i> 2	4-15
Gambar 4.26 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 2	4-16
Gambar 4.27 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 2	4-16

Gambar 4.28 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 2.....	4-17
Gambar 4.29 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 7e-4 dan <i>batch size</i> 2.....	4-17
Gambar 4.30 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 4.....	4-18
Gambar 4.31 Kurva pembelajaran U-Net menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 8.....	4-18
Gambar 4.32 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 4.....	4-19
Gambar 4.33 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 4.....	4-19
Gambar 4.34 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 4.....	4-20
Gambar 4.35 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 4.....	4-20
Gambar 4.36 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 2e-4 dan <i>batch size</i> 4.....	4-21
Gambar 4.37 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 3e-4 dan <i>batch size</i> 4.....	4-21
Gambar 4.38 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 4.....	4-22
Gambar 4.39 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 4.....	4-22
Gambar 4.40 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 4.....	4-23
Gambar 4.41 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 7e-4 dan <i>batch size</i> 4.....	4-23
Gambar 4.42 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 8e-4 dan <i>batch size</i> 4.....	4-24

Gambar 4.43 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 9e-4 dan <i>batch size</i> 4.....	4-24
Gambar 4.44 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> Yang et al (2018) dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 8.....	4-25
Gambar 4.45 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 4.....	4-26
Gambar 4.46 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 4.....	4-26
Gambar 4.47 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 4.....	4-27
Gambar 4.48 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 4.....	4-27
Gambar 4.49 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 2e-4 dan <i>batch size</i> 4.....	4-28
Gambar 4.50 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 3e-4 dan <i>batch size</i> 4.....	4-28
Gambar 4.51 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 4.....	4-29
Gambar 4.52 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 4.....	4-29
Gambar 4.53 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 4.....	4-30
Gambar 4.54 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 7e-4 dan <i>batch size</i> 4.....	4-30
Gambar 4.55 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 8e-4 dan <i>batch size</i> 4.....	4-31
Gambar 4.56 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 9e-4 dan <i>batch size</i> 4.....	4-31
Gambar 4.57 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> pribadi dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 8.....	4-32

Gambar 4.58 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-2 dan <i>batch size</i> 4	4-33
Gambar 4.59 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-3 dan <i>batch size</i> 4	4-33
Gambar 4.60 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-4 dan <i>batch size</i> 4	4-34
Gambar 4.61 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 1e-5 dan <i>batch size</i> 4	4-34
Gambar 4.62 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 2e-4 dan <i>batch size</i> 4	4-35
Gambar 4.63 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 3e-4 dan <i>batch size</i> 4	4-35
Gambar 4.64 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 4e-4 dan <i>batch size</i> 4	4-36
Gambar 4.65 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 4	4-36
Gambar 4.66 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 6e-4 dan <i>batch size</i> 4	4-37
Gambar 4.67 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 7e-4 dan <i>batch size</i> 4	4-37
Gambar 4.68 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 8e-4 dan <i>batch size</i> 4	4-38
Gambar 4.69 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 9e-4 dan <i>batch size</i> 4	4-38
Gambar 4.70 Kurva pembelajaran DeepLabV3+ menggunakan <i>dataset</i> gabungan dengan <i>learning rate</i> 5e-4 dan <i>batch size</i> 8	4-39
Gambar 4.71 Tes kinerja retak sederhana pada arsitektur U-Net dengan <i>dataset</i> Yang et al (2018)	4-42
Gambar 4.72 Tes kinerja retak berongga pada arsitektur U-Net dengan <i>dataset</i> Yang et al (2018)	4-43

Gambar 4.73 Tes kinerja retak kompleks pada arsitektur U-Net dengan <i>dataset</i> Yang et al (2018).....	4-44
Gambar 4.74 Tes kinerja retak sederhana pada arsitektur U-Net dengan <i>dataset</i> pribadi.....	4-45
Gambar 4.75 Tes kinerja retak berongga pada arsitektur U-Net dengan <i>dataset</i> pribadi.....	4-46
Gambar 4.76 Tes kinerja retak kompleks pada arsitektur U-Net dengan <i>dataset</i> pribadi.....	4-47
Gambar 4.77 Tes kinerja retak sederhana pada arsitektur U-Net dengan <i>dataset</i> gabungan.....	4-48
Gambar 4.78 Tes kinerja retak berongga pada arsitektur U-Net dengan <i>dataset</i> gabungan.....	4-49
Gambar 4.79 Tes kinerja retak kompleks pada arsitektur U-Net dengan <i>dataset</i> gabungan.....	4-50
Gambar 4.80 Tes kinerja retak sederhana pada arsitektur DeepLabV3+ dengan <i>dataset</i> Yang et al (2018).....	4-51
Gambar 4.81 Tes kinerja retak berongga pada arsitektur DeepLabV3+ dengan <i>dataset</i> Yang et al (2018).....	4-52
Gambar 4.82 Tes kinerja retak kompleks pada arsitektur DeepLabV3+ dengan <i>dataset</i> Yang et al (2018).....	4-53
Gambar 4.83 Tes kinerja retak sederhana pada arsitektur DeepLabV3+ dengan <i>dataset</i> pribadi	4-54
Gambar 4.84 Tes kinerja retak berongga pada arsitektur DeepLabV3+ dengan <i>dataset</i> pribadi	4-55
Gambar 4.85 Tes kinerja retak kompleks pada arsitektur DeepLabV3+ dengan <i>dataset</i> pribadi	4-56
Gambar 4.86 Tes kinerja retak sederhana pada arsitektur DeepLabV3+ dengan <i>dataset</i> gabungan	4-57
Gambar 4.87 Tes kinerja retak berongga pada arsitektur DeepLabV3+ dengan <i>dataset</i> gabungan	4-58

Gambar 4.88 Tes kinerja retak kompleks pada arsitektur DeepLabV3+ dengan <i>dataset</i> gabungan.....	4-59
Gambar 4.89 Perhitungan panjang retak dan lebar retak	4-60



DAFTAR TABEL

Tabel 4.1 <i>Hyperparameter</i> untuk arsitektur U-Net.....	4-39
Tabel 4.2 <i>Hyperparameter</i> untuk arsitektur DeepLabV3+	4-39
Tabel 4.3 Nilai akurasi, F1, <i>precision</i> , dan <i>recall</i> untuk arsitektur U-Net.....	4-40
Tabel 4.4 Nilai akurasi, F1, <i>precision</i> , dan <i>recall</i> untuk arsitektur DeepLabV3+ ...	4-40
Tabel 5.1 Nilai akurasi, F1, <i>precision</i> , dan <i>recall</i> untuk arsitektur U-Net dan DeepLabV3+	5-1
Tabel 5.2 <i>Hyperparameter</i> untuk arsitektur U-Net dan DeepLabV3+	5-2



BAB 1

PENDAHULUAN

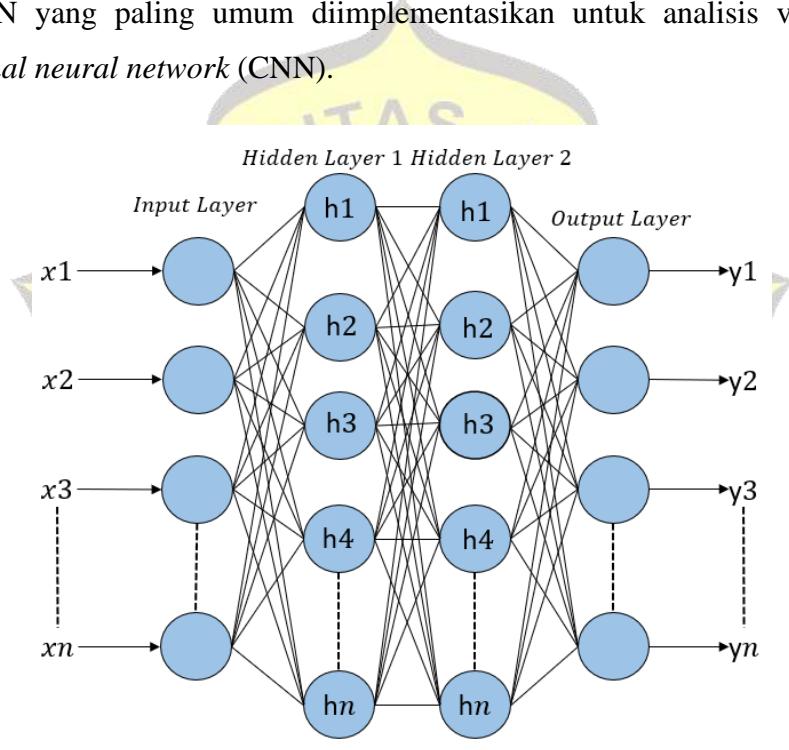
1.1 Latar Belakang

Pemeriksaan kondisi infrastruktur secara berkala sangat diperlukan untuk mencegah kondisi infrastruktur yang kurang baik, menjamin keamanan, dan memperpanjang umur layan infrastruktur tersebut. Pemeriksaan kondisi infrastruktur di Indonesia umumnya dilakukan secara manual oleh tenaga ahli di mana tenaga ahli tersebut melakukan inspeksi secara visual di lapangan dan memberikan penilaian tentang kondisi infrastruktur tersebut berdasarkan pengalaman dan pengetahuan yang mereka miliki. Namun, metode ini memiliki keterbatasan, yaitu tenaga ahli di Indonesia yang masih terbatas, biaya yang mahal, waktu yang relatif lama, dan persepsi setiap tenaga kerja ahli yang berbeda-beda dalam memberikan penilaian. Salah satu cara untuk mengatasi keterbatasan ini adalah dengan menggunakan kemampuan komputer mulai dari tahap dokumentasi sampai dengan penilaian kondisi infrastruktur tersebut.

Dewasa ini, pemanfaatan teknologi komputer untuk inspeksi kondisi eksisting suatu struktur telah banyak dikembangkan, misalnya pemanfaatan *image processing techniques* (IPTs) untuk mendeteksi retak dengan menggunakan berbagai macam filter visual. Namun, teknologi ini kurang dapat beradaptasi dengan berbagai kondisi lingkungan, misalnya adanya gangguan intensitas cahaya sekitar, *noise*, distorsi pada gambar, serta tekstur permukaan objek yang ditinjau. IPT dengan performa tinggi juga membutuhkan pemrograman yang ekstensif dan kapasitas komputasi yang besar.

Salah satu teknologi komputer yang berkembang dengan sangat pesat saat ini adalah kecerdasan buatan. Salah satu cabang dari kecerdasan buatan adalah *machine learning*. *Machine learning* dapat didefinisikan sebagai kemampuan komputer untuk bisa belajar sendiri dalam memutuskan sesuatu tanpa diprogram secara eksplisit seperti pemrograman tradisional. Cara pembelajaran dari *machine learning* mirip dengan otak manusia, yaitu belajar dari contoh-contoh dan pengalaman yang dimiliki.

Machine learning memiliki kemampuan untuk membuat model matematika dengan menganalisis pola-pola intrinsik dari *data training* atau pengalaman yang diberikan. Pendekatan *machine learning* yang paling populer dewasa ini adalah *deep learning*. *Deep learning* dibangun menggunakan *artificial neural network* (ANN) yang terinspirasi dari jaringan neuron pada otak manusia. Ilustrasi dari *artificial neural network* dapat dilihat pada Gambar 1.1. Pada skripsi ini, *deep learning* akan diaplikasikan pada tahap yang paling sederhana dari tahap-tahap pemeriksaan kondisi eksisting infrastruktur, yaitu mendeteksi retak pada permukaan beton. Salah satu model ANN yang paling umum diimplementasikan untuk analisis visual adalah *convolutional neural network* (CNN).

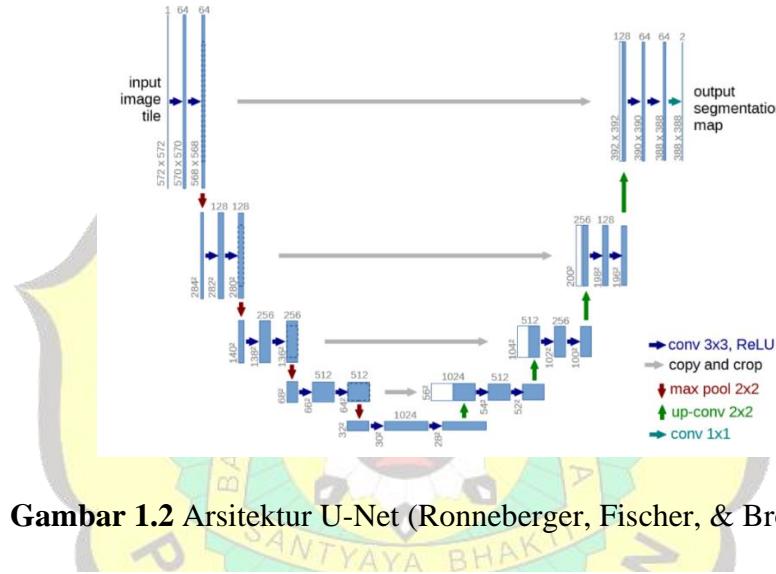


Gambar 1.1 Artificial Neural Network

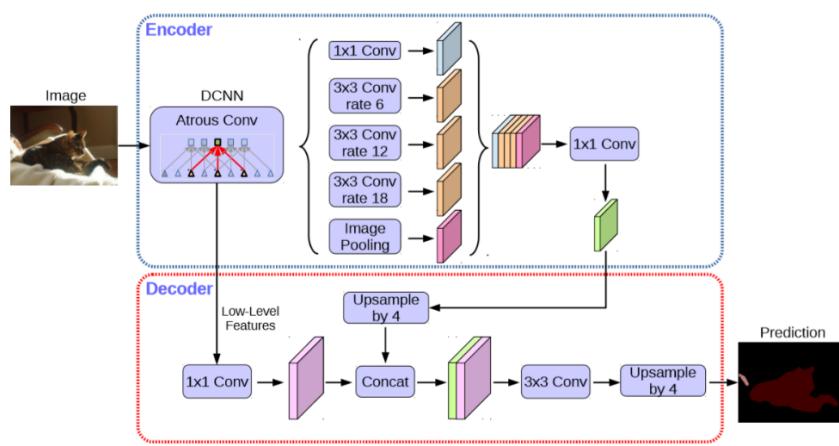
1.2 Inti Permasalahan

Pada skripsi ini, CNN digunakan untuk mendeteksi retak pada beton dengan ketelitian tingkat piksel. Ketelitian tingkat piksel dapat dicapai dengan menggunakan algoritme *semantic image segmentation*. Beberapa arsitektur *semantic image segmentation* yang populer saat ini adalah U-Net (Ronneberger, Fischer, & Brox, 2015) dan DeepLabV3+ (Chen, Zhu, Papandreou, Schroff, & Adam, 2018). U-Net

merupakan arsitektur yang paling umum digunakan untuk segmentasi gambar biomedis. U-Net telah terbukti akurasinya setelah diimplementasikan untuk mendeteksi objek seperti sel makhluk hidup. Arsitektur dari U-Net dapat dilihat pada Gambar 1.2. DeepLabV3+ merupakan arsitektur yang dikembangkan oleh *google* untuk mendeteksi objek secara multi skala. DeepLabV3+ menggunakan modul *atrous spatial pyramid pooling network* (ASPP) dengan skala yang berbeda-beda untuk melokalisasi fitur yang susah dideteksi oleh arsitektur lain. Arsitektur dari DeepLabV3+ dapat dilihat pada Gambar 1.3.



Gambar 1.2 Arsitektur U-Net (Ronneberger, Fischer, & Brox, 2015)



Gambar 1.3 Arsitektur DeepLabV3+ (Chen, Zhu, Papandreou, Schroff, & Adam, 2018)

Namun, arsitektur yang terbaik untuk mendeteksi retak pada beton perlu dipelajari lebih lanjut. Di samping itu, performa CNN tergantung pada dataset pelatihan yang digunakan. Kualitas dari dataset pelatihan akan berkontribusi besar terhadap performa dari model. Pada skripsi ini, pengaruh kualitas dataset pelatihan juga akan dipelajari.

1.3 Tujuan Penulisan

Tujuan dari penulisan skripsi ini adalah sebagai berikut:

1. membuat program *convolutional neural network* untuk mendeteksi retak pada permukaan beton dengan arsitektur U-Net dan DeepLabV3+.
2. membandingkan performa dari arsitektur U-Net dan DeepLabV3+ dalam mendeteksi retak pada permukaan beton.
3. mempelajari pengaruh kualitas *dataset training* terhadap akurasi dari model *neural network* untuk mendeteksi retak pada permukaan beton.
4. merancang kombinasi *hyperparameter* untuk meningkatkan performa arsitektur *neural network* dalam mendeteksi retak pada permukaan beton.
5. merancang algoritme untuk menghitung lebar dan panjang retak berdasarkan hasil yang diperoleh dari model *neural network*.

1.4 Batasan Masalah

1. model *neural network* yang dirancang hanya mendeteksi retak pada permukaan beton;
2. jenis *neural network* yang dirancang hanya berbasis *convolutional neural network*;
3. jenis model *convolutional neural network* yang dirancang hanya mengoperasikan *semantic image segmentation* pada gambar.
4. *dataset training* yang digunakan diperoleh dari Yang et al (2018) dan diri sendiri.

1.5 Metode Penelitian

Metode penelitian yang digunakan:

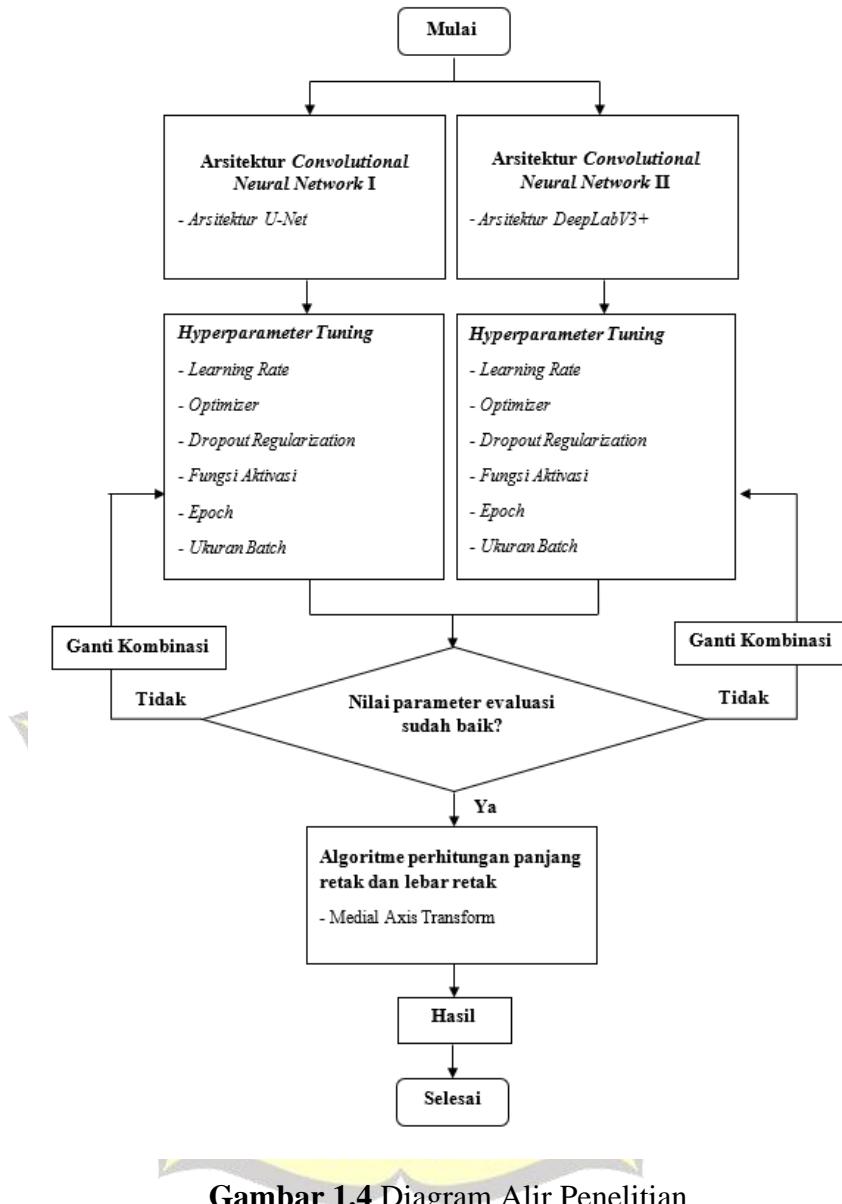
1. Studi Pustaka

Landasan teori bersumber dari buku-buku pustaka, makalah ilmiah, dan platform pembelajaran *online*.

2. Studi Analisis

Perancangan arsitektur *neural network* dilakukan menggunakan *framework machine learning tensorflow*. Langkah-langkah analisis dilakukan dengan diagram alir sebagai berikut:





Gambar 1.4 Diagram Alir Penelitian

1.6 Sistematika Penulisan

Sistematika pembahasan pada skripsi ini terdiri dari lima bab, yaitu:

Bab 1: Pendahuluan

Bab ini berisi tentang latar belakang, inti permasalahan, tujuan penelitian, pembatasan masalah, metode penelitian, dan sistematika penulisan skripsi.

Bab 2: Landasan Teori

Bab ini membahas teori-teori yang mendukung dalam penggerjaan skripsi ini. Teori-teori yang akan dibahas adalah *machine learning*, *deep learning*, *artificial neural network*, *convolutional neural network*, *hyperparameter tuning*, dan *medial axis transform*.

Bab 3: Pemodelan Neural network

Bab ini membahas pemodelan arsitektur *neural network* yang akan diterapkan pada permasalahan. Arsitektur yang akan dimodelkan adalah U-Net dan DeepLabV3+. Terdapat 3 *dataset* pelatihan, yaitu *dataset* yang bersumber dari Yang et al (2018), *dataset* pribadi, dan *dataset* gabungan. *Dataset* Yang et al (2018) terdiri dari 776 foto retak, sedangkan *dataset* pribadi terdiri dari 140 foto retak. *Dataset* gabungan merupakan gabungan dari *dataset* Yang et al (2018) dan *dataset* pribadi.

Bab 4: Hasil Analisis dan Pembahasan

Bab ini membahas perbandingan performa dari U-Net dan DeepLabV3+ untuk mendeteksi retak, pengaruh *hyperparameter*, pengaruh data pelatihan, dan performa algoritme lebar dan panjang retak.

Bab 5: Kesimpulan dan Saran

Bab ini berisi kesimpulan dari isi skripsi dan saran untuk pengembangan topik yang dapat digunakan untuk penelitian selanjutnya.

