

**PERANCANGAN SISTEM INSPEKSI KERUSAKAN
MENGUNAKAN CITRA PADA JARINGAN PIPA BAWAH
LAUT**

SKRIPSI

**DIAJUKAN UNTUK MEMENUHI PERSYARATAN
MEMPEROLEH GELAR SARJANA TEKNIK PADA DEPARTEMEN
TEKNIK SISTEM PERKAPALAN
FAKULTAS TEKNIK UNIVERSITAS HASANUDDIN**



ALAN FHAJOENG RAMADHAN

D33115301

DEPARTEMEN TEKNIK SISTEM PERKAPALAN

FAKULTAS TEKNIK

UNIVERSITAS HASANUDDIN

GOWA

2021

LEMBAR PENGESAHAN (TUGAS AKHIR)

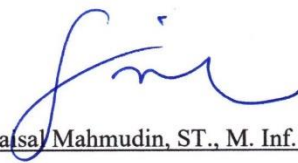
**Perancangan Sistem Inspeksi Kerusakan Menggunakan Citra pada Jaringan
Pipa Bawah Laut**

Disusun dan diajukan oleh

**Alan Fhajoeng Ramadhan
D331 15 301**

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian Studi
Program Sarjana Program Studi Teknik Sistem Perkapalan
Fakultas Teknik Universitas Hasanuddin
pada tanggal 21-10-2021
dan dinyatakan telah memenuhi syarat kelulusan
Menyetujui,

Pembimbing Utama,



Dr. Eng., Faisal Mahmudin, ST., M. Inf. Tech., M. Eng
Nip. 198102112005011003

Pembimbing Pendamping



Surya Hariyanto, ST., MT.
Nip. 197102021998021001

Ketua Departemen Teknik Sistem Perkapalan



Dr. Eng. Faisal Mahmuddin, ST., M. Inf. Tech., M. Eng.
Nip. 198102112005011003

HALAMAN PERSETUJUAN

Judul Skripsi : PERANCANGAN SISTEM INSPEKSI
KERUSAKAN MENGGUNAKAN CITRA PADA JARINGAN PIPA
BAWAH LAUT

Nama Mahasiswa : ALAN FHAJOENG RAMADHAN
NIM : D331 15 301

Skripsi ini telah direvisi dan disetujui oleh Panitia Ujian Sarjana Program Strata Satu (S1) Teknik Sistem Perkapalan Fakultas Teknik Universitas Hasanuddin untuk memenuhi persyaratan memperoleh gelar Sarjana Teknik.

Panitia Ujian Sarjana

Tanda Tangan

Ketua : Dr.Eng.Ir. Faisal Mahmuddin, M.Inf.,Tech., M.Eng
NIP : 19810211 200501 1 003



Sekretaris : Surya Hariyanto, ST., MT.
NIP : 19710202 200012 1 001



Anggota : Rahimuddin, ST., MT., Ph.D
NIP : 19710825 199903 1 002



Anggota : Baharuddin, ST., MT.
NIP : 19720202 199802 1 001



PERNYATAAN KEASLIAN SKRIPSI

Yang bertanda tangan dibawah ini:

Nama : Alan Fhajoeng Ramadhan

NIM : D331 15 301

Departemen : Teknik Sistem Perkapalan

Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Perancangan Sistem Inspeksi Kerusakan Menggunakan Citra pada
Jaringan Pipa Bawah Laut

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain bahwa skripsi yang saya tulis ini benar benar merupakan hasil karya saya sendiri.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan saya tersebut.

Makassar, 21 Oktober 2021

Yang menyatakan



(Alan Fhajoeng Ramadhan)

ABSTRAK

Pipa Offshpore merupakan suatu teknologi untuk mengalirkan fluida seperti minyak, gas atau air dalam jumlah besar dan jarak yang jauh melalui laut atau daerah lepas pantai. Karena medan yang dilalui oleh saluran pipa sangat beragam, yakni mulai dari dalam laut, dataran rendah, lembah, dan di dalam tanah, maka dalam pengoperasiannya akan banyak ditemui berbagai macam persoalan, baik masalah kelelahan (*fatigue*), korosi (*corrosion*), dan retak (*crack*). Dari ketiga jenis permasalahan yang biasa dialami pipa, maka korosi dan keretakan menjadi persoalan yang sangat diperhatikan karena efek lanjutan dari korosi dan retak ini bisa mengakibatkan kebocoran dan ledakan yang sangat merugikan baik dari segi struktur maupun ekonomis. Melihat kondisi permasalahan tersebut, maka dirancang sebuah sistem inspeksi berbasis pengenalan citra kerusakan pada pipa bawah laut dengan menggunakan metode Convolutional Neural Network (CNN) pada bahasa pemrograman Python. Metode CNN terdiri dari tiga tahap. Tahap pertama adalah klasifikasi citra kerusakan yang telah dibagi menjadi dua kategori yaitu “Corrosion” dan “Crack” dengan masing-masing data latih sebanyak 1200 gambar. Selanjutnya dilakukan *data training* menggunakan metode *deep-feed forward*. Tahap kedua adalah tahap klasifikasi dengan bobot dan bias yang diperbarui *training epoch*. Tahap terakhir adalah tahap pengujian *Data Test* untuk menilai tingkat keberhasilan proses *training* sebelumnya. Hasil uji coba dari klasifikasi citra kerusakan pipa (Crack dan Corrosion) dengan arsitektur CNN yang memiliki 2 lapisan konvolusi, 32 filter, dan 1 lapisan *fully connected* menghasilkan nilai akurasi mencapai 100% dan nilai eror mencapai $5.21e^{-5}$ % dalam 10 epoch. Sehingga dapat disimpulkan bahwa metode CNN yang digunakan pada Tugas Akhir ini mampu melakukan klasifikasi dengan baik.

Kata Kunci: Pipa, Crack, Corrosion, Python, Convolution Neural Network

ABSTRACT

Offshore pipeline is a technology for flowing fluids such as oil, gas or water in large quantities and for long distances through the sea or offshore areas. Because the terrain traversed by the pipeline is very diverse, starting from the sea, the lowlands, valleys, and in the ground, in its operation there will be many kinds of problems, both fatigue, corrosion and cracking problems. Of the three types of problems that can occur in pipes, corrosion and cracking are issues of high concern because the continued effects of corrosion and cracking can result in leakage and explosion which are very detrimental both in terms of structure and economics. Based on the condition of that problems, an inspection system based on the recognition of damage of the underwater pipeline was designed using the Convolutional Neural Network (CNN) method and using the Python for programming language. The CNN method consists of three stages. The first stage is the classification of damage images that have been divided into two categories, namely "Corrosion" and "Crack" with each training data of 1200 images. Then the training is conducted using the deep-feed forward method. The second stage is the classification stage with weights and biases that are updated epoch training. The last stage is the stage of testing the Data Test to assess the success of the previous training process. Test results from the classification of pipe damage images (Crack and Corrosion) with the CNN architecture which has 2 convolutional layers, 32 filters, and 1 fully connected layer produce an accuracy value of up to 100% and an error value reaching 5.21×10^{-5} % in 10 epochs. So, it can be concluded that the CNN method used in this research is able to do a good classification.

Keywords: Pipeline, Crack, Corrosion, Python, Convolution Neural Network

KATA PENGANTAR

Assalamu ‘alaikum Warahmatullahi Wabarakatuh

Alhamdulillah rabbil’alamin, dengan segala kerendahan hati, penulis panjatkan puji dan syukur kepada Allah SWT yang telah melimpahkan rahmat, hidayah, dan karunia-Nya, sehingga terselesaikanlah penulisan Tugas Akhir ini dengan judul:

“PERANCANGAN SISTEM INSPEKSI KERUSAKAN MENGGUNAKAN CITRA PADA JARINGAN PIPA BAWAH LAUT”

Penulisan Tugas Akhir ini dimaksudkan untuk memenuhi salah satu syarat Program Strata I pada Program Studi Teknik Sistem Perkapalan Jurusan Perkapalan Fakultas Teknik Universitas Hasanuddin. Tugas Akhir ini disusun berdasarkan kajian literatur, praktik dan juga diskusi.

Dalam penyajian Tugas Akhir ini, penulis menyadari masih belum mendekati kesempurnaan. Oleh karena itu, penulis sangat mengharapkan koreksi dan saran yang sifatnya membangun sebagai bahan masukan yang bermanfaat demi perbaikan dan peningkatan diri dalam bidang ilmu pengetahuan.

Penulis menyadari, berhasilnya studi dan penyusunan Tugas Akhir ini tidak lepas dari bantuan berbagai pihak yang telah memberikan semangat dan do’a kepada penulis dalam menghadapi setiap tantangan, sehingga sepatutnya pada kesempatan ini penulis menghaturkan rasa terima kasih kepada:

1. Allah SWT dengan segala limpahan rahmat-Nya yang tak henti menemani menyelesaikan penelitian ini.
2. Keluarga penulis, Ayahanda Hamzah Maleke dan Ibunda A. Leni Sari yang senantiasa memberikan dukungan baik moril maupun materil serta doa yang tiada hentinya kepada penulis. Dan adik-adik penulis serta keluarga besar penulis yang juga tak hentinya memberikan dukungan dalam menyelesaikan penelitian ini.
3. Dr.Eng. Faisal Mahmuddin, S.T., M. Inf. Tech, M. Eng, selaku ketua Departemen Teknik Sistem Perkapalan Fakultas Teknik Universitas Hasanuddin.
4. Dr.Eng. Faisal Mahmuddin, S.T., M. Inf. Tech, M. Eng, selaku dosen pembimbing utama yang telah meluangkan waktu dan pikiran serta perhatiannya guna memberikan bimbingan dan pengarahan demi terselesaikan penelitian ini.
5. Surya Hariyanto, S.T., M.T., selaku dosen pembimbing kedua sekaligus Pembimbing Akademik yang selalu memberikan saran dan support serta meluangkan waktu dan pikran guna memberikan bimbingan dan pengarahan demi terselesaikannya penelitian ini.
6. Para dosen penguji Tugas Akhir yang telah memberikan saran dan masukan yang terbaik pada penelitian ini.
7. David J. Malan, Brian Yu, dan Tim CS50 dari Harvard University, selaku pembimbing dalam bidang *Computer Science* yang selalu memberikan

saran dan support serta meluangkan waktu dan pikiran guna memberikan bimbingan dan pengarahan demi terselesaikannya penelitian ini.

8. Tim Oates, Casey Obrien, dan Adrian Rosebrock dari PyImageSearch, selaku pembimbing dalam bidang *Artificial Intelligence* yang selalu memberikan saran dan support serta meluangkan waktu dan pikiran guna memberikan bimbingan dan pengarahan demi terselesaikannya penelitian ini.
9. Bapak dan Ibu Dosen Jurusan Perkapalan Fakultas Teknik Universitas Hasanuddin atas ilmu dan wawasan yang diberikan selama masa studi penulis.
10. Staf Tata Usaha Departemen Teknik Sistem Perkapalan yang telah membantu segala aktivitas akademik dan administrasi dengan baik selama perkuliahan serta dalam penyelesaian Tugas Akhir ini.
11. Rekan-rekan mahasiswa Jurusan Teknik Perkapalan khususnya WINDLAS5. Rekan-rekan Laboratorium Sistem Bangunan Laut, Laboratorium Listrik dan Kendali, Laboratorium Propulsi, dan Laboratorium Permesinan Kapal, yang telah memberikan pengalaman berharga selama penulis menjadi seorang mahasiswa. Sahabat-sahabat di lingkaran kecil penulis yang senantiasa menjadi wadah bertukar pikiran. Dan tak lupa pula penulis sampaikan terima kasih kepada kanda-kanda senior dan dinda-dinda junior atas motivasi dan dukungannya sehingga penulis dapat belajar banyak dari mereka.

12. Komunitas CS50, HackerOne, PyImageSearch, IBM Developer, Google Developer, Amazon Developer, AWS Southeast Asia, SentDex, serta Devpost yang telah memberikan pengalaman dan bimbingan yang mengantarkan dalam memahami ilmu pemrograman sehingga memberikan gambaran secara keseluruhan lingkungan *Computer Science*.

Akhir kata, semoga hasil penelitian ini dapat dimanfaatkan dan dapat memberikan sumbangsih pemikiran untuk perkembangan pengetahuan bagi penulis maupun bagi pihak yang berkepentingan.

Wassalamu ‘alaikum Warahmatullahi Wabarakatuh

Makassar, 1 Februari 2021

Alan Fhajoeng Ramadhan

NIM. D33115301

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI.....	ii
HALAMAN PERSETUJUAN.....	iii
PERNYATAAN KEASLIAN.....	iv
ABSTRAK	v
ABSTRACT	vi
KATA PENGANTAR	vii
DAFTAR ISI.....	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL.....	xvi
DAFTAR SIMBOL.....	xvii
BAB 1.....	1
PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
1.6 Sistematika Penulisan.....	4
BAB 2.....	6
LANDASAN TEORI.....	6
2.1 Penyebab Keretakan Pada Pipa	6
2.2 Korosi Retak Tegang (Stress Corrosion Cracking (SCC)).....	7
2.3 Inspeksi Pipa Bawah Laut	9
2.4 Computer Vision	11
2.4.1 Proses penangkapan citra (<i>Image acquisition</i>).....	14
2.4.2 Proses pengenalan citra (<i>Image Processing</i>).....	15
2.4.3 Analisa data citra (<i>Image Analysis</i>).....	16
2.4.4 Proses pemahaman data citra (<i>Image Understanding</i>).....	16
2.5 OpenCV.....	17
2.6 Convolutional Neural Network (CNN)	19
2.6.1 Pengenalan Convolutional Neural Network (CNN).....	19

2.6.2	Konsep CNN	20
2.6.3	Arsitektur Jaringan CNN	22
BAB 3	30
METODE PENELITIAN		30
3.1	Waktu Penelitian	30
3.2	Metode Perancangan	30
3.2.1	Studi literatur.....	31
3.2.2	Analisa Kebutuhan.....	31
3.3	Alat dan Bahan Penelitian	32
3.4	Perancangan Sistem.....	32
3.4.1	Blok Diagram Sistem	33
3.4.2	Pelatihan Data (<i>Training Data</i>).....	33
3.4.3	Pengenalan (<i>Recognition</i>)	39
3.5	Pengujian Sistem	43
3.6	Dokumentasi	44
BAB 4	45
HASIL DAN PEMBAHASAN		45
4.1	Arsitektur Model CNN	46
4.2	Implementasi CNN.....	59
4.2.1	Melatih Data (<i>Data Training</i>)	60
4.2.2	Validasi Data (<i>Data Validation</i>)	62
4.2.3	Test Data (<i>Data Test</i>).....	64
BAB 5	73
PENUTUP		73
5.1	Kesimpulan	73
5.2	Saran	74
DAFTAR PUSTAKA		75
Lampiran 1: <i>Code</i> Sistem Inspeksi Kerusakan Jaringan Pipa Bawah Laut		77
Lampiran 2: Proses Kerja Sistem Inspeksi Kerusakan Jaringan Pipa Bawah Laut		92
Lampiran 3: Perhitungan Matematik Sistem Inspeksi Kerusakan Jaringan Pipa Bawah Laut		103

DAFTAR GAMBAR

Gambar 2.1 Korosi lubang	8
Gambar 2.2 Alat yang digunakan dalam General Imaging	10
Gambar 2.3 Rov dalam metod GVI	11
Gambar 2.4. Hubungan Antara Computer Vision, Pengolahan Citra, dan Pengenalan Pola	12
Gambar 2.5 Proses Pada Computer Vision	13
Gambar 2.6 Struktur dan konten OpenCV	18
Gambar. 2.7. Arsitektur MLP Sederhana	20
Gambar.2.8 Proses Konvolusi pada CNN	22
Gambar.2.9 Operasi Konvolusi	24
Gambar 2.10. Operasi Max Pooling	25
Gambar 2.11 Distribusi Fungsi Sigmoid	27
Gambar 2.12 Distribusi Fungsi <i>ReLU</i>	29
Gambar 3.1 Blok diagram sistem	33
Gambar 3.2. (a) Keretakan pada permukaan pipa, (b) Korosi pada permukaan pipa	34
Gambar 3.3 <i>Code</i> untuk pengelompokan kelas citra	35
Gambar 3.4 Hasil perubahan Data citra menjadi type RGB/ <i>true color</i>	35

Gambar 3.5 <i>Code</i> untuk proses pengelompokan citra berdasarkan nilai indeks kelas	36
Gambar 3.6 <i>Code</i> untuk menyimpan data citra menjadi dua tipe file	37
Gambar 3.7 Nilai scalar pada citra RGB	37
Gambar 3.8 <i>Code</i> untuk mengubah nilai scalar citra RGB agar mudah dalam proses <i>Training Data</i>	38
Gambar 3.9 <i>Code</i> model arsitektur jaringan CNN	39
Gambar 3.10 <i>Code</i> untuk menyimpan hasil <i>Training Data</i>	39
Gambar 3.11 Ukuran Citra diubah menjadi 1000 x 1000 piksel	40
Gambar 3.12 <i>Code</i> untuk mengubah ukuran Citra menjadi 1000 x 1000 piksel	41
Gambar 3.13 Hasil <i>Recognition</i> pada gambar uji	41
Gambar 3.14 <i>Code</i> untuk tahap <i>Recognition</i> untuk pengujian gambar	42
Gambar 3.15 <i>Code</i> untuk pengambilan citra pada pengujian <i>Real-time</i>	43
Gambar 3.16 Proses pengambilan citra pada pengujian <i>Real-time</i>	43
Gambar 3.17 Hasil <i>Recognition</i> pada pengujian <i>Real-time</i>	44
Gambar 3.18 <i>Code</i> untuk tahap <i>Recognition</i> untuk pengujian <i>Real-time</i>	44
Gambar 4.1. (a) Keretakan pada permukaan pipa, (b) Korosi pada permukaan pipa	46

Gambar 4.2 Arsitektur CNN yang digunakan.....	47
Gambar 4.3 Proses <i>Convolutional Layer 1 (C₁)</i>	49
Gambar 4.4 Proses <i>Convolutional Layer 2 (C₂)</i>	51
Gambar 4.5 Proses <i>Flattening</i> pada <i>Fully Connected Layer</i>	52
Gambar 4.6 Diagram alur <i>Forward Propagation</i>	53
Gambar 4.7 Diagram alur <i>Fully Connected Layer</i>	53
Gambar 4.8 Diagram alur untuk <i>Convolutional Layer 2</i>	55
Gambar 4.9 Diagram alur untuk <i>Convolutional Layer 1</i>	57
Gambar 4.10 Grafik <i>error</i> dan <i>accuracy training data</i>	62
Gambar 4.11 Grafik akurasi dan kesalahan <i>training</i>	64

DAFTAR TABEL

Tabel 4.1 Struktur model CNN	59
Tabel 4.2. Hasil <i>Training Data</i> model CNN	60
Tabel 4.3 Hasil <i>Validation Data</i> model CNN.....	62
Tabel 4.4 Hasil <i>Data Test</i> model CNN	65

DAFTAR SIMBOL

- $\sigma(x)$: Fungsi Sigmoid
- C : Ukuran *Convolutional Layer* (piksel)
- C_o : Jumlah koneksi pada *Convolutional Layer* (koneksi)
- C_p : Ukuran data citra setelah dilakukan *Pooling* (piksel)
- $RI(x)$: Fungsi *Rectified Linear Units*
- L : Nilai *binary cross-entropy loss* (%)
- x : Nilai *data input*
- y : Nilai *output training*
- \bar{Y} : Nilai prediksi
- f : Filter kernel

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Wilayah lautan Indonesia memiliki potensi sumber daya yang harus dapat dimanfaatkan dengan semaksimal mungkin untuk menunjang perekonomian Indonesia. Salah satu potensi sumber daya alamnya yaitu minyak bumi dan gas. Apabila keadaan ini dikaitkan perkembangan industry minyak dan gas di Indonesia yang semakin hari semakin mengalami peningkatan, maka permintaan akan minyak bumi dan gas juga mengalami peningkatan. Oleh karena itu pemerintah harus membangun suatu sistem untuk pendistribusian minyak bumi dan gas secara efektif. Sistem tersebut berupa sarana transportasi yang efektif dan efisien untuk menunjang kelancaran pendistribusian minyak dan gas.

Pembangunan pipa bawah laut merupakan salah satu sarana transportasi yang efektif dan efisien untuk pendistribusian minyak bumi dan gas di laut. Namun beberapa permasalahan teknis pada jaringan pipa bawah laut muncul terutama terkait dengan kondisi alam dan buatan, seperti kondisi geologi yang berhubungan dengan jalur pipa yang memotong patahan/sesar, kondisi kegempaan, morfologi dasar laut yang tidak rata (berundulasi), sebaran sedimen permukaan dasar laut, keberadaan infrastruktur jaringan kabel bawah laut di sekitar lokasi penggelaran pipa yang bersilangan dengan jalur pipa, kondisi arus dan gelombang yang cukup besar, kegiatan pelayaran, kegiatan nelayan dan penggelaran pipa yang tidak sesuai dengan ketentuan perundangan yang berlaku. Aspek-aspek ini akan berpengaruh

secara langsung terhadap stabilitas pipa di dasar laut, terutama terhadap kemungkinan terjadinya bentang bebas pada pipa (*freespan*), gerakan mendatar dan vertikal, kegagalan akibat Lelah (*fatigue*), dan pembengkokan pipa (*buckling*). Terganggunya stabilitas pipa di dasar laut akan berpengaruh secara langsung ataupun tidak langsung terhadap terjadinya kegagalan struktur pada jaringan pipa dan akan merubah karakteristik dari pipa itu sendiri.

Sebagai contoh kasus, jaringan pipa Labuhan Maringgai-Muara Bekasi Transmisi Sumatera-Jawa. Menurut Jalisman (2016), terdapat risiko kerusakan yang terjadi pada jaringan pipa bawah laut yaitu *General Metal Loss* (kegagalan yang diakibatkan *Internal Corrosion/Errosion*) dengan peluang terjadinya risiko sebesar 0.0072, *Mechanical overstress* (kegagalan yang dialami berupa *spanning* dan *upheavel/lateral buckling*) dengan peluang terjadinya risiko sebesar 0.0094, *Impact* (adanya sebuah objek yang mengenai pipa bawah laut) dengan peluang terjadinya resiko sebesar 0.0074, dan *Fatigue* (kegagalan yang disebabkan pembebanan berulang sehingga mengakibatkan keretakan (*crack*) dan memperpendek umur pipa itu sendiri) dengan peluang terjadinya resiko sebesar 0.0071.

Melihat kondisi permasalahan tersebut, penulis merancang sebuah inovasi perangkat teknologi inspeksi dan perawatan perpipaan bawah laut yang dapat mengetahui, dan mengklasifikasikan kerusakan yang tampak secara fisik pada jaringan pipa bawah laut maupun di darat baik disebabkan karena kerusakan berupa *Crack* dan *Corrosion* dengan metode *Convulational Neural Network* yang

menggunakan Analisa jaringan saraf tiruan jenis *Deep-feed forward* mengacu pada kemajuan Teknologi Industry 4.0.

1.2 Rumusan Masalah

Terkait masalah yang timbul maka dapat dibuat rumusan masalah sebagai berikut:

1. Bagaimana mengidentifikasi pipa bawah laut untuk dapat mengetahui kerusakan (*Crack* dan *Corrosion*) yang terjadi pada pipa tersebut.
2. Bagaimana menganalisa hasil identifikasi kerusakan (*Crack* dan *Corrosion*) pada pipa bawah laut untuk diolah menjadi beberapa kelompok permasalahan.
3. Bagaimana mengambil keputusan akan solusi permasalahan yang terjadi pada pipa bawah laut agar dapat menjadi pertimbangan pengambilan langkah perawatan atau perbaikan pada pipa selanjutnya

1.3 Batasan Masalah

Batasan masalah dalam penyusunan skripsi ini adalah:

1. Penelitian ini berfokus pada pembuatan teknologi program identifikasi kerusakan pada pipa bawah laut, dimana proses identifikasi ini menggunakan perangkat kamera.
2. Analisa hasil identifikasi menggunakan program *Oil and Gas Pipelines Inspection and Maintenance Application* (SPECTA) yang akan dibuat oleh penulis menggunakan bahasa pemrograman Python
3. Hasil analisa program akan dibandingkan dengan metode lain yang sudah ada.

1.4 Tujuan Penelitian

Penelitian ini memiliki beberapa tujuan yang hendak dicapai antaranya:

1. Mengidentifikasi pipa bawah laut bertujuan untuk mengklasifikasikan kerusakan (*Crack* dan *Corrosion*) yang terjadi pada pipa bawah laut.
2. Mengembangkan sebuah program menggunakan bahasa pemrograman Python yang dapat menganalisa hasil identifikasi kerusakan pipa bawah laut dengan mengelompokkan permasalahan-permasalahan yang terjadi pada pipa yang akan di tarik solusi permasalahannya
3. Memberikan atau mengambil keputusan dari hasil analisa akan solusi permasalahan yang terjadi pada pipa bawah laut.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Sistem pengenalan kerusakan pada pipa bawah laut ini dapat mempermudah inspektor atau surveyor pada perusahaan Offshore dalam menentukan kerusakan (*Corrosion* dan *Crack*) pada pipa dengan menggunakan citra pipa pada saat survei inspeksi pada pipa bawah laut.
2. Dapat memudahkan dalam pengambilan keputusan akan solusi permasalahan kerusakan yang terjadi pada pipa bawah laut.

1.6 Sistematika Penulisan

Secara garis besar, penulis membagi kerangka masalah dalam beberapa bagian agar pembaca mampu memahami uraian dan makna secara sistematis, maka penelitian ini disusun dengan pola sebagai berikut:

BAB 1 PENDAHULUAN

Bab ini berisi tentang penguraian secara singkat latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan.

BAB 2 TINJAUAN PUSTAKA

Bab ini menjelaskan tentang dasar teori dari kerusakan yang terjadi pada pipa bawah laut, proses inspeksi pada pipa bawah laut, prinsip kerja *Computer Vision*, serta *Arsitektur Convolutional Neural Network*.

BAB 3 METODOLOGI PENELITIAN

Bab ini menjelaskan tentang waktu dan lokasi penelitian, metode yang digunakan pada penelitian yaitu metode studi literatur, alur penelitian yang berupa pengumpulan data, pelatihan data, pengenalan data, serta pengujian data

BAB 4 HASIL DAN PEMBAHASAN

Bab ini menjelaskan hasil pengolahan data dari sistem inspeksi kerusakan menggunakan citra pada jaringan pipa bawah laut untuk mengklasifikasikan citra pada pipa berdasarkan kelas kerusakan yang terjadi pada pipa tersebut.

BAB 5 PENUTUP

Bab ini menjelaskan tentang kesimpulan dari hasil percobaan dan beberapa saran yang diberikan untuk perbaikan pada percobaan yang akan datang.

BAB 2

LANDASAN TEORI

2.1 Penyebab Keretakan Pada Pipa

Pipa merupakan suatu teknologi dalam mengalirkan fluida seperti minyak, gas atau air dalam jumlah besar dan jarak yang jauh melalui laut atau daerah lepas pantai. Menurut Soegiono (2007) karena medan yang dilalui oleh saluran pipa sangat beragam, yakni mulai dari dalam laut, dataran rendah, lembah, dan di dalam tanah, maka dalam pengoperasiannya akan banyak ditemui berbagai macam persoalan, baik masalah kelelahan (*fatigue*), korosi (*corrosion*), dan retak (*crack*). Dari ketiga jenis permasalahan yang biasa dialami pipa, maka korosi dan keretakan menjadi persoalan yang sangat diperhatikan karena efek lanjutan dari korosi dan retak ini bisa mengakibatkan kebocoran dan ledakan yang sangat merugikan baik dari segi struktur maupun ekonomis.

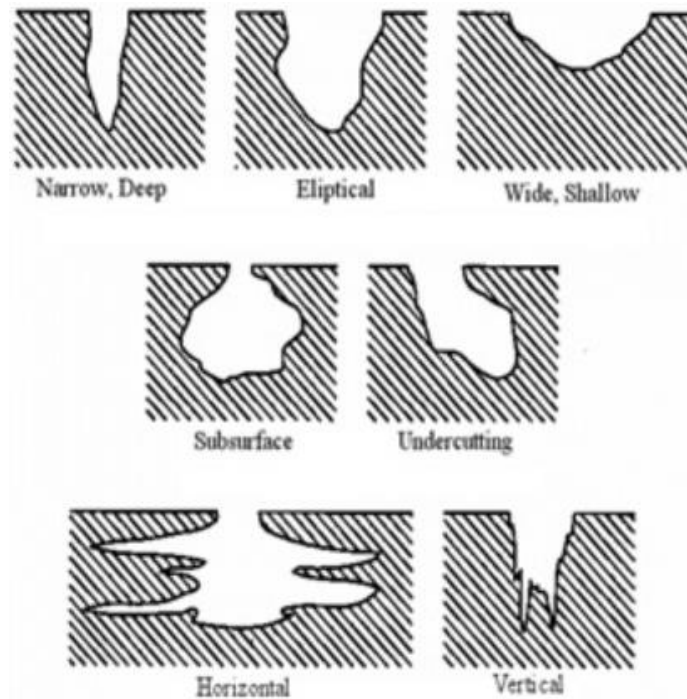
Menurut Putu Aditya Setiawan (2009) korosi adalah permasalahan yang selalu timbul ketika suatu material baik metal maupun non-metal berada pada lingkungan yang korosif. Sedangkan pada pipa bawah laut maka permasalahan korosi menjadi sangat diperhatikan karena konfigurasi pipa yang bermacam-macam dan lingkungan air laut yang sangat korosif. Apabila korosi ini terjadi dan dipadukan dengan adanya tegangan yang mengenainya (*stress* atau *strain*) maka besar kemungkinan suatu pipa akan mengalami keretakan (*crack*) yang akibatnya bisa sangat berbahaya.

Adanya keretakan membuat kekuatan pipa berkurang, penurunan kekuatan pipa sebanding dengan penambahan panjang retak sampai pipa tidak mampu lagi menahan beban yang diberikan fluida. Pada pipa yang terpasang di dalam laut mempunyai peluang terjadi retak (*crack*) yang besar. Hal ini bisa disebabkan karena adanya beban arus (*stress*) maupun karena adanya korosi yang diikuti dengan adanya tekanan fluida pada pipa yang biasa disebut dengan istilah *Stress Corrosion Cracking* (SCC).

2.2 Korosi Retak Tegang (Stress Corrosion Cracking (SCC))

Stress Corrosion Cracking (SCC) adalah keretakan akibat adanya tegangan dan media korosif secara bersamaan (Supomo, 2003). SCC terjadi karena adanya tiga kondisi yang saling berkaitan, yakni adanya tegangan, lingkungan yang korosif, dan temperature yang tinggi. Secara real, kejadian SCC sering terjadi pada peralatan perpipaan pada industry minyak dan gas.

Stress Corrosion bisa meningkat pada material yang dimuati secara mekanis pada lingkungan yang korosif. Permukaan material akan larut pada lokasi dimana permukaan material tersebut mengalami tegangan yang tinggi. Penyebab dari korosi tegangan ini antar lain adalah beban/tegangan, kondisi elektro-kimia yang sangat bervariasi, atau juga bisa karena aktifitas mikrobiologi yang terdapat pada suatu material. Beberapa interaksi ini menyebabkan beban mekanik menjadi semakin berat pada permukaan suatu material dan akibatnya akan terbentuk lubang korosi (korosi sumuran) yang merupakan awal dari terbentuknya keretakan (*crack*) pada suatu material.



Gambar 2.1 Korosi lubang

Mekanisme kegagalan komponen logam akibat retak yang terjadi karena adanya SCC terbagi menjadi dua fase, yakni fase pemicuan dan fase penjalaran. Menurut Jones (1992), Fase pemicuan adalah fase ketika pembangkit tegangan terbentuk. Pada fase ini terjadi serangan terhadap bagian-bagian logam material yang bersifat anoda sehingga mengakibatkan timbulnya cekukan atau lubang. Ketika tegangan melebihi kekuatan luluh material, maka material akan mengalami deformasi plastik, yakni ikatan-ikatan pada struktur kristalnya putus sehingga bentuk material berubah secara permanen. Sedangkan pengertian fase penjalaran adalah fase yang akhirnya menyebabkan kegagalan. Pada fase penjalaran ini dikenal istilah retak awal dan fase perambatan retak.

2.3 Inspeksi Pipa Bawah Laut

Jalur pipa yang sudah ada di dasar laut bukan berarti boleh dibiarkan terpasang begitu saja namun harus dilakukan inspeksi terhadap pipa di dasar laut tersebut. Menurut Pipeline Safety Regulations tahun 1996 kegiatan inspeksi terhadap pipa di dasar laut dilakukan untuk mengendalikan resiko yang akan terjadi pada pipa tersebut. Selain itu, kegiatan inspeksi pada pipa di dasar laut dilakukan agar tidak terjadi kebocoran dan kerusakan yang lebih besar yang akan mengakibatkan tercemarnya lingkungan sekitar, produksi berkurang, dan biaya perbaikan yang mahal.

Berdasarkan peraturan dari ESDM atau Dirjen Migas, survei inspeksi pada pipa dasar laut dikerjakan 1 kali dalam 2 tahun. Tapi dalam pelaksanaannya ada yang 1 kali dalam 1 tahun atau bahkan ada yang 1 kali dalam 3-4 tahun. Tergantung dari kebijakan tiap perusahaan, jenis material permukaan dasar laut, dan kedalaman pipanya. Jarang sekali survei inspeksi pada pipa dasar laut dikerjakan lebih dari 1 kali dalam 1 tahun karena umumnya factor biaya dan tidak ada perubahan yang signifikan pada kondisi pipa dalam kurun waktu kurang dari 1 tahun. Adapun macam-macam metode survei inspeksi pada pipa di dasar laut idealnya ada 2 yaitu General Imaging (GI) dan General Visual Inspection (GVI).

2.3.1 General Imaging (GI)

General Imaging (GI) adalah survei inspeksi semacam quick and dirty survei pada pipa dengan tujuan melakukan pengecekan yang umum saja, seperti

verifikasi posisi, deteksi free span, deteksi pipa yang terkubur (buried), dan debris. Peralatan yang sering dipakai menggunakan prinsip gelombang akustik, seperti Singlebeam Echosounder, Multibeam Echosounder, Side Scan Sonar, Magnetometer, dan Sub-Bottom Profiler. Adapun sensor platform yang sering digunakan adalah DP Vessel, Towfish, ROTV, dan AUV.



Gambar 2.2 Alat yang digunakan dalam General Imaging

Inspeksi pipa di dasar laut menggunakan metode General Imaging biasanya dilakukan setiap 2 tahun sekali. Pada gambar diatas merupakan contoh salah satu dari ROTV yang biasa digunakan untuk survei inspeksi metode GI.

2.3.2 General Visual Inspection (GVI)

General Visual Inspection (GVI) adalah metode survei inspeksi yang komprehensif dengan cara melihat langsung kondisi pipa saat itu juga. Alat yang digunakan pada metode ini adalah ROV yang dilengkapi dengan tiga kamera untuk melihat kondisi kedua sisi pipa dan bagian atas pipa, profiler untuk mengetahui posisi vertical relative terhadap sekitarnya, pipetracker untuk mendeteksi pipa yang terkubur (buried), alat penentuan posisi horizontal, dan sensor-sensor lainnya seperti Side Scan Sonar, Sensor temperature, dan

Multibeam Echosounder. Pada gambar dibawah ini berikut merupakan ilustrasi ROV yang sedang melakukan survei inspeksi pada pipa di dasar laut dengan metode GVI.



Gambar 2.3 Rov dalam metod GVI

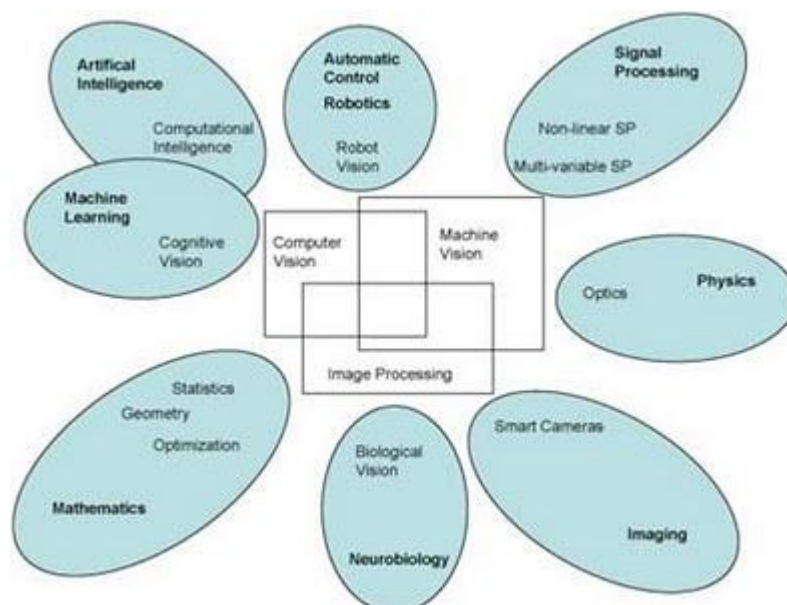
2.4 Computer Vision

Computer vision merupakan proses otomatis yang mengintegrasikan sejumlah besar proses untuk persepsi visual, seperti akuisisi citra, pengolahan citra, pengenalan dan membuat keputusan. *Computer vision* mencoba meniru cara kerja sistem visual manusia (*human vision*) yang sesungguhnya sangat kompleks. Untuk itu, *computer vision* diharapkan memiliki kemampuan tingkat tinggi sebagaimana *human visual*. Kemampuan itu diantaranya adalah:

- Object detection
- Recognition
- Description
- 3D Inference
- Interpreting motion

Computer Vision sering didefinisikan sebagai salah satu cabang ilmu pengetahuan yang mempelajari bagaimana komputer dapat mengenali obyek yang

diamati/ diobservasi. Cabang ilmu ini bersama inteligensia semu (*Artificial Intelligence*) akan mampu menghasilkan sistem intelijen visual (*Visual Intelligence System*). Menurut Priskanta Tarigan (2010), *Computer Vision* adalah kombinasi antara *Pengolahan Citra* dan *Pengenalan Pola* yang hubungan antara ketiganya dapat dilihat pada Gambar 2.4. *Pengolahan citra* merupakan proses awal dari *computer vision*, sedangkan *pengenalan pola* merupakan proses menginterpretasikan citra.

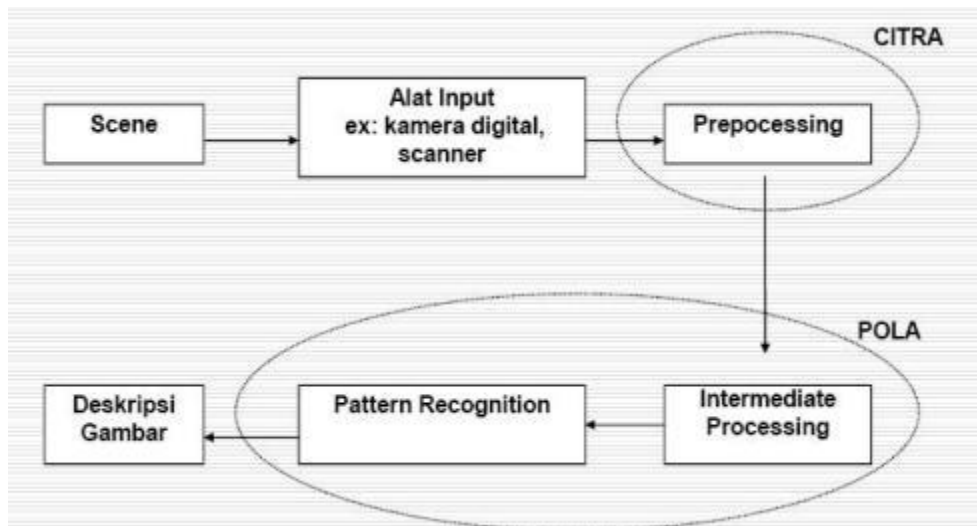


Gambar 2.4. Hubungan Antara *Computer Vision*, *Pengolahan Citra*, dan *Pengenalan Pola*

Menurut Edy Winarno (2009), *Pengolahan Citra (Image Processing)* merupakan bidang yang berhubungan dengan proses transformasi citra/gambar (*image*). Proses ini bertujuan untuk mendapatkan kualitas citra yang lebih baik. Sedangkan *Pengenalan Pola (Pattern Recognition)* berhubungan dengan proses identifikasi obyek pada citra atau interpretasi citra. Proses ini bertujuan untuk mengekstrak informasi/pesan yang disampaikan oleh gambar/citra.

Ada terdapat 3 proses yang terjadi dalam computer vision, yaitu:

- Memperoleh atau mengakuisisi citra digital.
- Operasi pengolahan citra.
- Menganalisis dan menginterpretasi citra dan menggunakan hasil pemrosesan untuk tujuan tertentu, misal memandu robot, mengontrol peralatan, dll.



Gambar 2.5 Proses Pada Computer Vision

Hirarki pada *computer vision* ada 3 tahap, yaitu:

- Pengolahan Tingkat Rendah (Image to image) → Menghilangkan noise, dan peningkatan gambar (*enchament image*).
- Pengolahan Tingkat Menengah (Image to dimbolic) → Kumpulan garis / vektor yang merepresentasikan batas sebuah obyek pada citra.
- Pengolah Tingkat Tinggi (Symbolic to simbolic) → Representasi simbolik batas- batas obyek menghasilkan nama obyek tersebut.

Untuk mendukung tugas dari *computer vision*, aka ada beberapa fungsi pendukung yang ditambahkan ke dalam sistemini, yaitu:

2.4.1 Proses penangkapan citra (*Image acquisition*)

Proses penangkapan citra adalah proses penangkapan informasi visual dan proses pengubahan sinyal analog menjadi data digital, yang siap untuk diproses oleh computer.

- Image Acquisition pada manusia dimulai dengan mata kemudian informasi visual diterjemahkan ke dalam suatu format yang kemudian dapat dimanipulasi oleh otak.
- Senada dengan proses di atas, computer vision membutuhkan sebuah mata untuk menangkap sebuah sinyal visual.
- Umumnyamata pada computer vision adalah sebuah kamera vi
- Kamera menerjemahkan sebuah scene atau image
- Kemudian sinyal listrik ini diubah menjadi bilangan biner yang akan digunakan oleh komputer untuk pemrosesan.
- Keluaran dari kamera adalah berupa sinyal analog, dimana frekuensi dan amplitudonya (frekuensi berhubungan dengan jumlah sinyal dalam satu detik, sedangkan amplitudo berkaitan dengan tingginya sinyal listrik yang dihasilkan) merepresentasikan detail ketajaman (brightness) pada scene.
- Kamera mengamati sebuah kejadian pada satu jalur dalam satu waktu, memindainya dan membaginya menjadi ratusan garis horizontal yang sama.
- Tiap-tiap garis membuat sebuah sinyal analog yang amplitudonya menjelaskan perubahan brightness sepanjang garis sinyal tersebut.

- Karena komputer tidak bekerja dengan sinyal analog, maka sebuah *analog-to-digital converter* (ADC), dibutuhkan untuk memproses semua sinyal tersebut oleh komputer.
- ADC ini akan mengubah sinyal analog yang direpresentasikan dalam bentuk informasi sinyal tunggal ke dalam sebuah aliran (stream) sejumlah bilangan biner
- Bilangan biner ini kemudian disimpan di dalam memori dan akan menjadi data raw yang akan diproses.

2.4.2 Proses pengenalan citra (*Image Processing*)

Proses pengenalan citra adalah proses pengolahan informasi image yang telah didigitalisasi oleh converter analog ke digital.

- Computer vision akan melibatkan sejumlah manipulasi utama (initial manipulation) dari data binary tersebut.
- Image processing membantu peningkatan dan perbaikan kualitas image, sehingga dapat dianalisa dan di olah lebih jauh secara lebih efisien.
- Image processing akan meningkatkan perbandingan sinyal terhadap noise (signal-to-noise ratio = s/n).
- Sinyal-sinyal tersebut adalah informasi yang akan merepresentasikan objek yang ada dalam image.
- Sedangkan noise adalah segala bentuk interferensi, kurang pengaburan, yang terjadi pada sebuah objek.

2.4.3 Analisa data citra (*Image Analysis*)

Analisa data citra adalah proses analisa terhadap image visual yang telah di proses sebelumnya.

- Image analysis akan mengeksplorasi scene ke dalam bentuk karakteristik utama dari objek melalui suatu proses investigasi.
- Sebuah program komputer akan mulai melihat melalui bilangan biner yang merepresentasikan informasi visual untuk mengidentifikasi fitur-fitur spesifik dan karakteristiknya.
- Lebih khusus lagi program image analysis digunakan untuk mencari tepi dan batas-batasan objek dalam image.
- Sebuah tepian (edge) terbentuk antara objek dan latar belakangnya atau antara dua objek yang spesifik.
- Tepi ini akan terdeteksi sebagai akibat dari perbedaan level brightness pada sisi yang berbeda dengan salah satu batasnya.

2.4.4 Proses pemahaman data citra (*Image Understanding*)

Pada proses ini *Computer vision* menerapkan konsep-konsep kecerdasan buatan (*Artificial Intelligent*) untuk memahami data visual yang ditangkapnya.

Ini adalah langkah terakhir dalam proses *computer vision*, yang mana spesifik objek dan hubungannya di identifikasi.

- Pada bagian ini akan melibatkan kajian tentang Teknik-teknik *artificial intelligent*.
- Understanding berkaitan dengan template matching yang ada dalam sebuah scene.
- Metoda ini menggunakan program pencarian (*search program*) dan teknik penyesuaian pola (*pattern matching techniques*).

2.5 OpenCV

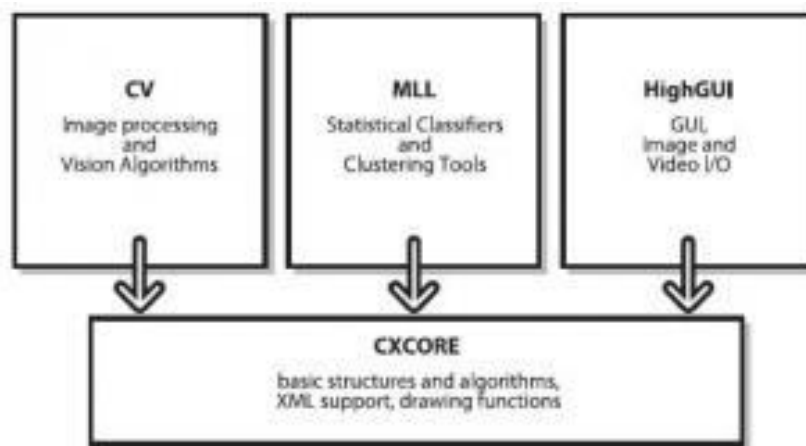
Menurut Bradski dan Kaehler (2008), OpenCV adalah *Open-Source Computer Vision Library*. Pustaka tersebut dikembangkan menggunakan pemrograman C dan C++ yang berjalan pada 3 sistem operasi, yaitu Linux, Windows dan Mac OS X.

OpenCV (*Open Computer Vision*) adalah sebuah API (*Application Programming Interface*) Library yang sudah sangat familiar pada Pengolahan Citra Computer Vision. Menurut Priawadi (2012), *Computer Vision* itu sendiri adalah salah satu cabang dari Bidang Ilmu Pengolahan Citra (*Image Processing*) yang memungkinkan komputer dapat melihat seperti manusia. Dengan vision tersebut komputer dapat mengambil keputusan, melakukan aksi, dan mengenali terhadap suatu objek. Beberapa pengimplementasian dari *Computer Vision* adalah *Face Recognition, Face Detection, Face/Object Tracking, Road Tracking, dll*. OpenCV didesain untuk aplikasi real-time, memiliki fungsi-fungsi akuisisi yang baik untuk image/video.

OpenCV sendiri terdiri dari 5 *library*, yaitu:

1. CV : untuk algoritma Image processing dan Vision.
2. ML : untuk machine learning library
3. Highgui : untuk GUI, Image dan Video I/O.
4. CXCORE : untuk struktur data, support XML dan fungsi-fungsi grafis.
5. CvAux

Struktur dan konten OpenCV:



Gambar 2.6 Struktur dan konten OpenCV

Fitur yang dimiliki OpenCV antara lain seperti:

1. Manipulasi data citra (alokasi, *copying*, *setting*, *conversion*)
2. Citra dan Video I/O (file dan kamera based input, image/video file output)
3. Manipulasi matriks dan vector beserta aljabar linear (*products*, *solvers*, *eigen values*, *SVD*)
4. Data struktur dinamis (*lists*, *queues*, *sets*, *trees*, *graphs*)

5. Pemrosesan citra fundamental (*filtering, edge detection, corner detection, sampling and interpolation, color conversion, morphological operation, histogram, image pyramids*)
6. Analisis struktur (*Connected components, contour processing, distance transform, various moments, template matching, Hough transform, polygonal approximation, line fitting, ellipse fitting, Delaunary triangulation*).
7. Kalibrasi kamera (*calibration patterns, estimation fundamental matrix, homography estimation, stereo correspondence*)
8. Analisis Gerakan (*optical flow, segmentation, tracking*)
9. Pengenalan objek
10. *Graphical User Interface* (*display image/video, penanganan keyboard dan mouse, scroll-bars*)
11. Pelabelan citra (*line, conic, polygon, text drawing*)
12. Fungsi-fungsi grafis

2.6 Convolutional Neural Network (CNN)

2.6.1 Pengenalan Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) adalah pengembangan dari *Multilayer Perceptron (MLP)* yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada kasus klasifikasi citra, MLP kurang sesuai untuk digunakan karena tidak menyimpan informasi spasial dari data citra dan menganggap setiap piksel adalah fitur yang independen

sehingga menghasilkan hasil yang kurang baik.

CNN pertama kali dikembangkan dengan nama NeoCognitron oleh Kunihiro Fukushima (1980), seorang peneliti dari NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang. Konsep tersebut kemudian dimatangkan oleh Yann LeCun, seorang peneliti dari AT&T Bell Laboratories di Holmdel, New Jersey, USA. Model CNN dengan nama LeNet berhasil diterapkan oleh LeCun (1990) pada penelitiannya mengenai pengenalan angka dan tulisan tangan. Pada tahun 2012, Alex Krizhevsky dengan penerapan CNN miliknya berhasil menjuarai kompetisi ImageNet Large Scale Visual Recognition Challenge 2012. Prestasi tersebut menjadi momen pembuktian bahwa metode Deep Learning, khususnya CNN. Metode CNN terbukti berhasil

2.6.2 Konsep CNN

Cara kerja CNN memiliki kesamaan pada MLP, namun dalam CNN setiap neuron dipresentasikan dalam bentuk dua dimensi, tidak seperti MLP yang setiap neuron hanya berukuran satu dimensi.



Gambar 2.7. Arsitektur MLP Sederhana

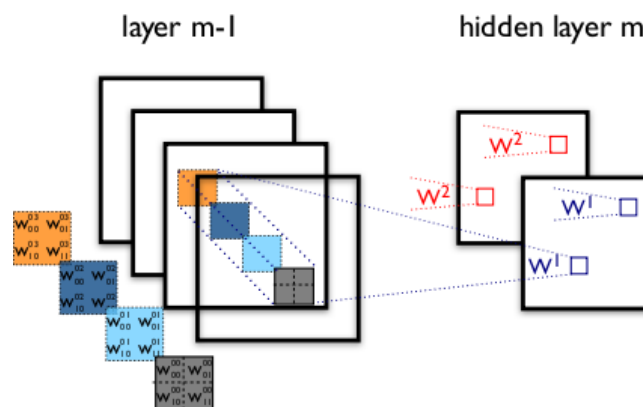
Sebuah MLP seperti pada Gambar 2.7 memiliki i layer (kotak merah dan

biru) dengan masing-masing *layer* berisi j_i neuron (lingkaran putih). MLP menerima *input* data satu dimensi dan mempropagasikan data tersebut pada jaringan hingga menghasilkan *output*. Setiap hubungan antar neuron pada dua *layer* yang bersebelahan memiliki parameter bobot satu dimensi yang menentukan kualitas mode. Disetiap data *input* pada *layer* dilakukan operasi *linear* dengan nilai bobot yang ada, kemudian hasil komputasi akan ditransformasi menggunakan operasi *non linear* yang disebut sebagai fungsi aktivasi.

Pada CNN, data yang dipropagasikan pada jaringan adalah data dua dimensi, sehingga operasi linear dan parameter bobot pada CNN berbeda. Pada CNN operasi linear menggunakan operasi konvolusi, sedangkan bobot tidak lagi satu dimensi saja, namun berbentuk empat dimensi yang merupakan kumpulan kernel konvolusi seperti pada Gambar 2.8. Dimensi bobot (*weight*) pada CNN adalah:

$$\text{neuron input} \times \text{neuron output} \times \text{tinggi} \times \text{lebar}$$

Karena sifat proses konvolusi, maka CNN hanya dapat digunakan pada data yang memiliki struktur dua dimensi seperti citra dan suara.



Gambar 2.8 Proses Konvolusi pada CNN

2.6.3 Arsitektur Jaringan CNN

Berdasarkan penelitian Stathakis (2008), JST terdiri dari berbagai layer dan beberapa neuron pada masing-masing layer. Kedua hal tersebut tidak dapat ditentukan menggunakan aturan yang pasti dan berlaku berbeda-beda pada data yang berbeda.

Pada kasus MLP, sebuah jaringan tanpa hidden layer dapat memecahkan persamaan linear apapun, sedangkan jaringan dengan satu atau dua hidden layer dapat memecahkan sebagian besar persamaan pada data sederhana.

Namun pada data yang lebih kompleks, MLP memiliki keterbatasan. Pada permasalahan jumlah *hidden layer* dibawah tiga *layer*, terdapat pendekatan untuk menentukan jumlah neuron pada masing-masing *layer* untuk mendekati hasil optimal. Penggunaan layer diatas dua pada umumnya tidak direkomendasikan dikarenakan akan menyebabkan *overfitting* serta kekuatan *backpropagation* berkurang secara signifikan.

Dengan berkembangnya *deep learning*, ditemukan bahwa untuk mengatasi kekurangan MLP dalam menangani data kompleks, diperlukan fungsi untuk mentransformasi data input menjadi bentuk yang lebih mudah dimengerti oleh MLP. Hal tersebut memicu berkembangnya *deep learning* dimana dalam satu model diberi beberapa *layer* untuk melakukan transformasi data sebelum data diolah menggunakan metode klasifikasi. Hal tersebut memicu berkembangnya model neural network dengan jumlah *layer* diatas tiga. Namun dikarenakan fungsi *layer* awal sebagai metode ekstraksi fitur, maka jumlah *layer* dalam sebuah DNN tidak memiliki aturan universal dan berlaku berbeda-beda tergantung dataset yang

digunakan.

Karena hal tersebut, jumlah *layer* pada jaringan serta jumlah neuron pada masing-masing *layer* dianggap sebagai *hyperparameter* dan dioptimasi menggunakan pendekatan *searching*.

Sebuah CNN terdiri dari beberapa *layer*. Berdasarkan arsitektur LeNet5, terdapat empat macam *layer* utama pada sebuah CNN namun yang diterapkan pada penelitian ini terdapat beberapa lapisan antara lain:

1. *Convolution Layer*

Convolution Layer melakukan operasi konvolusi pada *output* dari *layer* sebelumnya. *Layer* tersebut adalah proses utama yang mendasari sebuah CNN.


Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada *output* fungsi lain secara berulang. Dalam pengolahan citra, konvolusi berarti mengaplikasikan sebuah *kernel* (kotak kuning) pada citra disemua *offset* yang memungkinkan seperti yang ditunjukkan pada Gambar 2.9. Kotak hijau secara keseluruhan adalah citra yang akan dikonvolusi. *Kernel* bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut dapat dilihat pada gambar disebelah kanannya. Formula untuk melakukan konvolusi pada input data citra pada *Convolutional Layer* untuk mereduksi ukuran gambar adalah sebagai berikut:

$$C = (\text{Ukuran x piksel} - \text{ukuran x filter} + 1) \times (\text{Ukuran x piksel} - \text{ukuran x filter} + 1) \quad (2.1)$$

Dimana:

$C =$ Ukuran *Convolutional Layer* (piksel)

Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra *input*. Konvolusi akan menghasilkan transformasi *linear* dari data *input* sesuai informasi spasial pada data. Bobot pada *layer* tersebut menspesifikasikan *kernel* konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan *input* pada CNN.



Gambar 2.9 Operasi Konvolusi


Nilai fitur dihitung berdasarkan rumus berikut, di mana gambar input dilambangkan dengan x dan kernel dengan f . Indeks baris dan kolom dari matriks hasil masing-masing ditandai dengan i dan j .

$$y[i, j] = (x * f)[i, j] = \sum_m \sum_n f[i, j] * h[i - m, j - n] \quad (2.2)$$

2. *Subsampling Layer*

Subsampling adalah proses mereduksi ukuran sebuah data citra. Dalam pengolahan citra, *subsampling* juga bertujuan untuk meningkatkan invariansi posisi dari fitur. Dalam sebagian besar CNN, metode *subsampling* yang

digunakan adalah *max pooling*. *Max pooling* membagi output dari *convolution layer* menjadi beberapa *grid* kecil lalu mengambil nilai maksimal dari setiap *grid* untuk menyusun matriks citra yang telah direduksi seperti yang ditunjukkan pada Gambar 2.10. Grid yang berwarna merah, hijau, kuning dan biru merupakan kelompok *grid* yang akan dipilih nilai maksimumnya. Sehingga hasil dari proses tersebut dapat dilihat pada kumpulan *grid* disebelah kanannya. Proses tersebut memastikan fitur yang didapatkan akan sama meskipun objek citra mengalami translasi (pergeseran).



Gambar 2.10. Operasi Max Pooling

Menurut Springenberg dkk (2015), penggunaan *pooling layer* pada CNN hanya bertujuan untuk mereduksi ukuran citra sehingga dapat dengan mudah digantikan dengan sebuah *convolution layer* dengan *stride* yang sama dengan *pooling layer* yang bersangkutan. Proses operasi *Pooling* ukuran data citra dapat dihitung dengan formula berikut:

$$C_p = \left(\left(\frac{\text{Ukuran } x \text{ } C}{\text{ukuran } x \text{ pooling}} \right) \times \left(\frac{\text{Ukuran } y \text{ } C}{\text{ukuran } y \text{ pooling}} \right) \right) \quad (2.3)$$

Dimana:

C_p = Ukuran data citra setelah dilakukan *Pooling* (piksel)

C = Ukuran data citra (piksel)

Setelah data citra melewati proses operasi *Pooling* maka didapatkan nilai data citra yang akan menjadi nilai input pada *Convolutional Layer* selanjutnya. Jumlah koneksi data input terhadap lapisan selanjutnya dapat dihitung dengan formula berikut:

$$C_o = \text{Jumlah layer} \times C_p \times (\text{pooling} + 1) \quad (2.4)$$

Dimana:

C_o = Jumlah koneksi pada *Convolutional Layer* (koneksi)

C_p = Ukuran data citra setelah dilakukan *Pooling* (piksel)

3. *Fully Connected Layer*

Layer tersebut adalah *layer* yang biasanya digunakan dalam penerapan MLP dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear.

Setiap *neuron* pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah *fully connected layer*. Karena hal tersebut menyebabkan data kehilangan informasi spasialnya dan tidak reversibel, *fully connected layer* hanya dapat diimplementasikan di akhir jaringan.


Dalam sebuah jurnal oleh Lin dkk (2011)., dijelaskan bahwa *convolution layer* dengan ukuran kernel 1 x 1 melakukan fungsi yang sama dengan sebuah *fully connected layer* namun dengan tetap mempertahankan karakter spasial dari data. Hal tersebut membuat penggunaan *fully*

connectedlayer pada CNN sekarang tidak banyak dipakai.

4. Fungsi Aktivasi

Fungsi aktivasi adalah fungsi *non linear* yang memungkinkan sebuah JST untuk dapat mentransformasi data *input* menjadi dimensi yang lebih tinggi sehingga dapat dilakukan pemotongan *hyperlane* sederhana yang memungkinkan dilakukan klasifikasi. Dalam CNN terdapat fungsi aktivasi digunakan yaitu fungsi *sigmoid* dan fungsi *Rectified Linear Units (ReLU)*.

Fungsi *sigmoid* mentransformasi *range* nilai dari *input* x menjadi antara 0 dan 1 dengan bentuk distribusi fungsi seperti pada Gambar 2.11. Sehingga fungsi *sigmoid* memiliki bentuk sebagai berikut:



Gambar 2.11 Distribusi Fungsi Sigmoid

$$\sigma(x) = 1 / (1+e^{-x}) \quad (2.5)$$

Dimana:

$\sigma(x)$ = Fungsi Sigmoid

x = nilai data input

Fungsi *sigmoid* sekarang sudah tidak banyak digunakan dalam praktek karena memiliki kelemahan utama yaitu *range* nilai *output* dari fungsi *sigmoid* tidak terpusat pada angka nol.

Hal tersebut menyebabkan terjadinya proses *backpropagation* yang tidak ideal, selain itu bobot pada JST tidak terdistribusi rata antara nilai positif dan negatif serta nilai bobot akan banyak mendekati ektrim 0 atau 1. Dikarenakan komputasi nilai propagasi menggunakan perkalian, maka nilai ektrim tersebut akan menyebabkan efek *saturating gradients* dimana jika nilai bobot cukup kecil, maka lama kelamaan nilai bobot akan mendekati salah satu ektrim sehingga memiliki gradien yang mendekati nol. Jika hal tersebut terjadi, maka neuron tersebut tidak akan dapat mengalami *update* yang signifikan dan akan nonaktif.

Fungsi *Rectified Linear Units (ReLU)* merupakan fungsi yang mengaplikasikan fungsi aktivasi:

$$f(x) = \max(0, x) \quad (2.6)$$


Dimana:

$$f(x) = \text{Fungsi ReLU}$$

$$x = \text{nilai data input}$$

Fungsi *ReLU* meningkatkan sifat nilai non-linearitas fungsi keputusan dan jaringan secara keseluruhan tanpa mempengaruhi bidang-bidang reseptif

pada *Convolutional Layer*. Sehingga fungsi *ReLU* akan menghasilkan bentuk sebagai berikut:



Gambar 2.12 Distribusi Fungsi *ReLU*

5. *Loss Layer*

Loss Layer, merupakan lapisan terakhir dalam CNN, menentukan bagaimana pelatihan memberikan penalty atas penyimpangan antara hasil prediksi dan label. Terdapat sejumlah variasi *loss function*, diantaranya adalah *binary cross-entropy loss* yang digunakan untuk memprediksi sejumlah nilai probabilitas dalam interval [0,1] pada masalah yang memiliki beberapa kelas. Formula *binary cross-entropy* ditunjukkan pada formula berikut:

$$L(y, \hat{y}) = -\frac{1}{N} \sum_{i=0}^i (y \times \log(\hat{y}_i) + (1 - y) \times \log(1 - \hat{y}_i)) \quad (2.7)$$

Dimana:

\hat{y} = Nilai prediksi

y = Nilai *output training*

L = Nilai *binary cross-entropy loss (%)*