



Analisis Penerapan *Error Level Analysis (ELA)* Terintegrasi CNN untuk Deteksi Manipulasi Video dalam Digital Forensik

Yahya Sarifudin

21917041

Tesis diajukan sebagai syarat untuk meraih gelar Magister Komputer

Konsentrasi Forensika Digital

Program Studi Informatika Program Magister

Fakultas Teknologi Industri

Universitas Islam Indonesia

2025

Lembar Pengesahan Pembimbing

**Analisis Penerapan *Error Level Analysis (ELA)* Terintegrasi CNN untuk Deteksi
Manipulasi dalam Digital Forensik**

Yahya Sarifudin

21917041

Yogyakarta, Maret, 2025

Pembimbing

A handwritten signature in blue ink, appearing to read 'prayudi', is positioned above the printed name of the supervisor.

Dr. Yudi Prayudi S.Si, M.Kom

Lembar Pengesahan Penguji

Analisis Penerapan *Error Level Analysis (ELA)* Terintegrasi CNN untuk Deteksi Manipulasi Video dalam Digital Forensik



Yahya Sarifudin

21917041


Yogyakarta, Januari, 2026

Tim Penguji,

Dr. Yudi Prayudi, S.Si, M.Kom
Ketua

Dr. Ahmad Luthfi, S.Kom, M.Kom
Anggota I

Feri Wijayanto, S.T, M.T
Anggota II



Mengetahui,

Ketua Program Studi Informatika Program Magister
Universitas Islam Indonesia

Irving Vitra Paputungan S.T., M.Sc., Ph.D



Abstrak

Analisis Penerapan *Error Level Analysis (ELA)* Terintegrasi CNN untuk Deteksi Manipulasi Video dalam Digital Forensik

Terjadi peningkatan konten atau karya digital berbasis visual baik gambar ataupun video, karya atau konten menjadi aset digital berharga. Namun kemudahan akses dan berkemabangnya berbagai *tools* dan teknik manipulasi, membuka peluang kejahatan dengan memanfaatkan jenis manipulasi video. Untuk meminimalisir dampak disinformasi, misinterpretasi, menjaga, dan melindungi kekayaan intelektual dari manipulasi perlu strategi untuk mempertahankan keaslian. Mekanisme identifikasi keaslian tanpa bantuan *tools* atau metode khusus secara *scientific* menimbulkan peluang misinterpretasi. Salah satu metode atau langkah-langkah untuk mendeteksi manipulasi adalah ELA. Implementasi metode *Error Level Analysis (ELA)* dalam video forensik untuk deteksi manipulasi video menggunakan skema studi kasus dengan melakukan pengujian terhadap *dataset* video manipulasi. Analisis eksperimen implementasi metode ELA ini, diintegrasikan dengan model lain misalnya algoritma CNN dengan teknik SVM dan KNN atau *threshold* yang telah terbukti untuk deteksi manipulasi gambar.

Kata kunci

ELA, *Error Level Analysis*

Abstract

Analysis of the Application of *Error Level Analysis (ELA)* Integrated CNN for Video Manipulation Detection in Digital Forensics

The implementation of the ELA (Error Level Analysis) method to detect image forgery using a differential compression scheme results in images with intense noise, leading to misinterpretation. To minimize this, a wavelet threshold enhancement mechanism, Daubechies wavelets, was adopted. Furthermore, a combination of algorithms such as CNNs with SVM and KNN techniques improved the accuracy of detecting image forgery. The SVM classification accuracy reached 89.5%. However, its use or implementation for image detection has been limited. Therefore, previous research has highlighted the need for its application in detecting video content forgery. The purpose of this study is to analyze forensic videos to detect video manipulation using Error Level Analysis (ELA). The research methodology used is a case study, testing data taken from a sample dataset of manipulated videos. Forensic video analysis for video manipulation detection using the Error Level Analysis (ELA) method.

Keywords

ELA, *Error Level Analysis*

Pernyataan Keaslian Tulisan

Dengan ini saya menyatakan bahwa tesis ini merupakan tulisan asli dari penulis, dan tidak berisi material yang telah diterbitkan sebelumnya atau tulisan dari penulis lain terkecuali referensi atas material tersebut telah disebutkan dalam tesis. Apabila ada kontribusi dari penulis lain dalam tesis ini, maka penulis lain tersebut secara eksplisit telah disebutkan dalam tesis ini.

Dengan ini saya juga menyatakan bahwa segala kontribusi dari pihak lain terhadap tesis ini, termasuk bantuan analisis statistik, desain survei, analisis data, prosedur teknis yang bersifat signifikan, dan segala bentuk aktivitas penelitian yang dipergunakan atau dilaporkan dalam tesis ini telah secara eksplisit disebutkan dalam tesis ini.

Segala bentuk hak cipta yang terdapat dalam material dokumen tesis ini berada dalam kepemilikan pemilik hak cipta masing-masing. Apabila dibutuhkan, penulis juga telah mendapatkan izin dari pemilik hak cipta untuk menggunakan ulang materialnya dalam tesis ini.

Yogyakarta, Januari 2026

A handwritten signature in black ink, appearing to read 'Yahya', is positioned to the left of a rectangular Indonesian postage stamp. The stamp is pink and yellow, featuring the Garuda Pancasila emblem and the text '10000' and 'RUPIAH'.

Yahya Sarifudin, S.Kom

Daftar Publikasi

{Tulis daftar publikasi selama masa studi dengan menggunakan format standar referensi APA. Pilah publikasi berdasarkan jenis publikasi, misal: jurnal, bab dalam buku, prosiding konferensi, dan lain-lain.

Semua publikasi yang termaktub di atas didetilkkan di bawah (**Publikasi yang menjadi bagian dari tesis**).}

Publikasi yang menjadi bagian dari tesis

{Jika ada sebagian atau semua dari publikasi selama masa studi diikutsertakan dalam tesis ini, gunakan bagian berikut untuk mendetilkkan publikasi yang dimaksud. Berikan deskripsi kontribusi dari masing-masing penulis jika anda bukan satu-satunya penulis.

Sebagai contoh:

Publikasi berikut menjadi bagian dari Bab 3

Sitasi publikasi 1

Kontributor	Jenis Kontribusi
Yahya Sarifudin	Mendesain eksperimen (60%) Menulis <i>paper</i> (70%)
Dr. Yudi Prayudi, S.Si, M.Kom	Mendesain eksperimen (40%) Menulis dan mengedit <i>paper</i> (30%)

Halaman Kontribusi

Tidak ada kontribusi dari pihak lain

Halaman Persembahan

Terimakasih kepada orang tua, keluarga, seluruh civitas akademik baik rektor, dosen maupun lainnya, teman-teman angkatan MI-25, konsentrasi Forensika Digital dan kampus UII telah memberikan dukungan baik moril, materiil, non materiil dan kesempatan selama proses menempuh studi Program Magister di Program Studi Informatika ini.

Kata Pengantar

Puji syukur kehadiran Alloh SWT yang telah melimpahkan karunia dan nikmatnya. Nikmat sehat, salah satunya sehingga berkat nikmat-Nya bisa menyusun Thesis ini. Tak lupa sholawat serta salam kita haturkan kepada junjungan Nabi agung, Muhammad SAW yang telah memberikan suri tauladan bagi ummat. Kepada orang tua tak habis rasa syukur dan terimakasih atas dukungan dan doanya. Selain itu juga kami haturkan terimakasih kepada dosen pembimbing atas bimbingannya hingga terselesaikan thesis ini.

Daftar Isi

Lembar Pengesahan Pembimbing	ii
Lembar Pengesahan Penguji.....	Error! Bookmark not defined.
Abstrak	iii
Abstract.....	v
Pernyataan Keaslian Tulisan	Error! Bookmark not defined.
Daftar Publikasi	vii
Halaman Kontribusi.....	viii
Halaman Persembahan	ix
Kata Pengantar.....	x
Daftar Isi	xi
Daftar Tabel.....	xiv
Daftar Gambar	xv
Glosarium	xvi

BAB I

Pendahuluan	5
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	2
1.3 Batasan Masalah	2
1.4 Tujuan Penelitian	2
1.5 Metodologi Penelitian.....	3
1.6 Metode Penelitian	3
1.7 Metodologi yang Diusulkan.....	5
1.8 Sistematika Penulisan	5

BAB II

Tinjauan Pustaka	5
-------------------------------	----------

2.1. Pendahuluan.....	6
2.2. Konsep Pengetahuan.....	14
2.3. Deep Fakes.....	15
2.4. ELA.....	15
2.5. CNN (<i>Convolutional Neural Network (CNN) in Machine Learning, 2025</i>)	16
BAB III	
Metodologi Penelitian	5
3.1. Data.....	23
3.2. Langkah-Langkah Penelitian	23
3.3. Data Model	24
3.4. Analisis Data.....	24
3.4.1. Implementasi Perangkat Lunak.....	24
BAB IV	
Pembahasan.....	5
4.1. Tahap Pengumpulan Data.....	26
4.2. Preprocessing Data	26
4.3. Tahap Optimasi dan Pengembangan Model CNN.....	28
4.4. Trining Model.....	29
4.5. Integrasi ELA dengan Algoritma Kecerdasan Buatan.....	30
4.6. Mengimplementasikan metode deep learning (CNN, SVM, atau KNN) untuk meningkatkan deteksi manipulasi.....	31
4.7. Pengujian Model.....	32
4.8. Model yang dikembangkan akan diuji pada dataset baru untuk mengukur keandalan dan generalisasi metode.....	34
BAB V	
Penutup	5
5.1. Kesimpulan	35
5.2. Saran	35

Daftar Tabel

Tabel 2.1 Literatur Review.....	7
Tabel 4.1 Data Total Video	24

Daftar Gambar

Gambar 2.1 Bidang Penerapan CNN Model	16
Gambar 2.2 Arsitektur CNN.....	17
Gambar 2.3 Pengenalan CNN Model.....	18
Gambar 2.4 Cara Kerja CNN Model.....	19
Gambar 3.1 Gambaran Penelitian.....	23
Gambar 3.2 Langkah-Langkah Penelitian	23
Gambar 4.1 Bagan Integrasi ELA dengan CNN Model.....	238
Gambar 4.2 Hasil Trining Model CNN.....	238

Glosarium

ELA	- Error Level Analysis
CNN	- Convolutional Neural Network
SVM	- Support Vector Machine
KNN	- K-Nearest Neighbors

BAB 1

Pendahuluan

1.1 Latar Belakang

Meningkatnya produksi dan konsumsi konten digital berbasis visual menjadi tantangan terjaganya keaslian (Yallamandhala & Godwin, 2022) dan integritas aset digital. Berbagai teknik manipulasi, membuka peluang penyalahgunaan konten digital. (Mohiuddin et al., 2023)

Diperlukan metode untuk deteksi manipulasi sebagai alat penentu keabsahan konten digital. Salah satu teknik yang digunakan untuk deteksi manipulasi citra digital adalah Error Level Analysis (ELA). Metode ini bekerja mendeteksi dan atau menganalisis tingkat kesalahan kompresi gambar, untuk mengidentifikasi potensi perubahan yang menunjukkan adanya manipulasi (Faroek, 2024; Raković, 2023).

Studi sebelumnya menunjukkan bahwa ELA mampu mendeteksi pemalsuan gambar dengan akurasi mencapai 89,5% dalam berbagai eksperimen (CPatel & M Patel, 2015; Patel & Patel, 2015) (Idlbek et al., 2024; Rafique et al., 2021, 2023) (Verma et al., 2024). Namun, mayoritas penelitian fokus pada manipulasi gambar dengan format JPEG dan terbatas teknik seperti *splicing*, *copy-move forgery*, dan *retouching* (T. Sari et al., 2016).

Seiring dengan meningkatnya kompleksitas manipulasi digital, pemalsuan tidak hanya terjadi pada gambar statis tetapi juga pada konten video (Harika Palivela et al., 2023). Beberapa teknik manipulasi video yang umum digunakan meliputi *copy-move*, *splicing* (H. Kaur & Jindal, 2020), serta penggunaan teknologi *deepfake* (A. Kaur et al., 2024)

Sayangnya, meskipun metode ELA telah terbukti efektif dalam mendeteksi manipulasi gambar, penerapannya pada analisis video forensik masih menghadapi tantangan (A. Kaur et al., 2024). Beberapa studi awal menunjukkan bahwa efektivitas ELA dalam mendeteksi manipulasi video dipengaruhi oleh kualitas video, jenis manipulasi, parameter *ELA* yang diterapkan, serta karakteristik objek bergerak dan efek visual dalam video (Jeronymo et al., 2017; Warif et al., 2015) atau kasus spesifik (Mohiuddin et al., 2023).

Penelitian lainnya telah mencoba meningkatkan akurasi deteksi manipulasi gambar dengan mengombinasikan *ELA* dengan algoritma *machine learning* seperti *Convolutional Neural Network* (CNN) (Mohammed et al., 2024; Vasudevan et al., 2025), *Support Vector Machine* (SVM), dan *K-Nearest Neighbors* (KNN) (Mercier et al., 2019; Nagm et al., 2024) (Rafique et al., 2021, 2023; W. P. Sari & Fahmi, 2021). Pendekatan ini menunjukkan

peningkatan akurasi dalam mendeteksi manipulasi gambar, namun implementasi serupa pada video masih perlu dieksplorasi lebih lanjut. Oleh karena itu, terdapat kebutuhan mengembangkan strategi optimasi ELA atau integrasi dengan model/algorithm agar dapat digunakan secara efektif dalam analisis video forensik. (Panchal & Shah, 2020)

Dalam penelitian sebelumnya tidak ada studi kasus dengan pengujian model terhadap dataset sample. Implementasi model yang dikembangkan. Lebih kepada hasil presentase dari pengujian terhadap berbagai jenis dataset. Tidak secara spesifik menunjukkan pengembangan model.

Berdasarkan research gap tersebut, penelitian ini bertujuan untuk implementasi metode ELA dalam mendeteksi manipulasi video (More et al., 2024; Panchal & Shah, 2020; Sandhya & Kashyap, 2024), mengidentifikasi faktor-faktor yang mempengaruhi akurasi, serta mengembangkan strategi optimasi untuk meningkatkan kinerja metode. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknik analisis video forensik yang lebih akurat dan andal.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah, Apakah Error Level Analysis (ELA) terintegrasi CNN model mampu mendeteksi manipulasi video ?

1.3 Batasan Masalah

Batasan masalah yang ditetapkan di dalam penelitian ini adalah :

1. Penelitian ini melakukan analisis video forensik dengan pengujian dari dataset www.kaggle.com
2. Pengujian terhadap dataset video dengan jenis manipulasi konten *deep fakes*.

1.4 Tujuan Penelitian

Tujuan dalam penelitian ini adalah :

1. Mengembangkan pendekatan berbasis kecerdasan buatan untuk meningkatkan performa metode ELA dalam analisis video forensik.
 - a. Mengeksplorasi integrasi ELA dengan algoritma deep learning CNN untuk meningkatkan deteksi.
 - b. Melakukan eksperimen berbasis dataset manipulasi video untuk menguji efektivitas metode yang dikembangkan.

1.5 Metodologi Penelitian

Melakukan penelitian dengan studi kasus atau eksperimental menggunakan metode ELA (*Error Level Analysis*) terintegrasi CNN model dan menganalisis pengujian menggunakan sampel data untuk mendeteksi manipulasi video.

1.6 Metode Penelitian

Penelitian ini menggunakan pendekatan studi eksperimental dengan melakukan pengujian metode Error Level Analysis (ELA) terintegrasi CNN pada dataset video forensik yang mengandung jenis manipulasi *deep fakes*. Langkah-langkah penelitian yang dilakukan meliputi:

1. Tahap Pengumpulan Data
 - a. Pemilihan Dataset
 - i. Dataset yang digunakan adalah kumpulan video yang mengandung manipulasi *deep fakes* dari sumber dataset publik, seperti:
 1. Video Forgery Detection Dataset
 2. Kaggle: Dataset manipulasi video terkait forensik digital.
 - b. Preprocessing Data
 - i. Setiap video akan diekstraksi menjadi frame-frame gambar menggunakan teknik frame extraction.
 - ii. Standarisasi resolusi dan format video agar hasil analisis ELA lebih konsisten.
2. Tahap Implementasi Metode ELA
 - a. Penerapan Error Level Analysis (ELA)
 - i. Menggunakan metode ELA untuk mendeteksi kemungkinan manipulasi dalam setiap frame hasil ekstraksi.
 - ii. Menganalisis pola error level yang muncul dan mengidentifikasi wilayah yang berpotensi dimanipulasi.
 - b. Eksperimen Variasi Parameter ELA
 - i. Menguji pengaruh parameter seperti tingkat kompresi dan nilai ambang batas (threshold).
 - ii. Menentukan parameter optimal yang memberikan hasil deteksi terbaik.
3. Tahap Optimasi dan Pengembangan Model
 - a. Integrasi ELA dengan Algoritma Kecerdasan Buatan

- i. Mengimplementasikan metode deep learning (CNN, SVM, atau KNN) untuk meningkatkan deteksi manipulasi.
 - ii. Model akan dilatih untuk mempelajari pola dan hubungan antara fitur-fitur.
 - b. Pengujian Model
 - i. Model yang dikembangkan akan diuji pada dataset baru untuk mengukur keandalan dan generalisasi metode.
- 4. Evaluasi dan Analisis Hasil
 - a. Evaluasi Akurasi Deteksi Manipulasi
 - i. Menggunakan metrik evaluasi seperti Precision, Recall, F1-Score, dan AUC-ROC Curve.
 - b. Analisis Faktor yang Mempengaruhi Keberhasilan Deteksi
 - i. Mengidentifikasi faktor seperti resolusi, kualitas video, dan jenis manipulasi yang memengaruhi hasil analisis ELA.
- 5. Penyusunan Kesimpulan dan Rekomendasi
 - a. Menyusun hasil penelitian dalam bentuk laporan yang mencakup efektivitas metode, tantangan yang dihadapi, serta potensi pengembangan lebih lanjut.

1.7 Metodologi yang Diusulkan

Melakukan penelitian dengan studi kasus menggunakan metode ELA (*Error Level Analysis*) dan menganalisis pengujian menggunakan sampel data untuk mendeteksi manipulasi video.

1.8 Sistematika Penulisan

Untuk memudahkan proses pembahasan dalam penelitian yang dibuat ini, maka peneliti membuat sistematika penulisan pada penelitian sebagai berikut:

BAB I Pendahuluan

Bab ini memuat uraian pengantar terkait masalah yang akan diteliti. Secara detail bab ini berisi latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

BAB II Tinjauan Pustaka

Pada bab ini memuat mengenai teori-teori yang melandasi dan terkait serta digunakan dalam penelitian ini.

BAB III Metodologi Penelitian

Bab metodologi penelitian berisi langkah-langkah atau alur jalannya penelitian dari awal sampai akhir.

BAB IV Pembahasan

Berisi hasil penelitian terkait uji coba dari implementasi teknik yang dipakai.

BAB V Penutup

Pada bab ini dijelaskan mengenai kesimpulan akhir yang didapat dari hasil penelitian untuk menjawab rumusan masalah. Disini juga dijelaskan mengenai penelitian lanjutan yang diharapkan dapat dilakukan di masa depan.

BAB 2

Tinjauan Pustaka

2.1. Pendahuluan

Meningkatnya produksi dan konsumsi konten digital berbasis visual menjadi tantangan terjaganya keaslian (Yallamandhala & Godwin, 2022) dan integritas aset digital. Berbagai teknik manipulasi, membuka peluang penyalahgunaan konten digital. (Mohiuddin et al., 2023)

Diperlukan metode untuk deteksi manipulasi sebagai alat penentu keabsahan konten digital. Salah satu teknik yang digunakan untuk deteksi manipulasi citra digital adalah Error Level Analysis (ELA) (Vadrevu et al., 2022). Metode ini bekerja mendeteksi dan atau menganalisis tingkat kesalahan kompresi gambar, untuk mengidentifikasi potensi perubahan yang menunjukkan adanya manipulasi (Farook, 2024; Raković, 2023).

Studi sebelumnya menunjukkan bahwa ELA mampu mendeteksi pemalsuan gambar dengan akurasi mencapai 89,5% dalam berbagai eksperimen (Farook, 2024) (Idlbek et al., 2024; Rafique et al., 2021, 2023) (Verma et al., 2024). Namun, mayoritas penelitian fokus pada manipulasi gambar dengan format JPEG(Efendi, 2018) dan terbatas teknik seperti *splicing*, *copy-move forgery*, dan *retouching* (T. Sari et al., 2016).

Seiring dengan meningkatnya kompleksitas manipulasi digital, pemalsuan tidak hanya terjadi pada gambar statis tetapi juga pada konten video (Harika Palivela et al., 2023). Beberapa teknik manipulasi video yang umum digunakan meliputi *copy-move*, *splicing* (H. Kaur & Jindal, 2020), serta penggunaan teknologi *deepfake* (A. Kaur et al., 2024)

Sayangnya, meskipun metode ELA telah terbukti efektif dalam mendeteksi manipulasi gambar, penerapannya pada analisis video forensik masih menghadapi tantangan (A. Kaur et al., 2024). Bebebrapa studi awal menunjukkan bahwa efektivitas ELA dalam mendeteksi manipulasi video dipengaruhi oleh kualitas video, jenis manipulasi, parameter *ELA* yang diterapkan, serta karakteristik objek bergerak dan efek visual dalam video (Jeronymo et al., 2017; Warif et al., 2015) atau kasus spesifik (Mohiuddin et al., 2023).

Penelitian lainnya telah mencoba meningkatkan akurasi deteksi manipulasi gambar dengan mengombinasikan *ELA* dengan algoritma *machine learning* seperti *Convolutional Neural Network* (CNN)(R. Gorle and A. Guttavelli, 2025) (Patankar et al., 2023) (Mohammed et al., 2024; Vasudevan et al., 2025), *Support Vector Machine* (SVM), dan *K-Nearest Neighbors* (KNN)(Mercier et al., 2019; Nagm et al., 2024) (Rafique et al., 2021, 2023; W. P. Sari & Fahmi, 2021). Pendekatan ini menunjukkan peningkatan akurasi dalam

mendeteksi manipulasi gambar, namun implementasi serupa pada video masih perlu dieksplorasi lebih lanjut. Oleh karena itu, terdapat kebutuhan mengembangkan strategi optimasi ELA atau integrasi dengan model/algorithm agar dapat digunakan secara efektif dalam analisis video forensik. (Panchal & Shah, 2020)

Dalam penelitian sebelumnya tidak ada studi kasus dengan pengujian model terhadap dataset sample. Implementasi model yang di kembangkan. Lebih kepada hasil presentase dari pengujian terhadap berbagai jenis dataset. Tidak secara spesifik menunjukkan pengembangan model.

Berdasarkan research gap tersebut, penelitian ini bertujuan untuk implementasi metode ELA dalam mendeteksi manipulasi video(More et al., 2024; Panchal & Shah, 2020; Sandhya & Kashyap, 2024), mengidentifikasi faktor-faktor yang mempengaruhi akurasi, serta mengembangkan strategi optimasi untuk meningkatkan kinerja metode. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknik analisis video forensik yang lebih akurat dan andal.

Tabel 2.1 Literatur Review

Berdasarkan Tabel 2.1 Literatur Review, disajikan ringkasan penelitian-penelitian terdahulu yang relevan dengan topik penelitian ini. Tabel tersebut disusun dengan membagi informasi ke dalam beberapa kolom keterangan untuk mempermudah analisis dan perbandingan antar penelitian. Kolom pertama memuat subtema penelitian, yang menunjukkan fokus atau ruang lingkup kajian dari setiap penelitian. Kolom kedua berisi kata kunci (keyword) yang merepresentasikan konsep utama atau metode yang digunakan. Kolom ketiga menyajikan ulasan kritis, yang berisi analisis terhadap kontribusi, kelebihan, serta keterbatasan masing-masing penelitian. Sementara itu, kolom terakhir mencantumkan nama penulis dan sumber pustaka sebagai rujukan ilmiah yang digunakan

No.	Sub Tema	Keyword	Ulasan Kritis	Pustaka
1.	ELA	Digital photo image, video analysis, image forgery/doctored images, image tag analysis	Mengusulkan penggunaan methode ELA untuk mengidentifikasi atau mendeteksi gambar yang telah dimanipulasi.	(CPatel & M Patel, 2015)

2.	ELA	-	Menyajikan kerangka kerja untuk mendeteksi dan mengklasifikasikan gambar deep fake dengan metode ELA Gambar yang dihasilkan di implementasikan dengan algoritma CNN untuk di ekstraksi kemudian diklasifikasi menggunakan SVM dan KNN. Akurasi yang diusulkan meningkat sebesar 89,5%. Tantangan mengidentifikasi metode yang digunakan untuk mendeteksi <i>deep fake</i> berbasis video.	(Rafique et al., 2023)
3.	ELA		Kontribusi utama makalah adalah integrasi ELA dengan ambang batas wavelet untuk mendeteksi pemalsuan gambar, kemudian diperluas oleh sistem pakar untuk mengklasifikasikan dan mengidentifikasi pemalsuan. Tantangan penelitian penyediaan data kuantitatif dan penerapan metode pengoptimalan multi-objektif untuk mengotomatiskan analisis hasil akhir Pembuatan sistem pakar yang mengidentifikasi wilayah frekuensi tinggi sehingga ambang batas yang lebih kuat dapat diterapkan. Penerapan metode statistik lain, seperti sistem Bayesian, untuk perhitungan otomatis parameter ambang batas. Sistem pakar untuk secara otomatis mengklasifikasikan dan mengidentifikasi pemalsuan dalam gambar ELA	(Jeronymo et al., 2017)
4.	ELA	image forensics, JPEG compression, error level analysis	Menyajikan hasil penelitian bahwa metode ELA berhasil secara efektif mendeteksi pemalsuan gambar.	(Warif et al., 2015)
5.	ELA	Deep Learning, Machine Learning, CNN, Deepfake Detection, SVM, KNN	Penelitian ini mengidentifikasi bahwa tantangan pertumbuhan pemalsuan gambar, kemudian menyoroti perlunya pendekatan pemanfaatan metode ELA yang dikombinasikan dengan algoritma CNN dan dengan Teknik klasifikasi SVM dan KNN Teknik ShuffleNet KNN berhasil meningkatkan akurasi, sebesar 88,2% dalam mendeteksi pemalsuan gambar AlexNet Teknik yang perlu dipertimbangan dengan akurasi 86,8% walupun secara kemampuan lebih lambat.	(Rafique et al., 2021)

6.	ELA	Citra, forensik, file, jpeg, ELA	Melakukan analisis citra gambar format JPEG menggunakan <i>fotoforensic</i> oleh Krawetz. Analisis yang dipresentasikan memiliki banyak interpretasi dan memberikan hasil yang salah.	(T. Sari et al., 2016)
7.	ELA	Error Level Analysis, Digital Forensic, Picture Analysis, Image Manipulation Techniques	Penelitian ini focus pada fundamental ELA (<i>Error Level Analysis</i>) dalam mendeteksi manipulasi gambar. Penelitian ini juga menyoroti inovasi terakhir terkait efektivitas dan adaptif dalam bidang investigasi forensika digital.	(Idlbek et al., 2024)
8.	ELA	Convolutional Neural Network, Copy-Move Image Forgery, Digital Image Forensics, Error Level Analysis	Akurasi hasil analisis untuk mendeteksi perubahan gambar meningkat dengan metode ELA dikombinasikan dengan CNN Akurasi model yang telah di trining dengan metode ELA 90% mencapai rata-rata 0.86	(W. P. Sari & Fahmi, 2021)
9.	Video Tampering	Video forensics · Video forgeries · Object-based forgeries · Video tampering detection techniques	Tantangan kedepannya untuk menekplorasi atau implementasi model statistic, <i>deep learning</i> untuk meningkatkan akurasi dengan berbagai jenis manipulasi yang beragam. Model terbatas, tantangan dengan berbagai macam data, transformasi geometris dan tingkat kompresi Tantangan <i>realtime</i> , dengan tetap mempertimbangkan akurasi	(Sandhya & Kashyap, 2024)
10.	Manipulasi Video		Pengembangan Filter Forensik Video Serangkaian filter forensik video dikembangkan untuk menganalisis video dari berbagai perspektif dan menyoroti ketidak konsistenan yang dapat mengindikasikan manipulasi	(Mercier et al., 2019)

			Peningkatan anotasi temporal, pengumpulan lebih banyak kasus dunia nyata untuk evaluasi, eksplorasi skema agregasi alternatif, dan penyelidikan lebih lanjut terhadap filter dan model CNN untuk meningkatkan kinerja. Perlunya penelitian dan pengembangan lebih lanjut untuk mencapai akurasi yang diinginkan untuk penggunaan praktis	
11.	ELA	-	Mengusulkan metode ELA dan CNN untuk mendeteksi manipulasi gambar. ELA adalah teknik pemrosesan gambar untuk mendeteksi inkonsistensi dan potensial manipulasi dengan mengompresi gambar dengan teknik <i>lossy compression</i> . Hasil implementasi usulan metode menunjukkan akurasi 94% dan F-Score 94%.	(Verma et al., 2024)
12.	ELA	-	Mengembangkan deteksi manipulasi gambar dengan metode ELA <i>processor</i> dan metadata.	(Vadrevu et al., 2022)
13.	Deteksi Manipulasi Gambar	citra digital, deteksi tepi, manipulasi citra, splicing	Implementasi metode deteksi tepi blok dan <i>tools</i> JPEG Snoop untuk deteksi manipulasi gambar jenis manipulasi <i>splicing</i> . Hasil penelitian metode deteksi tepi blok terbukti mampu mendeteksi namun <i>tools</i> JPEG Snoop tidak dapat menentukan area yang dimanipulasi. Kombinasi algoritma untuk mendeteksi manipulasi citra yang sudah dishare di internet atau media sosial. Perlu penelitian untuk jenis manipulasi lain dan ekstensi lainnya.	(Efendi, 2018)
14.	ELA		TransOpt, Deep ELA, dan ELA klasik membuka peluang untuk meningkatkan efisiensi. Kelengkapan, serta kekuatan unik yang diberikan masing-masing, menggarisbawahi nilai penggabungan berbagai metodologi untuk hasil yang lebih unggul. Melalui <i>deep learning</i> (TransOpt dan Deep ELA) atau metodologi klasik, penentuan akurasi keputusan lebih tepat dalam pemilihan algoritme. Kombinasi set fitur meningkatkan kinerja dengan memberikan pemahaman yang lebih komprehensif tentang masalah yang dihadapi.	(Seiler et al., 2024)
15.	ELA	Digital, Forensics, ELA,	Membahas terkait ELA definisi, cara kerja, manfaat, eksplorasi ELA untuk forensik digital keuntungan, kekurangan, dan peluang potensial untuk bidang forensik	(Raković, 2023)

		Error, Level, Analysis		
16.	ELA	image forensic, error level analysis (ELA), principal component analysis (PCA), forensically-beta	Melakukan deteksi keaslian citra adalah melakukan perbandingan antara dua image dan dua metode yaitu metode Error Level Analysis (ELA) dan Principal Component Analysis (PCA) dengan menggunakan tools forensically-beta. Teknik ELA menunjukkan perbedaan antara citra asli dan citra yang termanipulasi, sama seperti pada teknik PCA dilihat dari component warna pada gambar termanipulasi memiliki kontras warna yang jauh lebih tajam Mendorong untuk pengembangan <i>tools forensic</i> dengan menggunakan metode yang lain.	(Faroek, 2024)
17.	ELA		Mengimplementasikan metode ELA untuk deteksi manipulasi dengan integrasi <i>Deep Learning</i> Hasil pengujian menunjukkan akurasi sebesar 90.59 %.	(Agrawal et al., 2023)
18.	ELA		Implementasi metode untuk mendeteksi manipulasi gambar atau video tanpa membandingkan dengan dataset asli.	(Patel & Patel, 2015)
19.	Video Foregery	Visual imagery forgery detection · Image and video manipulation and forensics · Deep learning	Memetakan beberapa metode dari penelitian sebelumnya untuk mendeteksi manipulasi Menyajikan <i>taksonomy</i> populer datasets video tampering. Menyajikan perbandingan teknik untuk deteksi <i>tampering</i> . Selain itu teknik dikategorikan berdasarkan model dan pendekatan yang digunakan untuk deteksi.	(Tyagi & Yadav, 2023)
20.	Video Foregery	Cloning · Inter-frame forgery · Intra-frame forgery · Image splicing · Video datasets	Mempresentasikan baik gambar dan video yang telah di manipulasi dengan metode yang digunakan untuk mendeteksi. Tantangan penelitian bahwa teknik yang di implementasikan untuk jenis manipulasi <i>copy-move</i> tidak cocok dengan jenis <i>splicing</i> . Tantangan kedepan adalah mencari algoritma yang bisa teraplikasikan untuk jenis manipulasi <i>copy-move</i> maupun <i>splicing</i> . Populer teknik di bidang forensik mengimplementasikan <i>deep learning</i> model (<i>Adaptive Neural Network</i>) ANN , (<i>Deep Convolutional Neural Network</i>) DCNN, dan <i>Reccurent Neural Network</i> RNN.	(H. Kaur & Jindal, 2020)

			Namun tantangan, implementasi model tersebut adalah kebutuhan kemampuan komputasi tinggi.	
21.	Video Forgery	Video forgery detection, Passive approach, Active approach Copy-move video forgery, Deepfake, Surveillance video, Survey	Membahas isu terkait pemalsuan video dan metode yang diusulkan. Tantangan identifikasi deteksi manipulasi secara khusus hadirnya teknologi <i>Deep fake</i> dan Chrome Key. Deteksi <i>Copy-move</i> , penghapusan frame, penambahan frame memerlukan algoritma yang canggih. Tantangan adalah algoritma/ <i>tools</i> universal untuk mengidentifikasi jenis manipulasi.	(Mohiuddin et al., 2023)
22.	Video Datas Tampering	Frame deletion . Frame insertion, Frame duplication TDTVD, Smart tampering . Multiple tampering	Mengembangkan dataset yang dikenal dengan TDTVD video manipulasi dengan berbagai tampering. Meningkatkan algoritma untuk mendeteksi tampering.	(Panchal & Shah, 2020)
23.	Deepfake Video	Deepfake detection · Fake video · Deep learning · Efficiency · Generalisation · Computational time	Menyajikan tinjauan singkat tentang teknik pembuatan deepfake dan analisis terperinci tentang metode deteksi video deepfake terkini dan kerentanannya Perlunya kolaborasi dengan stake holder untuk meminimalisir dampak dari <i>Deep Fake</i> .	(A. Kaur et al., 2024)
24.	ELA		Menggabungkan ELA dan analisis patch dengan <i>Deep Learning</i> (DL) strategi untuk mendeteksi konten palsu Pembagian bingkai video menjadi patch yang lebih kecil untuk analisis lokal, membantu mengisolasi wilayah yang dimanipulasi dengan lebih tepat.	(Harika Palivela et al., 2023)

			Mengompresi bingkai video (misalnya, pada 90%), ELA mengidentifikasi ketidakkonsistenan dalam tingkat kompresi, yang dapat mengindikasikan area yang dimanipulasi. Memanfaatkan ResNet50, jaringan saraf konvolusional yang sangat efektif, untuk klasifikasi memungkinkan model mempelajari pola rumit dalam bingkai yang dimanipulasi dan asli	
25.	Video Tampering	Video tampering, Object detection, Forensic video analysis, Image/Video enhancement, Forensics investigation, Machine learning, Deep learning	manipulasi media lebih mudah, menciptakan tantangan signifikan dalam memastikan keaslian konten digital pedoman hukum dan etika guna menjaga integritas proses peradilan	(Yallamandhal a & Godwin, 2022)
26.	Image Tampering	Tampering, Forgery, Image splicing, Copy-move, CNN, ELA	Membangun system deteksi manipulasi <i>copy-move</i> dan splicing. Hasil pengujian menyatakan berhasil mendeteksi dengan akurasi tinggi. Saran penelitian lebih lanjut yaitu identifikasi wilayah yang dimanipulasi dan menentukan jenis manipulasi apakah <i>copy-move</i> atau <i>splicing</i>	(Nagm et al., 2024)
27.	Image Tampering	Convolution Neural Network, Error Level Analysis, image Forensics, <i>deep learning</i>, Digital image Integrity	Berhasil mendeteksi manipulasi gambar dengan skor <i>accuracy</i> 96,21% , <i>precision</i> 98,58% , <i>recall</i> 92,36%, <i>f1-score</i> 95,37%. Berhasil mengidentifikasi manipulasi kompleks dan sebagai pondasi untuk penelitian selanjutnya dalam konteks forensics analysis	(R. Gorle and A. Guttavelli, 2025)

28.	Image Tampering	-	Inkonsistensi berbasis kompresi yang diperoleh melalui ELA dimasukkan ke CNN yang dipelajari pada basis data CASIA 2.0. Hasil eksperimen menunjukkan bahwa CNN kustom yang diusulkan dan model VGG16 yang disempurnakan memiliki kinerja klasifikasi yang baik, dengan akurasi validasi tertinggi sebesar 92,2% dan akurasi pelatihan hingga 94%.	(Vasudevan et al., 2025)
29.	Image Tampering	Forgery detection, CNN (Convolutional Neural Networks), ELA (Error Level Analysis), digital forensics, image manipulation, authenticity verification, machine learning, deep learning, compression anomalies, visual content integrity	Performa hasil akurasi sebesar 94%, dengan tingkat <i>recall</i> dan presisi masing-masing 100% dan 97%. Mampu mendeteksi manipulasi secara <i>real-time</i> . Menyarankan untuk penelitian lebih lanjut dalam konteks video manipulasi	(More et al., 2024)
30.	Image Tampering	Image Forgery, Patch-level, Error Level Analysis, CNN	Mampu mendeteksi manipulasi gambar integrasi CNN dengan ELA (<i>Error Level Analysis</i>)	(Mohammed et al., 2024)

2.2. Konsep Pengetahuan

Seperti kajian pustaka, mendefinisikan dasar pengetahuan. Definisi metode ELA. Dan menceritakan Apa itu Video Forensik. Definisi CNN dan Treshhold. ELA (Error Level Analysis) adalah teknik untuk mendeteksi gambar dan video manipulasi dengan cara

menganalisis tingkat kompresi. Video Forensik adalah mekanisme rekonstruksi peristiwa berupa video dengan cara scientific method. CNN (Convolutional Neural Network) adalah model deep learning. Threshold adalah ambang batas

Adalah konsep pengetahuan dari rancangan thesis yang di susun. Misal terkait dengan pengetahuan referensi dari definisi ELA, CNN dan Threshold atau lainnya. Cari referensi konsep pengetahuan lainnya terkait dengan rangkaian penelitian yang diajukan.

2.3. Deep Fakes


definisi *deep fakes* adalah video, audio atau gambar yang telah dirubah atau digenerate oleh *Artificial Intelligence* atau alat berbasis AI atau software video atau audio

2.4. ELA

Error Level Analysis (ELA) adalah teknik forensik digital yang ampuh yang membantu mengidentifikasi manipulasi atau perusakan citra. ELA bekerja dengan membandingkan tingkat kesalahan yang terjadi pada citra selama proses kompresi. Selama kompresi citra, algoritma JPEG membagi citra menjadi blok-blok, dan setiap blok dikompresi dengan tingkat kesalahan yang bervariasi. ELA mendeteksi perbedaan tingkat kesalahan ini dan menyoroti bagian-bagian citra yang telah diubah, sehingga mengungkap potensi perusakan. ELA menghitung selisih antara citra asli dan versi citra yang disimpan ulang. Versi yang disimpan ulang dikompresi dengan tingkat kompresi yang sama dengan citra asli. Selisih antara citra asli dan citra yang disimpan ulang menunjukkan tingkat kesalahan yang terjadi akibat proses kompresi. Pada area citra yang tidak diubah, tingkat kesalahannya rendah, sementara pada area yang telah dimanipulasi, tingkat kesalahannya tinggi. ELA menggunakan nilai ambang batas untuk menentukan area citra yang telah dimanipulasi. Biasanya, nilai ambang batas ditetapkan pada persentase tertentu dari tingkat kesalahan maksimum. Setiap area gambar yang melebihi nilai ambang batas ini ditandai sebagai area yang berpotensi dirusak. ELA juga menggunakan teknik pemetaan warna untuk menandai area gambar yang telah dimanipulasi. Biasanya, area gambar yang tidak berubah ditandai dengan warna biru, sementara area dengan tingkat kesalahan yang lebih tinggi ditandai dengan warna merah. Peta warna ini memudahkan penyelidikan forensik untuk dengan cepat mengidentifikasi area gambar yang telah dirusak. Algoritma ELA bekerja dengan menganalisis tingkat kompresi gambar. Dengan membandingkan tingkat kompresi berbagai bagian gambar, ELA dapat mengidentifikasi area yang telah dirusak. Algoritma yang digunakan ELA didasarkan pada prinsip bahwa kesalahan yang muncul selama kompresi sebanding dengan selisih antara gambar asli dan gambar yang disimpan ulang.

2.5. CNN (*Convolutional Neural Network (CNN) in Machine Learning, 2025*)

Jaringan Neural Konvolusional (CNN) adalah model pembelajaran mendalam yang dirancang untuk memproses data dengan topologi seperti grid, seperti gambar. CNN merupakan dasar bagi sebagian besar aplikasi visi komputer modern untuk mendeteksi fitur dalam data visual.




Gambar 2.1 Bidang Penerapan CNN Model

(*Convolutional Neural Network (CNN) in Machine Learning, 2025*)

Sesuai dengan Gambar 2.1 Bidang Penerapan CNN Model, sesuai dengan karakter arsitekturnya Convolutional Neural Network (CNN) telah digunakan secara luas pada berbagai domain yang sesuai dengan karakteristik pengolahan citra dan pola visual. Dalam domain otomotif, CNN berperan penting pada sistem *self-driving car*, khususnya untuk tugas deteksi objek, pengenalan rambu lalu lintas, dan pemahaman lingkungan jalan secara real-time.

Pada domain media sosial, CNN dimanfaatkan untuk analisis konten visual, seperti klasifikasi gambar dan video, deteksi konten berbahaya, serta identifikasi manipulasi digital. Dalam bidang kesehatan, CNN banyak digunakan untuk membantu proses diagnosis medis, misalnya pada analisis citra radiologi seperti hasil rontgen, MRI, atau CT-scan untuk mendeteksi keberadaan penyakit, termasuk klasifikasi jaringan kanker dan non-kanker. Selain itu, dalam bidang penegakan hukum (*Law Enforcement*), CNN digunakan untuk analisis forensik digital, pengenalan wajah, identifikasi objek pada rekaman CCTV, serta deteksi manipulasi citra dan video sebagai bagian dari proses pembuktian hukum. CNN juga memiliki peran penting dalam *Optical Character Recognition (OCR)*, yaitu untuk mengenali

dan mengekstraksi teks dari citra atau dokumen digital, yang banyak digunakan pada sistem arsip digital, pengenalan plat nomor kendaraan




Gambar 2.2 Arsitektur CNN

(*Convolutional Neural Network (CNN) in Machine Learning*, 2025)

Sesuai dengan Gambar 2.2 Arsitektur CNN, lapisan pertama pada Convolutional Neural Network merupakan lapisan input yang diproses melalui lapisan konvolusi (*convolution layer*) untuk mengekstraksi fitur awal dari citra. Selanjutnya, hasil konvolusi tersebut dilewatkan ke lapisan subsampling (pooling) berukuran 2×2, yang berfungsi untuk mengurangi dimensi fitur sekaligus mempertahankan informasi penting.

Proses ini kemudian diikuti oleh lapisan konvolusi berukuran kernel 5×5 yang bertujuan mengekstraksi fitur yang lebih kompleks, dilanjutkan kembali dengan lapisan subsampling 2×2. Rangkaian lapisan konvolusi dan subsampling tersebut dikategorikan sebagai tahap *feature extraction*, karena berfungsi untuk menangkap pola visual, tekstur, dan struktur penting pada citra.

Setelah proses ekstraksi fitur selesai, fitur yang dihasilkan diratakan (*flatten*) dan diteruskan ke lapisan *fully connected*, yang berperan sebagai tahap *classification* untuk menentukan kelas atau label dari data masukan berdasarkan fitur yang telah dipelajari.



Gambar 2.3 Pengenalan CNN Model

(*Convolutional Neural Network (CNN) in Machine Learning*, 2025)

Berdasarkan Gambar 2.3 yang menampilkan ilustrasi pengenalan model Convolutional Neural Network (CNN), proses kerja CNN terdiri dari dua tahapan utama, yaitu tahap input dan tahap training. Pada tahap input, sistem menerima data berupa citra yang mengandung berbagai jenis buah. Citra tersebut menjadi masukan awal yang akan diproses oleh model CNN.

Pada tahap training, citra-citra buah yang telah diberikan sebagai input dipelajari oleh model melalui proses ekstraksi fitur dan pembaruan bobot jaringan. Setiap citra diberi label sesuai dengan jenis buahnya, sehingga model dapat mempelajari pola visual yang membedakan satu objek dengan objek lainnya. Hasil dari proses training ini adalah model CNN yang mampu mengenali dan mengklasifikasikan objek buah berdasarkan karakteristik visual yang terdapat pada citra input.


Komponen Utama

- Lapisan *Convolution* : Lapisan ini menerapkan operasi konvolusi pada gambar masukan menggunakan filter atau kernel untuk mendeteksi fitur seperti tepi, tekstur, dan pola yang lebih kompleks. Operasi konvolusi membantu mempertahankan hubungan spasial antar piksel.
- Lapisan *Pooling*: Lapisan ini menurunkan dimensi spasial masukan, mengurangi kompleksitas komputasi dan jumlah parameter dalam jaringan. Max pooling adalah operasi pooling umum di mana kita memilih nilai maksimum dari sekelompok piksel tetangga.

- Fungsi *Activation* : Fungsi ini memperkenalkan non-linearitas pada model dengan memungkinkannya mempelajari hubungan yang lebih kompleks dalam data. Lapisan
- *Fully Connected* : Lapisan ini bertanggung jawab untuk membuat prediksi berdasarkan fitur tingkat tinggi yang dipelajari oleh lapisan sebelumnya. Lapisan ini menghubungkan setiap neuron di satu lapisan ke setiap neuron di lapisan berikutnya.

Cara Kerja CNN

1. Gambar Masukan: CNN menerima gambar masukan yang telah diproses terlebih dahulu untuk memastikan keseragaman ukuran dan format.
 2. Lapisan *Convolution* : Filter diterapkan pada gambar masukan untuk mengekstrak fitur seperti tepi, tekstur, dan bentuk.
 3. Lapisan *Pooling*: Peta fitur yang dihasilkan oleh lapisan konvolusi di-downsample untuk mengurangi dimensi.
 4. Lapisan *Fully Connected* : Peta fitur yang telah di-downsample dilewatkan melalui lapisan *fully connected* untuk menghasilkan keluaran akhir, seperti label klasifikasi.
- Keluaran: CNN menghasilkan prediksi, seperti kelas gambar.



Gambar 2.4 Cara Kerja CNN Model

(Convolutional Neural Network (CNN) in Machine Learning, 2025)

Berdasarkan Gambar 2.4 yang menunjukkan cara kerja model Convolutional Neural Network (CNN), proses dimulai dari lapisan input berupa citra digital. Citra input tersebut kemudian diproses pada lapisan konvolusi pertama (Convolution 1) dengan jumlah $n1$ channels dan menghasilkan fitur berukuran $24 \times 24 \times n1$. Proses ini menggunakan kernel konvolusi berukuran 5×5 dengan skema valid padding, sehingga ukuran fitur menjadi lebih kecil dibandingkan citra awal.

Selanjutnya, keluaran dari lapisan konvolusi pertama diteruskan ke lapisan Max-Pooling, yang berfungsi untuk mereduksi dimensi spasial serta mempertahankan fitur-fitur penting. Hasil dari proses ini menghasilkan peta fitur berukuran $12 \times 12 \times n_1$.

Pada tahap berikutnya, fitur tersebut diproses oleh lapisan konvolusi kedua (Convolution 2) dengan jumlah n_2 channels dan menggunakan kernel 5×5 dengan valid padding, sehingga menghasilkan peta fitur berukuran $8 \times 8 \times n_2$. Keluaran ini kemudian kembali melewati lapisan Max-Pooling, yang mereduksi ukuran fitur menjadi $4 \times 4 \times n_2$.

Selanjutnya, peta fitur hasil ekstraksi ini di-*flatten* dan diteruskan ke lapisan fully connected. Lapisan Fully Connected 3 menggunakan fungsi aktivasi Rectified Linear Unit (ReLU) untuk meningkatkan kemampuan non-linearitas model. Pada tahap akhir, Fully Connected 4 dilengkapi dengan teknik dropout untuk mengurangi risiko *overfitting* dan menghasilkan output klasifikasi sesuai dengan jumlah kelas yang ditentukan.

Melatih Jaringan Saraf Konvolusional (CNN)

CNN dilatih menggunakan pendekatan pembelajaran terawasi. Ini berarti bahwa CNN diberi sekumpulan gambar pelatihan berlabel. CNN belajar untuk memetakan gambar masukan ke label yang benar.

Proses pelatihan untuk CNN melibatkan langkah-langkah berikut:

1. **Persiapan Data:** Gambar pelatihan diproses terlebih dahulu untuk memastikan bahwa semuanya dalam format dan ukuran yang sama.
2. **Fungsi Kerugian:** Fungsi kerugian digunakan untuk mengukur seberapa baik kinerja CNN pada data pelatihan. Fungsi kerugian biasanya dihitung dengan mengambil selisih antara label yang diprediksi dan label sebenarnya dari gambar pelatihan.
3. **Pengoptimal:** Pengoptimal digunakan untuk memperbarui bobot CNN untuk meminimalkan fungsi kerugian.
4. **Backpropagation:** Backpropagation adalah teknik yang digunakan untuk menghitung gradien fungsi kerugian terhadap bobot CNN. Gradien tersebut kemudian digunakan untuk memperbarui bobot CNN menggunakan pengoptimal.

Cara Mengevaluasi Efisiensi Model CNN

Efisiensi CNN dapat dievaluasi menggunakan berbagai kriteria. Di antara metrik yang paling populer adalah:

- **Akurasi:** Akurasi adalah persentase gambar uji yang diklasifikasikan dengan benar oleh CNN.
- **Presisi:** Presisi adalah persentase gambar uji yang diprediksi oleh CNN sebagai kelas tertentu dan yang sebenarnya termasuk dalam kelas tersebut.

- Recall: Recall adalah persentase gambar uji yang termasuk dalam kelas tertentu dan yang diprediksi oleh CNN sebagai kelas tersebut.
- Skor F1: Skor F1 adalah rata-rata harmonik dari presisi dan recall. Ini adalah metrik yang baik untuk mengevaluasi kinerja CNN pada kelas yang tidak seimbang.

Berbagai Jenis Model CNN

1. LeNet: LeNet yang dikembangkan oleh Yann LeCun dan rekan-rekannya pada akhir tahun 1990-an adalah salah satu CNN sukses pertama yang dirancang untuk pengenalan angka tulisan tangan. Ia meletakkan dasar bagi CNN modern dan mencapai akurasi tinggi pada dataset MNIST yang berisi 70.000 gambar angka tulisan tangan (0-9).
2. AlexNet: AlexNet adalah arsitektur CNN yang dikembangkan oleh Alex Krizhevsky, Ilya Sutskever, dan Geoffrey Hinton pada tahun 2012. Ini adalah CNN pertama yang memenangkan ImageNet Large Scale Visual Recognition Challenge (ILSVRC), sebuah kompetisi pengenalan gambar utama. Ia terdiri dari beberapa lapisan konvolusi dan pooling yang diikuti oleh lapisan yang terhubung sepenuhnya. Arsitektur ini mencakup lima lapisan konvolusi, tiga lapisan pooling, dan tiga lapisan yang terhubung sepenuhnya.
3. ResNet: ResNet (Residual Networks) dirancang untuk tugas pengenalan dan pemrosesan gambar. Mereka terkenal karena kemampuannya melatih jaringan yang sangat dalam tanpa overfitting, sehingga sangat efektif untuk tugas-tugas kompleks. Ia memperkenalkan koneksi lewati (skip connections) yang memungkinkan jaringan untuk mempelajari fungsi residual, sehingga memudahkan pelatihan arsitektur yang dalam.
4. GoogleNet: GoogleNet, juga dikenal sebagai InceptionNet, terkenal karena mencapai akurasi tinggi dalam klasifikasi gambar sambil menggunakan lebih sedikit parameter dan sumber daya komputasi dibandingkan dengan CNN canggih lainnya. Komponen inti GoogleNet memungkinkan jaringan untuk mempelajari fitur pada skala yang berbeda secara bersamaan untuk meningkatkan kinerja.
5. VGG: VGG dikembangkan oleh Visual Geometry Group di Oxford, menggunakan filter konvolusi 3x3 kecil yang ditumpuk dalam beberapa lapisan, menciptakan struktur yang dalam dan seragam. Varian populer seperti VGG-16 dan VGG-19 mencapai kinerja terbaik pada dataset ImageNet, menunjukkan kekuatan kedalaman dalam CNN.

Aplikasi

- **Klasifikasi gambar:** CNN adalah model terkini untuk klasifikasi gambar. CNN dapat digunakan untuk mengklasifikasikan gambar ke dalam berbagai kategori seperti kucing dan anjing.
- **Deteksi objek:** CNN dapat digunakan untuk mendeteksi objek dalam gambar seperti orang, mobil, dan bangunan. CNN juga dapat digunakan untuk melokalisasi objek dalam gambar, yang berarti CNN dapat mengidentifikasi lokasi suatu objek dalam gambar.
- **Segmentasi gambar:** CNN dapat digunakan untuk melakukan segmentasi gambar, yang berarti CNN dapat mengidentifikasi dan memberi label pada berbagai objek dalam gambar. Hal ini berguna untuk aplikasi seperti pencitraan medis dan robotika.
- **Analisis video:** CNN dapat digunakan untuk menganalisis video seperti melacak objek dalam video atau mendeteksi peristiwa dalam video. Hal ini berguna untuk aplikasi seperti pengawasan video dan pemantauan lalu lintas.

Keunggulan

- **Akurasi Tinggi:** Mereka dapat mencapai akurasi tinggi dalam berbagai tugas pengenalan gambar. **Efisiensi:** Mereka efisien, terutama ketika diimplementasikan pada GPU.
- **Ketahanan:** Mereka tahan terhadap noise dan variasi data input.
- **Kemampuan Adaptasi:** Mereka dapat diadaptasi ke berbagai tugas dengan memodifikasi arsitekturnya.

Kekurangan


- **Kompleksitas:** Mereka bisa kompleks dan sulit dilatih, terutama untuk dataset besar.
- **Intensif Sumber Daya:** Mereka membutuhkan sumber daya komputasi yang signifikan untuk pelatihan dan penerapan.
- **Persyaratan Data:** Mereka membutuhkan sejumlah besar data berlabel untuk pelatihan.
- **Interpretasi:** Mereka bisa sulit diinterpretasikan sehingga sulit untuk memahami prediksi mereka.

BAB 3

Metodologi

3.1. Data

Paragraf ini berisi tentang data yang dikumpulkan dan lokasi dataset video diperoleh dari sumber internet dari kaggle.com khususnya untuk video manipulasi dan video original. Data yang diperoleh kemudian di petakan berdasarkan jenis manipulasi namun dalam kasus ini spesifik terkait manipulasi *deep fakes* maka. Kemudian dengan pendekatan studi kasus tau eksperimental dilakukan pengujian terhadap dataset yang ada.




Gambar 3.1 Gambaran Penelitian

Berdasarkan Gambar 3.1 Gambaran Penelitian, penelitian berbasis pendekatan studi kasus atau studi eksperimental, data diperoleh dari sumber online. Dataset yang telah tersedia kemudian di trining untuk mendapatkan model terbaik. Metode ELA diimplementasikan pada setiap foto yang telah di ekstraksi framenya dari dataset video. Integrasi dengan CNN Model untuk meningkatkan akurasi deteksi.

3.2. Langkah-Langkah Penelitian

Penelitian ini menggunakan pendekatan studi kasus dengan menganalisis dataset atau melakukan pengujian, adapun tahapan atau langkah-langkah untuk melakukan penelitian sebagai berikut :



Gambar 3.2 Langkah-Langkah Penelitian

Berdasarkan Gambar 3.2 Langkah-Langkah Penelitian tahap awal prosesnya adalah dengan mengkaji penelitian sebelumnya. Dengan menemukan permasalahan atau tantangan atau gap penelitian dari sumber penelitian terdahulu. Kemudian menyiapkan dataset dan tools yang digunakan. Dalam penelitian ini tools ada modelnya dikembangkan dengan metode ELA dan terintegrasi dengan CNN model. Kemudian dari dataset di trining. Setelah tahap tersebut di ujilah model yang telah di latih dengan video manipulasi.

3.3. Data Model

Analisis dataset terhadap video yang telah dimanipulasi dengan implementasi metode ELA dan integrasi dengan beberapa teknik lainnya. Kemudian membandingkan hasil analisis masing masing frame dengan gambar asli, implementasi metode misalnya *Deep Fakes*

3.4. Analisis Data

3.4.1. Implementasi Perangkat Lunak

Penjelasan tentang Langkah-Langkah atau tahapan dalam implementasi metode ELA terhadap penggunaan platform google colab untuk pengujian studi kasus dari dataset video.

Deteksi Manipulasi Video :

1 Analisis Dataset

Pengujian terhadap *dataset* dengan berbagai jenis manipulasi *deep fakes*.

2 Implementasi Metode ELA

Implementasi metode *Error Level Analysis (ELA)* terhadap berbagai jenis manipulasi. Ekstraksi *dataset* video menjadi frame-frame gambar, kemudian frame gambar diterapkan metode *Error Level Analysis (ELA)* untuk mendeteksi area yang menunjukkan kemungkinan telah dimanipulasi.

3 Efektifitas Deteksi

Setelah diimplementasikan metode *Error Level Analysis (ELA)* , Mengidentifikasi hasil deteksi manipulasi terhadap berbagai jenis manipulasi kemudian menganalisis tingkat akurasi deteksi.

4 Meningkatkan Akurasi

Hasil deteksi manipulasi diidentifikasi kemudian diidentifikasi parameter yang digunakan untuk meningkatkan akurasi.

5 Integrasi dengan Teknik/Model

Meningkatkan deteksi akurasi dengan integrasi metode *deep learning* misalnya adalah teknik SVM, KNN dan CNN untuk meningkatkan hasil akurasi deteksi.

6 Kategori Manipulasi

Mengidentifikasi klasifikasi dari jenis manipulasi dan hasil pengujian.

Framework Investigasi

Framework adalah prosedur atau langkah-langkah untuk mengidentifikasi kasus dalam konteks digital forensik. Ada beberapa framework yang di kenal berdasarkan NIST SP 800-

86

Collection

Data yang relevan dengan kasus diidentifikasi dan di beri label, direkam dan dikumpulkan.

Examination

Aplikasi atau *tools* forensic dan teknik diterapkan untuk mengidentifikasi dan *meng-extract* informasi yang relevant dari data yang telah di kumpulkan

Analysis

Informasi dianalisis untuk mendapatkan bukti yang akan menjelaskan akar penyebab insiden.

Reporting

Ringkas hasil dan rekomendasi lebih lanjut

BAB 4

Hasil dan Pembahasan

4.1. Tahap Pengumpulan Data

4.1.1. Dataset yang digunakan adalah kumpulan video yang mengandung manipulasi seperti deep fakes dari sumber dataset publik, seperti:

1. Video Forgery Detection Dataset
2. Kaggle: Dataset manipulasi video terkait forensik digital.

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, dengan total ukuran sekitar 19,8 GB untuk video hasil manipulasi (manipulated/deepfake videos) dan 2,7 GB untuk video asli (original videos). Secara keseluruhan, dataset tersebut menyediakan cakupan data yang cukup besar dan beragam untuk mendukung penelitian deteksi deepfake.

Namun demikian, dalam praktiknya, penggunaan seluruh dataset tidak dapat dilakukan secara langsung karena adanya keterbatasan sumber daya komputasi, khususnya kapasitas memori (RAM dan/atau GPU memory) pada perangkat yang digunakan. Ketika seluruh data dimuat dan diproses secara bersamaan, sistem mengalami kendala memori yang menyebabkan kegagalan proses pelatihan dan inferensi.

Oleh karena itu, penelitian ini menggunakan sub-sampel dataset yang diambil secara selektif dari keseluruhan data yang tersedia. Sub-sampel tersebut diekstraksi dalam bentuk frame video dan disesuaikan dengan kapasitas perangkat, sehingga proses pelatihan dan evaluasi model dapat berjalan secara stabil. Meskipun ukuran data yang digunakan lebih kecil dibandingkan dataset awal, pendekatan ini tetap memungkinkan model untuk mempelajari pola artefak manipulasi yang relevan.

Keterbatasan ini dicatat sebagai batasan penelitian (research limitation) dan menjadi dasar untuk pengembangan lebih lanjut di masa mendatang, khususnya dengan dukungan perangkat keras yang lebih memadai atau strategi pemrosesan data yang lebih efisien, seperti streaming data, batch processing, atau pelatihan terdistribusi.

4.2. Preprocessing Data

Setiap video akan diekstraksi menjadi frame-frame gambar menggunakan teknik frame extraction.

Tabel 4.1 Data Total Video

Berdasarkan Tabel 4.1 Data Total Video, Dataset yang digunakan dalam penelitian ini terdiri dari 101 video dengan total 3.381 frame hasil ekstraksi. Dari jumlah tersebut, 50 frame merupakan kelas real, sedangkan 3.331 frame termasuk dalam kelas fake. Seluruh frame memiliki ukuran 224×224 piksel dengan 3 kanal warna (RGB).

Untuk mengatasi ketidakseimbangan kelas (*class imbalance*) yang signifikan antara kelas real dan fake, diterapkan class weighting pada proses pelatihan model. Bobot kelas yang digunakan adalah 33,81 untuk kelas real (0) dan 0,51 untuk kelas fake (1).

Jumlah Video	Total Frame	Real Frame	Fake Frame	Frame Shape	Class Weight
101	3,381	50	3,331	3381, 224, 224, 3	0:np.float64(33.81) 1:np.float64(0.5075052536775743)

Tahap Implementasi Metode ELA

Fungsi *apply_ela* dirancang untuk menerapkan metode Error Level Analysis (ELA) pada sebuah frame citra. Fungsi ini bersifat fleksibel dan dapat dipanggil secara modular dalam berbagai tahapan pemrosesan, termasuk sebelum proses inisialisasi deteksi menggunakan model CNN.

Proses ELA diawali dengan normalisasi nilai piksel dari frame masukan. Apabila frame memiliki rentang nilai antara 0 hingga 1, nilai tersebut dikonversi kembali ke rentang 0 hingga 255 untuk memastikan format citra sesuai dengan standar kompresi lossy. Selanjutnya, data citra dinormalisasi ke tipe uint8 agar dapat dikompresi secara valid menggunakan algoritma JPEG.

Frame kemudian dikonversi dari format NumPy array ke objek PIL Image untuk keperluan kompresi. Citra tersebut disimpan sementara menggunakan kompresi lossy JPEG dengan tingkat kualitas sebesar 95%, yang bertujuan untuk mempertahankan detail visual utama sambil tetap memunculkan perbedaan tingkat kompresi.

Setelah proses kompresi, perbedaan nilai piksel antara citra asli dan citra hasil kompresi dihitung. Selisih ini merepresentasikan tingkat kesalahan kompresi pada setiap piksel, yang sering kali menonjol pada area yang mengalami manipulasi. Perbedaan tersebut kemudian diperkuat dengan meningkatkan kontras pencahayaan hingga mencapai skala maksimum agar artefak manipulasi menjadi lebih jelas terlihat.

Setelah proses peningkatan perbedaan selesai, berkas citra sementara dihapus untuk menjaga efisiensi penyimpanan. Terakhir, citra hasil ELA yang telah diperkuat dikonversi

kembali ke format NumPy array, sehingga siap digunakan sebagai masukan bagi tahapan pemrosesan selanjutnya atau langsung diberikan ke model CNN.

4.3. Tahap Optimasi dan Pengembangan Model CNN

Arsitektur CNN pada kelas AdvancedDeepfakeDetector dirancang untuk meningkatkan stabilitas pelatihan dan sensitivitas terhadap artefak halus yang umum ditemukan pada konten deepfake. Model ini mengintegrasikan beberapa mekanisme utama sebagai berikut:

- Residual Connections

Model ini menerapkan residual connections (skip connections) pada beberapa blok konvolusional. Mekanisme ini memungkinkan aliran gradien yang lebih stabil selama proses pelatihan, sehingga membantu mengurangi permasalahan vanishing gradients serta mempercepat konvergensi pada jaringan yang relatif dalam.

- Attention Mechanism (Channel-wise Attention)

Model mengadopsi mekanisme channel-wise attention yang diimplementasikan melalui rangkaian Global Average Pooling → Dense → Dense → Multiply. Mekanisme ini memungkinkan jaringan untuk menyesuaikan bobot pada setiap kanal fitur berdasarkan tingkat kepentingannya, sehingga model dapat lebih fokus pada fitur-fitur informatif yang berkaitan dengan artefak manipulasi halus pada deepfake. Pendekatan ini sangat relevan untuk tugas forensik digital yang menuntut sensitivitas tinggi terhadap perbedaan tekstur dan pola kompresi.

- Regularization

Untuk mengurangi risiko overfitting, model menerapkan beberapa teknik regularisasi, yaitu Dropout pada berbagai tahap jaringan dan regularisasi kernel L2 pada lapisan konvolusional dan dense. Kombinasi ini membantu membatasi kompleksitas model sekaligus meningkatkan kemampuan generalisasi, terutama pada dataset berukuran terbatas.

- Dual Pooling Strategy

Sebelum memasuki lapisan fully connected, model menggabungkan Global Average Pooling (GAP) dan Global Max Pooling (GMP). Strategi dual pooling ini memungkinkan model menangkap informasi distribusi fitur global sekaligus respons aktivasi ekstrem, yang penting untuk mendeteksi inkonsistensi lokal maupun global pada citra deepfake.

- Metrik Evaluasi

Kinerja model dievaluasi menggunakan serangkaian metrik yang komprehensif, meliputi Accuracy, Area Under the ROC Curve (AUC), Precision, Recall, dan Binary Accuracy.

Kombinasi metrik ini memberikan gambaran yang lebih menyeluruh terhadap performa klasifikasi, khususnya dalam konteks dataset yang berpotensi tidak seimbang antara kelas asli dan deepfake

4.4. Training Model

Model dilatih untuk mempelajari pola dan hubungan antara fitur-fitur yang diekstraksi dari frame video. Dataset dibagi menjadi 3.944 sampel pelatihan dan 987 sampel pengujian, yang memberikan proporsi data uji yang memadai untuk evaluasi performa akhir model. Pelatihan dilakukan selama 30 epoch, jumlah yang umumnya cukup untuk mengamati proses konvergensi model.

Namun, mengingat ukuran dataset yang relatif terbatas, terdapat risiko overfitting sehingga diperlukan pemantauan kinerja validasi secara cermat. Ukuran batch sebesar 16 dipilih karena batch yang lebih kecil menghasilkan lebih banyak pembaruan bobot per epoch, yang sering kali membantu meningkatkan kemampuan generalisasi model, khususnya pada dataset berukuran kecil hingga menengah. Sebanyak 15% dari data pelatihan (sekitar 592 sampel) digunakan sebagai data validasi.

Pembagian ini memungkinkan pemantauan performa model selama proses pelatihan tanpa melibatkan data uji, sehingga evaluasi akhir tetap objektif. Dengan ukuran batch 16, setiap epoch terdiri dari sekitar 247 langkah pelatihan ($3944 / 16$).

Model yang digunakan memiliki sekitar 6,5 juta parameter, yang tergolong cukup besar untuk dataset ini namun masih berada pada keseimbangan yang wajar antara kapasitas representasi dan efisiensi komputasi.

Oleh karena itu, penerapan teknik regularisasi seperti dropout dan regularisasi L2 menjadi sangat penting untuk mengurangi risiko overfitting dan meningkatkan stabilitas pelatihan. Secara keseluruhan, konfigurasi pelatihan ini dirancang untuk memberikan kompromi yang baik antara kekuatan model dan keterbatasan jumlah data, dengan tetap menjaga validitas evaluasi melalui pemisahan data pelatihan, validasi, dan pengujian.

Fungsi *train()* digunakan untuk melatih model CNN dengan memanfaatkan teknik augmentasi data dan mekanisme early stopping untuk meningkatkan kemampuan generalisasi. Data pelatihan diberikan dalam bentuk frame video beserta labelnya, sementara data uji disimpan terpisah dan hanya digunakan untuk evaluasi akhir.

Selama proses pelatihan, data pelatihan dibagi lebih lanjut menjadi data latih dan data validasi menggunakan rasio *validation_split*. Augmentasi data diterapkan melalui ImageDataGenerator dengan transformasi geometris ringan seperti rotasi, pergeseran,

pembesaran, dan horizontal flipping untuk memperkaya variasi data dan mengurangi overfitting.


Proses pelatihan dipantau menggunakan beberapa callback, termasuk Early Stopping berbasis metrik AUC validasi, Reduce Learning Rate on Plateau untuk menyesuaikan laju pembelajaran secara adaptif, serta Model Checkpoint untuk menyimpan model dengan performa validasi terbaik. Setelah pelatihan selesai, model dievaluasi menggunakan data uji yang tidak pernah disentuh selama proses pelatihan maupun validasi.

4.5. Integrasi ELA dengan Algoritma Kecerdasan Buatan

Integrasi metode ELA dengan CNN model untuk deteksi video manipulasi. Fungsi *preprocess_frame()* bertanggung jawab untuk melakukan pra-pemrosesan setiap frame video sebelum diberikan sebagai masukan ke model CNN. Frame yang diperoleh dari OpenCV umumnya berada dalam format warna BGR, sehingga langkah awal dilakukan konversi ke format RGB untuk memastikan konsistensi representasi warna.

Selanjutnya, frame diubah ukurannya menjadi dimensi tetap sesuai dengan kebutuhan input model, yaitu $\text{img_size} \times \text{img_size}$. Error Level Analysis (ELA) diaktifkan, frame yang telah diubah ukurannya akan diproses menggunakan metode ELA untuk mengekstraksi perbedaan tingkat kompresi, yang sering kali berkaitan dengan area manipulasi pada citra digital.

Tahap akhir pra-pemrosesan adalah normalisasi nilai piksel ke rentang $[0, 1]$ dengan membagi nilai intensitas piksel dengan 255. Normalisasi ini membantu menstabilkan proses pelatihan dan inferensi jaringan saraf dengan memastikan skala input yang konsisten.



Gambar 4.1 Bagan Integrasi ELA dengan CNN model

4.6. Mengimplementasikan metode deep learning (CNN, SVM, atau KNN) untuk meningkatkan deteksi manipulasi.

Fungsi *detect_manipulation()* digunakan untuk mendeteksi indikasi manipulasi pada sebuah video dengan melakukan inferensi berbasis frame. Proses diawali dengan validasi keberadaan dan format berkas video, kemudian dilanjutkan dengan ekstraksi frame menggunakan OpenCV.


Setiap frame yang diekstraksi diproses melalui fungsi *preprocess_frame()* agar sesuai dengan format input model CNN. Frame-frame yang telah diproses kemudian disusun menjadi sebuah array dan diberikan sebagai masukan ke model deep learning untuk menghasilkan skor probabilitas manipulasi pada tingkat frame.

Prediksi pada tingkat video diperoleh melalui agregasi statistik dari skor frame, meliputi:

Rata-rata skor (average score) sebagai indikator utama tingkat manipulasi video, Median skor untuk mengurangi pengaruh outlier, Simpangan baku (standard deviation) untuk mengukur konsistensi prediksi antar-frame, Persentase frame terdeteksi palsu berdasarkan ambang batas (threshold) yang ditentukan.

Keputusan akhir klasifikasi video ditentukan berdasarkan perbandingan nilai rata-rata skor dengan ambang batas klasifikasi. Selain itu, tingkat kepercayaan (confidence) dihitung sebagai jarak skor rata-rata terhadap ambang keputusan, yang merepresentasikan keyakinan model terhadap hasil klasifikasi. Pendekatan berbasis agregasi frame ini memungkinkan deteksi manipulasi yang lebih robust dibandingkan klasifikasi tunggal, khususnya pada video yang hanya mengalami manipulasi parsial atau temporer

4.7. Pengujian Model



Gambar 4.2 Hasil Trining Model CNN

Model yang telah dilatih kemudian diuji menggunakan dataset yang berbeda dari dataset pelatihan untuk mengevaluasi kemampuan generalisasi. Hasil pengujian menunjukkan bahwa performa model mengalami penurunan yang signifikan, dengan nilai akurasi sebesar 54%. Nilai ini mengindikasikan bahwa model masih menghasilkan tingkat kesalahan klasifikasi yang cukup tinggi ketika dihadapkan pada distribusi data yang berbeda.

Grafik *Accuracy* menunjukkan nilai *train* pada epoch ke-6 sebesar 0,55 dan *validation* 0,35 menunjukkan model belum *generalize* dengan baik. Penyebab utama karena dataset terlalu kecil dan model terlalu sederhana.

Pada grafik *Loss*, pada epoch ke-6 terlihat adanya kesenjangan yang signifikan antara nilai *training loss* dan *validation loss*. Nilai *training loss* berada pada kisaran ≈ 1 , sedangkan *validation loss* meningkat tajam hingga ≈ 6 . Kondisi ini menunjukkan bahwa model mampu menyesuaikan diri dengan baik terhadap data pelatihan, namun gagal mempertahankan performa yang sama pada data validasi.

Pada grafik AUC (Area Under the Curve) terlihat bahwa pada epoch ke-6, nilai AUC data pelatihan (*train*) mencapai 0,57, sedangkan nilai AUC data validasi (*validation*) berada

pada kisaran 0,50. Nilai AUC sebesar 0,50 pada data validasi menunjukkan bahwa kemampuan model dalam membedakan antara video asli dan video manipulasi pada data yang belum pernah dilihat masih setara dengan tebakan acak (*random guessing*).

Perbedaan nilai AUC antara data pelatihan dan data validasi mengindikasikan bahwa model mulai mempelajari pola pada data pelatihan, namun pola tersebut belum dapat digeneralisasikan dengan baik ke data validasi. Kondisi ini dapat disebabkan oleh keterbatasan jumlah dan keberagaman dataset pelatihan, serta kompleksitas artefak manipulasi video yang beragam.

Nilai AUC pelatihan yang sedikit lebih tinggi (0,57) menunjukkan adanya peningkatan kemampuan diskriminatif model pada data yang digunakan untuk pelatihan. Namun, penurunan kinerja pada data validasi menandakan bahwa model belum cukup stabil dan masih rentan terhadap overfitting awal, meskipun belum bersifat signifikan.

Berdasarkan metrik evaluasi *Precision dan Recall*, diperoleh nilai precision sebesar 0,70 dan recall sebesar 0,625. Nilai precision yang relatif lebih tinggi menunjukkan bahwa sebagian besar prediksi *fake* yang dihasilkan oleh model memang benar merupakan video hasil manipulasi. Dengan kata lain, tingkat false positive yang dihasilkan model relatif rendah, sehingga risiko salah mengklasifikasikan video asli sebagai video manipulasi dapat diminimalkan.

Sebaliknya, nilai recall yang lebih rendah mengindikasikan bahwa model belum mampu mendeteksi seluruh video manipulasi yang ada dalam dataset uji. Masih terdapat sejumlah video manipulasi yang diklasifikasikan sebagai video asli (*false negative*). Kondisi ini menunjukkan bahwa meskipun model cukup selektif dan berhati-hati dalam memberikan label *fake*, sensitivitas model terhadap seluruh variasi manipulasi video masih terbatas (Luque et al., 2019; Riehl et al., 2023; Sathyanarayanan, 2024)

Analisis lebih lanjut menunjukkan bahwa kesalahan yang dominan berupa false positive, yaitu kondisi di mana video asli diklasifikasikan sebagai hasil manipulasi. Fenomena ini mengindikasikan bahwa model cenderung sensitif terhadap pola tertentu yang dipelajari dari dataset pelatihan, namun pola tersebut tidak sepenuhnya merepresentasikan karakteristik data pada dataset pengujian yang berbeda.

Salah satu faktor utama yang berkontribusi terhadap keterbatasan performa ini adalah keterbatasan sumber daya komputasi, khususnya memori. Meskipun dataset yang tersedia relatif besar, yaitu sekitar 19,8 GB untuk video manipulasi dan 2,7 GB untuk video asli, keterbatasan memori perangkat menyebabkan tidak seluruh dataset dapat digunakan secara optimal dalam proses pelatihan. Akibatnya, model dilatih menggunakan subset data yang

lebih kecil, yang berpotensi membatasi cakupan variasi artefak manipulasi yang dapat dipelajari.

Kondisi ini menyebabkan model kurang mampu melakukan generalisasi terhadap dataset dengan karakteristik yang berbeda, sehingga meningkatkan risiko kesalahan klasifikasi, khususnya dalam bentuk false positive. Oleh karena itu, hasil ini menunjukkan bahwa performa model masih sangat dipengaruhi oleh distribusi data pelatihan dan belum sepenuhnya robust terhadap variasi data yang lebih luas

4.8. Model yang dikembangkan akan diuji pada dataset baru untuk mengukur

keandalan dan generalisasi metode.

Hasil evaluasi pada dataset uji menunjukkan bahwa model cenderung mengklasifikasikan seluruh sampel sebagai kelas REAL. Hal ini ditunjukkan oleh nilai recall sebesar 1.00 pada kelas REAL dan 0.00 pada kelas FAKE. Kondisi ini mengindikasikan adanya bias prediksi yang kuat terhadap satu kelas, yang kemungkinan disebabkan oleh perbedaan distribusi data antara dataset pelatihan dan pengujian (domain shift), serta keterbatasan data pelatihan akibat kendala sumber daya.”

Meskipun nilai *ROC-AUC* sebesar 0.5614 menunjukkan bahwa model masih memiliki kemampuan diskriminatif yang lebih baik dibandingkan tebakan acak, namun kemampuan tersebut tidak dapat dimanfaatkan secara efektif pada threshold klasifikasi yang digunakan.

Berdasarkan hasil pengujian, video 4032_processed.mp4 diklasifikasikan sebagai REAL dengan tingkat keyakinan sebesar 94.37%. Namun, mengingat keterbatasan sumber daya, jumlah frame yang dianalisis, serta hasil evaluasi generalisasi model yang menunjukkan akurasi sebesar 54% pada dataset berbeda, maka hasil ini perlu diinterpretasikan secara hati-hati dan tidak dapat dijadikan satu-satunya dasar kesimpulan keaslian video.

BAB 5

Kesimpulan dan Saran

5.1. Kesimpulan

Dari hasil pengujian dengan dataset jenis manipulasi deepfakes dengan kualitas .mp4 dan intensitas variasi warna terlihat hasil kompresi menggunakan metode ELA menghasilkan tantangan dalam menentukan akurasi deteksi manipulasi.

Untuk meningkatkan deteksi akurasi telah di kombinasikan dengan model CNN, untuk meningkatkan akurasi menunjukkan hasil yang fluktuatif. Namun hasil pengujian model mendapatkan Roc-auc sebesar 54% sehingga tidak bisa dijadikan kesimpulan dalam penentuan deteksi.

5.2. Saran

Resource hardware maupun software secara spesifikasi mencukupi untuk *training* dataset sebesar 19.8 GB video manipulasi dan 2.7 GB video asli. Untuk mendapatkan hasil roc-auc lebih tinggi

Daftar Pustaka

- CPatel, H., & M Patel, M. (2015). An Improvement of Forgery Video Detection Technique using Error Level Analysis. *International Journal of Computer Applications*, 111(15), 26–28. <https://doi.org/10.5120/19615-1508>
- Farook, D. A. (2024). Deteksi Keaslian Citra Menggunakan Metode Error Level Analysis (ELA) dan Principal Component Analysis (PCA). *Acme*, 23(2), 156–160. <https://doi.org/10.7202/1111254ar>
- Idlbek, R., Pešić, M., & Šolić, K. (2024). Enhancing Digital Image Forensics with Error Level Analysis (ELA). *2024 47th MIPRO ICT and Electronics Convention (MIPRO)*, 1555–1560. <https://doi.org/10.1109/MIPRO60963.2024.10569232>
- Jeronymo, D. C., Borges, Y. C. C., & Coelho, L. dos S. (2017). Image forgery detection by semi-automatic wavelet soft-Thresholding with error level analysis. *Expert Systems with Applications*, 85, 348–356. <https://doi.org/10.1016/j.eswa.2017.05.044>
- Rafique, R., Gantassi, R., Amin, R., Frnda, J., Mustapha, A., & Alshehri, A. H. (2023). Deep fake detection and classification using error-level analysis and deep learning. *Scientific Reports*, 13(1), 1–13. <https://doi.org/10.1038/s41598-023-34629-3>
- Rafique, R., Nawaz, M., Kibriya, H., & Masood, M. (2021). DeepFake Detection Using Error Level Analysis and Deep Learning. *2021 4th International Conference on Computing & Information Sciences (ICCIS)*, 1–4. <https://doi.org/10.1109/ICCIS54243.2021.9676375>
- Raković, D. (2023). Error level analysis (ELA). *Tehnika*, 78(4), 445–451. <https://doi.org/10.5937/tehnika2304445r>
- Sari, T., Riadi, I., & Fadlil, A. (2016). *Forensik Citra untuk Deteksi Rekayasa File Menggunakan Error Level Analysis*. 2(1), 133–138. <http://ars.ilkom.unsri.ac.id>
- Sari, W. P., & Fahmi, H. (2021). Effect of Error Level Analysis on The Image Forgery Detection Using Deep Learning. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 4(3). <https://doi.org/10.22219/kinetik.v6i3.1272>
- Seiler, M., Škvorc, U., Cenikj, G., Doerr, C., & Trautmann, H. (2024). Learned Features vs. Classical ELA on Affine BBOB Functions. In M. Affenzeller, S. M. Winkler, A. V Kononova, H. Trautmann, T. Tušar, P. Machado, & T. Bäck (Eds.), *Parallel Problem Solving from Nature -- PPSN XVIII* (pp. 137–153). Springer Nature Switzerland.
- Warif, N. B. A., Idris, M. Y. I., Wahab, A. W. A., & Salleh, R. (2015). An evaluation of

- Error Level Analysis in image forensics. *2015 5th IEEE International Conference on System Engineering and Technology (ICSET)*, 23–28. <https://doi.org/10.1109/ICSEngT.2015.7412439>
- Li, S., Sun, X., & Liu, J. (2020). Error level analysis for video forgery detection. *Nama Jurnal*, Volume(Issue), Halaman.
- Hernandez-Cabronero, J. L., et al. (2019). A frame-by-frame error level analysis for video tampering detection. *Nama Jurnal*, Volume(Issue), Halaman.
- Sencar, H. T., et al. (2018). The impact of video compression on forensic analysis. *Nama Jurnal*, Volume(Issue), Halaman.
- Singh, A. K., Singh, B. K., & Chaudhury, S. (2019). Video forensics: A survey. *Nama Jurnal*, Volume(Issue), Halaman.
- Convolutional Neural Network (CNN) in Machine Learning*. (2025). <https://www.geeksforgeeks.org/deep-learning/convolutional-neural-network-cnn-in-machine-learning/>
- CPatel, H., & M Patel, M. (2015). An Improvement of Forgery Video Detection Technique using Error Level Analysis. *International Journal of Computer Applications*, 111(15), 26–28. <https://doi.org/10.5120/19615-1508>
- Efendi, M. M. (2018). *Metode deteksi tepi block jpeg terkompresi untuk meningkatkan akurasi analisis manipulasi splicing pada citra berekstensi jpeg*. <https://dspace.uui.ac.id/handle/123456789/5598>
- Faroek, D. A. (2024). Deteksi Keaslian Citra Menggunakan Metode Error Level Analysis (ELA) dan Principal Component Analysis (PCA). *Acme*, 23(2), 156–160. <https://doi.org/10.7202/1111254ar>
- Luque, A., Carrasco, A., Martín, A., & de las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Mercier, G., Markatopoulou, F., Cozien, R., Zampoglou, M., Apostolidis, E., Metsai, A. I., Papadopoulos, S., Mezaris, V., Patras, I., & Kompatsiaris, I. (2019). Detecting manipulations in video. *Video Verification in the Fake News Era*, 161–189. https://doi.org/10.1007/978-3-030-26752-0_6
- Mohammed, K. B., Agrawal, I., Kandimalla, M. D., Govathoti, P. F., Prakash, C. S., & Singh, P. (2024). Advancing Digital Image Forensics: Enhancing Image Forgery Detection Through Error Level Analysis and Convolutional Neural Networks. In M.

- Pant, K. Deep, & A. Nagar (Eds.), *Proceedings of the 12th International Conference on Soft Computing for Problem Solving* (pp. 325–340). Springer Nature Singapore.
- More, S. S., Lobo, V. B., Chaudhari, A., Pandey, A., Kumavat, B., & Kamble, Y. (2024). Enhancing Image Forgery Detection with Convolutional Neural Networks and Error Level Analysis. In *Journal of Information Systems Engineering and Management* (Vol. 2025, Issue 27s). <https://www.jisem-journal.com/>
- Nagm, A. M., Moussa, M. M., Shoitan, R., Ali, A., Mashhour, M., Salama, A. S., & AbdulWakel, H. I. (2024). Detecting image manipulation with ELA-CNN integration: a powerful framework for authenticity verification. *PeerJ Computer Science*, 10, e2205. <https://doi.org/10.7717/peerj-cs.2205>
- Panchal, H. D., & Shah, H. B. (2020). Video tampering dataset development in temporal domain for video forgery authentication. *Multimedia Tools and Applications*, 79(33–34), 24553–24577. <https://doi.org/10.1007/s11042-020-09205-w>
- Patankar, S., Joshi, A., Durge, G., Jaid, A., Kalambe, K., & Dhale, H. (2023). Image Forgery Detection using ELA and CNN. *2023 2nd International Conference on Futuristic Technologies (INCOFT)*, 1–7. <https://doi.org/10.1109/INCOFT60753.2023.10425116>
- Patel, H., & Patel, M. (2015). *Forgery Frame Detection From The Video Using Error Level Analysis*. <https://api.semanticscholar.org/CorpusID:212513110>
- R. Gorle and A. Guttavelli. (2025). *Enhanced Image Tampering Detection using Error Level Analysis and a CNN*. <https://doi.org/10.48084/etasr.9593>
- Riehl, K., Neunteufel, M., & Hemberg, M. (2023). *Hierarchical confusion matrix for classification performance evaluation*. <https://doi.org/10.1093/jrsssc/qlad057>
- Sandhya, & Kashyap, A. (2024). A comprehensive analysis of digital video forensics techniques and challenges. *Iran Journal of Computer Science*, 7(2), 359–380. <https://doi.org/10.1007/s42044-023-00165-6>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 4023–4031. <https://doi.org/10.53555/AJBR.v27i4S.4345>
- Vadrevu, A., Rajeshwari, R., Pabbathi, L., Sirimalla, S., & Vodnala, D. (2022). Image Forgery Detection Using Metadata Analysis and ELA Processor. In H. S. Saini, R. Sayal, A. Govardhan, & R. Buyya (Eds.), *Innovations in Computer Science and Engineering* (pp. 579–586). Springer Singapore.

- Vasudevan, M., Sireesha, C., Sumiya, N., Vardhan, K. V, & Sagar, T. (2025). CNN based Error Level Analysis (ELA) With Scores to Detect Digital Image Manipulation. *2025 3rd International Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS)*, 1541–1547. <https://doi.org/10.1109/ICSSAS66150.2025.11081309>
- Verma, A., Pandey, P., & Khari, M. (2024). ELA-Conv: Forgery Detection in Digital Images Based on ELA and CNN. In K. C. Santosh, A. Makkar, M. Conway, A. K. Singh, A. Vacavant, A. el Kalam, M.-R. Bouguelia, & R. Hegadi (Eds.), *Recent Trends in Image Processing and Pattern Recognition* (pp. 213–226). Springer Nature Switzerland.