

FAKE FACE IMAGE CLASSIFICATION USING FACENET WITH ERROR LEVEL ANALYSIS

IRMA AMELIA DEWI^{1*}, RUTH MANA MARGARETHA^{1*}

¹Institut Teknologi Nasional Bandung, Indonesia
Email : Irma_amelia@itenas.ac.id, rumasidormsd21@gmail.com

Received 04 09 2023 | Revised 11 09 2023 | Accepted 11 09 2023

ABSTRAK

Berkembangnya teknologi membuat semakin berkembangnya kreatifitas. Seperti contohnya adalah edit pada foto. Dimana data berupa foto yang dapat diunggah pada social media. Hasil foto yang diunggah pada social media bisa saja merupakan foto asli (tanpa editan) atau foto hasil edit. Hasil edit foto ini sering digunakan sebagai tindak kecurangan untuk menipu seseorang. Untuk itu perlu adanya sistem untuk mendeteksi apakah gambar itu real atau fake. Dataset yang digunakan sebanyak 9.742 data yang terbagi menjadi dua kelas yaitu Real dan Fake menggunakan FaceNet dan metode Error Level Analysis serta klasifikasi menggunakan Support Vector Machines dengan menentukan hyperparameter tuning yaitu epoch = 10, optimizer = Adam, batch size = 64, dan learning rate = 0.0001 menghasilkan akurasi sebesar 95.78% dan hyperplane terbaik untuk SVM yaitu kernel = Linear, C = 0.1 menghasilkan precision 53%, recall 54%, dan f1-score 54%.

Kata kunci: *Deep learning, FaceNet, Error Level Analysis, Support Vector Machines, Fake Face Image*

ABSTRACT

The development of science and technology is currently quite advanced, especially information technology has experienced rapid development. Currently, the use of websites is dynamic and indispensable throughout the company. In making a website profile in an itenas interior design study program, Bandung is still incomplete to collect data and information, so it requires a system that is able to provide information that is fast, accurate and can update. In making a website profile in an interior design study program, itenas bandung is still incomplete to collect data and information. This problem can be solved by building a dynamic website profile of the itenas interior design study program using the Laravel framework in order to make it easier to find data and information from the study program.

Keywords: *Deep learning, FaceNet, Error Level Analysis, Support Vector Machines, Fake Face Image*

1. PENDAHULUAN

Social media merupakan wadah yang populer untuk saat ini khususnya di kalangan remaja dan dewasa. Salah satu contoh penggunaannya pada *social media* adalah dimana data berupa foto yang dapat diunggah pada *social media* dari hasil foto asli (tanpa editan) atau foto hasil edit. Dimana hasil foto edit ini berguna untuk mempercantik diri, menyesuaikan dengan nada *contrast* foto lainnya agar terlihat lebih *aesthetic*, dan lainnya. Foto yang diunggah juga bisa dijadikan informasi palsu seperti menipu seseorang dari foto yang digunakan terutama foto hasil edit (manipulasi). Menggunakan arsitektur *FaceNet* yang memiliki model yang kompleks dan menggabungkannya dengan *Error Level Analysis* lalu gabungan dari hasil ekstraksi fitur *FaceNet* dan *Error Level Analysis* ini digunakan pada klasifikasi oleh *Support Vector Machines* (SVM) dan mendapatkan akurasi yang baik berdasarkan *image* yang diinput untuk mengetahui apakah *image* tersebut *real* atau *fake*. Sistem ini dapat membantu untuk mendeteksi apakah gambar citra wajah tersebut *real* atau *fake*.

Mengenai deteksi manipulasi yang dilakukan oleh *Error Level Analysis* (ELA), pemalsuan citra sering tak dapat dikenali secara kasat mata karena citra hasil modifikasi sehingga sulit ditentukan keasliannya. Kemunculan citra-citra digital yang dimodifikasi akan menimbulkan permasalahan dalam kehidupan sosial seperti penyebaran informasi yang tidak benar. *Error Level Analysis* (ELA) menghasilkan tingkat akurasi mencapai 97% dalam menentukan gambar asli atau manipulasi (Candra & Prapanca, 2020). Uji coba pada jenis citra modifikasi tekstur, tercatat uji coba pada 20 citra uji dengan kompresi 90% yang paling efektif dalam melakukan proses filter ELA dimana total citra uji yang dilakukan uji coba sebanyak 250 citra dengan kompresi 90%. (Darmawan, Sasmitha, & Buana, 2019). Cara kerja ekstraksi fitur *FaceNet* dan *Error Level Analysis* dalam mengatasi adanya tindakan manipulasi pada citra wajah. Dengan adanya gabungan hasil dari ekstraksi fitur *FaceNet* dan *Error Level Analysis* serta diklasifikasikan oleh *Support Vector Machines* (SVM), maka akan diketahui seberapa besar akurasi yang didapatkan oleh kinerja sistem berikut dalam mengetahui apakah citra tersebut asli atau palsu.

Hasil uji coba dengan metode ELA+VGG16 menghasilkan tingkat akurasi 83,3%, ELA+*RestNet50* menghasilkan tingkat akurasi 95,4%, ELA+*ResNet101* menghasilkan tingkat akurasi 95,1%, dan ELA+*ResNet152* menghasilkan tingkat akurasi 93,8% (Zhang, Zhao, & Li, 2020). *Error Level Analysis* (ELA)+VGG16 menghasilkan tingkat akurasi 91,97%, *Error Level Analysis* (ELA)+VGG19 menghasilkan tingkat akurasi sebesar 92,09% (Qurat-ul-ain, Nida, Irtaza, & Ilyas, 2021). Hasil uji yang dilakukan oleh ELA+*ResNet18*+SVM menghasilkan tingkat akurasi sebesar 89,5% (Rafque, et al., 2023).

Tujuan penelitian yang dilakukan oleh penulis bertujuan untuk mendeteksi potensi manipulasi pada gambar citra wajah dengan menggunakan ekstraksi fitur *FaceNet* dengan metode *Error Level Analysis* dan *Support Vector Machines* sebagai klasifikasi dan mengetahui tingkat akurasi yang baik berdasarkan *hyperplane C* yang digunakan pada *Support Vector Machines* untuk melihat adanya potensi manipulasi pada gambar citra wajah.

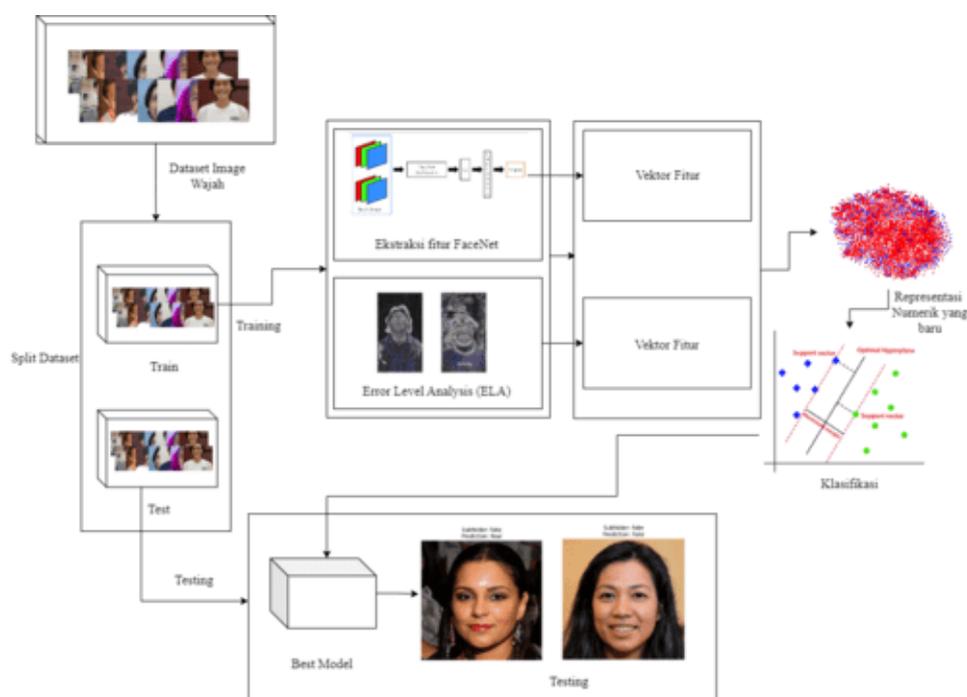
2. METODE PENELITIAN

Metode penelitian merupakan proses yang perlu dilakukan untuk mendapatkan hasil dari penelitian yang maksimal. Dataset yang digunakan pada penelitian ini sebanyak 9.742 data yang terbagi menjadi dua kelas yaitu *fake* dan *real*. Dua kelas yang sudah terbagi menjadi dua kelas ini merupakan gabungan dataset primer dan dataset sekunder. Dataset yang ada pada kelas *fake* merupakan dataset citra wajah dari hasil edit atau bisa disebut dengan teknik

manipulasi. Dataset yang ada pada kelas *real* merupakan dataset citra wajah asli tanpa hasil edit. Pada metode penelitian yang dilakukan adalah dengan menggunakan arsitektur model *FaceNet* dengan menggunakan analisa tingkat kesalahan pada citra wajah yaitu menggunakan *Error Level Analysis* (ELA) dan klasifikasi menggunakan *Support Vector Machines* (SVM). Adanya metode penelitian menggunakan *FaceNet*, *Error Level Analysis* (ELA) dan *Support Vector Machines* (SVM) untuk menganalisa tingkat analisa manipulasi pada citra wajah lebih akurat dengan memanfaatkan arsitektur model *FaceNet* yang lebih kompleks digabung dengan hasil analisa tingkat kesalahan oleh *Error Level Analysis* (ELA) dan melakukan klasifikasi oleh *Support Vector Machines* (SVM) yang menghasilkan citra wajah tersebut adalah citra wajah *fake* atau *real*. Proses awalnya adalah melakukan *training* pada model *FaceNet* yang sudah dibangun dan mendapatkan model terbaik untuk digunakan sebagai ekstraksi fitur hingga klasifikasi. Setelah mendapatkan model terbaik dari *FaceNet* maka dilanjutkan dengan ekstraksi oleh *FaceNet* pada data train, kemudian melakukan analisa tingkat kesalahan oleh *Error Level Analysis* (ELA) pada data train. Setelah mendapatkan hasil dari ekstraksi fitur dari *FaceNet* berupa *array* dan mendapatkan hasil analisa tingkat kesalahan dari *Error Level Analysis* (ELA) berupa *array* maka menggabungkan kedua hasil tersebut menjadi representasi numerik yang baru yang dapat digunakan pada klasifikasi oleh *Support Vector Machines* (SVM). Setelah mendapatkan parameter terbaik dari model SVM yang digunakan untuk klasifikasi dan mendapatkan akurasi yang terbaik, maka model SVM tersebut digunakan untuk *predict* pada data yang belum pernah diujikan. Berikut adalah proses penelitian yang ditunjukkan pada Gambar 1.

2.1. Block Diagram

Berikut adalah *block diagram* yang dilakukan dalam penelitian ditunjukkan pada Gambar 1.



Gambar 1. Block Diagram

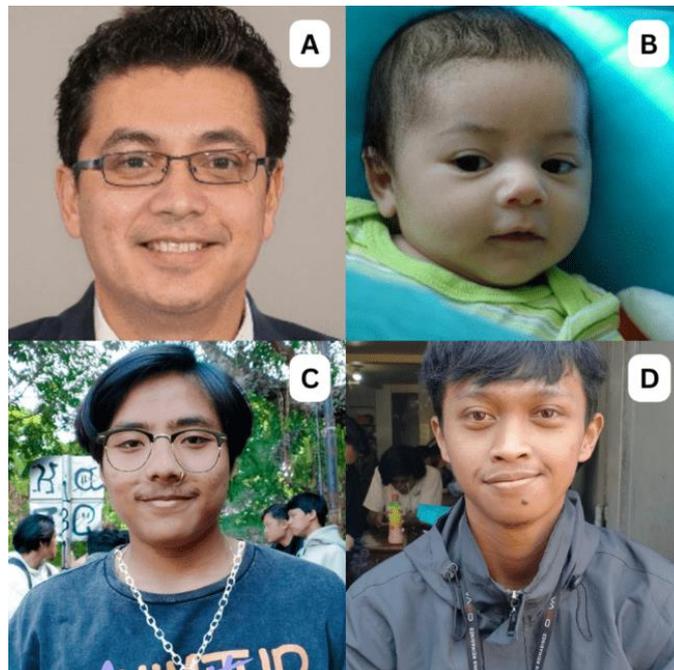
Melakukan analisa tingkat kesalahan menggunakan *Error Level Analysis* (ELA) dan mendapatkan fitur dari hasil analisa tingkat kesalahan berupa nilai numerik pada train image lalu mengekstraksi *train image* menggunakan model *FaceNet* dan mendapatkan vektor fitur. Lalu dengan mendapatkan masing-masing fitur dari setiap hasil yang dihasilkan, digabungkan

secara *horizontal* (dalam satu baris) yang akan digunakan untuk klasifikasi model menggunakan *Support Vector Machines* (SVM). Menggabungkan kedua fitur tersebut seperti contoh, ELA memiliki 50 fitur sehingga bentuknya adalah (100, 50) dan setiap gambar yang dihasilkan dari ekstraksi fitur *FaceNet* sebanyak 128 fitur sehingga bentuknya (100,128) dengan jumlah dataset yang sama yaitu misal 100. Sehingga penggabungannya akan menjadi $(100, 50 + 128) = (100, 178)$ dimana kolom pertama hingga 50 berisi fitur-fitur ELA sedangkan 51 hingga 178 berisi fitur-fitur dari *FaceNet*.

2.2. Dataset

Data yang digunakan pada penelitian ini adalah gabungan data primer dan data sekunder dimana data primer didapatkan dari hasil gambar yang diambil sendiri dan di edit sendiri untuk menjadikan gambar citra wajah tersebut ke dalam kelas *fake*. Kemudian dataset sekunder diambil dari website *Kaggle* dan dikumpulkan sebanyak 8.912 data sekunder yang sudah terbagi menjadi dua kelas yaitu *fake* dan *real*. Dataset primer yang terbagi menjadi dua kelas yaitu *fake* dan *real* dengan masing-masing kelas terbagi menjadi 413 data sedangkan pada dataset sekunder yang terbagi menjadi dua kelas yaitu *fake* dan *real* masing-masing terbagi menjadi 4.456 data.

Keterbatasan dalam pengambilan data primer ialah pengambilan wajah dari masing-masing pribadi orang yang cukup memakan banyak waktu karena mengumpulkan sumber daya manusia untuk mengumpulkan dataset tersebut. Kategori yang terbagi pada dataset primer menjadi dua jenis yaitu: (1) *Fake*, citra wajah yang sudah dimanipulasi atau hasil editan dari citra wajah asli, (2) *Real*, citra wajah asli tanpa edit atau teknik manipulasi. Begitu juga dengan dataset sekunder yang terbagi menjadi dua jenis yaitu *Fake* dan *Real*. Karena terbagi menjadi dua jenis yang sama yaitu *fake* dan *real* sehingga digabungkan menjadi satu dataset yang sama yang terbagi menjadi dua kelas yaitu *fake* dan *real*. Dengan adanya dua kelas yang sudah terbagi menjadi *fake* dan *real*, maka dilakukan *splitting data* dengan pembagian dataset yaitu *train data* 80%, *validation data* 10%, dan *test data* 10%.



Gambar 2. Gambar wajah fake dan real: (a) Fake dari Kaggle.com, (b) Real dari Kaggle.com, (c) Fake dataset primer, (d) Real dataset primer

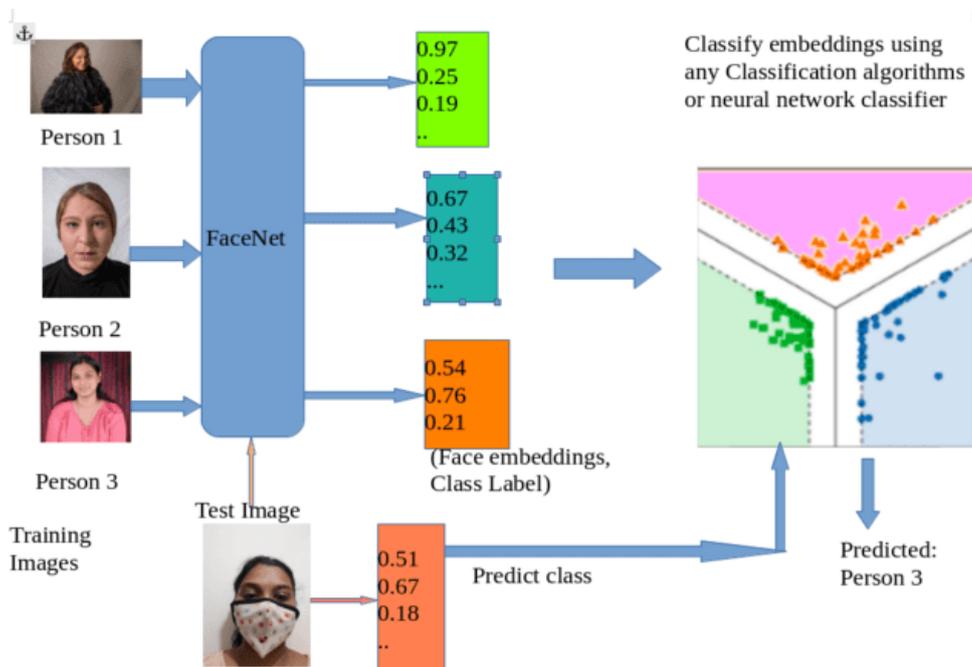
Sumber: (Margaretha, 2023), (xhlulu, 2020)
Tabel 1. Pendataan Citra Wajah Fake dan Real

Tipe Data	Data Latih	Data Validasi	Data Uji	Total Data
Dataset primer dan dataset sekunder	6928	1732	1082	9742

2.3. FaceNet

FaceNet merupakan arsitektur pengenalan wajah dimana dapat mengekstraksi penyematan wajah berdimensi tinggi yang dapat menangkap fitur dari masing-masing wajah. Fitur wajah di dalam area yang dicurigai dapat diekstraksi dan mengonversi setiap wajah menjadi vektor *embedding* yang merepresentasikan fitur-fitur wajah tersebut (Sanchez-Moreno, Sanchez-Perez, & Benitez-Garcia, 2021).

FaceNet merupakan arsitektur yang digunakan pada penelitian ini dimana FaceNet sebagai model arsitektur *Deep Learning* yang digunakan untuk ekstraksi fitur citra wajah dan hasil ekstraksi fitur FaceNet tersebut digabungkan dengan hasil dari analisa tingkat kesalahan menggunakan *Error Level Analysis* (ELA) dimana menjadi sebuah representasi fitur yang baru. Representasi fitur yang baru ini digunakan untuk mengklasifikasi menggunakan *Support Vector Machines* (SVM). Nilai-nilai yang berupa vektor fitur dari hasil *embedding* ekstraksi fitur FaceNet akan digunakan dalam penggabungan klasifikasi untuk *predict* wajah tersebut adalah *real* dan *fake*. Berikut flow dari FaceNet:



Gambar 3. FaceNet
 Sumber: (T, 2020)

Berikut parameter yang dapat dioptimalkan dan diharapkan dapat meningkatkan kinerja model yaitu terdapat 4 parameter, dapat dilihat pada Tabel 2.

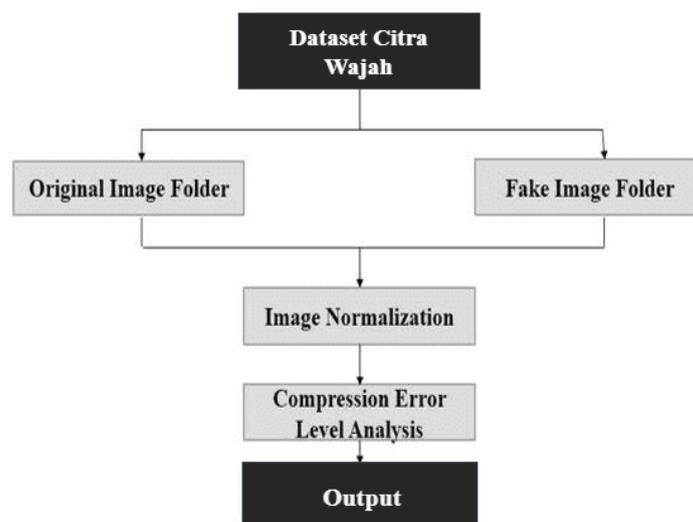
Tabel 2. Hyperparameter yang digunakan dalam FaceNet

No	Hyperparameter	Kegunaan Hyperparameter	Range
1	Optimizer	Mencari bobot yang optimal yang dapat mengurangi nilai <i>loss</i> atau <i>error</i> model	Adam, Adamax, dan Nadam
2	Epoch	Proses iterasi dalam pelatihan dan untuk mendapatkan hasil yang baik dari model	10-30
3	Learning_rate	Mengontrol seberapa besar Langkah yang diambil oleh <i>optimizer</i> saat memperbarui bobot model.	0.0001
4	Batch_size	Jumlah sample data yang digunakan pada setiap iterasi saat melatih model.	32 dan 64

2.4. Error Level Analysis

Metode *Error level analysis* (ELA) merupakan sebuah teknik untuk mendekteksi manipulasi citra dengan menyimpan ulang citra pada level kualitas tertentu, dan kemudian menkomputasi perbedaan antara citra kompresi dan citra sebelumnya. Metode *Error Level Analysis* (ELA) yang diterapkan pada sistem deteksi wajah ini untuk mendapatkan fitur dari tingkat kesalahan atau potensi manipulasi yang didapatkan gambar. *Error Level Analysis* memiliki rumus seperti berikut: (Zhang, Zhao, & Li, 2020).

Error Level Analysis (ELA) biasa diterapkan untuk menganalisa citra wajah untuk mendapatkan tingkat kesalahan dari citra wajah yang diinput (dataset citra wajah). Adanya *Error Level Analysis* (ELA) dapat lebih mempertegas tingkat kesalahan (manipulasi) yang ada pada gambar atau citra wajah yang diinput sehingga bisa lebih akurat dalam menghasilkan citra image yang dihasilkan. Berikut flow dari *Error Level Analysis* (ELA):



Gambar 4. Error Level Analysis (ELA)

Analisa tingkat kesalahan dengan menggunakan *Error Level Analysis* dapat dilakukan dengan input dataset yang sudah terbagi menjadi dua kelas yaitu *fake* dan *real*. Dataset tersebut dilakukan *normalization* kemudian *compression* dengan menggunakan *Error Level Analysis*. Setelah *Error Level Analysis* dilakukan maka melakukan ekstraksi fitur dengan menggunakan model arsitektur *FaceNet* (salah satu model arsitektur yang ada di *Convolutional Neural Network* (CNN)) lalu akan menghasilkan *output Error Level Analysis* (ELA).

2.5. Support Vector Machines

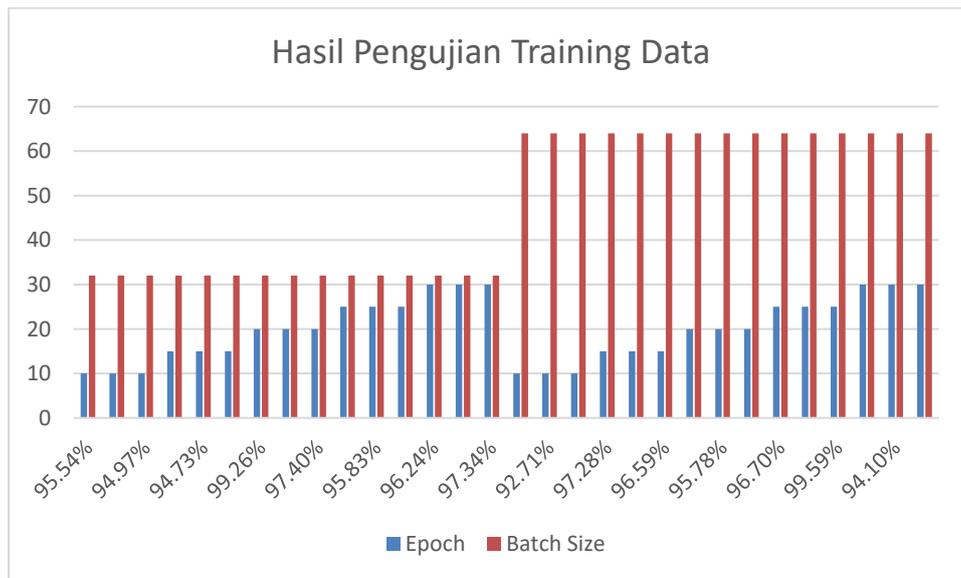
Metode *Support Vector Machine* (SVM) merupakan *supervised learning* dimana sebuah sistem pembelajaran yang menggunakan ruang hipotesis berupa fungsi-fungsi linear di dalam sebuah fitur yang memiliki dimensi tinggi dan dilatih dengan menggunakan algoritma pembelajaran berdasarkan teori optimasi. *Support Vector Machines* biasa digunakan untuk proses klasifikasi. Adanya metode *Support Vector Machines* ini dapat membantu proses dari hasil ekstraksi fitur *FaceNet* dan analisa tingkat kesalahan *Error Level Analysis* pada klasifikasi *Support Vector Machines*. Output *FaceNet* berupa vektor fitur yang mewakili berbagai karakteristik kompleks dari gambar wajah seperti bentuk, tekstur, dan atribut wajah dan *Error Level Analysis* menghasilkan output berupa nilai numerik yang mewakili tingkat kompresi dalam area pada gambar dimana nilai ELA ini yang mengindikasikan potensi manipulasi atau penyuntingan pada gambar wajah. Penggabungan kedua hasil tersebut menjadi satu vektor fitur yang panjang atau representasi numerik yang baru. Gabungan dari hasil ekstraksi fitur *FaceNet* dan *Error Level Analysis* ini yang digunakan pada klasifikasi *Support Vector Machines* (SVM) dimana model SVM akan mempelajari pola dari vektor fitur dan digunakan untuk mengklasifikasikan gambar tersebut adalah gambar *real* atau *fake*. Berikut *hyperplane* yang digunakan untuk model *Support Vector Machines* (SVM):

Tabel 3. Hyperplane yang digunakan di Support Vector Machines (SVM)

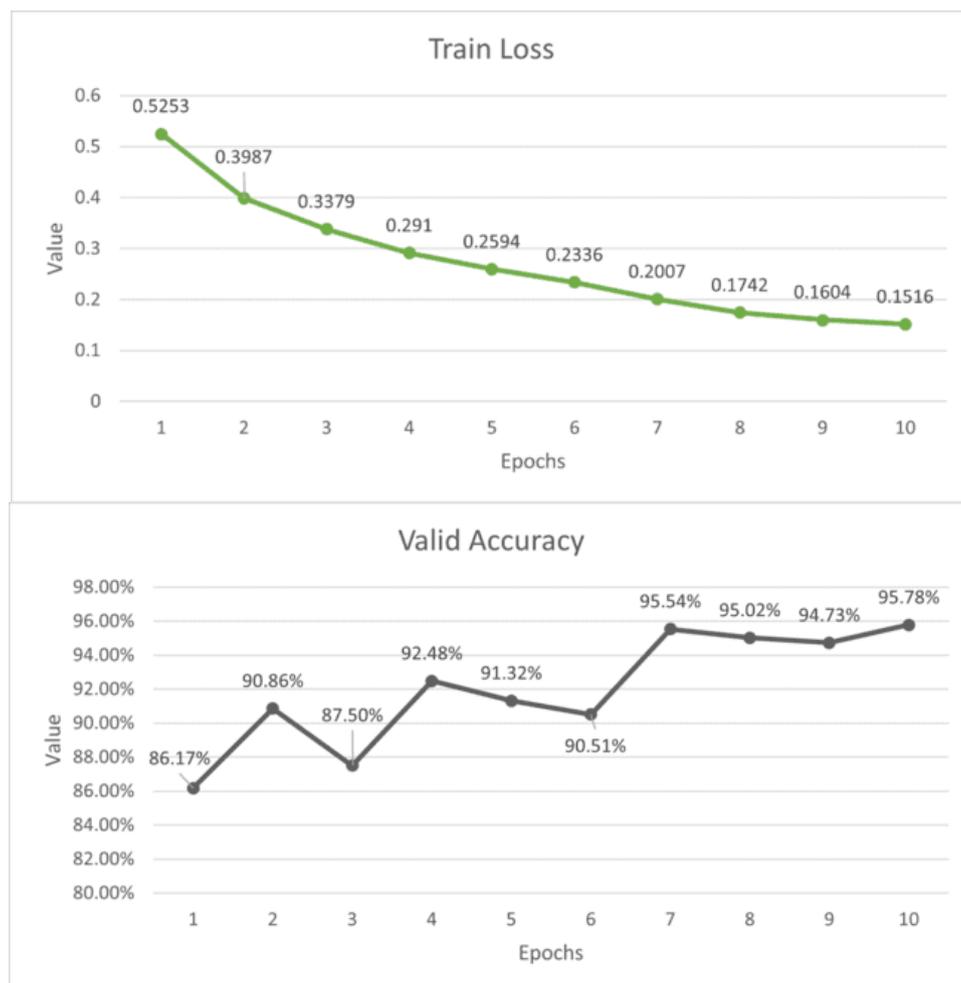
No	Hyperparameter	Kegunaan Hyperparameter	Range
1	Kernel	Menghitung titik antar pasangan data dimana kernel ini berfungsi untuk menghitung seberapa mirip atau sejauh mana pasangan data dalam ruang fitur	Linear, Sigmoid, Polynomial, RBF
2	C	Penalti kesalahan dalam model SVM (meminimalkan kesalahan pelatihan)	0.1, 1.0, 10

3. HASIL DAN PEMBAHASAN

Pada tahap ini adalah untuk mengevaluasi kinerja model *FaceNet* dan Analisa tingkat kesalahan menggunakan *Error Level Analysis* (ELA) serta klasifikasi menggunakan *Support Vector Machines* (SVM) dengan dataset sebanyak 9.742 data yang terbagi menjadi dua kelas yaitu *fake* dan *real*. Proses ini melakukan *training* model terlebih dahulu untuk melihat kinerja model *FaceNet* terbaik untuk melakukan ekstraksi fitur.



Gambar 5. Grafik Akurasi Hasil Keseluruhan



Gambar 6. Grafik Akurasi Model Terbaik 95.78%



Gambar 7. Grafik Akurasi Model Terbaik 99.59%

Hasil model terbaik adalah akurasi yang bernilai 95.78% dimana tidak terjadinya early stopping seperti model yang bisa menghasilkan akurasi sebesar 99.59%. Early stopping merupakan kondisi dimana training model akan berhenti jika akurasi model yang dihasilkan terlalu overfitting atau terlalu underfitting sehingga dapat dipastikan saat pengujian nanti pada data validasi (data yang belum pernah dilatih sebelumnya) akan dapat menghasilkan hasil yang buruk. Untuk hasil yang dihasilkan dari train model menggunakan model dengan akurasi 95.78%, dapat menghasilkan akurasi pada data validasi yang lebih baik dikarenakan train loss yang dihasilkan lebih stabil dikarenakan terjadinya penurunan yang stabil. Sehingga model terbaik adalah model yang menghasilkan akurasi sebesar 95.78% dan model ini yang digunakan untuk klasifikasi.

Tabel 4. Hasil Pengujian Training Data

Train Model	Optimizer	Epoch	Learning Rate	Batch Size	Accuracy
FaceNet	Adam	10	0.0001	32	95.54%
FaceNet	Adamax	10	0.0001	32	93.63%

FaceNet	Nadam	10	0.0001	32	94.97%
FaceNet	Adam	15	0.0001	32	97.34%
FaceNet	Adamax	15	0.0001	32	94.73%
FaceNet	Nadam	15	0.0001	32	95.95%
FaceNet	Adam	20	0.0001	32	99.26%
FaceNet	Adamax	20	0.0001	32	95.95%
FaceNet	Nadam	20	0.0001	32	97.40%
FaceNet	Adam	25	0.0001	32	97.05%
FaceNet	Adamax	25	0.0001	32	95.83%
FaceNet	Nadam	25	0.0001	32	96.93%
FaceNet	Adam	30	0.0001	32	96.24%
FaceNet	Adamax	30	0.0001	32	94.91%
FaceNet	Nadam	30	0.0001	32	97.34%
FaceNet	Adam	10	0.0001	64	95.78%
FaceNet	Adamax	10	0.0001	64	92.71%
FaceNet	Nadam	10	0.0001	64	94.04%
FaceNet	Adam	15	0.0001	64	97.28%
FaceNet	Adamax	15	0.0001	64	94.21%
FaceNet	Nadam	15	0.0001	64	96.59%
FaceNet	Adam	20	0.0001	64	97.34%
FaceNet	Adamax	20	0.0001	64	95.78%
FaceNet	Nadam	20	0.0001	64	97.16%
FaceNet	Adam	25	0.0001	64	96.70%
FaceNet	Adamax	25	0.0001	64	95.95%
FaceNet	Nadam	25	0.0001	64	99.59%
FaceNet	Adam	30	0.0001	64	97.05%
FaceNet	Adamax	30	0.0001	64	94.10%
FaceNet	Nadam	30	0.0001	64	98.03%

Pada Tabel 3. Hasil Pengujian Training Data merupakan hasil dari keseluruhan dalam proses pembangunan model *FaceNet* berhasil memperoleh model terbaik yakni dengan menggunakan parameter $epoch = 10$, $optimizer = Adamax$, $learning_rate = 0.0001$, $batch_size = 64$ memperoleh akurasi 95.78%. Model tersebut dikatakan terbaik dikarenakan mendapatkan hasil yang lebih stabil dibandingkan dengan model yang mencapai 99.59%. Dikatakan stabil karena tidak menghasilkan hasil *underfitting* ataupun *overfitting*. *Underfitting* dan *overfitting* bisa dilihat dari grafik yang mengalami penurunan atau kenaikan yang sangat tajam antar

epochnya atau proses *epoch* yang mengalami *early stopping* (dimana kondisi ini akan memberhentikan proses jalannya *epoch* jika hasil akurasi yang dihasilkan antar epoch stagnan seperti naik turun yang berturut-turut). Hasil dari pengujian terbaik pada model *FaceNet* ini akan digunakan pada ekstraksi fitur *FaceNet*. Setelah melakukan proses *training*, model *FaceNet* terbaik akan dilakukan ekstraksi fitur dan akan diklasifikasi menggunakan metode *Support Vector Machines* (SVM).

3.1. Pengujian dan Pembahasan *Support Vector Machines*

Berikut ini adalah pengujian yang dilakukan oleh *Support Vector Machines* yang sudah melalui proses ekstraksi *FaceNet* dan analisa tingkat kesalahan *Error Level Analysis* (ELA) dan mencari parameter terbaik dari model *Support Vector Machines* (SVM) untuk data yang akan diuji (data yang belum pernah diuji sebelumnya):

1. Kernel : Linear, RBF, Sigmoid, dan Polynomial
2. C : 0.1, 1.0, dan 10

Penggunaan hyperplane pada model SVM berikut seperti kernel yang digunakan pada SVM adalah 4 kernel tersebut untuk mencari akurasi yang lebih baik dibandingkan jika hanya menggunakan 1 kernel saja. Untuk nilai C yang digunakan mengapa 0.1, 1.0, dan 10 adalah memulai nilai yang rendah, normal dan tinggi untuk mendapatkan titik penalti kesalahan yang lebih luas. Berikut pengujian yang telah dilakukan menggunakan data *training*, validasi, dan *testing* dengan konfigurasi parameter pada Tabel 5.

Tabel 5. Konfigurasi parameter yang akan digunakan

Nama Parameter	Nilai Parameter
<i>Kernel</i>	Linear, Sigmoid, Polynomial, RBF
<i>C</i>	0.1, 1.0, 10

Hasil pengujian keseluruhan sehingga didapatkan confusion matrix yaitu *precision*, *recall*, dan *f1-score* sebagai berikut:

Tabel 5. Keseluruhan Hasil Pengujian *Support Vector Machines*

<i>Classification</i>	<i>Kernel</i>	<i>C</i>	<i>Degree</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
0 (Real)	Linear	0.1	-	0,51	0,53	0,52
1 (Fake)				0,54	0,53	0,53
0 (Real)	Sigmoid	0.1	-	0,49	0,7	0,58
1 (Fake)				0,52	0,31	0,39
0 (Real)	RBF	0.1	-	0,49	0,99	0,65

1 (Fake)				0,36	0,01	0,01
0 (Real)	Poly	0.1	-	0,49	0,97	0,65
1 (Fake)				0,52	0,03	0,06
0 (Real)	Linear	1.0	-	0,51	0,53	0,52
1 (Fake)				0,54	0,53	0,53
0 (Real)	Sigmoid	1.0	-	0,49	0,54	0,52
1 (Fake)				0,52	0,47	0,5
0 (Real)	RBF	1.0	-	0,51	0,54	0,52
1 (Fake)				0,53	0,5	0,52
0 (Real)	Poly	1.0	-	0,49	0,68	0,57
1 (Fake)				0,51	0,32	0,4
0 (Real)	Linear	10	-	0,51	0,53	0,52
1 (Fake)				0,54	0,53	0,53
0 (Real)	Sigmoid	10	-	0,49	0,48	0,48
1 (Fake)				0,51	0,52	0,51
0 (Real)	RBF	10	-	0,49	0,52	0,5
1 (Fake)				0,51	0,49	0,5
0 (Real)	Poly	10	-	0,47	0,56	0,51
1 (Fake)				0,49	0,41	0,45
0 (Real)	Poly	0.1	2	0,49	0,96	0,65
1 (Fake)				0,5	0,04	0,08
0 (Real)	Poly	0.1	3	0,49	0,97	0,65
1 (Fake)				0,52	0,03	0,06
0 (Real)	Poly	0.1	4	0,49	0,97	0,65
1 (Fake)				0,5	0,03	0,05
0 (Real)	Poly	1.0	2	0,48	0,61	0,54
1 (Fake)				0,51	0,38	0,44
0 (Real)	Poly	1.0	3	0,49	0,68	0,57
1 (Fake)				0,51	0,32	0,4
0 (Real)	Poly	1.0	4	0,49	0,78	0,6
1 (Fake)				0,51	0,22	0,31
0 (Real)	Poly	10	2	0,49	0,51	0,5
1 (Fake)				0,52	0,5	0,51
0 (Real)	Poly	10	3	0,47	0,45	0,46
1 (Fake)				0,5	0,52	0,51
0 (Real)	Poly	10	4	0,49	0,64	0,55
1 (Fake)				0,51	0,36	0,42

Tabel 5 menunjukkan hasil keseluruhan proses klasifikasi dengan menggunakan *Support Vector Machines* (SVM) dengan menggunakan beberapa parameter *kernel* dan C dan menghasilkan akurasi yang baik ada di parameter *kernel Linear* dan nilai $C = 0.1$ itu menghasilkan akurasi precision 51%, recall 53%, dan f1-score 52% pada data 0 atau Real. Kemudian hasil akurasi pada data 1 atau Fake yaitu precision 54%, recall 53%, dan f1-score 53%. Sehingga didapatkan rata-rata akurasi sebesar 53%. Klasifikasi yang dilakukan tentunya hasil representasi yang baru melalui gabungan hasil ekstraksi fitur *FaceNet* dan analisa tingkat kesalahan *Error Level Analysis* yang digunakan untuk klasifikasi. Hasil yang dihasilkan oleh model *Support Vector Machines* tersebut mendapatkan akurasi yang rendah bisa disebabkan oleh *train* model *FaceNet* yang *overfitting* dan *underfitting* pada *val* accuracy sehingga dapat menyebabkan hasil akurasi klasifikasi yang cukup rendah.

4. KESIMPULAN

Penelitian ini bertujuan mendeteksi potensi manipulasi citra wajah apakah wajah tersebut merupakan citra wajah *fake* atau *real* berdasarkan gabungan hasil ekstraksi fitur *FaceNet* dan analisa tingkat kesalahan menggunakan *Error Level Analysis* yang dimana gabungan hasil tersebut digunakan untuk klasifikasi *Support Vector Machines* (SVM). Berdasarkan 30 kali hasil pengujian training yang dilakukan pada model *FaceNet* yaitu dengan menggunakan beberapa optimizer seperti Adam, Adamax, dan Nadam, batch size yang digunakan adalah 32 dan 64, learning rate yang digunakan adalah 0.0001, epochs yang digunakan range 10-30, maka didapatkan model *FaceNet* yang terbaik ada di epoch 10, batch size 64, learning rate 0.0001, optimizer Adam dengan menghasilkan akurasi sebesar 95.78%. Berdasarkan 21 kali pengujian pada model klasifikasi dimana telah melalui ekstraksi fitur *FaceNet* dari model terbaik dan Analisa tingkat kesalahan menggunakan metode Error Level Analysis (ELA) kemudian menggabungkan kedua hasil tersebut menjadi representasi numerik baru yang dijadikan untuk klasifikasi SVM. Klasifikasi SVM terbaik adalah dengan menggunakan hyperplane kernel Linear dan $C = 0.1$ yang menghasilkan akurasi precision 51%, recall 53%, dan f1-score 52% pada data 0 atau Real. Kemudian hasil akurasi pada data 1 atau Fake yaitu precision 54%, recall 53%, dan f1-score 53%. Sehingga didapatkan rata-rata akurasi sebesar 53%.

DAFTAR PUSTAKA

- Arrofiqoh, E. N., & Harintaka. (2018). IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI. *Geomatika Volume 24 No.2*, 61-67.
- DQLAB. (2021). Memahami Perbedaan Algoritma Machine Learning vs Deep Learning.
- Garcia-Molina, H. U. (2009). *Database System The Complete Book*.
- Kusuma, A. M. (2016). Aplikasi Buku Digital Bidang Teknologi Informasi Berbasis Android Mobile Pada Perpustakaan BPPKI Surabaya Badan Litbang Kementerian Koinfo. *5 No 2*.
- Margaretha, R. M. (2023, August). *Kaggle*. Retrieved from DATASET TAKEN BY RUTH: <https://www.kaggle.com/datasets/ruthmanam/dataset-taken-by-ruth>
- Qurat-ul-ain, Nida, N., Irtaza, A., & Ilyas, N. (2021). Forged Face Detection using ELA and Deep Learning Techniques. *International Bhurban Conference on Applied Sciences & Technology (IBCAST)*, 271-275.
- Rafque, 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*.

- Sanchez-Moreno, A. S., Sanchez-Perez, G., & Benitez-Garcia, G. (2021). Efficient Face Recognition System for Operating in Unconstrained Environments. *Journal of Imaging*, 1-21.
- Sri Tjahyanti, L. P., Saputra, P. S., & Gitakarma, M. S. (2022). Peran Artificial Intelligence (AI) untuk Mendukung Pembelajaran di Masa Pandemi Covid-19. *Journal Komputer dan Teknologi Sains (KOMTEKS)*, 15-21.
- Suartika E. P, I., Wijaya, A. Y., & Soelaiman, R. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS Vol. 5 No.1*, A65.
- T, J. (2020, November 3). *Face Recognition Walkthrough-FaceNet*. Retrieved from PluralSight: <https://www.pluralsight.com/guides/face-recognition-walkthrough-facenet>
- xhlulu. (2020). *Kaggle*. Retrieved from 140k Real and Fake Faces: <https://www.kaggle.com/datasets/xhlulu/140k-real-and-fake-faces>
- Yusuf, A., Wihandika, R. C., & Dewi, C. (2019). Klasifikasi Emosi Berdasarkan Ciri Wajah Menggunakan Convolutional Neural Network. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol. 3 No.11*.
- Zhang, W., Zhao, C., & Li, Y. (2020). A Novel Counterfeit Feature Extraction Technique for Exposing Face-Swap Images Based on Deep Learning and Error Level Analysis. *MDPI*, 2-16.
- Zufar, M. (2016). Convolutional Neural Networks untuk Pengenalan Wajah Secara Real-Time. *TUGAS AKHIR - SM 141501*, 14 - 15.