

Pengenalan Wajah Untuk Sistem Presensi Menggunakan Convolutional Neural Network

^{1st}M. Rafi Hizdarandha Riswant
Program Studi Teknologi Informasi
Universitas Telkom
Surabaya, Indonesia
rafih2003@gmail.com

^{2nd}Yohanes Setiawan
Program Studi Teknologi Informasi
Universitas Telkom
Surabaya, Indonesia
yohanessetiawan@telkomuniversity.ac.id

^{3rd}Farah Zakiah Rahmanti
Program Studi Teknologi Informasi
Universitas Telkom
Surabaya, Indonesia
farahzakiah@telkomuniversity.ac.id

Abstrak — Penelitian ini bertujuan mengatasi permasalahan sistem presensi karyawan manual yang rentan terhadap manipulasi dan kecurangan dari setiap individu, serta kebutuhan akan sistem presensi otomatis berbasis pengenalan wajah yang akurat dan andal, khususnya untuk membatasi akses keluar-masuk keruang Server DRC di PT. Pelindo Marine Service. Sebagai solusi, penelitian ini bertujuan untuk merancang dan membandingkan kinerja tiga arsitektur Convolutional Neural Network (CNN), yaitu InceptionV3, ResNet50, dan VGG16, dalam penerapan sistem pengenalan wajah. Dataset wajah yang digunakan diambil pada saat magang dan telah melalui tahap cropping secara otomatis menggunakan metode atau model MTCNN, pada tiga skenario training dataset yang berbeda berdasarkan jumlah epoch: 50, 80, dan 100. Evaluasi dilakukan terhadap akurasi pelatihan, akurasi validasi, serta efisiensi waktu pelatihan dari masing-masing arsitektur. Hasil penelitian menunjukkan bahwa arsitektur VGG16 memberikan performa terbaik dengan akurasi validasi tertinggi sebesar 99,31% pada epoch ke-100, meskipun membutuhkan waktu pelatihan lebih lama. VGG16 menempati posisi kedua dengan akurasi validasi 96,74%, namun lebih efisien dari sisi durasi pelatihan. Namun pada saat ditahap pengujian atau demo hasil arsitektur VGG16 menjadikannya pilihan yang kurang baik untuk implementasi pada dataset yang digunakan, dilanjutkan dengan arsitektur Resnet50 yang sedikit lebih baik dari segi classification pada saat tes pengujian hasil. Untuk hasil yang terbaik didapatkan oleh arsitektur InceptionV3 yang hasil Accuracy nya mendapatkan 78% dari hasil classification report. Dari hasil evaluasi tersebut, dapat disimpulkan bahwa InceptionV3 paling direkomendasikan untuk sistem pengenalan wajah yang membutuhkan akurasi tinggi, hal ini bisa dibuat bahan acuan untuk mencari mana hasil terbaik untuk sistem pengenalan wajah untuk karyawan. Sistem yang dikembangkan memiliki potensi untuk diterapkan di lingkungan kerja seperti PT. Pelindo Marine Service.

Kata kunci—Pengenalan wajah, Computer Vision, InceptionV3, Resnet50, VGG16, Deep learning

I. PENDAHULUAN

Presensi karyawan merupakan komponen krusial dalam pengelolaan sumber daya manusia, terutama dalam menjamin efektivitas dan efisiensi operasional suatu institusi. Di banyak perusahaan, termasuk PT. Pelindo Marine Service, sistem presensi masih dilakukan secara manual, termasuk dalam pengaturan akses ke ruangan vital seperti Server Disaster Recovery Center (DRC). Penggunaan sistem kunci tradisional pada ruang DRC menjadi tantangan tersendiri karena terbatasnya akses dan risiko keamanan yang lebih tinggi. Oleh karena itu, dibutuhkan sistem otomatis yang andal, cepat, dan akurat untuk mendeteksi identitas karyawan

yang memiliki wewenang memasuki area tersebut.

Seiring dengan kemajuan teknologi kecerdasan buatan, khususnya pada bidang Computer Vision, sistem pengenalan wajah (face recognition) menawarkan solusi non-kontak yang praktis dan real-time dalam mengidentifikasi individu. Salah satu pendekatan yang banyak digunakan dalam teknologi ini adalah Convolutional Neural Network (CNN), yang terbukti efektif dalam pengolahan citra dan pengenalan pola wajah. Namun demikian, performa sistem sangat bergantung pada arsitektur CNN yang diterapkan.

Penelitian ini bertujuan mengevaluasi dan membandingkan kinerja tiga arsitektur CNN populer—InceptionV3, ResNet50, dan VGG16—dalam konteks sistem presensi otomatis berbasis pengenalan wajah di ruang Server DRC PT. Pelindo Marine Service. Sebagai perusahaan penyedia jasa maritim yang berada di bawah naungan Badan Usaha Milik Negara (BUMN), PT. Pelindo Marine Service memiliki kebutuhan untuk meningkatkan efisiensi sistem keamanan internal, khususnya pada akses terbatas seperti ruang server. Oleh karena itu, pemilihan model arsitektur CNN yang paling optimal sangat penting untuk menjamin akurasi, kecepatan pelatihan, serta efisiensi sistem secara keseluruhan.

Melalui pendekatan berbasis website dan penerapan CNN, sistem ini dikembangkan untuk dapat mengenali wajah karyawan dalam berbagai kondisi pencahayaan dan lingkungan. Penggunaan dataset internal dari proses magang di perusahaan, serta penerapan evaluasi terhadap masing-masing arsitektur tanpa pipeline yang seragam, memberikan kontribusi nyata dalam menilai kelebihan dan kekurangan masing-masing model. Penelitian ini tidak hanya memberikan solusi praktis dalam peningkatan sistem keamanan berbasis teknologi di industri maritim, tetapi juga dapat menjadi rujukan dalam penerapan sistem serupa di sektor lainnya.

II. KAJIAN TEORI

A. Studi Literatur Sistem Pengenalan Wajah dan CNN

Berbagai penelitian telah menunjukkan efektivitas Convolutional Neural Network (CNN) dalam bidang klasifikasi citra dan pengenalan wajah. Ramadhan (2024) mengembangkan sistem klasifikasi bentuk bingkai kaca mata berbasis CNN dengan arsitektur InceptionV3, di mana hasilnya menunjukkan bahwa model ini memiliki akurasi terbaik dalam mengenali bentuk wajah untuk keperluan estetika pengguna.

Pradana dan Khoirunnisa (2020) menganalisis performa LeNet dan VGG16 dalam mengidentifikasi gender dari citra wajah. Penelitian ini menyimpulkan bahwa VGG16 menghasilkan akurasi lebih tinggi, khususnya karena dukungan fungsi aktivasi Rectified Linear Unit (ReLU), yang mempercepat konvergensi dan meningkatkan akurasi model secara keseluruhan.

Penelitian Hutamaputra et al. (2022) melakukan perbandingan antara VGG16 dan ResNet34 dalam klasifikasi sampah botol plastik. Hasil menunjukkan bahwa VGG16 mencapai akurasi sebesar 96,39%, lebih unggul dibanding ResNet34 yang hanya meraih 91,57%. Selain itu, VGG16 juga terbukti lebih efisien dari segi waktu pelatihan.

Tri Anita Resky Ramadhani (2024) mengkaji perbandingan antara VGG16 dan ResNet50 dalam klasifikasi multilabel gambar kerbau Toraja. Hasilnya menunjukkan bahwa VGG16 secara konsisten unggul dengan akurasi pelatihan sebesar 0,95 dan akurasi validasi sebesar 0,94, serta F1-score hingga 0,92 pada data validasi.

Sementara itu, Nurbaiti dan Widhiantoro (2024) melakukan studi perbandingan metode face recognition seperti Haar Cascade Classifier, Local Binary Pattern Histograms (LBPH), dan CNN. Mereka menyimpulkan bahwa Haar Cascade memiliki keunggulan dari segi kecepatan dan efisiensi deteksi objek (wajah), namun CNN tetap menunjukkan potensi besar dalam konteks akurasi dan kedalaman pemrosesan fitur wajah.

B. Convolutional Neural Network (CNN)

CNN merupakan arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk grid, seperti citra. CNN terdiri dari beberapa lapisan utama, yaitu convolutional layer, pooling layer, dan fully connected layer. Lapisan konvolusi bertugas mengekstraksi fitur lokal dari gambar, yang kemudian dikompres pada lapisan pooling dan diolah menjadi representasi akhir pada lapisan fully connected. CNN sangat efektif dalam tugas klasifikasi, segmentasi gambar, dan pengenalan objek karena kemampuannya dalam menangkap informasi spasial (Danial & Setiawati, 2024; Lina et al., 2022).

C. MTCNN (Multi-task Cascaded Convolutional Networks)

MTCNN adalah metode yang digunakan untuk deteksi dan cropping wajah secara otomatis sebelum gambar wajah

diproses oleh arsitektur CNN. MTCNN bekerja melalui tiga tahap jaringan: Proposal Network (P-Net), Refinement

Network (R-Net), dan Output Network (O-Net), yang bersama-sama menghasilkan deteksi wajah yang presisi serta mampu menyesuaikan pose dan ekspresi wajah dengan baik.

Dalam konteks penelitian ini, MTCNN digunakan untuk

menyiapkan data sebelum pelatihan menggunakan arsitektur InceptionV3, ResNet50, dan VGG16.

D. InceptionV3

InceptionV3 merupakan arsitektur jaringan saraf konvolusional yang dirancang untuk pengenalan gambar dengan efisiensi tinggi. Arsitektur ini memperkenalkan teknik factorization into smaller convolutions, asymmetric convolutions, dan auxiliary classifiers, yang secara signifikan mengurangi kompleksitas komputasi tanpa mengorbankan akurasi. InceptionV3 memungkinkan pemrosesan paralel pada berbagai ukuran filter konvolusi, sehingga dapat menangkap fitur pada berbagai skala secara bersamaan. Arsitektur ini sangat cocok untuk dataset besar dan aplikasi real-time yang memerlukan efisiensi komputasi tinggi.

E. ResNet50

ResNet50 adalah model deep learning dengan 50 lapisan yang memanfaatkan residual learning melalui skip connection atau shortcut. Arsitektur ini dikembangkan untuk mengatasi masalah degradation pada jaringan dalam, di mana peningkatan jumlah layer justru dapat menurunkan akurasi. Skip connection memungkinkan informasi untuk melewati satu atau lebih lapisan secara langsung, sehingga mengurangi hilangnya informasi penting selama pelatihan. ResNet50 dilatih pada dataset ImageNet dan terbukti unggul dalam berbagai kompetisi klasifikasi gambar karena kemampuannya dalam memodelkan fitur kompleks (Dian Anisa Agustina, 2024).

F. VGG16

VGG16 merupakan arsitektur CNN yang dikembangkan oleh Visual Geometry Group (VGG), terdiri dari 13 lapisan konvolusi dan 3 lapisan fully connected. Ciri khas utama arsitektur ini adalah penggunaan filter konvolusi berukuran 3x3 dan stride 1 secara konsisten di semua lapisan, serta pengurangan ukuran (subsampling) melalui max-pooling 2x2. Desain yang sederhana dan berulang ini membuat VGG16 sangat stabil dan mudah diimplementasikan dalam berbagai studi klasifikasi citra. Meskipun memiliki jumlah parameter besar dan komputasi yang tinggi, VGG16 tetap menjadi model andalan karena akurasi tinggi dan struktur arsitektur yang mudah dimodifikasi (Siddik, 2023).

G. Confusion Matrix

Confusion matrix adalah alat evaluasi yang digunakan untuk menilai performa sistem klasifikasi. Matriks ini mengandung empat komponen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dari matriks ini, dapat dihitung berbagai metrik kinerja seperti:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{II-1})$$

$$\text{Precision} = \frac{TP}{TP + FN} \quad (\text{II-2})$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{II-3})$$

$$\text{F1-Score} = 2 \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (\text{II-4})$$

Metode evaluasi ini digunakan dalam penelitian untuk mengukur kinerja akhir dari model InceptionV3, ResNet50, dan VGG16 dalam mendeteksi wajah secara otomatis (Gunawan et al., 2021).

H. Relevansi Terhadap Sistem Presensi Ruang Server Kajian


teori di atas menjadi dasar dalam pengembangan sistem presensi otomatis berbasis pengenalan wajah untuk ruang DRC PT Pelindo Marine Service. Pemanfaatan CNN, khususnya tiga arsitektur terpilih (InceptionV3, ResNet50, dan VGG16), memungkinkan sistem bekerja secara real-time, non-kontak, serta memiliki tingkat akurasi tinggi dalam kondisi pencahayaan dan ekspresi wajah yang bervariasi. Evaluasi menyeluruh terhadap performa model melalui confusion matrix akan menghasilkan rekomendasi arsitektur terbaik yang paling sesuai untuk kebutuhan keamanan dan efisiensi perusahaan.

III. METODE

Memberikan gambaran rancangan penelitian yang meliputi prosedur atau langkah-langkah penelitian, waktu penelitian, sumber data, cara perolehan data dan menjelaskan metode yang akan digunakan dalam penelitian [10 pts].

A. Flowchart Penelitian


Penelitian dimulai dengan mengidentifikasi masalah untuk menganalisis kebutuhan sistem presensi di ruang server DRC, permasalahan yang diangkat meliputi kunci manual yang dipegang setiap karyawan khusus agar tidak semua karyawan bisa memasuki area ruangan. Tahap selanjutnya adalah pengumpulan dataset berupa citra wajah karyawan, yang dikumpulkan dari sumber asli pada saat magang menggunakan kamera *webcam* laptop. Tahap *preprocessing* untuk meningkatkan kualitas sebelum digunakan dalam pelatihan model InceptionV3, Resnet50, dan VGG16, tahap *preprocessing* mencakup anotasi objek menggunakan platform manajemen proyek *computer vision* seperti roboflow, pembagian dataset dibagi menjadi 3 kategori (*train*, *valid*, *test*) serta *resize* citra agar sesuai dengan input standar InceptionV3, Resnet50, dan VGG16, dataset yang telah melalui tahap *preprocessing* digunakan untuk melatih ketiga model, training model dilakukan menggunakan data latih sebanyak 50, 80, 100 *epoch*. Setelah model berhasil dilatih, dilakukan pengujian/tes sistem pengenalan wajah, hasil pengujian sistem kemudian dianalisis pada tahap hasil pengujian sistem, mencakup nama wajah dan presentase akurasi. Tahap terakhir merupakan tahap evaluasi sistem yang dilakukan dengan evaluasi hasil pengujian untuk deteksi dan memberikan hasil rekomendasi terbaik untuk sistem presensi pengenalan wajah.



GAMBAR 1
(FLOWCHART PENELITIAN)

B. Flowchart Pengumpulan Data

Proses diawali dengan menangkap data wajah anak magang PT. Pelindo Marine Service menggunakan kamera *webcam* laptop. Data tersebut kemudian dipisah secara manual dan dimasukkan pada setiap *class*/ Nama yang sesuai.



GAMBAR 2
(FLOWCHART PENGUMPULAN DATA)

IV. HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini diperoleh secara langsung dari kegiatan magang peneliti di Kantor PT. Pelindo Marine Service. Fokus utama penelitian ini adalah mengembangkan sistem presensi karyawan berbasis pengenalan wajah menggunakan model CNN. Oleh karena itu, pengambilan data dilakukan dengan melibatkan karyawan yang memiliki akses ke ruang Server Disaster Recovery Center (DRC), sesuai dengan batasan yang telah ditentukan.

Dataset dikumpulkan menggunakan kamera bawaan laptop dan dilakukan secara langsung di lingkungan kantor PT. Pelindo Marine Service. Pengambilan citra dilakukan dalam kondisi pencahayaan yang konsisten untuk menjaga

kualitas data. Sebanyak 13 orang berpartisipasi dalam proses ini, dan masing-masing diminta untuk mengambil lima pose wajah berbeda. Hal ini menghasilkan 65 gambar asli.

Namun, untuk mengatasi keterbatasan jumlah data dan meningkatkan kemampuan generalisasi model selama proses pelatihan, dilakukan proses augmentasi data. Augmentasi bertujuan menambah variasi citra melalui teknik seperti rotasi, zoom, dan perubahan kontras. Setelah augmentasi selesai, jumlah total dataset meningkat menjadi 75 gambar berformat .jpg, yang kemudian digunakan dalam seluruh proses pelatihan dan pengujian model.

Sebelum digunakan dalam proses pelatihan, seluruh citra pada dataset di-resize menjadi ukuran standar 224 x 224 piksel. Penyesuaian ini dilakukan untuk memastikan kesesuaian input dengan kebutuhan arsitektur masing-masing model CNN, sebagaimana dirangkum pada Tabel IV.1 berikut:

Dataset dibagi menjadi tiga kelompok utama: train set, validation set, dan test set. Data latih (train set) digunakan untuk melatih model agar mampu mengenali pola wajah; data validasi (validation set) digunakan untuk mengevaluasi performa model selama proses pelatihan dan mencegah terjadinya overfitting; sedangkan data uji (test set) digunakan untuk mengukur kinerja akhir model terhadap data baru yang tidak pernah dilihat sebelumnya.

Distribusi jumlah data pada masing-masing kategori berbeda tergantung pada konfigurasi tiap arsitektur dan jumlah epoch yang digunakan selama pelatihan. Pembagian ini mengikuti prinsip umum 60:20:20 atau disesuaikan dengan kebutuhan eksperimen.

Sebelum proses pelatihan model dilakukan, seluruh citra wajah melalui tahap deteksi dan cropping otomatis menggunakan algoritma Multi-task Cascaded Convolutional Networks (MTCNN). MTCNN bertugas mendeteksi keberadaan wajah dari gambar mentah dan memberikan koordinat area wajah dalam bentuk bounding box. Proses ini memfasilitasi pemotongan otomatis (auto-cropping) untuk mengambil bagian wajah saja dan menghilangkan latar belakang yang tidak relevan.

Dengan demikian, hanya bagian wajah yang relevan yang digunakan dalam pelatihan model, sehingga meningkatkan fokus sistem terhadap fitur-fitur unik dari wajah setiap individu dan mengurangi noise visual dari lingkungan sekitar.

Secara keseluruhan, proses persiapan data dalam penelitian ini meliputi pengumpulan citra wajah secara langsung, augmentasi untuk memperkaya dataset, penyesuaian ukuran gambar, pembagian dataset sesuai kebutuhan pelatihan, serta deteksi dan pemotongan wajah menggunakan MTCNN. Seluruh proses ini menjadi fondasi penting untuk memastikan bahwa pelatihan dan pengujian model CNN berjalan secara efektif dan optimal dalam konteks implementasi sistem presensi berbasis pengenalan wajah di lingkungan PT. Pelindo Marine Service.

Tahap pemodelan (model training) merupakan langkah krusial dalam membangun sistem pengenalan wajah berbasis *deep learning*. Pada tahap ini, dataset yang telah melalui proses *preprocessing* digunakan untuk melatih tiga arsitektur CNN populer, yaitu **InceptionV3**, **ResNet50**, dan **VGG16**. Tujuan utama dari proses ini adalah untuk mengembangkan model yang mampu mengklasifikasikan wajah secara otomatis dengan tingkat akurasi tinggi, serta memiliki

kemampuan generalisasi yang baik terhadap citra baru, khususnya dalam konteks lingkungan kerja PT. Pelindo Marine Service (PMS).

Selama pelatihan, seluruh model dikonfigurasi dengan parameter yang konsisten agar memungkinkan perbandingan kinerja secara objektif antar arsitektur. Pelatihan dilakukan dengan tiga skenario jumlah epoch yang berbeda, yaitu 50, 80, dan 100 epoch. Adapun konfigurasi *hyperparameter* yang digunakan dalam pelatihan masing-masing model adalah sebagai berikut:

- Ukuran input citra: 224 x 224 piksel
- Optimizer: Adam dengan learning rate 1e-4
- Loss function: Categorical Crossentropy
- Batch size: 64
- Callback: Model Checkpoint dan EarlyStopping untuk mencegah overfitting

Dengan konfigurasi tersebut, setiap model diharapkan dapat belajar secara optimal dari dataset yang tersedia, dan performa akhir akan dievaluasi melalui metrik evaluasi seperti akurasi, presisi, recall, dan F1-score.

Eksperimen pemodelan dan pelatihan dilakukan pada lingkungan pengembangan lokal dengan spesifikasi perangkat keras dan lunak sebagai berikut:

Spesifikasi Perangkat Keras:

- CPU: Intel Core i7-6600U
- RAM: 12 GB
- Storage: SSD 500 GB (Samsung)
- Sistem Operasi: Windows 11 Pro 64-bit

Spesifikasi Perangkat Lunak:

- Bahasa Pemrograman: Python 3
- Library utama: TensorFlow versi 2.8.1 dan Keras versi 2.9

Penggunaan perangkat keras dan lunak tersebut dirancang agar pelatihan dapat berjalan stabil dan efisien meskipun dengan keterbatasan sumber daya, serta tetap mendukung proses komputasi intensif dari ketiga arsitektur CNN yang digunakan dalam penelitian ini.

A. Gambar



GAMBAR 3
(DATASET)



GAMBAR 4
(PEMBAGIAN DATASET)



GAMBAR 5
(DATASET HASIL CROPPING)

```
#0
import tensorflow as tf
from tensorflow.keras.applications import InceptionV3
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Dropout, GlobalAveragePooling2D
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping
import time
from datetime import datetime

batch_size = 64
img_size = 224
```

GAMBAR 6
(PROSES TRAINING DATASET
INCEPTIONV3)

```
#2
import tensorflow as tf
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Dropout, GlobalAveragePooling2D
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping
import time
from datetime import datetime

batch_size = 64
img_size = 224
```

GAMBAR 7
(PROSES TRAINING DATASET RESNET50)


```
#0
import tensorflow as tf
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Dropout, GlobalAveragePooling2D
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping
import time
from tensorflow.keras.applications.vgg16 import preprocess_input
from datetime import datetime

batch_size = 64
img_size = 224
```

GAMBAR 8
(PROSES TRAINING DATASET VGG16)

TABEL 1
(IMG BACTH)

No	Arsitektur	Resolusi Citra
1	InceptionV3	224 x 224
2	ResNet50	224 x 224
3	VGG16	224 x 224



GAMBAR 9
(HASIL PENGUJIAN)

Pada tahap pengujian dilakukan untuk melihat bagaimana model yang telah dilatih dapat diimplementasikan secara nyata, dalam sistem pengenalan wajah. Arsitektur InceptionV3 pada skenario percobaan ketiga menunjukkan bahwa kemampuan dari prediksi *class* terbukti bisa unggul untuk mendeteksi wajah citra pada sistem pengenalan wajah terbaik. Pengujian ini menggunakan antarmuka aplikasi sederhana yang memanfaatkan *webcam* untuk memotret atau mengambil gambar wajah karyawan. Gambar pada IV 7, dilakukan pemilihan performa terbaik dari ketiga arsitektur dalam hal sistem pengenalan wajah. Sistem pengujian ini memiliki beberapa fitur utama seperti: Ambil gambar, pilih gambar, simpan ke log, dan mulai ulang kamera jika hasil deteksi masih mengalami hasil yang kurang presisi. Dan dari hasil kurang presisi bisa saja terdapat beberapa faktor lain seperti: pencahayaan yang kurang, jarak antar wajah dan webcam laptop terlalu dekat atau terlalu jauh. Pengujian ini menggunakan arsitektur InceptionV3 dari hasil training/pelatihan skenario ketiga dengan konfigurasi: Optimizer Adam (*learning rate* 1e-4), *loss function*, *batch size* 64, *epoch* 100, dan menggunakan *earlystopping* agar pada saat training tidak mengalami *overfitting*. Yang memang diatas kertas sangat tertinggal diantara arsitektur lainnya, Resnet50 dan VGG16. Penelitian ini tidak hanya mengevaluasi hasil kinerja setiap arsitektur untuk sistem pengenalan wajah, melainkan juga memberikan rekomendasi terbaik dari ketiga model arsitektur yang digunakan untuk sistem pengenalan wajah pada ruang server DRC.

V. KESIMPULAN

Penelitian ini telah diselesaikan dengan membandingkan dengan performa arsitektur InceptionV3, Resnet50, dan VGG16 dalam pengenalan wajah karyawan PT. Pelindo Marine Service. Menggunakan metode CNN dengan transfer learning menggunakan 3 skenario pengujian epoch yang berbeda (50, 80, dan 100). Perbandingan penelitian ini berdasarkan hasil akurasi, Confusion Matrix, Classification report dan kecepatan training dataset. Penelitian ini mengevaluasi berdasarkan tes pengujian bahwasannya arsitektur VGG16 memang secara Accuracy, Confusion matrix, Classification report mendapatkan hasil yang lebih akurat untuk pengenalan wajah. Dibandingkan dengan kedua arsitektur yang lainnya. Maka dari itu penelitian ini menyimpulkan jumlah angka dari classification report dan confusion matrix tidak dapat dijadikan acuan.

REFERENSI

- Balasubramanian, A. A., Al-Heejawi, S. M. A., Singh, A., Breggia, A., Ahmad, B., Christman, R., Ryan, S. T., & Amal, S. (2024). Ensemble Deep LearningBased Image Classification for Breast Cancer Subtype and Invasiveness Diagnosis from Whole Slide Image Histopathology. *Cancers*, 16(12). <https://doi.org/10.3390/cancers16122222>
- Danial, N. H., & Setiawati, D. (2024). Convolutional Neural Network (Cnn) Based on Artificial Intelligence in Periodontal Diseases Diagnosis. *Interdental Jurnal Kedokteran Gigi (IJKG)*, 20(1), 139–148. <https://doi.org/10.46862/interdental.v20i1.8641>
- Dwiparawati, S. V. (2022). Implementasi Pengenalan Wajah Secara Real-Time Dengan Metode Haar Cascade Classifier Menggunakan OpenCV-Python Implementasi Pengenalan Wajah Secara Real-Time Dengan Metode Haar Cascade Classifier Menggunakan Opencv-Python. *Ug Jurnal*, 16(2), 51–59.
- Fasounaki, M., Yüce, E. B., Öncül, S., & Ince, G. (2021). CNN-based Textindependent Automatic Speaker Identification Using Short Utterances. *Proceedings - 6th International Conference on Computer Science and Engineering, UBMK 2021*, 01, 413–418. <https://doi.org/10.1109/UBMK52708.2021.9559031>
- Fuadi, M., Darusalam, U., Kusuma Whardana, A., Nasional, U., Sawo Manila, J., Ps Minggu Jakarta, P., Sistem Informatika, J., & Teknologi Komunikasi dan Informatika, F. (2021). Face Recognition Menggunakan Opencv Dengan Bahasa Pemograman Python Oop Untuk Sistem Presensi Rumah Sakit. *Journal of Artificial Intelligence and Innovative Applications*, 2(3), 2775–4057. <http://openjournal.unpam.ac.id/index.php/JOAIIA/index218>
- Lina, Adhitya Marunduh, A., Wasino, & Ajienegro, D. (2022). Identifikasi Emosi Wajah Pengguna Konferensi Video Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-16. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 9(5), 1047–1054. <https://doi.org/10.25126/jtiik.202295269>
- Lu, W., Li, J., Wang, J., & Qin, L. (2021). A CNN-BiLSTM-AM method for stock price prediction. *Neural Computing and Applications*, 33(10), 4741–4753. <https://doi.org/10.1007/s00521-020-05532-z>
- Putra, S. P., Fitri, I., & Ningsih, S. (2021). Absensi Pengenalan Wajah Menggunakan Menggunakan Algoritma Eigenface Berbasis Web. *Journal of Applied Informatics and Computing*, 5(1), 21–27. <https://doi.org/10.30871/jaic.v5i1.2711>
- Rachman, F. P. (2021). Perbandingan Model Deep Learning untuk Klasifikasi Sentiment Analysis dengan Teknik Natural Language Processing. *Jurnal Teknologi dan Manajemen Informatika*, 7(2), 113–121. <https://doi.org/10.26905/jtmi.v7i2.6506>
- Reihardian, E. (2024). Klasifikasi Ekspresi Wajah Manusia Menggunakan Metode CNN Dengan Arsitektur Visual Geometry Group (VGG-Net). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 8(8), 1–6.
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjaljly, A., Alsolai, H., Siddiqui, T., & Mellit, A. (2023). A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope. *Sustainability* (Switzerland), 15(7). <https://doi.org/10.3390/su15075930>
- Septyanto, M. W., Sofyan, H., Jayadianti, H., Simanjuntak, O. S., & Prasetyo, D. B. (2020). Aplikasi Presensi Pengenalan Wajah Dengan Menggunakan Algoritma Haar Cascade Classifier. *Telematika*, 16(2), 87. <https://doi.org/10.31315/telematika.v16i2.3182>
- Siddik, A. M. A. (2023). Comparison of Transfer Learning Algorithm Performance in Hand Sign Language Digits Image Classification. *Jurnal Matematika, Statistika dan Komputasi*, 20(1), 75–89. <https://doi.org/10.20956/j.v20i1.26503>
- Sugeng, S., & Mulyana, A. (2022). Sistem Absensi Menggunakan Pengenalan Wajah (Face Recognition) Berbasis Web LAN. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 11(1), 127–135. <https://doi.org/10.32736/sisfokom.v11i1.1371>
- Tanuwijaya, E., & Roseanne, A. (2021). Modifikasi Arsitektur VGG16 untuk Klasifikasi Citra Digital Rempah-Rempah Indonesia. *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(1), 189–196. <https://doi.org/10.30812/matrik.v21i1.1492>
- Ulumul, M., & Huda, I. (2024). IDENTIFICATION OF DIGITAL SIGNATURE PATTERNS BASED ON THE CNN METHOD AT ALMAS ' UDIYYAH ISLAMIC BOARDING SCHOOL IDENTIFIKASI POLA TANDA TANGAN DIGITAL BERBASIS METODE CNN PADA PONDOK PESANTREN ALMAS ' UDIYYAH.
- Wardani, K. R. R., Suryalim, H., Engel, V. J. L., & Christian, H. (2023). Analisis Pemilihan Optimizer dalam Arsitektur Convolution Neural Network VGG16 dan Inception untuk Sistem Pengenalan Wajah. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 9(2), 186. <https://doi.org/10.26418/jp.v9i2.60432>