

## **SISTEM ABSENSI MAHASISWA MENGGUNAKAN FACE RECOGNITION DENGAN ALGORITMA CNN**

**Aditya Firmansyah<sup>1</sup>, Ahmad Fauzul Itsnan<sup>2</sup>, Ahmad Apip<sup>3</sup>, Randy Tri Mulliya<sup>4</sup>, Perani Rosyani<sup>5</sup>**

<sup>1</sup>Fakultas Teknik, Program Studi Ilmu Komputer, Universitas Pamulang, Kota Tangerang Selatan, Indonesia

E-mail : <sup>1</sup>[aditfir4@gmail.com](mailto:aditfir4@gmail.com), <sup>2</sup>[fauzul883@gmail.com](mailto:fauzul883@gmail.com), <sup>3</sup>[Ahmadapip1200@gmail.com](mailto:Ahmadapip1200@gmail.com),

<sup>4</sup>[randymulliya46@gmail.com](mailto:randymulliya46@gmail.com), <sup>5</sup>[dosen00837@unpam.ac.id](mailto:dosen00837@unpam.ac.id)

**ABSTRAK-** Sistem kehadiran mahasiswa sangat membantu dalam memantau kehadiran mahasiswa. Teknologi modern, seperti pengenalan suara, retina mata, dan pengenalan wajah, dapat digunakan untuk mendeteksi objek. Penulis akan membuat model untuk mengidentifikasi wajah mahasiswa. Dalam penelitian ini, penulis menggunakan algoritma Convolutional Neural Network (CNN) yang dimodifikasi. Spesifikasi hardware dan software yang digunakan menentukan kompleksitas CNN yang dirancang. Data wajah siswa dikumpulkan secara langsung dari dataset pribadi. menggunakan kamera handphone standar untuk memotret wajah mahasiswa. Setiap mahasiswa menghasilkan 60 gambar, masing-masing dengan 4 kelas (label). Pengambilan foto dari berbagai sudut wajah, termasuk dari atas, bawah, depan, samping kiri, dan samping kanan. Dalam penelitian ini, berbagai teknik augmentasi digunakan, seperti teknik flip, rotasi acak, dan affine, untuk memperkaya dataset wajah siswa. Selain itu, penerapan teknik regularisasi, seperti dropout, dilakukan untuk meningkatkan akurasi model, mempercepat proses pelatihan, dan mencegah terjadinya overfitting. Hasil evaluasi menggunakan confusion matrix pada algoritma Convolutional Neural Network (CNN) yang dimodifikasi menunjukkan bahwa proses pelatihan model menjadi lebih cepat dengan waktu 1.23 jam. Akurasi model mencapai 99.85%, dan nilai loss stabil pada angka 0.0112 setelah 40 epoch. Model yang dihasilkan dengan metode ini dapat direkomendasikan untuk diimplementasikan dalam sistem kehadiran mahasiswa, menunjukkan kehandalan dan efektivitasnya.

**Kata Kunci:** Pengenalan Wajah, Sistem Kehadiran, Convolutional Neural Network Modifikasi, Augmentasi Data, Confusion Matrix.

**ABSTRACT-The student attendance system is very helpful in providing student attendance. Modern technologies, such as voice recognition, eye retina, and facial recognition, can be used to detect objects. The author will create a model to identify student faces. In this research, the author uses a modified Convolutional Neural Network (CNN) algorithm. The specifications of the hardware and software used determine the complexity of the CNN being designed. Student facial data is collected directly from private datasets. using a standard cell phone camera to take photos of students' faces. Each student produces 60 images, each with 4 classes (labels). Take photos from various angles of the face, including from above, below, front, left side and right side. In this research, various augmentation techniques are used, such as flip, random rotation, and affine techniques, to enrich the student face dataset. In addition, the application of regularization techniques, such as dropout, is carried out to increase model accuracy, speed up the training process, and prevent overfitting. Evaluation results using the confusion matrix on the modified Convolutional Neural Network (CNN) algorithm show that the model training process becomes faster with time. 1.23 hours. The model accuracy reached 99.85%, and the loss value was stable at 0.0112 after 40 epochs. The model produced by this method can be recommended for implementation in student attendance systems, demonstrating its reliability and effectiveness.**

**Keywords:** Face Recognition, Attendance System, Convolutional Neural Network Modification, Data Augmentation, Confusion Matrix

### **1. PENDAHULUAN**

Saat ini, teknologi informasi seperti perkembangan teknologi kecerdasan buatan (AI), pengajaran mesin, ilmu data, pengajaran mendalam, dan teknologi visi komputer serta kecanggihan perangkat hardware komputer merupakan contoh perkembangan teknologi informasi yang sangat pesat. Software dan hardware saat ini memiliki kemampuan untuk mengolah jumlah data yang sangat besar, seperti mengkonversi gambar menjadi informasi. Sekolah sangat membutuhkan sistem absensi digital untuk memantau kehadiran siswa.. Ada berbagai teknologi biometrik yang dapat digunakan, seperti sidik jari, deteksi wajah, dan deteksi mata, serta penggunaan kode bar. Penulis sedang membuat prototipe sistem kehadiran siswa dengan menggunakan teknologi pengenalan wajah.(Kurniawan dan Kusrini 2023)

Kehadiran fisik di setiap perkuliahan yang sebelumnya ditutup. Setiap siswa akan memberikan umpan balik terhadap lembar presensi yang tersedia pada setiap sesi. Prestasi siswa di kelas perkuliahan akan menentukan dapat atau tidaknya siswa tersebut mengikuti ujian semester sepuluh (UTS) dan ujian akhir semester (UAS). Kemampuan siswa dalam mengikuti UTS maupun UAS pada setiap pembelajaran matematika yang ditentukan adalah dengan menjamin minimal 75% materi tercakup dalam setiap pembelajaran..(Haryansyah dkk. 2022).

Salah satu ukuran fisiologis yang paling mudah dan sering digunakan untuk membedakan identitas seseorang adalah wajahnya orang dapat dengan cepat dan mudah mengingat wajah orang lain. Oleh karena itu, para ahli mempelajari dan mengembangkan *face recognition* sebagai salah satu teknologi biometrics (Alwendi dan Masriadi 2021).

Salah satu teknologi yang dapat mengenali pola wajah adalah deteksi wajah, karena setiap orang memiliki karakteristik wajah yang unik, sehingga dapat memberikan informasi tentang identitas setiap orang seperti pola suara, sidik jari, renita mata, dan pola wajah.

Meskipun teknologi biometrik—khususnya pengenalan wajah—telah terbukti bermanfaat di banyak bidang, penerapannya dalam mendeteksi perilaku menyimpang siswa belum mencapai potensi maksimalnya. Penelitian ini diharapkan dapat memberikan kontribusi terhadap kemajuan teknologi biometrik, khususnya dalam rangka mendeteksi perilaku menyimpang siswa di lingkungan pendidikan tinggi. Implementasi CNN diharapkan akan meningkatkan efisiensi pengajaran siswa dan menyediakan data otomatis yang akurat untuk evaluasi akademik.

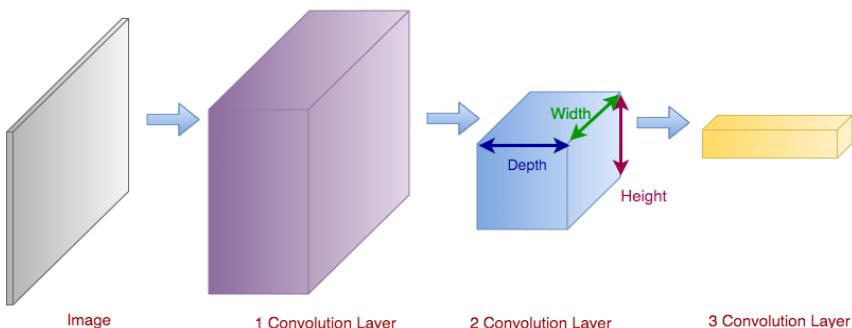
## 2. METODE PENELITIAN

### 2.1 Pengumpulan Data

Data yang dibutuhkan untuk penelitian ini adalah gambar/foto wajah mahasiswa berukuran 224 x 224 pixel yang diambil dengan kamera handphone. Data ini akan dibuat menjadi dataset pribadi menggunakan library Phyton OpenCV. Gambar akan dimasukkan ke dalam folder dengan struktur Dataset/nama mahasiswa. Pengambilan gambar dilakukan dengan posisi dari depan, samping kiri dan samping kanan tetapi wajah tetap menjadi pusat utamanya. Jadi total semua gambar yaitu 60 gambar.

### 2.2 Metode Convolution Neutral Network

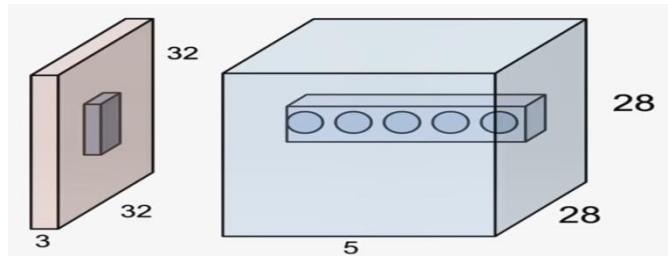
Convolutional neural network (CNN), juga dikenal sebagai CovNet atau CNN, adalah salah satu jenis deep feed-forward artificial neural networks yang paling banyak digunakan dalam analisis gambar. CNN terdiri dari satu lapis masukan (input layer), satu lapis keluaran (output layer), dan beberapa lapis tersembunyi. biasanya terdiri dari lapisan convolutional, lapisan pooling, lapisan normalisasi, lapisan ReLu, dan lapisan yang penuh terhubung, dan lapisan kehilangan (Srinivas, T., et al. 2022) Lapisan-lapisan ini disusun secara berurutan. Dibandingkan dengan MLP yang CNN menggunakan arsitektur tiga dimensi (lebar, width, dan tinggi). (tinggi) dan dalam (dalam).



**Gambar 1** Arsitektur CNN Secara Umum

### 2.3.1 Convolution Layer

Sebagian besar komputasi neural konvolusi (CNN) dilakukan di lapisan konvolusional. Misalkan kita membuat lapisan convolutional dengan satu lembaran neuron berukuran  $28 \times 28$ . Masing-masing terhubung ke area kecil dalam gambar input, seperti  $5 \times 5$  pixel, yang berfungsi sebagai bidang reseptif untuk setiap neuron dan menunjukkan filter yang digunakan. berukuran lima kali lima inci, seperti yang ditunjukkan pada Gambar 2 yang terkait di bawah ini.

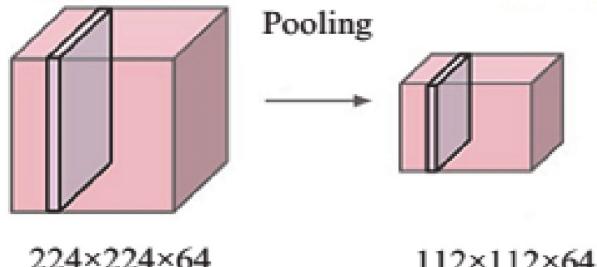


**Gambar 2** Convolution layer dengan satu buah filter berukuran  $5 \times 5$

Dengan menggunakan formula  $w1 \times h1 \times d1$ , (1) di mana  $w1$  dan  $h1$  adalah lebar dan tinggi citra, dan  $d1$  adalah jumlah kanal RGB Red Green Blue dalam CNN menggunakan istilah "kedalaman atau kedalaman citra masukan".

### 2.3.2 Pooling Layer

Seperti yang ditunjukkan pada Gambar 3, lapisan penggabungan memungkinkan representasi data yang lebih kecil, lebih mudah untuk diurus, dan lebih mudah untuk mengontrol overfitting. Fungsi lapisan penggabungan adalah untuk menjaga ukuran data saat pergeseran.



**Gambar 3** Proses pooling dengan mereduksi dimensi data

Max pooling, yang mengambil nilai maksimum pada suatu wilayah tertentu, adalah proses pooling yang paling umum digunakan.

### 2.3.3 ReLu Layer

Layer Rectified Linear Units (ReLU) menggunakan fungsi aktivasi  $f(x) = \max(0, x)$ . Tanpa mengubah bidang reseptif pada lapisan convolutional, ini meningkatkan sifat nonlinearitas jaringan dan fungsi keputusan secara keseluruhan. Selain itu, Anda dapat memanfaatkan fungsi tambahan, seperti tangen hiperbolik  $f(x) = \tanh(x)$ ,  $f(x) = |\tanh(x)|$ , atau  $f(x) = (1 + e^{-x}) - 1$ .

### 2.3.4. Fully Connected Layer

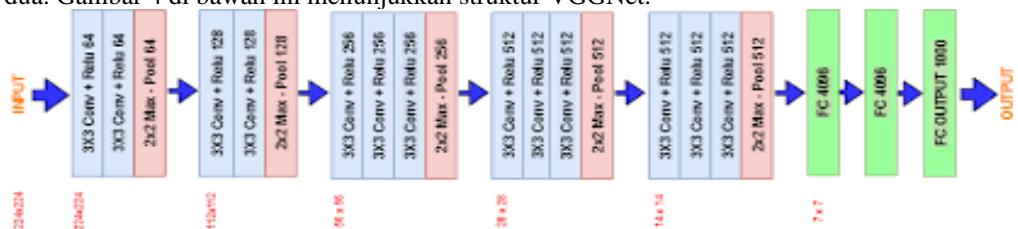
Setiap neuron pada lapisan yang terhubung secara penuh (lapisan yang terhubung secara penuh) memiliki akses penuh ke semua aktivasi pada lapisan sebelumnya. Hal ini sama dengan yang ada pada MLP. Model aktivasinya, yang menggunakan perkalian matriks yang diikuti dengan bias offset, juga sama.

### 2.3.5. Loss Layer

Lapisan Loss CNN menentukan bagaimana pelatihan memberikan hukuman atas ketidaksesuaian antara hasil prediksi dan label. Kehilangan Softmax, salah satu dari banyak varisi kehilangan fungsi, digunakan untuk memprediksi sejumlah nilai probabilitas dalam interval [0,1].

### 2.4 Arsitektur CNN (VGGNet)

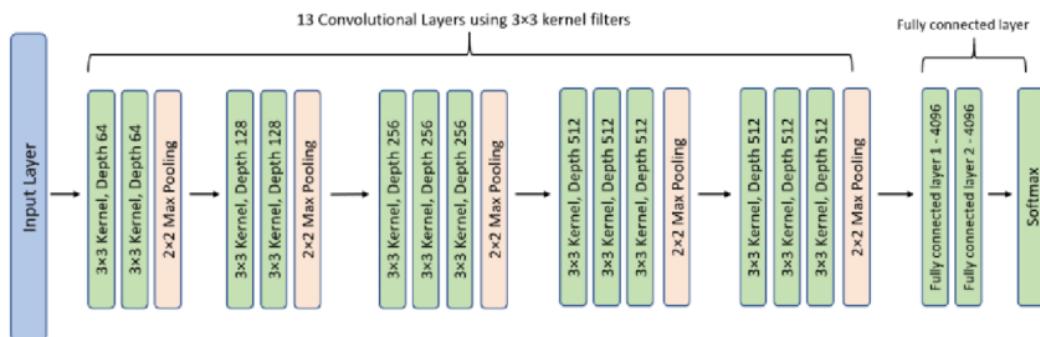
Karen Simoyan dan Andrew Zisserman membangun VGGNet, yang muncul sebagai juara kedua dalam ILSVRC 2014 (Lab 2018). Arsitektur ini menunjukkan bahwa kedalaman jaringan sangat penting untuk menghasilkan kinerja yang tinggi. Dengan kata lain, jaringan CNN yang lebih dalam seharusnya lebih akurat. Networking arsitektur VGGNet yang paling baik terdiri dari enam belas lapisan convolutional atau penuh terhubung yang memiliki arsitektur yang sama. Dari lapisan awal hingga lapisan akhir, mereka hanya melakukan konvolusi tiga kali tiga dan pooling dua kali dua. Gambar 4 di bawah ini menunjukkan struktur VGGNet.



Gambar 4 Arsitektur VGG16

### 2.5 Perumusan Model Arsitektur CNN-1

Penulis melakukan penelitian untuk pengenalan wajah mahasiswa dengan menggunakan banyak gambar yang berfungsi sebagai data. Diharapkan arsitektur CNN dapat mencapai akurasi model yang tinggi, yang berarti proses pelatihan model membutuhkan perangkat keras berkualitas tinggi. Untuk mengubah Penulis akan menyederhanakan algoritma arsitektur VGGNet dengan menggunakan perangkat komputer yang tersedia. Arsitektur CNN-1 yang penulis ajukan digambarkan di bawah ini.



Gambar 5 Arsitektur CNN-1

Model yang dibangun oleh penulis menggunakan jenis arsitektur Convolutional Neural Network (CNN) terdiri dari beberapa lapisan Flatten, Dense dan Dropout. Yang digunakan untuk mengolah data gambar. Gambar 1 dimensi dengan ukuran 224 x 224 pixel digunakan sebagai lapisan input dengan tiga saluran warna (RGB). Menentukan dimensi yang diharapkan oleh model dengan ukuran input\_shape = (224, 224, 3). Selanjunya Gambar-gambar dalam set pelatihan diubah secara acak menggunakan ImageDataGenerator. Augmentasi ini mencakup rotasi, pergeseran horizontal dan vertikal, pergeseran zoom, dan horizontal flip. Tujuan dari augmentasi adalah untuk meningkatkan keragaman data pelatihan dan meningkatkan generalisasi model. Menggunakan arsitektur VGG16 sebagai model dasar VGG16 memiliki beberapa lapisan konvolusi dan max

pooling yang efektif dalam mengekstrak fitur gambar. Output dari VGG16, yang berupa tensor tiga dimensi, diubah menjadi vektor satu dimensi menggunakan layer Flatten.

Lapisan Fully Connected selanjutnya mencakup lapisan Flatten, dua lapisan dense dengan 256 unit masing – masing menggunakan fungsi aktivitas ReLU dan menerapkan layer dropout dengan Tingkat 0.5 untuk mengurangi overfitting. Menentukan probabilitas kelas yang diprediksi. Konfigurasi pelatihan melibatkan pengoptimal Adam dengan laju pembelajaran 0,001, loss categorical crossentropy, 30 epoch, dan batch size 32.

## 2.6 Augmentasi Data

Langkah selanjutnya adalah masuk ke lapisan Fully Connected. Lapisan flatten mengubah data dua dimensi menjadi vektor satu dimensi, yang memungkinkan lapisan Dense berikutnya untuk mengolahnya. Dua lapisan tebal memiliki 256 masing-masing, dan setelah aktivasi ReLU dengan fungsi dropout. Pada akhirnya, lapisan Dense dengan empat unit atau kelas digunakan sebagai output lapisan dan aktivasi softmax digunakan. Untuk mengkompilasi model terakhir, optimizer Adam digunakan untuk laju pembelajaran 0.001 dan fungsi kehilangan kategorical\_crossentropy. Meskipun model ini memiliki banyak parameter dan kompleks, ia tetap dapat mendekripsi gambar dengan baik.

## 2.7 Evaluasi Model Klasifikasi

Setelah model dibangun, mereka harus dievaluasi untuk memilih yang terbaik. Untuk mengevaluasi model, akurasi, ketepatan, pengejaan, skor F1, dan matrix kekacauan digunakan (Negi, Alok, et al 2021). Untuk mengevaluasi suatu model klasifikasi, data uji yang tidak digunakan dalam pelatihan diperlukan. Dalam model pembelajaran TP, TP adalah positif asli, TN adalah positif negatif, FP adalah positif palsu, dan FN adalah positif palsu. Beberapa dimensi tertentu dapat digunakan untuk mengevaluasi model ini. Dalam penelitian ini, matrix confusion digunakan sebagai alat ukur untuk memeriksa enam belas model pembelajaran transfer (Majib, Mohammad Shahjahan, et al. 2021). Penulis juga menghitung nilai precision score, recall score, dan f1 score untuk mengevaluasi model yang telah dibangun menggunakan rumus berikut:

$$\text{Accuracy} = \frac{TP+TN}{P+N}$$
 (1)

$$\text{Recall} = \frac{TP}{P}$$
 (2)

$$\text{Precision} = \frac{TP}{TP+FP}$$
 (3)

$$\text{f1-Score} = \frac{2 \times \text{Precision} \times \text{recall}}{\text{precision}+\text{recall}}$$
 (4)

## 3. HASIL DAN PEMBAHASAN

### 3.1 Kumpulan Data dan Pra-Pemrosesan Gambar

Data pribadi yang dikumpulkan merupakan informasi pribadi yang diambil langsung dari subjek penelitian, termasuk berupa potret wajah mahasiswa. Foto wajah mahasiswa diambil menggunakan kamera handphone. Setiap mahasiswa menghasilkan 60 gambar asli dengan resolusi 224 x 224 pixel dalam 3 dimensi (RGB). Gambar – gambar tersebut sudah melalui proses pemilihan agar gambar tidak buram dan terlalu mirip, dengan tujuan untuk mengurangi jumlah data yang akan digunakan pada saat pelatihan model, karena keterbatasan spesifikasi teknis komputer yang digunakan. Digunakan untuk melatih model tanpa perangkat GPU. Saat memotret, kamera difokuskan dengan fokus utama pada wajah mahasiswa. Jarak antara wajah siswa dan kamera kurang lebih 30 cm. Gambar yang dihasilkan memiliki resolusi 224x224 piksel dalam 3 dimensi (RGB). Proses pengambilan dataset pribadi ini ditunjukkan pada Gambar 8 di bawah.

Label atau kelas yang terdapat dalam dataset pribadi ini adalah: adit, apip, fauzul, randy. Setiap kelas memiliki satu contoh gambar yang mewakili label tersebut.

**Tabel 1.** Contoh Dataset Label Wajah Siswa (Data Private)

Gambar	Nama Kelas	Jumlah Data
	adit	60
	apip	60
	fauzul	60
	randy	60

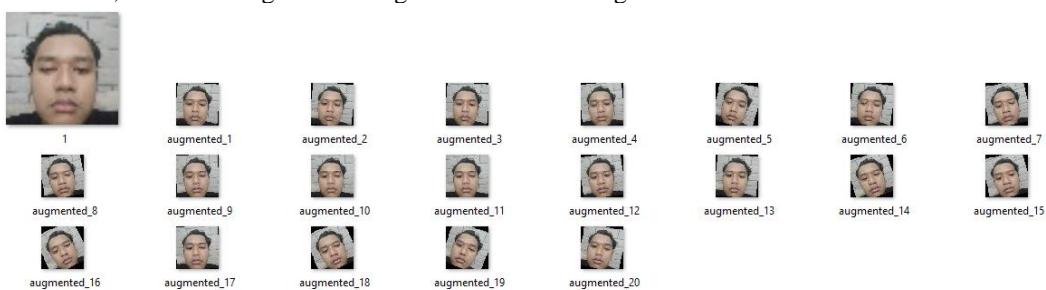
Gambar-gambar tersebut kemudian akan membentuk dataset tersendiri yang diolah menggunakan algoritma bernama CNN yang diusulkan oleh penulis. Sebelum melakukan penskalaan, ukuran setiap gambar akan diperkecil menjadi 224x224x1. Pengukuran ini akan menjadi dasar untuk 6 pengulangan percobaan yang direncanakan. Proses selanjutnya akan melibatkan augmentasi, dimana 3 teknik augmentasi akan diterapkan: flip, rotasi acak dan Affine. Proses ini akan menghasilkan 20 variasi gambar yang berbeda dari setiap gambar aslinya. Setelah proses ini, jumlah data setiap lapisan akan bertambah menjadi 1.260, termasuk 60 data asli.

Total kumpulan data akan menjadi 4.800, ditambah data asli.

240, sehingga total kumpulan data menjadi 5.040. Jumlah data untuk setiap lapisan dijaga agar tetap konsisten untuk menjamin validitas bentuk hasil model.

Setelah langkah augmentasi, dataset akan dibagi menjadi 80% data pelatihan (4020 gambar) dan 20% data validasi (1020 gambar).

Gambar ke 4 dibawah ini merupakan contoh hasil penyempurnaan salah satu gambar wajah mahasiswa, dimana satu gambar menghasilkan 20 variasi gambar.



**Gambar 6** Hasil proses dataset privat

### 3.2 Hardware dan Sofware

Dalam penelitian ini, penulis menggunakan perangkat lunak dan perangkat keras yang tersedia tanpa menggunakan GPU, pelatihan model dilakukan hanya menggunakan CPU dan RAM. Rincian spesifikasi dapat ditemukan dalam Tabel.

**Table 1** Sofware dan Hardware

<b>SOFWARE</b>	<b>HARDWARE</b>
OS : Windows 10 pro	CPU : Intel Core I3-4030U @1.6GHz
Python 3.11, OpenCV	RAM : 8 GB
Visual Studio Code	Hard Disk : 256 GB

### 3.3 Arsitektur CNN dengan menggunakan DropOut.

Arsitektur CNN merupakan hasil yang disusun dengan mempertimbangkan ketersediaan perangkat lunak dan perangkat keras yang dimiliki oleh peneliti. Berikut adalah kode yang mewakili arsitektur CNN yang diterapkan oleh penulis.

```

model = models.Sequential()
model.add(base_model)
model.add(layers.Flatten())
model.add(layers.Dense(256, activation='relu'))
model.add(layers.Dropout(0.5))
model.add(layers.Dense(len(train_generator.class_indices), activation='softmax'))

base_model.trainable = False

model.compile(
    loss='categorical_crossentropy',
    optimizer=optimizers.Adam(learning_rate=1e-4),
    metrics=['accuracy']
)

history = model.fit(
    train_generator,
    steps_per_epoch=len(train_generator),
    epochs=epochs,
    validation_data=validation_generator,
    validation_steps=len(validation_generator)
)

```

### 3.4 Hasil Training Model

Hasil dari pelatihan model terdapat pada Tabel 3 di bawah ini. Pada uji ke-1 hingga ke-6, parameter yang diterapkan pada objek gambar memiliki ukuran 224x224 piksel dengan jumlah epoch berturut-turut dari 10, 20, 30, 40, 50, dan 60. pada uji ke-1 hingga ke-6, parameter yang

sama digunakan dengan penerapan teknik regularisasi (dropout).

Tabel 3. Skenario dan Hasil Uji Pelatihan Model dengan Arsitektur CNN

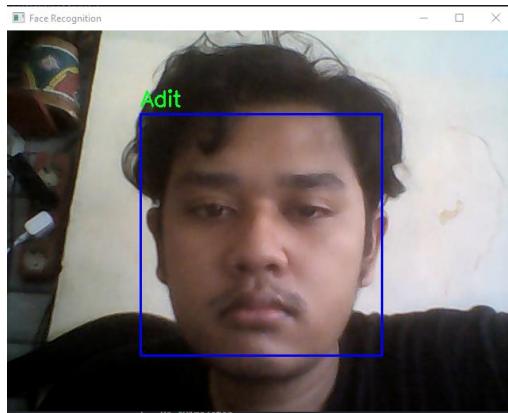
No Uji	Ukuran Citra	Jumlah Epoch	Augmentasi	Drop out	(%) Akurasi	(%) Loss	(%) Validasi Akurasi	(%) Validasi Loss	Waktu Training (jam)
1	224x224	10	Ya	Ya	0.9512	0.1311	0.9768	0.3696	0.14
2	224x224	20	Ya	Ya	0.9723	0.0975	0.9802	0.3418	0.36
3	224x224	30	Ya	Ya	0.9782	0.0864	0.9817	0.3265	1.05
4	224x224	40	Ya	Ya	0.9985	0.0112	0.9950	0.0121	1.23
5	224x224	50	Ya	Ya	1.0000	0.1143	1.0000	0.0130	2.19
6	224x224	60	Ya	Ya	0.9956	0.0189	0.7205	1.8539	2.45

Berdasarkan data diatas menunjukkan hasil pelatihan model pada pengujian dengan rentang parameter epoch dari 1 hingga 60. Pengujian dilakukan dengan penerapan augmentasi, penggunaan gambar dengan skema warna grayscale, dengan menerapkan dropout. Hasil dari pengujian ini juga tercermin dalam tabel di atas pada nomor uji 1 hingga 6. Dalam pengamatan, terlihat bahwa pada epoch 60, terjadi overfitting pada model. Hal ini ditunjukkan dengan penurunan yang signifikan pada akurasi serta validasi akurasi, dan juga peningkatan yang tajam pada nilai loss dan validasi loss.

Ada beberapa cara yang dapat digunakan untuk meningkatkan kinerja model dan mencegah overfitting. Salah satunya adalah dengan mengurangi kompleksitas struktur CNN, menggunakan metode regularisasi seperti dropout, atau menggunakan metode augmentasi untuk menambah jumlah gambar.

### 3.5 Hasil Deteksi

Pada gambar 7 ini merupakan hasil dari pendekripsi ketepatan pengenalan wajah berdasarkan model yang telah dibuat.



Gambar 7 Hasil deteksi wajah

## 4. KESIMPULAN

Proses pengambilan data gambar pribadi yang terdiri dari wajah mahasiswa telah dilakukan dengan teknik pengambilan sebagaimana dijelaskan sebelumnya, dan proses pengolahan dataset telah dilaksanakan dengan sangat baik, terbukti dari kualitas hasil akurasi model yang terbentuk yang telah stabil dan baik. Pendekatan yang diadopsi oleh peneliti untuk melatih model melibatkan 4.020 data untuk pelatihan dan 1.020 data untuk validasi, dengan merancang arsitektur CNN yang dimodifikasi dari struktur VGG16. Dari 6 skenario pengujian yang dilakukan, hasil terbaik diperoleh melalui pengaturan parameter berikut: ukuran gambar 224x224 piksel, skema warna gambar dalam

format RGB, penerapan augmentasi dengan teknik flip, rotasi acak, dan Affine, serta penerapan teknik regularisasi dropout dengan nilai 0.2. Selain itu, jumlah data gambar untuk setiap kelas diatur sedemikian rupa agar seimbang. Dengan konfigurasi tersebut, model yang dihasilkan mencapai akurasi sebesar 99.85%, nilai loss adalah 0.0112, akurasi validasi sebesar 99.50%, dan nilai validasi loss adalah 0.121, yang diperoleh setelah melalui 40 iterasi (epoch). Dengan parameter tersebut, tim kami berhasil membangun sebuah model yang mampu memberikan hasil akurasi yang sangat baik dan stabil untuk pengolahan data kelompok kami.

## **DAFTAR PUSTAKA**

- aryansyah, H., Gusmana, R., Fadlan, M., & Wibisono, A. D. (2022). Sistem Presensi Perkuliahian Berbasis Internet Of Things Untuk Efektifitas Rekapitulasi Kehadiran Mahasiswa. *Sebatik*, 26(2), 834-844.
- Kurniawan, Henri, dan Kusnawi Kusrini. 2023. "JURNAL MEDIA INFORMATIKA BUDIDARMA Klasifikasi Pengenalan Wajah Siswa Pada Sistem Kehadiran dengan Menggunakan Metode Convolutional Neural Network."
- Alwendi, A., & Masriadi, M. (2021). Aplikasi Pengenalan Wajah Manusia Pada Citra Menggunakan Metode Fisherface. *Jurnal Digit: Digital of Information Technology*, 11(1), 01-08.
- Srinivas, T., Aditya Sai, G., & Mahalaxmi, R. (2022). A comprehensive survey of techniques, applications, and challenges in deep learning: A revolution in machine learning. *International Journal of Mechanical Engineering*, 7(5), 286-296.
- Qassim, H., Verma, A., & Feinzimer, D. (2018, January). Compressed residual-VGG16 CNN model for big data places image recognition. In *2018 IEEE 8th annual computing and communication workshop and conference (CCWC)* (pp. 169-175). IEEE.
- Negi, A., Kumar, K., Chauhan, P., & Rajput, R. S. (2021, February). Deep neural architecture for face mask detection on simulated masked face dataset against covid-19 pandemic. In *2021 international conference on computing, communication, and intelligent systems (ICCCIS)* (pp. 595-600). IEEE.
- Majib, M. S., Rahman, M. M., Sazzad, T. S., Khan, N. I., & Dey, S. K. (2021). Vgg-snet: A vgg net-based deep learning framework for brain tumor detection on mri images. *IEEE Access*, 9, 116942-116952.
- Zhang, Hongli & Jolfaei, Alireza & Alazab, Mamoun. (2019). A Face Emotion Recognition Method Using Convolutional Neural Network and Image Edge Computing. *IEEE Access*. PP. 1-1. 10.1109/ACCESS.2019.2949741.
- .