

Comparative Analysis of CNN Architectures with an Augmented Dataset to Support a Face Recognition-Based Student Attendance System

Asrul Khasanah¹, Ghea Zahwa Ramadhania², Ulfa Chairiah³,
Sandy Salomo Saruan^{4*}

^{1,2,3}Departemen Matematika, Universitas Gadjah Mada, Sleman, Indonesia,

⁴Program Studi Matematika, Institut Teknologi Batam, Batam, Indonesia,

¹asrul.khasanah@mail.ugm.ac.id, ²gheazahwaramadhania525610@mail.ugm.ac.id,

³ulfachairiah2000@mail.ugm.ac.id, ⁴sandy@iteba.ac.id

*Corresponding author

ABSTRAK

Face recognition merupakan metode yang efektif dalam mengoptimalkan tingkat efisiensi sistem presensi. Untuk meningkatkan akurasi sistem presensi mahasiswa Magister Matematika berbasis *face recognition* di Universitas Gadjah Mada, penelitian ini menggunakan pendekatan *convolutional neural network* (CNN) pada dataset gambar mahasiswa sebanyak 747 gambar unik dengan 15 label yang diaugmentasi menjadi 15.687 gambar. Arsitektur-arsitektur CNN yang diuji meliputi VGG-16, GoogLeNet, AlexNet, dan ResNet-152. Hasil penelitian menunjukkan bahwa arsitektur ResNet-152 memberikan performa terbaik dalam pengenalan wajah dengan akurasi sebesar 99,96%, diikuti oleh GoogLeNet (99,41%) dan VGG-16 (99,32%). Keunggulan ResNet-152 dipengaruhi oleh kemampuan struktur residualnya dalam pembelajaran mendalam tanpa penurunan kualitas. GoogLeNet memanfaatkan *batch normalization* dan faktorisasi untuk mengurangi jumlah parameter dan mempercepat pelatihan, sedangkan VGG-16 meningkatkan non-linearitas dengan kernel yang lebih kecil. Arsitektur AlexNet menghasilkan akurasi terendah sebesar 94,10%. Meskipun arsitektur ini populer, namun membutuhkan lebih banyak waktu untuk mencapai tingkat akurasi yang memadai karena AlexNet memiliki kedalaman model yang relatif lebih dangkal dibandingkan dengan ResNet-152, GoogLeNet, dan VGG-16.

Kata Kunci: *Face recognition; convolutional neural networks; augmentasi dataset; sistem presensi*

ABSTRACT

Face recognition is an effective method in optimizing the efficiency level of the attendance tracking system. To improve the accuracy of the student attendance system based on face recognition for master's students in mathematics at Universitas Gadjah Mada, this research uses a convolutional neural network (CNN) approach on a dataset of 747 unique student images with 15 labels that were augmented into 15,687 images. The CNN architectures tested include VGG-16, GoogLeNet, AlexNet, and ResNet-152. The results show that ResNet-152 architecture provides the best performance in face recognition with an accuracy of 99.96%, followed by GoogLeNet (99.41%) and VGG-16 (99.32%). The superiority of ResNet-152 is influenced by the ability of its residual structure in deep learning without degradation. GoogLeNet utilizes batch normalization and factorization to reduce the number of parameters and speed up training, while VGG-16 improves non-linearity with a smaller kernel. The AlexNet architecture produced the lowest accuracy of 94.10%. Although this architecture is popular, it requires more time to achieve sufficient accuracy as AlexNet has limited model depth compared to ResNet-152, GoogLeNet, and VGG-16.

Keywords: *Face recognition; convolutional neural networks; augmented dataset; attendance system*

1. PENDAHULUAN

Dalam proses pembelajaran di suatu institusi pendidikan tinggi, sistem presensi memiliki peran krusial dalam mengelola kehadiran mahasiswa untuk memastikan kegiatan belajar

mengajar berjalan efisien. Presensi yang akurat dan efisien menjadi sangat penting untuk mengevaluasi kehadiran serta keterlibatan mahasiswa secara aktif dalam kegiatan perkuliahan baik secara online maupun offline. Sistem presensi mahasiswa ini tidak hanya berfungsi sebagai alat untuk memantau kehadiran mahasiswa, tetapi juga memberikan kontribusi langsung terhadap kualitas pembelajaran dan manajemen akademik dalam lingkungan civitas akademika. Dalam rangka meningkatkan efisiensi sistem presensi di Universitas Gadjah Mada khususnya, telah diaplikasikan metode *Quick-Response* (QR) Code melalui aplikasi Simaster yang dapat diinstal melalui Android/iOS. Mahasiswa dapat menggunakan sistem tersebut apabila telah memiliki akun UGM di aplikasi Simaster.

Dalam upaya menjadikan proses absensi siswa menjadi lebih praktis dan memudahkan proses pengelolaan data secara lebih efisien telah dikembangkan sistem informasi presensi QR Code berbasis web [1]. Perkembangan teknologi presensi berbasis QR Code ini sangat memberikan kemudahan dalam menyajikan data hasil absensi sehingga lebih cepat dan akurat karena rekapan data tersebut dapat langsung tercetak pada sistem [2]. Di samping itu, kemudahan yang dapat diterima oleh mahasiswa melalui penerapan QR Code pada presensi berbasis android adalah karena aplikasi tersebut dapat diakses secara langsung melalui telepon seluler masing-masing sehingga lebih efisiensi waktu [3]. Maulana et. al. [4] menjelaskan sejumlah manfaat dari pendekatan QR Code dalam sistem presensi sehingga prosesnya dapat berjalan dengan optimal. Manfaat-manfaat yang ditemukan antara lain adalah kemampuannya dalam mengurangi waktu proses presensi dan rekapitulasi serta meminimalkan penggunaan kertas.

Di samping banyaknya manfaat sistem presensi menggunakan QR Code, dalam pelaksanaannya masih terdapat beberapa kekurangan seperti seringkali terjadi galat yang menyebabkan mahasiswa tidak dapat melakukan absensi. Selain itu, terdapat beberapa kasus ketika smartphone mahasiswa tidak dapat digunakan untuk mengenerate QR Code sehingga proses presensi hanya dapat dilakukan secara manual oleh dosen yang mengajar atau melalui admin program studi. Lebih lanjut, metode ini memiliki potensi manipulasi data presensi apabila terdapat mahasiswa yang menitipkan gadgetnya untuk digunakan dalam melakukan presensi di dalam kelas meskipun orangnya tidak hadir. Oleh sebab itu, penelitian ini berusaha untuk memberikan alternatif sistem presensi menggunakan metode pengenalan wajah (*face recognition*).

Terdapat beragam metode pengenalan wajah yang telah dikembangkan seperti metode berbasis *eigenface*, metode berbasis distribusi (*distribution-based*), jaringan saraf (*neural networks*), *Support Vector Machines*, *Naive Bayes Classifiers*, *Hidden Markov Model*, *Information-Theoretical Approach*, dan *Inductive Learning*. Dari banyaknya metode-metode pengenalan wajah di atas, salah satu alat yang banyak digunakan dalam klasifikasi dan pengenalan pola adalah pendekatan jaringan saraf tiruan. Dalam pendekatan *neural networks*, telah dikenal metode *feed-forward neural networks* (FFNN), *self-organizing maps* (SOM) dan *convolutional neural network* (CNN) di mana CNN memiliki kelebihan dalam hal invariansi translasi parsial dan deformasi [5]. Invariansi translasi parsial dan deformasi adalah kemampuan CNN dalam mengenali objek atau fitur meskipun terdapat perubahan posisi atau bentuk dalam gambar yang digunakan. Karena kemampuan metode CNN dalam mengenali pola dan klasifikasi tersebut, studi ini menggunakan metode CNN dalam meningkatkan akurasi presensi mahasiswa berbasis *face recognition*, khususnya di program studi Magister Matematika Universitas Gadjah Mada.


Dalam beberapa tahun terakhir, terdapat banyak pengembangan dalam penggunaan metode CNN. Salah satu keberhasilan CNN adalah kemampuannya dalam mengenali wajah [6]. Khan et.al. [7] menggunakan metode *region proposal network* dalam CNN untuk pengenalan wajah dalam gambar. Ia juga menambahkan metode augmentasi data untuk membalik setiap gambar

dalam dataset yang digunakan, sehingga mampu menghasilkan akurasi sebesar 97,9%. Pengembangan sistem presensi pegawai oleh Wijaya et. al [8] menggunakan metode PyCharm dan OpenCV dalam CNN berhasil memberikan kemudahan kepada pegawai dalam melakukan presensi dengan lebih cepat, di mana data orang yang telah melakukan presensi tersebut dapat disimpan dengan cepat pula. Pengembangan sistem deteksi wajah untuk pencatatan kehadiran mahasiswa di kelas menggunakan metode CNN juga telah dilakukan oleh Zahrah et. al yang menguji 300 data gambar wajah dengan hasil akurasi sebesar 80% dan dapat mendeteksi 8 dari 10 wajah mahasiswa [9].

Berdasarkan referensi di atas, perbedaan penelitian ini dan penelitian-penelitian sebelumnya terletak pada metode CNN yang digunakan dalam membuat algoritma pengenalan wajah. Penelitian ini akan membandingkan akurasi dari empat arsitektur dalam CNN, yaitu VGG-16, GoogLeNet, AlexNet, dan ResNet-152. Selain itu, penelitian ini juga menggunakan dataset yang lebih besar daripada penelitian-penelitian sebelumnya.

2. METODE

Face recognition dikembangkan untuk membuat sistem otomatis yang dapat menyetarai kemampuan manusia dalam mengenali wajah. Manusia cukup baik dalam mengidentifikasi wajah yang dikenal, namun sedikit terkendala ketika mengenali sejumlah besar wajah yang tidak dikenal. Dengan menggunakan bantuan komputer yang memiliki memori dan kecepatan komputasi dapat membantu mengatasi keterbatasan manusia tersebut. Pada penelitian ini, digunakan bantuan Python 3, dengan library Keras untuk *load* arsitektur yang digunakan. Tahapan penelitian dilakukan seperti pada Gambar 1 berikut.



Gambar 1. Flowchart menggunakan metode CNN

2. 1. Pengumpulan Data dan Input Data

Data yang akan digunakan merupakan data primer. Beberapa mahasiswa yang terdaftar dalam program magister matematika diminta untuk berpartisipasi dalam penelitian ini dengan mengirimkan minimal 20 gambar diri masing-masing. Gambar-gambar tersebut akan digunakan sebagai bagian dari analisis dalam studi ini. Diperoleh 15 orang yang berpartisipasi dalam penelitian ini. Selanjutnya data akan dikumpulkan menjadi bentuk list dan akan diinputkan ke dalam program python yang digunakan.


2. 2. *Preprocessing* Data

Preprocessing merupakan tahap untuk mempersiapkan data yang berupa gambar sebelum penelitian. Tahapan ini diperlukan jika gambar memiliki dimensi yang besar, terdapat lebih

dari satu objek dalam gambar, dan dimensi yang dimiliki setiap gambar berbeda-beda. Dimensi gambar akan diubah menjadi lebih kecil dan berbeda di setiap arsitektur yang digunakan.

2. 3. Augmentasi Data

Data *augmentation* (augmentasi data) berfungsi untuk membantu memperbanyak data yang dimiliki sehingga program dapat mengklasifikasi dengan lebih baik. Augmentasi bekerja dengan cara seperti merotasi foto, mengurangi kontras foto, menggeser posisi foto, zoom in dan zoom out foto. Fadillah et. al. [10] menjelaskan bahwa augmentasi data dapat mengurangi resiko terjadinya *overfitting* dengan meningkatkan ukuran *dataset* dalam upaya seminimum mungkin. Setiap data yang diinputkan akan diaugmentasi menjadi 20 gambar. Contoh hasil data augmentasi diperlihatkan pada Gambar 2.



Gambar 2. Contoh hasil data augmentasi

2. 4. Konstruksi Model dengan CNN


Metode *Convolutional Neural Network* (CNN) merupakan metode jaringan saraf tiruan yang dapat diterapkan dalam masalah umum seperti mengenali objek berupa gambar. Tidak hanya terbatas di gambar, metode ini dapat menyelesaikan masalah pemrosesan bahasa alami dan pengenalan suara [11]. Jaringan saraf tiruan terdiri lapisan input, beberapa lapisan tersembunyi dan lapisan output. Setiap lapisan memiliki node dan setiap node memiliki bobot tertimbang dalam proses dari satu lapisan ke lapisan berikutnya [12].

Metode CNN memiliki beberapa arsitektur dalam mengonstruksi model. Pada kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC), arsitektur AlexNet meraih peringkat pertama pada tahun 2012. Pada tahun 2014, arsitektur GoogLeNet dan VGG Net masing-masing menempati peringkat pertama dan kedua, sedangkan pada tahun 2015, arsitektur ResNet-152 meraih peringkat pertama. Berdasarkan hal tersebut, akan digunakan keempat arsitektur tersebut untuk memperoleh arsitektur dengan evaluasi terbaik dalam sistem presensi mahasiswa Magister Matematika UGM Berbasis *Face Recognition*.

i. Arsitektur AlexNet

Arsitektur Alexnet merupakan tonggak dalam perkembangan *deep learning* dan CNN. Arsitektur ini dapat membuktikan *neural networks* dalam bentuk CNN mampu


mengatasi pengenalan objek yang kompleks dalam skala besar. AlexNet mampu mencapai akurasi klasifikasi yang tinggi pada dataset ImageNet [13]. Berikut arsitektur AlexNet seperti pada Gambar 3.



Gambar 3. Arsitektur AlexNet

ii. Arsitektur GoogLeNet

Arsitektur GoogLeNet bekerja dengan mendeteksi citra (gambar yang diproses) dengan lapisan yang dimiliki mulai dari 5 hingga 22 lapisan namun tetap mempertahankan akurasi yang tinggi [14]. Gambar 4 merupakan arsitektur GoogLeNet yang digunakan.




Gambar 4. Arsitektur GoogLeNet

iii. Arsitektur VGG-16

Sesuai dengan namanya, arsitektur VGG-16 terdiri dari 16 lapisan. Arsitektur ini dikembangkan oleh Karen Simonyan dan Andrew Zisserman yang kemudian


dipublikasikan dalam salah satu paper mereka pada tahun 2014 [15]. Berikut arsitektur VGG16 seperti di Gambar 5.



Gambar 5. Arsitektur VGG-16

iv. Arsitektur ResNet-152

Arsitektur ini dirancang oleh Kaiming He untuk mengatasi masalah penurunan kualitas, dimana disaat *neural networks* semakin dalam diikuti dengan tingkat *error* pada training juga meningkat. Arsitektur ini dapat menyelesaikan masalah tersebut dengan memanfaatkan struktur *residual* yang menjadi masukan pada setiap lapisan [16]. Arsitektur ResNet dapat dilihat pada Gambar 6.



Gambar 6. Arsitektur ResNet

2. 5. Evaluasi Model

Evaluasi model dapat dilakukan dengan beberapa teknik seperti akurasi, *confusion matrix*, *precision*, *recall* dan *F1-Score*.

- i. Model dapat dievaluasi dengan memvisualisasikan grafik akurasi dan *loss* dari proses data pelatihan dan data latih selama beberapa *epoch* yang dilakukan.
- ii. *Confussion* matriks berguna untuk melihat jumlah prediksi yang benar dan yang salah untuk setiap kelas.
- iii. *Precision* (presisi) mengukur seberapa baik model mengklasifikasi data positif yang sebenarnya. Presisi dapat diperoleh dengan Persamaan (1).

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

- iv. *Recall* (Sensitivitas) mengukur seberapa baik model mengidentifikasi data positif yang sebenarnya. *Recall* diformulasikan dengan Persamaan (2).

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

- v. *F1-Score* merupakan rata-rata dari presisi dan *recall*. Nilai ini berguna ketika keseimbangan antara presisi dan *recall* dirasa penting. *F1-Score* dapat diperoleh menggunakan formula pada Persamaan (3).

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

3. HASIL DAN PEMBAHASAN


Dalam penelitian ini program yang kami gunakan untuk melatih dan menguji model CNN serta dataset yaitu bahasa pemrograman python, khususnya kami menggunakan JupyterLab dengan beberapa paket dalam Python yang tujuannya mendeteksi gambar. Paket yang digunakan untuk memodelkan CNN yaitu dari paket TensorFlow dan Keras. Dataset yang digunakan adalah gambar wajah sebagian mahasiswa Magister Matematika angkatan tahun 2023 yang berjumlah 747 gambar unik dengan 15 *label* atau jumlah mahasiswa dengan ukuran gambar $n \times n$ yang bervariasi. Ukuran gambar yang akan dilatih dan diuji disesuaikan berdasarkan dengan arsitektur CNN yang digunakan, umumnya digunakan ukuran $224 \times 224 \times 3$ yaitu ukuran gambar 224×224 piksel dan nilai 3 mengindikasikan warna dari gambar. Ukuran gambar sebagai *input.shape* untuk setiap arsitektur yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1. Perbedaan size ini terjadi karena mengikuti *default template* setiap arsitektur CNN. Sebanyak 747 gambar unik diaugmentasi menjadi 20 gambar yang berbeda seperti pada Gambar 2 untuk setiap gambarnya, sehingga diperoleh 15.687 gambar. Kemudian data latih dan data uji dibagi 85:15 secara berurutan.

Tabel 1. Ukuran *input* gambar setiap arsitektur CNN


<i>Arsitektur CNN</i>	<i>Input Size</i>
AlexNet	$227 \times 227 \times 3$
GoogLeNet	$224 \times 224 \times 3$
VGG-16	$224 \times 224 \times 3$
ResNet-152	$128 \times 128 \times 3$

3. 1. **Arsitektur AlexNet.** Berdasarkan Tabel 1, arsitektur ini memiliki skala ukuran dan warna $227 \times 227 \times 3$. Dari Gambar 7 model yang dilatih terlihat bahwa akurasi model meningkat dan *loss* model menurun seiring dengan bertambahnya epoch. Dengan jumlah epoch 20 akurasi model ini dapat mencapai lebih dari 94%. Gambar 8 memperlihatkan matriks *confusion* dengan ukuran 15×15 yang terlihat bahwa model

dengan arsitektur ini dapat memprediksi atau mendeteksi gambar dengan baik sesuai dengan label yang diberikan. Evaluasi metrik yang digunakan pada model dapat dikatakan baik, dapat dilihat pada Tabel 2.




Gambar 7. Akurasi dan *loss* arsitektur AlexNet untuk setiap epoch




Gambar 8. Matriks *confusion* arsitektur AlexNet

3. 2. **Arsitektur GoogLeNet.** Model arsitektur yang terkenal dengan akurasinya yang sangat tinggi, arsitektur ini memiliki skala input ukuran dan warna $224 \times 224 \times 3$. Dengan jumlah epoch sebanyak 20, model ini dilatih hingga dapat mencapai akurasi lebih dari 99%, dapat dilihat pada Gambar 9 pada epoch ke-4 terjadi penurunan yang besar pada akurasi model dan lonjakan pada *loss* model yang sedang dilatih. Untuk matriks *confusion*-nya dapat dilihat pada gambar 10, dan evaluasi metrik yang digunakan disajikan pada Tabel 2.





Gambar 9. Akurasi dan *loss* arsitektur GoogLeNet untuk setiap epoch




Gambar 10. Matriks *confusion* arsitektur GoogLeNet


3. 3. **Arsitektur VGG-16.** Model arsitektur yang memiliki 152 lapisan. Model yang dilatih ini dapat mencapai akurasi lebih dari 99% pada epoch ke-5, dapat dilihat pada Gambar 11 pada epoch ke-1 sampai ke-5 akurasi model ini bertahan di atas 98%. Untuk matriks *confusion* dapat dilihat pada Gambar 12, dan evaluasi metrik yang digunakan disajikan pada Tabel 2.



Gambar 11. Akurasi dan *loss* arsitektur VGG-16 untuk setiap epoch**Gambar 12. Matriks *confusion* arsitektur VGG-16**

3. 4. **Arsitektur ResNet-152.** Model ResNet-152 dapat mencapai akurasi lebih dari 99% pada epoch ke-5, dapat dilihat pada Gambar 13 pada epoch ke-0 sampai ke-6 akurasi model ini meningkat dari awalnya pada kurang lebih 92% sampai lebih dari 99%. Untuk matriks confusion dapat dilihat pada Gambar 14, dan evaluasi metrik yang digunakan disajikan pada Tabel 2.

**Gambar 13. Akurasi dan *loss* arsitektur ResNet-152 untuk setiap epoch**




Gambar 14. Matriks *confusion* arsitektur ResNet-152

Dapat dilihat pada Gambar 15 arsitektur ResNet-152 diikuti GoogLeNet dan VGG-16 memiliki performa terbaik berdasarkan akurasi klasifikasi gambar keseluruhan. Hasil yang baik dari arsitektur ResNet-152 ini karena model ini dapat menyelesaikan masalah dengan memanfaatkan struktur residual yang menjadi *input* pada setiap layer.

Arsitektur GoogLeNet memiliki performa yang baik disebabkan karena adanya *Batch Normalization*, yaitu suatu metode yang ampuh untuk jaringan pelatihan, dapat mengurangi pergeseran kovariat internal, juga menghilangkan gradien. Hal ini dapat membuat transformasi dari data ke label menjadi lebih stabil. Faktorisasi pada GoogLeNet juga membuat jumlah parameter menjadi lebih sedikit dan mempercepat proses pelatihan, juga menghindari overfitting. Adanya *residual connection*, yang mana kita dapat mentransfer jaringan dengan kedalaman 100 atau lebih lapisan dengan cara yang mudah. Jaringan yang lebih dalam bagus untuk mengekstraksi fitur [17], [18].

Arsitektur VGG-16 membawa peningkatan besar dalam akurasi dan juga peningkatan kecepatan. Hal ini terutama disebabkan oleh peningkatan kedalaman model dan juga pengenalan model yang telah dilatih sebelumnya. Peningkatan jumlah lapisan dengan kernel yang lebih kecil menunjukkan peningkatan non-linearitas yang selalu berdampak positif dalam pembelajaran mendalam.

Untuk arsitektur AlexNet sendiri kedalaman model ini sangat kurang sehingga sulit mempelajari fitur dari kumpulan gambar. Dapat dilihat bahwa dibutuhkan lebih banyak waktu atau epoch untuk mencapai hasil akurasi yang lebih tinggi dibandingkan model-model yang lain.



Gambar 15. *Perfomance* arsitektur CNN berdasarkan Akurasi Model

Tabel 2. Classification Report dari arsitektur CNN yang dilatih

<i>Arsitektur CNN</i>	<i>Akurasi</i>	<i>Presisi</i>	<i>Recall</i>	<i>F1-Score</i>
AlexNet	94,10%	94,24%	94,13%	94,10%
GoogLeNet	99,41%	99,41%	99,41%	99,41%
VGG-16	99,32%	99,37%	99,32%	99,33%
ResNet-152	99,96%	99,96%	99,96%	99,96%

Gambar 16 merupakan hasil pengujian deteksi wajah secara langsung menggunakan arsitektur CNN ResNet-152. Dari gambar terlihat bahwa model ini mampu dengan benar mendeteksi dan mengklasifikasi wajah sesuai dengan label atau orangnya. Adapun wajah yang tak dikenal oleh model artinya gambar wajah yang tak dikenal ini tidak disertakan dalam pelatihan model sehingga model ini tidak dapat mengklasifikasi gambar wajah sesuai dengan label yang dipelajari. Dari hasil ini juga bahwa model mampu mengklasifikasi dengan benar sejalan dengan performa model dan matriks *confusion* arsitektur ResNet-152.

**Gambar 16. Live face recognition menggunakan arsitektur ResNet-152**

4. KESIMPULAN

Berdasarkan hasil pengujian terhadap empat arsitektur *Convolutional Neural Networks* (CNN) untuk meningkatkan akurasi sistem presensi mahasiswa Magister Matematika Universitas Gadjah Mada, diperoleh bahwa arsitektur VGG-16, GoogleNet, AlexNet, dan ResNet-152 secara umum menunjukkan performa yang sangat baik karena memiliki akurasi serta presisi yang sangat tinggi. Pada penelitian ini, ResNet-152 menjadi arsitektur yang terbaik dalam melakukan pengenalan wajah dengan tingkat akurasi 99,96%. Hal ini disebabkan oleh struktur residual dalam ResNet-152 yang memungkinkan jaringan untuk mempelajari fitur lebih dalam tanpa mengalami masalah penurunan kualitas. GoogLeNet dan VGG-16 juga menunjukkan akurasi yang sangat tinggi, masing-masing 99,41% dan 99,32%, di mana arsitektur GoogLeNet memanfaatkan *batch normalization* dan faktorisasi yang mengurangi jumlah parameter serta mempercepat proses pelatihan. Sedangkan VGG-16 yang menggunakan kernel lebih kecil dan memiliki kedalaman model yang lebih baik mampu meningkatkan non-linearitas yang memberikan manfaat positif dalam proses pembelajaran mendalam dalam CNN. Di sisi lain, ditemukan bahwa AlexNet merupakan arsitektur yang membutuhkan banyak waktu atau epoch untuk mencapai hasil akurasi yang memadai. Pada penelitian ini, akurasi Alexnet dalam pengenalan wajah adalah yang terendah yaitu 94,10%.

Merujuk pada hasil temuan penelitian di atas, dapat disimpulkan bahwa arsitektur CNN yang sangat direkomendasikan untuk tugas klasifikasi gambar pada sistem presensi berbasis face recognition adalah ResNet-152, diikuti oleh GoogLeNet, VGG-16, dan yang terakhir adalah AlexNet. Berdasarkan kelebihan-kelebihan dari masing-masing arsitektur yang

digunakan dalam penelitian ini, hal yang sangat penting adalah bagaimana memilih arsitektur CNN yang tepat sesuai kebutuhan spesifik dalam permasalahan klasifikasi gambar. Sementara itu, kajian lanjutan yang dapat dilakukan dari penelitian ini adalah tentang implementasi sistem presensi berbasis face recognition dengan cara menguji pengenalan wajah secara langsung di dalam kelas agar dapat dibuktikan tingkat keefektifan dan efisiensi dari pendekatan ini. Penemuan dan eksplorasi lebih lanjut terhadap arsitektur-arsitektur CNN yang terbaru dalam pengenalan wajah juga sangat direkomendasikan sebagai saran untuk penelitian selanjutnya.

5. REFERENSI

- [1] Vitriani, G. Ali, W. N. Rohman, and M. Novalia, "Perancangan Sistem Informasi Absensi Siswa Menggunakan QR Code Berbasis Web," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 3, no. 5, pp. 523–531, 2023.
- [2] A. H. Fitri and M. F. Adiwisastara, "Perancangan Sistem Informasi Absensi Menggunakan Metode QR Code Berbasis Android Pada CV Adi Bakti Tasikmalaya." 2023. [Online]. Available: <https://repository.bsi.ac.id/>
- [3] N. E. Budiyo and R. Sultonuddin, "Penerapan QR Code pada Presensi Seminar Kerja Praktek Teknik Informatika Unwahas Berbasis Android," *JINRPL*, vol. 3, no. 2, p. 148, Oct. 2021, doi: 10.36499/jinrpl.v3i2.4608.
- [4] M. A. Maulana, S. R. Natasia, D. A. Prambudi, and T. P. Fiqar, "THE DEVELOPMENT OF QR CODE BASED MOBILE ATTENDANCE INFORMATION SYSTEM USING SCRUM FRAMEWORK," *JUTI*, pp. 1–13, Jan. 2022, doi: 10.12962/j24068535.v19i3.a1015.
- [5] P. De Carrera and I. Marqués, "Face Recognition Algorithms," Master's Thesis, Universidad del País Vasco / Euskal Herriko Unibertsitatea, Spain, 2010. [Online]. Available: <https://www.ehu.eus/ccwintco/uploads/e/e8/DeCarrera-Marques.pdf>
- [6] R. E. Saragih and Q. H. To, "A Survey of Face Recognition based on Convolutional Neural Network," *Indonesian J. of Inf. Syst.*, vol. 4, no. 2, Feb. 2022, doi: 10.24002/ijis.v4i2.5439.
- [7] M. Z. Khan, S. Harous, S. U. Hassan, M. U. Ghani Khan, R. Iqbal, and S. Mumtaz, "Deep Unified Model For Face Recognition Based on Convolution Neural Network and Edge Computing," *IEEE Access*, vol. 7, pp. 72622–72633, 2019, doi: 10.1109/ACCESS.2019.2918275.
- [8] A. Wijaya, Joseph Eric Samodra, and Suyoto, "Sistem Presensi Pegawai dengan Face Recognition Menggunakan Deep Learning CNN," *Jurnal Informatika Atma Jogja*, vol. 4, no. 2, pp. 163–168, Nov. 2023, doi: 10.24002/jiaj.v4i2.7660.
- [9] S. Zahrah, A. Azhar, and M. Abdi, "Sistem Deteksi Wajah Untuk Pencatatan Kehadiran Mahasiswa Di Kelas Menggunakan Metode Convolutional Neural Network," *jaise*, vol. 2, no. 1, May 2022, doi: 10.30811/jaise.v2i1.3873.
- [10] R. Z. Fadillah, A. Irawan, and M. Susanty, "Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *Jurnal Informatika*, vol. 8, no. 2, pp. 208–214, 2021.

- [11] B. Raharjo, *Deep Learning dengan Python*. Semarang: Yayasan Prima Agus Teknik, 2022.
- [12] S. Sharma, S. Sharma, and A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," *IJEAST*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.
- [13] S. Lu, S.-H. Wang, and Y.-D. Zhang, "Detection of abnormal brain in MRI via improved AlexNet and ELM optimized by chaotic bat algorithm," *Neural Comput & Applic*, vol. 33, no. 17, pp. 10799–10811, Sep. 2021, doi: 10.1007/s00521-020-05082-4.
- [14] Sofia Saidah, I. P. Y. N. Suparta, and E. Suhartono, "Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit," *JNTETI*, vol. 11, no. 2, pp. 148–153, May 2022, doi: 10.22146/jnteti.v11i2.2739.
- [15] R. A. Jasin and V. L. Santoso, "Pengembangan Arsitektur VGG16 dan DCNN7 pada Convolutional Neural Network dalam Melakukan Klasifikasi Pose Yoga," *justin*, vol. 11, no. 2, p. 314, Jul. 2023, doi: 10.26418/justin.v11i2.55533.
- [16] J. Liang, "Image classification based on RESNET," *J. Phys.: Conf. Ser.*, vol. 1634, no. 1, p. 012110, Sep. 2020, doi: 10.1088/1742-6596/1634/1/012110.
- [17] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 2818–2826. doi: 10.1109/CVPR.2016.308.
- [18] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning," *AAAI*, vol. 31, no. 1, Feb. 2017, doi: 10.1609/aaai.v31i1.11231.