

Klasifikasi Bentuk Wajah Menggunakan Algoritma CNN Dengan Arsitektur DenseNet-201

DOI: <http://dx.doi.org/10.35889/jutisi.v15i1.3448>

Creative Commons License 4.0 (CC BY – NC)

Putri Hasanah^{1*}, Hafiz Irsyad²

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

*e-mail Corresponding Author : putrihasanah30@mhs.mdp.ac.id

Abstract

Face shape classification is an important component in various face recognition-based applications, such as security systems, social media personalization, and style recommendation systems. However, accurate face shape classification remains a challenge due to the complex variations in facial morphological structures, such as oval, square, heart, oblong, and round shapes. This study uses a Convolutional Neural Network (CNN) algorithm with the DenseNet-201 architecture. The collected dataset consists of 5,000 facial images categorized into Oval, Round, Square, Heart, and Oblong, with a data split of 80% for training and 20% for testing. The model was then trained using the DenseNet-201 architecture and evaluated using two different learning rates (0.001 and 0.0001), two batch sizes (16 and 32), and 50 and 100 epochs. The initial results showed a model accuracy of 42%, with a tendency to classify face images as the square category. Subsequently, an additional experiment was conducted, which successfully achieved an accuracy of 89%.

Keywords: Facial shape; Convolutional Neural Network; DenseNet-201; Facial classification

Abstrak

Klasifikasi bentuk wajah merupakan komponen penting dalam berbagai aplikasi berbasis pengenalan wajah, seperti sistem keamanan, personalisasi media sosial, hingga sistem rekomendasi gaya. Namun, pengklasifikasian bentuk wajah secara akurat masih menjadi tantangan karena adanya variasi kompleks dalam struktur morfologi wajah, seperti bentuk oval, persegi, hati, oblong dan bulat. Penelitian ini menggunakan algoritma CNN dengan arsitektur DenseNet-201. Dataset yang dikumpulkan sebanyak 5000 gambar wajah, dengan kategori (Oval, Round (Bulat), Square (Persegi), Heart (Hati), dan Oblong/lonjong), dengan masing-masing proporsi 80% data *Training* dan 20% data *Testing*. Kemudian model dilatih dengan arsitektur DenseNet-201 dan dilakukan uji coba dengan dua nilai *learning rate* yang berbeda 0.001 dan 0.0001, dua ukuran *batch* 16 dan 32, dan *epoch* 50 dan 100. Hasil akurasi model yang di dapatkan sebesar 42% dengan kecenderungan model klasifikasi citra bentuk wajah *square*. Lalu dilakukan eksperimen tambahan yang berhasil mendapatkan akurasi sebesar 89%.

Kata kunci: Bentuk wajah; Convolutional Neural Network; DenseNet-201; Klasifikasi wajah.

1. Pendahuluan

Saat ini, dengan adanya kecerdasan buatan serta teknologi yang berkembang semakin hari bertambah pesat, dan sangat berdampak besar pada bidang pengelolaan citra terkhusus pada klasifikasi dan pengenalan wajah. Hal ini sangat penting diteliti karena pengklasifikasian bentuk wajah secara akurat masih menjadi tantangan dengan adanya variasi kompleks dalam struktur morfologi wajah, seperti bentuk oval, persegi, hati, oblong dan bulat.

Wajah manusia memiliki bentuk yang sangat bervariasi diantaranya meliputi bentuk hati, persegi, oval, bulat dan lain-lain. Setiap masing-masing bentuk wajah tersebut memiliki ciri khas perbedaan baik pada kontur wajah maupun struktur tulang yang mengharuskan menggunakan algoritma yang tepat dalam pengklasifikasian bentuk wajah [1]. Metode manual kurang mampu dalam menangkap berbagai macam fitur yang abstrak dan kompleks. Maka dari itu, tantangan penting yang harus diperhatikan secara teliti adalah pengklasifikasian bentuk wajah secara akurat dan otomatis.

Bersamaan dengan bidang pembelajaran mesin yang semakin berkembang maju, khususnya seperti arsitektur *Convolutional Neural Network* (CNN) dan *deep learning* sudah menjadi pendekatan yang utama dalam pengelolaan citra. *Convolutional Neural Network* (CNN) sendiri tanpa perlu desain fitur manual mampu secara otomatis mengekstraksi fitur dari data citra [2]. *Convolutional Neural Network* (CNN) memiliki beberapa struktur yang memungkinkan mempelajari fitur hierarkis mulai tingkat terendah hingga tingkat tertinggi. Dengan begitu akan membuat kemampuan klasifikasi wajah jadi jauh lebih bagus dibanding metode tradisional. Beberapa struktur tersebut yakni lapisan *fully connected*, *pooling*, dan lapisan konvolusi [3].

Sebagai upaya mengatasi permasalahan di atas, arsitektur *DenseNet* menjadi salah satu solusi yang dapat digunakan dalam menyelesaikan masalah tersebut. Melalui koneksi padat (*DenseNet connectivity*), *DenseNet* bisa menghubungkan semua layer dengan layer sebelumnya secara bersamaan. Sehingga memungkinkan aliran gradien yang menjadi lebih stabil dan transfer fitur yang menjadi semakin efektif [4]. Melalui konsep ini, akan membuat *DenseNet* menjadi lebih mudah dalam meningkatkan efisiensi pelatihan serta meminimalkan kehilangan informasi walaupun menggunakan jaringan yang cukup dalam.

Saat menggunakan *DenseNet-201* untuk mendeteksi wajah baik memakai masker maupun tidak, dapat menghasilkan nilai akurasi baik mencapai 99%. Dengan begitu, ini menjadi bukti khusus yang memungkinkan solusi dalam mengatasi pengenalan wajah dengan kondisi bervariasi dan kompleks adalah dengan menerapkan *DenseNet-201* [5]. Penelitian dengan menggunakan *DenseNet-201* menunjukkan bahwa model konfigurasi tersebut memiliki akurasi 0,96, lebih baik daripada penggunaan optimasi Adam dengan akurasi 0,86 [6].

Melakukan perbandingan kinerja algoritma *Convolutional Neural Network* (CNN) dengan algoritma MLP dalam untuk proses klasifikasi jenis sampah. Dari penelitian tersebut, mendapatkan bahwa performa *Convolutional Neural Network* (CNN) yang lebih baik dimana hasil *precision*, *recall*, *f1-score*, dan *accuracy* sebesar 0,98 dan model *Convolutional Neural Network* (CNN) lebih efektif dalam melakukan klasifikasi sampah berdasarkan kelasnya [7].

Penelitian yang secara khusus bertujuan menangani klasifikasi bentuk wajah, memiliki potensi pemanfaatan yang luas khususnya dalam pengembangan aplikasi yang ditujukan bagi kalangan muda serta platform media sosial. Dengan mempertimbangkan keunggulan arsitektur *DenseNet-201* dalam pengolahan citra wajah, penelitian ini bertujuan untuk mengeksplorasi implementasinya dalam tugas klasifikasi bentuk wajah dengan memanfaatkan dataset citra wajah. Selain itu, penelitian ini juga akan melakukan performa *Convolutional Neural Network* (CNN) dengan arsitektur *DenseNet-201* guna mengidentifikasi sejauh mana peningkatan akurasi dan efisiensi yang dapat dicapai.

2. Tinjauan Pustaka

Pada penelitian ini menunjukan penelitian terdahulu dalam mengklasifikasikan bentuk wajah menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur *DenseNet-201*. Diantaranya seperti penelitian yang dilakukan oleh Prana Pramudita Kusdiananggali, Ema Rachmawati, Risnandar yang membahas tentang Pengenalan Ekspresi Wajah Dari Cross Dataset Menggunakan *Convolutional Neural Network* (CNN) [8]. Arsitektur CNN mengenali ekspresi wajah manusia menggunakan pendekatan cross dataset antara dataset FER2013 (non-Indonesia) sebagai data latih dan dataset buatan sendiri (wajah orang Indonesia) sebagai data uji. Penelitian ini menunjukkan hasil bahwa arsitektur CNN yang dibangun mampu mengenali ekspresi wajah dengan akurasi sebesar 91,29%, *recall* dan *precision* yang sama besar (91,29%), serta total akurasi keseluruhan mencapai 97,51%.

Selain itu, terdapat penelitian yang dilakukan oleh Jasman Pardede, Syafiq Salim Kleb yang berjudul Face Race Classification using ResNet-152 and DenseNet- 121 [9]. Model diuji menggunakan dataset besar dengan evaluasi metrik akurasi, *precision*, *recall*, dan F1-score. Penelitian ini berhasil menunjukan bahwa algoritma *DenseNet-201* dan *ResNet-152* mendapatkan akurasi yang sama yakni sekitar 78.8%, namun *ResNet-152* menunjukkan keunggulan pada metrik F1-score yang lebih tinggi dibanding *DenseNet-121*.

Penelitian lain dilakukan oleh Wayan Widya Premanandara dan Gede Arta Wibawa yang berhasil mengklasifikasi bentuk wajah manusia menjadi bentuk kotak dan bentuk bulat dan mendapatkan hasil berupa akurasi pengujian sebesar 75% [10]. Hasil tersebut mendekati hasil akurasi pelatihan dan pengujian sebesar 81%. Dengan tingkat akurasi yang baik, *Convolutional Neural Network* (CNN) mampu digunakan karena memiliki akurasi yang baik dan umum digunakan di berbagai bidang.

Penelitian lain dilakukan oleh Faisal Dharma Adhinata, Dioviando Putra Rakhmadani, Merlinda Wibowo, Akhmad Jayadi yang berfokus pada deteksi wajah menggunakan masker dan tidak menggunakan masker dengan menggunakan arsitektur *DenseNet-201*. Jumlah parameter model *DenseNet-201* lima kali lebih banyak daripada model *MobileNet V2*. Penelitian ini memperoleh hasil dari beberapa hingga 30 *epoch* menunjukkan bahwa model *DenseNet-201* menghasilkan akurasi 99% saat melatih data [5].

Penelitian selanjutnya dilakukan oleh Geoffrey Edmund Pierre Purba, Satrio Hadi Wijoyo, Nanang Yudi Setiawan. Dengan menggunakan metode Convolutional Neural Network (CNN) khususnya pada arsitektur ResNet50 dan DenseNet-201 dalam pengenalan ekspresi wajah, penelitian ini cukup maksimal dimana model DenseNet-121 yang telah dilatih menggunakan FER-2013 dan telah di finetuning, hingga berhasil mencapai akurasi 78.57% dan model ResNet-50 yang dilatih menggunakan FER-2013 mencapai akurasi 71.42% [11].

Berdasarkan penelitian terdahulu yang dipaparkan, belum ada penelitian yang menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet-201 dalam mengklasifikasikan 5 bentuk wajah yaitu oval, persegi, hati, oblong dan bulat. State of the art dari penelitian ini yaitu berfokus pada klasifikasi bentuk wajah menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet-201 menggunakan dataset 5 bentuk citra wajah yaitu : oval, persegi, hati, oblong dan bulat yang diambil dari Kaggle.

3. Metodologi


Model dibangun melalui proses pelatihan (*training phase*) menggunakan dataset citra wajah yang telah diberi label bentuk wajah yaitu Oval, Round (Bulat), Square (Persegi), Heart (Hati) dan Oblong/lonjong. Dataset terbagi menjadi tiga tahap yakni *training set* (data latih), *validation set* (data validasi) dan *testing set* (data uji). Algoritma *Convolutional Neural Network* (CNN) digunakan untuk mempelajari pola visual pada wajah dari data latih (*training set*). Pada saat proses ini dilakukan, data validasi (*validation set*) dipakai untuk mengevaluasi terhadap performa model pada iterasi pelatihan. Dengan demikian dapat mengurangi resiko *overfitting* serta memantau kemampuan generalisasi. Dalam menyesuaikan *hyperparameter*, dilakukan berdasarkan pada hasil evaluasi data validasi agar mendapatkan konfigurasi model dengan optimal seperti jumlah *learning rate* dan *epoch*. Proses pelatihan dihentikan apabila model mendapatkan performa yang optimal dan stabil pada data validasi (*validation set*). Selanjutnya, model yang sudah dilatih dilakukan pengujian menggunakan data uji baru yang belum pernah digunakan sebelumnya baik pada tahap *training set* maupun *validation set*. Model yang telah diuji ini kemudian digunakan untuk mengklasifikasikan bentuk wajah berdasarkan citra masukan.

3.2 Pengumpulan Dataset

Dalam penelitian ini dilakukan pengumpulan data dengan mengambil gambar jenis bentuk muka yang berbeda yakni, Oval, Round (Bulat), Square (Persegi), Heart (Hati) dan Oblong/lonjong. Dataset didapatkan dari data publik yang diunduh melalui Kaggle's <https://www.kaggle.com/datasets/niten19/face-shape-dataset> Total dataset yang dikumpulkan adalah 5000 gambar wajah, dengan masing-masing kategori (Oval, Round (Bulat), Square (Persegi), Heart (Hati), dan Oblong/lonjong), dengan masing-masing proporsi 80% data *Training* dan 20% Data *Testing*. Selanjutnya foto menjalani proses pra-pemrosesan, seperti penyesuaian ukuran dan pencahayaan, agar data menjadi konsisten sebelum tahap ekstraksi fitur dilakukan. Setelah itu, dataset dibagi sesuai dengan proporsi yang telah ditetapkan untuk melatih model klasifikasi, serta pengujian akhir untuk menilai kinerja sistem dalam mengenali berbagai jenis bentuk wajah secara tepat.

3.3 Perancangan

Pada tahapan ini dilakukan perancangan model klasifikasi bentuk wajah menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur *DenseNet-201*. Untuk tahapan perancangan dapat dilihat pada gambar 1.



Gambar 1. Tahapan Perancangan

1) *Pre-processing*

Setiap gambar kemudian melewati tahap awal pengolahan data atau *Preprocessing* yang mencakup beberapa proses penting yaitu :

- Labeling* : Pada tahapan ini data diberi keterangan pada setiap gambar, tujuannya agar model mengetahui isi gambar tersebut. Pada penelitian ini labeling data dibagi menjadi 5 yaitu : Oval, bulat, lonjong, persegi dan hati.
- Normalisasi : Pada tahapan ini semua piksel gambar dinormalisasikan ke rentang $[0,1]$ untuk memastikan data memiliki skala yang seragam.
- Resize* gambar : Pada tahapan ini semua gambar di *resize* menjadi ukuran 224×224 piksel. Menurut (Karisma & Adhinata, 2023) perlu diubah ukurannya menjadi 224×224 piksel agar dapat diterima oleh arsitektur *Densenet-201* [12].
- Data Augmentasi* : *Data Augmentasi* dilakukan dengan cara rotasi, *flipping horizontal*, dan pergeseran gambar. Hal ini dilakukan untuk meningkatkan variasi data dan mencegah terjadinya *overfitting*.


2) Pembagian Dataset

Setelah itu dataset dibagi secara proporsional yang terdiri dari 80% data *Training* dan 20% *Data Testing*. Semua pembagian ini dilakukan dengan mempertahankan keseimbangan proporsi setiap kategori bentuk wajah pada setiap subset data.

3) *DenseNet-201*

DenseNet adalah salah satu arsitektur dari *Convolutional Neural Network (CNN)* yang digunakan untuk mengatasi masalah gradient pada jaringan. Arsitektur ini diperkenalkan oleh Huang et al. pada tahun 2017. Setiap layer dapat menerima input dari seluruh layer sebelumnya. Akibatnya, fitur yang dipelajari pada layer pertama tetap terjaga dan dapat digunakan kembali oleh layer selanjutnya. Dimana *DenseNet-201* adalah salah satu bagian dari *DenseNet* dengan memiliki layer sebanyak 201 (Huang et al., 2017)[13].


Dengan mempunyai 201 lapisan, *DenseNet-201* yang merupakan Jaringan Saraf Konvolusional *Convolutional Neural Network (CNN)*, masing-masing lapisannya terhubung dengan padan serta dirancang dalam memfasilitasi klasifikasi dan pengenalan gambar dalam deep learning. Kemampuan *DenseNet* untuk menyebarkan informasi dan gradien dengan lebih efisien serta mampu untuk menggunakan kembali fitur secara maksimal, keunggulan utama *DenseNet* dibandingkan dengan struktur *Convolutional Neural Network (CNN)* konvensional lainnya. Yang memungkinkan jaringan untuk belajar secara lebih efektif bahkan dengan jumlah data yang terbatas. Untuk alur *DenseNet-201* dapat dilihat pada gambar 2 berikut:



Gambar 2. Alur DenseNet-201 [12]

Gambar 2 merupakan alur kerja *DenseNet201* dalam proses klasifikasi. Proses dimulai dari input citra setelah itu gambar melalui tahapan *Preprocessing*, dilanjutkan dengan operasi konvolusi menggunakan filter 7×7 dan *stride* 2. Setelah itu, dilakukan *pooling* 3×3 dengan *stride* 2 untuk menghasilkan matriks fitur. Matriks ini kemudian diproses melalui beberapa tahapan, yaitu dense block 1, *transition layer* 1, *denseblock* 2, *transition layer* 2, dan seterusnya hingga *denseblock* 4. Hasil akhir dari *block* ini kemudian diolah melalui *global average pooling* berukuran 7×7 , yang dilanjutkan dengan aktivasi *softmax*. Fungsi aktivasi *softmax* ini berperan sebagai lapisan akhir untuk menentukan hasil klasifikasi pada model *DenseNet-201* [12].

Dalam proses ekstraksi fitur, citra bentuk wajah yang sudah melalui tahapan pra-pemrosesan selanjutnya dimasukkan ke dalam arsitektur *DenseNet-201*. Model ini akan mengenali fitur-fitur dasar wajah seperti tekstur, garis dan tepi pada lapisan konvolusi awal. Setelah itu, *dense block* akan memproses fitur-fitur tersebut dimana seluruh *feature map* dari layer sebelumnya diterima dan digabungkan. Mekanisme yang padat seperti ini akan membuat model mampu menjaga informasi dari berbagai tingkatan fitur baik tingkat tinggi maupun rendah. Hingga membuat detail-detail penting bentuk wajah dapat terjaga selama proses berlangsung. Detail-detail bentuk wajah tersebut yakni seperti proporsi wajah, bentuk dahi dan kontur rahang. Untuk *Denseblock* dapat dilihat pada gambar 3.



Gambar 3. Denseblock [12]

Gambar 3 merupakan tahapan-tahapan yang terjadi dalam lapisan *denseblock* setiap matriks keluaran akan digabungkan karena adanya koneksi langsung antar layer. Semua layer akan menghasilkan *feature map* baru dengan *growth rate* sebesar 32 di dalam setiap *denseblock*. Dengan begitu, 32 *feature map* baru akan ditambahkan pada

setiap layer tanpa menghapus feature map sebelumnya. Melalui pendekatan ini, *DenseNet-201* mungkin akan mempelajari setiap morfologi wajah yang berbeda baik bersifat kompleks maupun halus, seperti perbedaan antara wajah persegi dan bulat atau perbedaan antara bentuk wajah oblong dan oval. Selanjutnya untuk mengurangi dimensi dan kompleksitas data, *feature map* akan diproses oleh *transition layer* setelah melewati satu dense block. Transition layer terdiri dari *batch normalization*, *convolution* 1×1, dan *average pooling*. Yang bertujuan untuk mencegah terjadinya *overfitting* dan meningkatkan efisiensi komputasi [12].

Setelah melewati seluruh *denseblock*, *global average pooling layer* akan memproses fitur wajah yang sudah diekstraksi untuk meringkas informasi fitur menjadi representasi yang lebih singkat. Selanjutnya representasi fitur tersebut dilanjutkan ke *fully connected layer* yang memiliki peran sebagai pengklasifikasi. Di tahapan ini, setiap kelas bentuk wajah seperti oblong, hati, persegi, bulat dan oval akan mendapatkan hasil dari model tersebut. Klasifikasi bentuk wajah akan ditetapkan setelah mendapatkan nilai probabilitas tertinggi.

Dengan menggunakan algoritma optimasi tertentu, *DenseNet-201* akan melakukan pembaruan bobot jaringan berdasarkan nilai *loss function* yang didapatkan selama proses *training* (pelatihan). Agar performa yang didapatkan model dapat optimal maka perlu melakukan proses ini secara berulang-ulang dengan menyesuaikan jumlah *epoch* yang sudah ditentukan. Lalu jika tahap pelatihan sudah dilakukan, pengujian model dengan menggunakan data testing agar dapat mengevaluasi tingkat kemampuan generalisasi model untuk mengklasifikasi bentuk wajah yang sebelumnya tidak dikenali.

4) Model Klasifikasi

Untuk model klasifikasi, arsitektur *DenseNet-201* digunakan, data yang telah dilatih sebelumnya dengan dataset *ImageNet*. Lapisan dasar model dipertahankan untuk memanfaatkan fitur yang sudah dipelajari, sementara lapisan klasifikasi baru dibangun khusus untuk keperluan penelitian ini. Beberapa komponen penting terdiri dari lapisan baru ini termasuk lapisan *pooling* untuk mengurangi dimensi, lapisan padat yang memiliki 512 unit *neuron*, lapisan *dropout* untuk mencegah *overfitting*, dan lapisan *output* yang memiliki lima unit sesuai jumlah kategori klasifikasi.

Uji coba dilakukan dengan dua nilai *learning rate* yang berbeda 0.001 dan 0.0001, dua ukuran *batch* 16 dan 32, dan *epoch* 50 dan 100. Selama pelatihan, kinerja model dilihat melalui nilai *loss* dan akurasi. Evaluasi dilakukan secara komprehensif, tidak hanya melihat akurasi keseluruhan tetapi juga menganalisis performa model pada masing-masing kategori melalui *confusion matrix* dan perhitungan *precision-recall*. *hyperparameter* yang akan diuji list pengujian dapat dilihat pada tabel 1.

Tabel 1. List Pengujian Model

No	Learning Rate	Batch Size	Epoch
1.	0.001	16	50
2.	0.001	32	50
3.	0.0001	16	50
4.	0.0001	32	50
5.	0.001	16	100
6.	0.001	32	100
7.	0.0001	16	100
8.	0.0001	32	100

Kombinasi ini didapatkan dengan cara mengalikan setiap *hyperparameter* yakni *rate* (0.001 dan 0.0001). Untuk *batch size* menggunakan (16 dan 32) dan untuk *Epoch* (50 dan 100). Maka dengan itu, jumlah kombinasi total adalah $2 \times 2 \times 2 = 6$ kombinasi yang akan diuji.

Model dengan kinerja terbaik kemudian diuji menggunakan dataset yang benar-benar baru dan belum pernah dilihat sebelumnya setelah melalui serangkaian pelatihan dan seleksi. Evaluasi dilakukan secara menyeluruh, menilai akurasi total dan menganalisis kinerja model pada masing-masing kategori.

3.3 Implementasi

Pada tahapan ini, model yang telah dirancang sebelumnya diimplementasikan. Ini memungkinkan model untuk mengidentifikasi dan mengklasifikasikan data pelatihan yang telah diolah sebelumnya.

3.4 Pengujian

Pada tahapan ini, pengujian dilakukan dengan menggunakan data uji untuk mengukur performa *metrix* evaluasi, akurasi, presisi, *recall*. *Confusion metrix* digunakan untuk mengukur mengenali model dari masing-masing gambar bentuk wajah. Jika model sudah menunjukkan performa yang baik. Adapun rumus untuk menghitung akurasi model CNN sebagai berikut:

1) Akurasi

Akurasi adalah metrik yang menunjukkan tingkat keakuratan model dalam melakukan klasifikasi secara keseluruhan. Melalui akurasi, seluruh data yang diuji akan diukur sesuai proporsi jumlah prediksi yang benar.

2) Presisi

Presisi adalah metrik yang menunjukkan tingkat keakuratan model dalam melakukan prediksi kelas positif. Melalui presisi, data akan diukur sesuai seberapa besar proporsi yang diprediksi sebagai data positif.

3) Recall

Recall adalah metrik yang menunjukkan kesanggupan model dalam mendeteksi semua data yang termasuk sebagai kelas positif. Melalui *recall*, semua data positif diukur setelah berhasil diklasifikasikan oleh model dengan benar. Akurasi, presisi dan recall dirumuskan sebagai berikut [14]:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

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

Keterangan :

TP = *True Positive* (Benar mengklasifikasikan kelas positif)

TN = *True Negative* (Benar mengklasifikasikan kelas negatif)

FP = *False Positive* (Salah mengklasifikasikan kelas positif)

FN = *False Negative* (Salah mengklasifikasikan kelas negatif)

4. Hasil dan Pembahasan

4.1 Hasil

1) Pre-processing

pengumpulan data gambar dengan jenis bentuk muka yang diambil yakni, Oval, Round (Bulat), Square (Persegi), Heart (Hati) dan Oblong/lonjong. Dataset didapatkan dari data publik yang diunduh melalui *Kaggle's* <https://www.kaggle.com/datasets/niten19/face-shape-dataset> total dataset yang dikumpulkan adalah 5000 gambar wajah dengan masing-masing kategori (Oval, Round (Bulat), Square (Persegi), Heart (Hati), dan Oblong/lonjong). Untuk gambar dataset wajah dapat dilihat pada gambar 4.

Sempel data awal



Gambar 4. Dataset Wajah

Gambar 4 merupakan *dataset* citra bentuk wajah yang digunakan pada penelitian ini yang berisi 5 bentuk wajah yaitu : oval, persegi, hati, oblong dan bulat. Dataset ini akan digunakan untuk melatih dan menguji model dalam klasifikasi bentuk wajah. Selanjutnya foto menjalani proses pra-pemrosesan seperti penyesuaian ukuran dan pencahayaan, agar data menjadi konsisten sebelum tahap ekstraksi fitur dilakukan. Setelah itu, dataset dibagi sesuai dengan proporsi yang telah ditetapkan untuk melatih model klasifikasi, serta pengujian akhir untuk menilai kinerja sistem dalam mengenali berbagai jenis bentuk wajah secara tepat.

2) *Resize Dataset*

Selanjutnya, gambar diseragamkan dengan dilakukan *resize* menjadi 224x224 px. Dalam penelitian ini *resize* dataset gambar dilakukan dengan menggunakan kode yang digunakan sebelum training model.

3) *Pembagian Dataset*

Setelah itu dataset dibagi secara proporsional yang terdiri dari 80% data *Training* dan 20% Data *Testing*. Semua pembagian ini dilakukan dengan mempertahankan keseimbangan proporsi setiap kategori bentuk wajah pada setiap subset data.


4) *Training Model*

Setelah itu dataset dilatih dengan menggunakan data latih. Pada tahapan ini model CNN dengan arsitektur *Densenet-201* yang digunakan untuk mengenali pola dan karakteristik gambar 5 bentuk wajah yang telah disediakan. Kemudian model dilatih dengan cara di *input* ke dalam algoritma CNN dengan arsitektur *Densenet-201*, data yang di masukkan merupakan data yang sudah melalui *processing*, sudah diberi label dan sudah dilakukan *resize images*. Data yang digunakan memiliki 5 kelas, yaitu kategori Oval, Bulat, Persegi, Hati, dan Oblong. Kemudian, uji coba dilakukan dengan dua nilai *learning rate* yang berbeda 0.001 dan 0.0001, dua ukuran *batch* 16 dan 32, dan *epoch* 50 dan 100. Selama pelatihan, kinerja model dilihat melalui nilai *loss* dan akurasi. Hasil list pengujian model dapat dilihat pada tabel 2.

Tabel 2. Hasil List Pengujian Model

No	Learning Rate	Batch Size	Epoch	Accuracy	Precision	Recall	F1-Score
1.	0.001	16	50	0.31	0.46	0.31	0.26
2.	0.001	32	50	0.39	0.46	0.39	0.36
3.	0.0001	16	50	0.33	0.47	0.33	0.28
4.	0.0001	32	50	0.32	0.43	0.32	0.27
5.	0.001	16	100	0.42	0.44	0.42	0.40
6.	0.001	32	100	0.41	0.47	0.41	0.38
7.	0.0001	16	100	0.36	0.46	0.36	0.32
8.	0.0001	32	100	0.35	0.45	0.35	0.31

Setelah dilakukan 8x pengujian didapat hasil akurasi training dan validasi loss terbaik menggunakan *Learning rate* 0.001 dengan ukuran *Batch size* 16 dan *Epoch* 100 dengan Tingkat akurasi mencapai 42%. Hasil dari training validasi loss dapat dilihat pada gambar 5.

Gambar 5. Grafik *Training dan Validation Accuracy*

Grafik menunjukkan peningkatan sebesar 50% hingga kurang lebih 76% pada data *training accuracy* dengan penurunan *training loss* dari 1.2 menjadi 0.6, akan tetapi ketika dilakukan pengujian pada data validasi performanya hanya berada di kisaran 35% hingga 42% yang tidak menunjukkan peningkatan. Terdapat ketidakstabilan pada *validation loss* yang cenderung tinggi berada pada 1.4 hingga 2.0. Hal ini terjadi akibat model mengalami *overfitting* yang dimana model terlalu menghafal data *training* sehingga tidak mampu mengenali pola baru pada data validasi.

5) Testing

Setelah dilakukan pelatihan pada model, tahapan selanjutnya yaitu pengujian dengan menggunakan data uji sebanyak 1000 data. Visualisasi hasil dari *testing model* dapat dilihat menggunakan *confusion Matrix* dan *classification report* yang dapat dilihat pada gambar 6.

Confusion Matrix:

```
[[ 39  23  16  43  79]
 [ 11  74  16  29  70]
 [  7  11  36  49  97]
 [  2   4  10 110  74]
 [  5   5   3  29 158]]
```

Classification Report:

	precision	recall	f1-score	support
Heart	0.61	0.20	0.30	200
Oblong	0.63	0.37	0.47	200
Oval	0.44	0.18	0.26	200
Round	0.42	0.55	0.48	200
Square	0.33	0.79	0.47	200
accuracy			0.42	1000
macro avg	0.49	0.42	0.39	1000
weighted avg	0.49	0.42	0.39	1000

Gambar 6. Performa Hasil Pengujian Model

Hasil *testing model* pada *confusion matrix* dan *classification report* hanya mencapai akurasi sebesar 42% yang menunjukkan klasifikasi dari model ini benar dengan akurasi 42% dari jumlah data pengujian dengan total 1000 gambar. Beberapa bentuk wajah memiliki performa yang terbilang rendah saat dilihat dari masing-masing kelasnya. Seperti bentuk *Heart* dengan *recall* sebesar 20% serta bentuk *Oval* dengan hasil *f1-score* sebesar 26% dan *recall* sebesar 18%. Selain itu, hasil *recall* yang tertinggi dimiliki oleh kelas *Square* yakni sebesar 79%, tetapi hanya memiliki *precision* sebesar 33%, hal ini dapat disimpulkan bahwa prediksi *Square* yang sebenarnya banyak salah. Selanjutnya, nilai yang didapatkan *macro average f1-score* Adalah sebesar 39%, hal ini menunjukkan bahwa dalam mengenali semua kelas rata-rata model ini masih terbilang rendah. Jika dilihat dari grafik *training-validation*, hasilnya masih sejalan dengan indikasi *overfitting* yang sebelumnya. Dapat disimpulkan bahwa dalam mengenali pola yang terdapat pada bentuk wajah masih terlihat belum mampu serta arsitektur model dan data memerlukan perbaikan.



Gambar 7. Sempel data yang dikenali

Sempel data ini dapat dengan akurat dikenali oleh model dimana menghasilkan akurasi di tingkat yang lebih baik. Data ini berhasil akurat karena posisi gambar fokus menghadap ke depan. Selain itu, kualitas kecerahan gambar juga berpengaruh terhadap kerja model yang lebih akurat.




Gambar 8. Sempel data yang tidak dikenali

Sempel data tidak dapat dikenali dikarenakan model kesulitan membaca bentuk wajah dengan posisi yang tidak simetris menghadap ke depan serta tingkat kecerahan pada gambar rendah. Hal ini sangat berpengaruh terhadap tingkat akurasi yang dihasilkan.

4.2 Analisa

Hasil Analisa pengujian ini menjelaskan bahwa model mengalami *overfitting*, dimana terdapat perbedaan-perbedaan antara *validation accuracy* yang hanya berkisaran 25% hingga 42% dan *training accuracy* yang berada sekitar 76%, serta *validation loss* yang berada tinggi sekitar 1,4 sampai 2,0 sedangkan *training loss* turun mencapai 0,6. Disamping itu, nilai akurasi saat pengujian mendapatkan hasil sebesar 42% dimana nilai *f1-score* rata-rata sebesar 0,39, dengan demikian dapat disimpulkan bahwa masih belum kosnsiten dalam klasifikasi bentuk wajah. Model juga bekerja antar kelas masih tidak merata seperti contoh kelas Oval yang hanya memiliki recall sebesar 18% sehingga sulit untuk dikenali sedangkan kelas *Square* mempunyai *recall* sebesar 79% yang berarti banyak bentuk wajah ditebak sebagai kelas ini. Penyebab performa ini rendah salah satunya dikarenakan dataset yang digunakan dari segi kualitasnya belum ideal. Kurang ideal yang dimaksud seperti contoh gambar dataset yang digunakan tidak presisi menghadap ke depan, kurang pencahayaan serta gambar bentuk wajah banyak yang buram. Kondisi ini yang membuat model sering kali salah menebak bahkan kesulitan dalam membedakan bentuk wajah secara akurat. Model hanya valid untuk wajah menghadap frontal dan tidak dapat digeneralisasikan untuk kondisi *in-the-wild*.

Setelah dilakukan seleksi data input yang arah gambar wajah menghadap ke depan dengan menggunakan uji coba dengan nilai *learning rate* 0.001, ukuran *batch* 16, dan *epoch* 50. Selama pelatihan didapatkan peningkatan akurasi yang cukup tinggi. Untuk *training model* dan *testing model* dapat dilihat pada gambar 9 dan 10.



Gambar 9. *Training Model*

Analisis di atas menunjukkan hasil setelah proses pelatihan pada model dengan data *input* yang sudah secara khusus terseleksi yakni hanya pada data wajah menghadap ke depan. Tujuan seleksi data ini adalah agar memastikan model dapat mendapat data dengan konsisten. Dengan kualitas gambar yang baik, model akan lebih mudah dan jelas dalam mempelajari bentuk wajah tanpa pengaruh pose atau variasi sudut. Setelah data homogen seperti ini, dapat dilihat dari grafik *validation* dan *training accuracy* dengan mengalami peningkatan secara konsisten sekitar 90%, dimana kedua kurva yang tidak menunjukkan *overfitting* dan saling berdekatan. Hal ini menunjukkan bahwa model ini mampu mempelajari data dengan lebih stabil. Disamping itu, proses latihan juga berjalan efektif yang ditunjukkan grafik *loss* pada kedua data menurun secara stabil.

Confusion Matrix:				
[[106	0	1	3	8]
[2	87	2	0	9]
[3	0	76	8	13]
[2	0	0	94	2]
[2	1	0	1	99]]

Classification Report:				
	precision	recall	f1-score	support
Heart_crop	0.92	0.90	0.91	118
Oblong_crop	0.99	0.87	0.93	100
Oval_crop	0.96	0.76	0.85	100
Round_crop	0.89	0.96	0.92	98
Square_crop	0.76	0.96	0.85	103
accuracy			0.89	519
macro avg	0.90	0.89	0.89	519
weighted avg	0.90	0.89	0.89	519

Gambar 10. Testing Model

Testing model dari *classification report* dan *confusion matrix*, nilai *f1-score*, *recall* dan *precision* berkisaran rata-rata 85% hingga 93%. Dapat disimpulkan bahwa model ini memberikan performa yang baik pada semua kelas. Model ini mampu melakukan klasifikasi pada bentuk wajah dengan ketepatan yang tinggi hingga akurasi keseluruhannya mencapai 89%. Hasil dari seleksi data yang dilakukan dapat meningkatkan model belajar dalam mengenali pola bentuk wajah.

4.3 Pembahasan

Penelitian ini mengindikasikan bahwa pendekatan CNN dengan arsitektur *DenseNet-201* mampu mengklasifikasikan citra bentuk wajah. Pengujian pada penelitian ini dilakukan sebanyak 8 kali. Setelah dilakukan pengujian, didapatkan hasil akhir dari akurasi tertinggi yakni sebesar 42%. Akurasi ini terbilang masih kecil dan perlu perbaikan terhadap dataset yang digunakan. Setelah dievaluasi, peneliti mendapatkan akurasi kecil dikarenakan dataset yang digunakan tidak merata alias masih perlu dipilah agar mudah terbaca oleh arsitektur *DenseNet-201*.

Setelah evaluasi terhadap dataset yang akan digunakan, peneliti kemudian memilah data-data untuk dilakukan pengujian dengan ketentuan dan posisi yang tepat sebagai eksperimen tambahan. Dataset dipilah dengan menyesuaikan posisi bentuk wajah menghadap jelas kedepan dengan tujuan arsitektur *DenseNet-201* dapat membaca data dengan baik dan akurat. Model hanya valid untuk wajah menghadap *frontal* dan tidak dapat digeneralisasikan untuk kondisi *in-the-wild*. Hasil dari eksperimen tambahan ini menunjukkan akurasi yang sangat baik hingga mencapai 89%. Dengan demikian, arsitektur *DenseNet-201* mampu digunakan dalam mendeteksi bentuk wajah dengan baik dan akurat.

Penelitian ini memiliki keterkaitan dengan penelitian yang dilakukan oleh (Mahardika Yoshi Putra, 2024) [2] yang memberikan keakuratan dengan presentase akurasi mencapai 85%. Pada penelitian ini, disampaikan bahwa metode *Convolutional Neural Network (CNN)* dengan *Optimizer Adam* untuk menentukan gaya model rambut laki-laki dan bentuk wajah, ada 4 bentuk wajah yang dideteksi adalah Oval, Kotak, Persegi Panjang, dan Bulat. Sedangkan penelitian yang akan dilakukan menggunakan metode *Convolutional Neural Network (CNN)* dengan arsitektur *DenseNet-201* untuk klasifikasi 5 bentuk wajah yaitu : oval, persegi, hati, oblong dan bulat. Pada penelitian ini, arsitektur *DenseNet-201* mampu menunjukkan hasil yang baik dan cocok untuk digunakan dalam mengklasifikasi bentuk wajah.

Dalam mengembangkan pengklasifikasian model wajah menggunakan beberapa bentuk seperti oval, persegi, hati, oblong dan bulat, temuan pada penelitian ini berada pada posisi penting. Walaupun hasil dari akurasi yang didapatkan masih belum melebihi hasil dari penelitian (Premanandara & Wibawa, 2022) [10], (Adhinata et al., 2021) [5] dan (Khaliqah et al., 2024) [15]. Pengembangan dan kontribusi utamanya berfokus pada pengklasifikasian model wajah dengan menggunakan beberapa bentuk seperti oval, persegi, hati, oblong dan bulat.

Penelitian ini memperluas kajian pada pengklasifikasian bentuk wajah menggunakan algoritma *Convolutional Neural Network (CNN)* dengan arsitektur *DenseNet-201*, dengan memfokuskan pada pengklasifikasian bentuk wajah seperti oval, persegi, hati, oblong dan bulat. Tantangan utama yang dihadapi yakni bentuk wajah masing-masing orang yang beragam dan kualitas dari masing-masing gambar seperti pencahayaan dan resolusi. Penelitian ini menemukan bahwa masih perlunya penyesuaian terhadap data yang akan digunakan dalam

mengklasifikasikan bentuk wajah menggunakan algoritma *Convolutional Neural Network (CNN)* dengan arsitektur *DenseNet-201*. Seperti peningkatan kualitas pencahayaan dan resolusi, posisi gambar yang jelas menghadap ke depan serta peningkatan jumlah dataset yang digunakan saat pengujian.

5. Simpulan

Penelitian ini menggunakan algoritma *Convolutional Neural Network (CNN)* dengan arsitektur *DenseNet-201* dalam mengklasifikasikan bentuk wajah. Dengan pengujian yang dilakukan hingga 8 kali, hasil akhir dari akurasi yang didapatkan tertinggi hanya mencapai 42%. Dengan begitu, akurasi ini terbilang masih sangat kecil dan perlu dilakukan evaluasi. Evaluasi dilakukan dengan memilah dataset yang lebih baik dan akurat serta jelas menghadap ke depan sebagai eksperimen tambahan dalam penelitian ini. Eksperimen tambahan tersebut menghasilkan akurasi yang cukup baik sebesar 89%. Akurasi ini dapat disimpulkan bahwa algoritma *Convolutional Neural Network (CNN)* dengan menggunakan arsitektur *DenseNet-201* dalam mengklasifikasikan bentuk wajah mampu mencapai akurasi yang baik dan akurat.

Model ini saat bekerja dipengaruhi beberapa faktor seperti dataset yang bervariasi, bentuk wajah yang tidak sesuai baik dari pencahayaan maupun resolusinya, dan posisi gambar yang tidak menghadap ke depan dengan jelas. Beberapa hal tersebut sangat mempengaruhi performa arsitektur *DenseNet-201* dalam bekerja. Untuk penelitian berikutnya disarankan agar menggunakan dataset dengan posisi wajah menghadap jelas ke depan dan menyesuaikan gambar dengan tingkat pencahayaan dan resolusi yang baik.

Daftar Referensi

- [1] S. Sohail, G. Anjum, and M. Aziz, "Hijab and encloded cognition: The effect of hijab on interpersonal attitudes in a homogenous Muslim-majority context," *Cogent Psychol.*, vol. 10, no. 1, pp. 1–19, 2023, doi: 10.1080/23311908.2023.2219084.
- [2] M.Y. Putra, "Rancang Bangun Deteksi Bentuk Wajah Untuk Menentukan Gaya Rambut Menggunakan Algoritma CNN," *Repeater Publ. Tek. Inform. dan Jar.*, vol. 2, no. 3, pp. 206–212, 2024, doi: 10.62951/repeater.v2i3.139.
- [3] A. E. D. Tio, "Face shape classification using Inception v3," 2019. doi: 10.48550/arXiv.1911.07916.
- [4] P. Chao, C. Y. Kao, Y. Ruan, C. H. Huang, and Y. L. Lin, "HarDNet: A low memory traffic network," in *Proceedings of the IEEE International Conference on Computer Vision*, 2019, pp. 1–10. doi: 10.1109/ICCV.2019.00365.
- [5] F. D. A. D. P. R. M. Wibowo and A. Jayadi, "A Deep Learning Using DenseNet201 to Detect Masked or Non-masked Face," *JUITA J. Inform.*, vol. 9, no. 1, pp. 115–122, 2021, doi: 10.30595/juita.v9i1.9624.
- [6] A. J. M. F. Novriandy, B. Rahmat, "Klasikasi Citra Pada Penyakit Kanker Mulut Menggunakan Arsitektur Densenet201 Menggunakan Optimasi Adam Dan Sgd," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 4, pp. 6132–6140, 2024, doi: 10.36040/jati.v8i4.10077.
- [7] K. L. Kohsasih, M. D. Agung Rizky, T. Fahriyani, V. Wijaya, and R. Rosnelly, "Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah," *J. TIMES*, vol. 10, no. 2, pp. 22–28, 2022, doi: 10.51351/jtm.10.2.2021655.
- [8] R. P. P. Kusdiananggalih, E. Rachmawati, "Pengenalan Ekspresi Wajah Dari Cross Dataset Menggunakan Convolutional Neural Network (CNN)," *J. Tugas Akhir Fak. Inform.*, vol. 8, no. 2, pp. 3429–3445, 2021.
- [9] S. S. K. JASMAN PARDEDE and Department, "Face Race Classification using ResNet-152 and DenseNet- 121," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 12, no. 3, pp. 798–809, 2024, doi: 10.26760/elkomika.v12i3.798.
- [10] I. W. W. Premanandara and I. G. A. Wibawa, "Klasifikasi Bentuk Wajah Manusia Menggunakan Metode Convolutional Neural Network (CNN)," *J. Nas. Teknol. Inf. dan Apl. Klasifikasi*, vol. 1, no. 1, pp. 373–378, 2022.
- [11] G. E. P. Purba, S. H. Wijoyo, and N. Y. Setiawan, "Pengaruh Transfer Learning Resnet Dan Densenet Terhadap Performa Klasifikasi Ekspresi Wajah Menggunakan Dataset Fer-2013," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 1, pp. 1–9, 2017, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [12] R. A. Karisma and F. D. Adhinata, "Transfer Learning with Densenet201 Architecture Model for Potato Leaf Disease Classification," *ICCoSITE 2023 - Int. Conf. Comput. Sci. Inf.*

- Technol. Eng. Digit. Transform. Strateg. Facing VUCA TUNA Era*, pp. 738–743, 2023, doi: 10.1109/ICCoSITE57641.2023.10127772.
- [13] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017, pp. 1–9. doi: 10.1109/CVPR.2017.243.
- [14] S.D. Chandra, H. Oktavianto, and A.K. Wardoyo, “Klasifikasi Malware Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Website,” *J. Penelit. Teknol. Inf. dan Sains*, vol. 2, no. 2, pp. 84–99, 2024, doi: 10.54066/jptis.v2i2.1931.
- [15] M. Khaliqah, L. Sarifah, and S. Khotijah, “Implementasi Algoritma K-Nearest Neighbor (K-NN) dalam Mengklasifikasikan Berbagai Jenis Ekspresi Wajah Manusia,” *Zeta - Math J.*, vol. 9, no. 1, pp. 10–20, 2024, doi: 10.31102/zeta.2024.9.1.10-20.