

Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network (CNN)

M. Iqbal Maulana¹, Khurotul Aeni², Fathulloh³

^{1,2,3}Program Studi Informatika, Fakultas Sains dan Teknologi, Universitas Peradaban
akaisulimam@gmail.com, khaeni988@gmail.com, fathul.peradaban@gmail.com
Jl. Raya Pagojengan Km 3 Paguyangan, Brebes, Jawa Tengah 52276

Keywords:

Facial Expression Recognition, Machine Learning, Deep Learning, Convolutional Neural Network, Dataset.

ABSTRACT

Facial expression recognition has become an interesting research topic in the fields of pattern recognition and image processing. In this research, we propose the use of Convolutional Neural Network (CNN) for effective and accurate facial expression recognition. In the initial stage, we collected a dataset that includes a variety of facial expressions, including happy, sad, angry, afraid, surprised, and neutral. The proposed CNN architecture consists of convolution layers, pooling layers, and fully connected layers. We use the ReLU activation function in the convolutional and fully connected layers, and use the dropout method to prevent overfitting. Experimental results show that the use of CNN in facial expression recognition produces good results. In conclusion, this research shows that Convolutional Neural Network (CNN) can be an effective approach in facial expression recognition. This research contributes to the development of facial expression recognition technology that can be applied in various applications such as emotion recognition, identity recognition, and more intuitive human-machine interactions.

Kata Kunci:

Pengenalan Ekspresi Wajah, Machine Learning, Deep Learning, Convolutional Neural Network, Dataset.

ABSTRAK

Pengenalan ekspresi wajah telah menjadi topik penelitian yang menarik dalam bidang pengenalan pola dan pengolahan citra. Dalam penelitian ini, kami mengusulkan penggunaan *Convolutional Neural Network* (CNN) untuk pengenalan ekspresi wajah yang efektif dan akurat. Pada tahap awal, kami mengumpulkan *dataset* yang mencakup berbagai ekspresi wajah, termasuk bahagia, sedih, marah, takut, terkejut, dan netral. Arsitektur CNN yang diusulkan terdiri dari lapisan konvolusi, lapisan *pooling*, dan lapisan *fully connected*. Kami menggunakan fungsi aktivasi ReLU pada lapisan konvolusi dan *fully connected*, serta menggunakan metode *dropout* untuk mencegah *overfitting*. Hasil eksperimen menunjukkan bahwa penggunaan CNN dalam pengenalan ekspresi wajah memberikan hasil yang baik. Kesimpulannya, penelitian ini menunjukkan bahwa *Convolutional Neural Network* (CNN) dapat menjadi pendekatan yang efektif dalam pengenalan ekspresi wajah. Penelitian ini memberikan kontribusi dalam pengembangan teknologi pengenalan ekspresi wajah yang dapat diterapkan dalam berbagai aplikasi seperti pengenalan emosi, pengenalan identitas, dan interaksi manusia-mesin yang lebih intuitif.

PENDAHULUAN

Perkembangan ilmu teknologi saat ini semakin pesat, apalagi dengan adanya kehadiran kecerdasan buatan atau biasa kita kenal *Artificial Intelligence* (AI). *Artificial Intelligence* (AI) atau kecerdasan buatan merupakan bidang ilmu komputer yang berfokus pada pengembangan komputer

atau mesin yang dapat melakukan tugas-tugas yang membutuhkan kecerdasan manusia. AI mencakup pengembangan algoritma dan model komputasional yang memungkinkan sistem untuk mempelajari, merencanakan, memecahkan masalah, dan mengambil keputusan berdasarkan data atau informasi yang ada[1]. Dalam penelitian pengenalan ekspresi wajah, AI dan *deep learning* bekerja sama untuk mengembangkan model dan algoritma yang mampu mengenali dan mengklasifikasikan ekspresi emosi secara akurat dan efisien. *Deep learning* menjadi komponen kunci dalam penggunaan AI dalam pengenalan ekspresi wajah karena kemampuannya dalam mempelajari fitur-fitur kompleks dan menghasilkan hasil yang tinggi dalam tugas tersebut.

Deep learning adalah subbidang dari *machine learning* yang menggunakan *neural networks* dengan banyak lapisan (*layers*) yang disebut jaringan syaraf (*neural network*) dalam upaya untuk memodelkan dan mempelajari pola-pola yang kompleks. *Deep learning* terinspirasi oleh struktur dan fungsi otak manusia, dimana setiap lapisan dalam jaringan syaraf tiruan bertanggung jawab untuk pemrosesan fitur-fitur yang semakin kompleks secara bertingkat. Perbedaan utama antara *deep learning* dan *machine learning* tradisional terletak pada kedalaman (*depth*) dan kompleksitas *model* yang digunakan dalam *deep learning*. *Deep learning* mampu mempelajari representasi yang semakin abstrak dan kompleks dari data dengan menggunakan banyak lapisan. Ini memungkinkan sistem untuk mengenali objek dalam gambar, mengenali ucapan dalam suara, menerjemahkan teks dengan lebih baik dan menciptakan konten visual baru seperti gambar dan musik[2].

Convolutional Neural Network (CNN) adalah jenis arsitektur *neural network* yang di desain khusus untuk memproses data citra dan memiliki kemampuan untuk mengekstraksi fitur-fitur penting dari citra. CNN terdiri dari beberapa *layer*; *layer konvolusi*, *layer pooling*, dan *layer fully connected*, yang memungkinkan jaringan ini untuk belajar secara hierarkis dan mengenali pola visual yang kompleks. CNN adalah pengembangan dari *multilayer perceptron* (MLP) yang termasuk dalam *neural network* bertipe *feed forward*. *Convolutional Neural Network* adalah *neural network* yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *deep neural network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN digunakan untuk menganalisis citra visual, mendeteksi dan mengenali objek pada *image*, yang merupakan vektor berdimensi tinggi yang akan melibatkan banyak parameter untuk mencirikan jaringan. Secara garis besar, CNN tidak terlalu jauh berbeda dengan *neural network* biasa. CNN terdiri dari *neuron* yang memiliki *weight*, *bias* dan *activation function*. [2].

Ekspresi wajah merupakan perubahan bentuk raut muka wajah dalam menanggapi keadaan, perasaan niat dan komunikasi sosial seseorang. Perwujudan pada wajah manusia secara tidak langsung memberi ungkapan akan suatu bentuk perasaan, keinginan, serta tujuan tertentu. Setiap mimik wajah memiliki pemaknaan yang dapat terbaca oleh orang lain, maka melalui mimik wajah dapat diketahui apa yang sedang terjadi dan bagaimana perasaan seseorang[4]. Dalam deteksi ekspresi wajah, terdapat sejumlah tantangan yaitu posisi bentuk wajah, skala, ekspresi, wajah yang terhalang objek lain, dan kondisi pencahayaan yang kurang. Ekspresi wajah adalah salah satu bentuk komunikasi non-verbal yang merupakan hasil dari satu atau lebih gerakan posisi otot pada wajah serta dapat menyampaikan keadaan emosi seseorang kepada orang yang mengamatinya. Ekspresi wajah menyumbang 55% dalam penyampaian pesan, sedangkan bahasa dan suara masing-masing menyumbang 7% dan 38%. Pengenalan ekspresi wajah merupakan topik penelitian yang penting dalam bidang pengenalan pola dan pengolahan citra[5]. Pengenalan ekspresi wajah melalui piksel dapat dilakukan dengan menggunakan metode CNN. Dimana fitur wajah dapat ditemukan melalui serangkaian proses konvolusi yang dilakukan pada citra. Hal ini tentunya berbeda dengan penggunaan ekstraksi fitur lainnya dimana harus menentukan bentuk ekstraksi fitur apa yang dapat menjelaskan objek (wajah)[6]. Pengenalan ekspresi wajah sering dikaitkan dengan emosi. Pada bidang *marketing*, kepuasan pelanggan terhadap pelayanan penting untuk diperhatikan oleh perusahaan. Salah satu indikator yang dapat menunjukkan kepuasan pelanggan terhadap pelayanan adalah ekspresi wajah atau emosi pelanggan. Dengan adanya pengenalan ekspresi wajah, perusahaan telah dibukakan peluang untuk meningkatkan tingkat loyalitas pelanggan terhadap perusahaan. Oleh karena itu, penulis tertarik untuk membangun sistem pengenalan ekspresi wajah dengan menggunakan metode *convolutional neural network*.

Selain *convolutional neural network*, ada metode lain yang digunakan untuk pengenalan wajah yaitu metode *K-Nearest Neighbors* (K-NN). Diantaranya penelitian yang dilakukan oleh

Kosasih pada tahun 2020 dengan menggunakan K-NN. Penelitian ini menggunakan citra wajah yang terdiri dari 6 orang, tiap orang memiliki 4 citra wajah dengan ekspresi yang berbeda-beda. Data citra ini dibagi menjadi dua bagian yaitu data latih dan data uji. Selanjutnya, data citra tersebut diubah menjadi vektor. Metode *isomap* digunakan untuk mentransformasikan vektor tersebut menjadi vektor yang mengandung fitur wajah. Setelah fitur wajah diperoleh, selanjutnya dilakukan pengujian pada data uji dengan menggunakan algoritma K-NN. Algoritma K-NN digunakan untuk pengklasifikasian dengan cara mencari K data latih yang terdekat dengan data uji. Dari hasil klasifikasi diperoleh bahwa tingkat akurasi sebesar 83,33%[8]. K-NN adalah metode yang sederhana dan mudah dipahami. K-NN melibatkan proses pembelajaran yang kompleks seperti CNN. Namun, K-NN cenderung kurang efisien dalam mengatasi dimensi tinggi dan keberadaan fitur-fitur yang tidak relevan. CNN memiliki keunggulan dalam mengenali fitur-fitur spasial dan menghasilkan representasi yang lebih abstrak dari wajah, sementara K-NN lebih sesuai untuk pengenalan ekspresi wajah dalam skala yang lebih kecil atau ketika data pelatihan terbatas. Namun dalam CNN, seperti *model deep learning* lainnya, memiliki kelemahan yaitu proses komputasi *model* yang cukup lama. Tetapi dengan perkembangan *hardware* yang semakin pesat, hal tersebut dapat diatasi menggunakan teknologi *graphical processing unit* (GPU) dan PC yang memiliki spesifikasi tinggi.

Berdasarkan latar belakang diatas, penulis memutuskan untuk melakukan penelitian yang berjudul “**Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network (CNN)**”. Pada penelitian ini berfokus terhadap bagaimana cara mengimplementasikan algoritma CNN untuk mengidentifikasi jenis citra ekspresi wajah seperti bahagia, sedih, marah, takut, terkejut, jijik dan netral, untuk mengetahui tingkat akurasi yang dihasilkan dari penerapan metode CNN. Dengan melibatkan pengumpulan *dataset* ekspresi wajah yang komprehensif, pra-pemrosesan data yang tepat, dan perancangan arsitektur CNN yang sesuai.

LANDASAN TEORI

A. Ekspresi Wajah

Ekspresi wajah (*facial expression recognition*) merupakan salah satu penerapan *deep learning* di bidang pengolahan citra yang berguna untuk mendeteksi emosi manusia menggunakan algoritma *neural network*. Dalam penerapan *facial expression recognition* secara umum untuk mendeteksi emosi, langkah yang digunakan adalah dengan cara melakukan perhitungan dari nilai piksel setiap emosi dan secara urutan untuk mendapatkan informasi dalam *frame dataset*[14]. Saat ini, teknologi *face recognition*, sudah digunakan di berbagai bidang seperti kepolisian hingga pemerintahan. Di kepolisian, *face recognition* digunakan untuk identifikasi forensik, sedangkan di perusahaan metode ini digunakan untuk akses keamanan pada area tertentu. Bahkan baru-baru ini, pemerintah Amerika menggunakan *face recognition* untuk mencari dan mengidentifikasi anak yang hilang pada internet.

B. Artificial Intelligence

Kecerdasan buatan (*Artificial Intelligence*) merupakan salah satu bagian dari ilmu komputer yang mempelajari bagaimana membuat mesin (komputer) dapat melakukan pekerjaan seperti dan sebaik manusia, bahkan bisa lebih baik dari pada yang dilakukan manusia. Kecerdasan buatan juga merupakan kawasan penelitian, aplikasi dan instruksi yang terkait dengan pemrograman komputer untuk melakukan sesuatu hal, dalam pandangan manusia adalah cerdas. Salah satu teknologi kecerdasan buatan adalah sistem pakar yang merupakan program komputer yang dapat meniru proses pemikiran pengetahuan pakar untuk menyelesaikan suatu masalah yang spesifikasi[15]. *Artificial Intelligence* bisa diibaratkan payung yang lebih luas, dimana *machine learning* dan *deep learning* berada dalam lingkungannya.

C. Machine Learning

Machine learning atau dikenal dengan pembelajaran mesin adalah ilmu komputer yang bisa bekerja tanpa diprogram secara eksplisit. Banyak peneliti berpikir bagaimana cara untuk membuat kemajuan menuju AI terhadap tingkat manusia. *Machine learning* ini merupakan kecerdasan buatan yang mempelajari bagaimana membuat data. *Machine learning* bisa disingkat dengan ML. Ini dibutuhkan untuk menerapkan teknik yang cepat dan kuat dalam menemukan masalah baru. Secara definisi, *machine learning* merupakan ilmu atau studi yang mempelajari tentang algoritma dan *model* statistik yang digunakan oleh sistem komputer untuk melakukan tugas tertentu tanpa instruksi eksplisit. *Machine learning* bergantung pada pola dan kesimpulan. Untuk mendapatkan pola dan

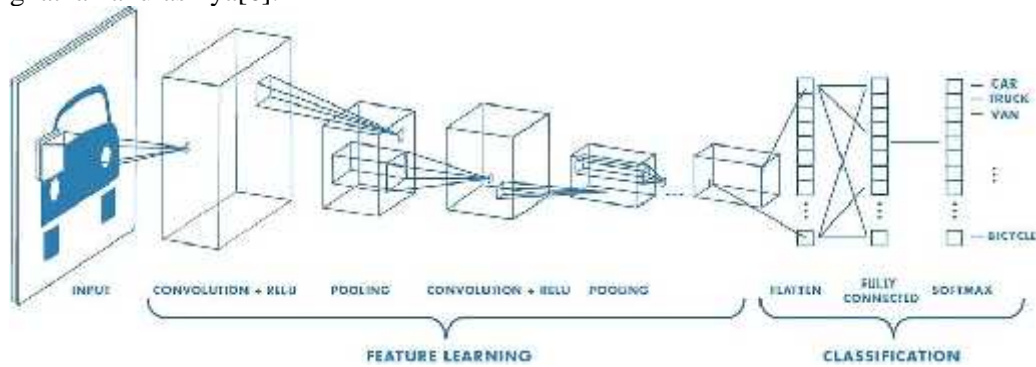
kesimpulan tersebut, algoritma *machine learning* menghasilkan *model* matematika yang didasari dari data sampel yang sering disebut dengan *training data*[16].

D. Deep Learning

Deep learning merupakan sebuah algoritma *neural network* yang menggunakan metadata sebagai *input* dan mengolah *input* tersebut menggunakan sekumpulan fungsi transformasi *non-linier* yang ditata berlapis-lapis dan mendalam. Pada *deep learning* terdapat *hidden layer* (lapisan tersembunyi) yang bertugas untuk melatih serangkaian fitur unik berdasarkan *output* dari jaringan sebelumnya[20].


E. Convolutional Neural Network (CNN)

Convolutional neural network (CNN) adalah salah satu metode paling populer digunakan untuk *deep learning*, sebuah *machine learning* yang *model* pembelajarannya dikhususkan untuk melakukan klasifikasi langsung pada 2 dimensi seperti gambar, video, teks, atau suara, namun pada penerapannya CNN juga dapat digunakan untuk tipe data 1 dimensi dan 3 dimensi[24]. Algoritma CNN akan sangat berguna khususnya ketika digunakan untuk mencari pola pada suatu gambar kemudian mengenali objek pada gambar tersebut. Bukan hanya pada objek atau benda saja, CNN ini sebenarnya juga bisa digunakan untuk mengenali wajah yang selama ini perlu segmentasi untuk meningkatkan akurasi[6].



Gambar 1. Arsitektur CNN (Stanford Course)

CNN pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiko Fukushima, seorang peneliti dari NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang. Konsep tersebut kemudian dimatangkan oleh Yann LeChun[25], seorang peneliti dari AT&T Bell Laboratories di Holmdel, New Jersey, USA. Model CNN dengan nama *LeNet* berhasil diterapkan oleh LeChun pada penelitiannya mengenai pengenalan angka dan tulisan tangan. Pada tahun 2012, Alex Krizhevsky dengan penerapan CNN miliknya berhasil menjuarai kompetisi *ImageNet Large Scale Visual Recognition Challenge 2012*. Metode CNN terbukti berhasil mengungguli metode *machine learning* lainnya seperti SVM pada kasus klasifikasi objek pada citra[26].




Gambar 2. Gambar Lapisan CNN

Secara umum model CNN terdiri dari 4 komponen, yaitu *convolution layer*, *pooling layer*, fungsi aktivasi, dan *fully connected layer*:

1. Convolution Layer

Convolution Layer melakukan operasi konvolusi pada *output* dari *layer* sebelumnya. *Layer* tersebut adalah proses utama yang mendasari sebuah CNN. Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada *output* fungsi lain secara berulang. *Convolutional layer* adalah tahap yang dilakukan untuk melakukan filter terhadap citra, dimana filter itu akan bergeser ke seluruh bagian gambar, dan menghasilkan *output* yang disebut *feature map*. Proses *convolution layer* dapat dilihat pada gambar 2.8 berikut:



Gambar 3. Operasi Konvolusi (Stanford Course)

Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra *input*. Konvolusi akan menghasilkan transformasi *linear* dari data *input* sesuai informasi spasial pada data. Bobot pada *layer* tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN.

a. Stride

Stride merupakan sebuah parameter untuk menyatakan jumlah pergeseran pada sebuah filter. Apabila *stride* bernilai 1, maka pada proses konvolusi *kernel* bergeser sebanyak 1 *pixel* secara *horizontal* lalu *vertikal*. Jika *stride* bernilai 2, *kernel* akan bergeser sebanyak 2 *pixel* secara *horizontal* lalu *vertikal*. Jika nilai *stride* yang digunakan semakin kecil, informasi yang diperoleh dari sebuah citra *input* akan semakin detail walaupun waktu komputasi yang dibutuhkan semakin besar. Meskipun demikian, dengan nilai *stride* yang kecil dan informasi yang diperoleh semakin detail bukan berarti bahwa performansi yang dihasilkan oleh sistem akan semakin baik[28].

b. Padding

Padding adalah parameter yang menentukan jumlah *pixels* (berisi nilai 0) yang akan ditambahkan di setiap sisi dari *input*. Hal ini digunakan dengan tujuan memanipulasi dimensi *output* dari *convolution layer* (*feature map*). Tujuan dari penggunaan *padding* adalah dimensi *output* dari *convolution layer* selalu lebih kecil dari *input*-nya (kecuali penggunaan filter 1x1 dengan *stride* 1). *Output* ini akan digunakan kembali sebagai *input* dari *convolution layer* selanjutnya, sehingga makin banyak informasi yang terbuang. Dengan menggunakan *padding*, maka dapat diatur dimensi *output* agar tetap sama seperti dimensi *input* atau setidaknya tidak berkurang secara drastis. Sehingga bisa digunakan *convolution layer* yang lebih dalam/*deep* sehingga lebih banyak fitur yang berhasil diekstrak. Meningkatkan performa dari *model* karena *convolution filter* akan fokus pada informasi yang sebenarnya yaitu yang berada di antara *zero padding* tersebut. Untuk menghitung dimensi dari *feature map* digunakan rumus[29]:


$$O = \frac{W - N + 2P}{S} + 1 \dots\dots\dots(4)$$

- W = Panjang/Tinggi Input
- N = Panjang/Tinggi Filter
- P = Zero Padding
- S = Stride

2. Pooling Layer

Pooling layer dilakukan untuk mengurangi dimensi *feature map* sehingga mempercepat komputasi[30]. Pada dasarnya *pooling layer* ini terdiri dari sebuah filter dengan ukuran tertentu yang akan dioperasikan dengan *stride* tertentu ke *feature map* hasil *convolutional layer*. *Max pooling* akan mengambil nilai terbesar untuk menyusun *matriks* baru berdasarkan citra yang telah direduksi. Pada penerapannya, *pooling layer* yang biasa digunakan di *pooling layer* ini yaitu *average pooling* dan

max pooling. Perbedaan dari 2 metode ini adalah pada nilai rata-rata dari matrik yang mengalami operasi *pooling*. Sedangkan *max pooling* adalah mengambil nilai tertinggi.



Gambar 4. Operasi *Max Pooling* (Stanford Course)

Berdasarkan ilustrasi di atas, pada *feature map* hasil konvolusi dilakukan operasi *max pooling*. Operasi untuk mengambil nilai tertinggi pada batasan ukuran filter tertentu. Dari operasi *max pooling* dengan *filter* 2x2 dan *stride* 2 tersebut didapatkan *feature map* baru dengan ukuran yang lebih kecil yaitu 2x2.

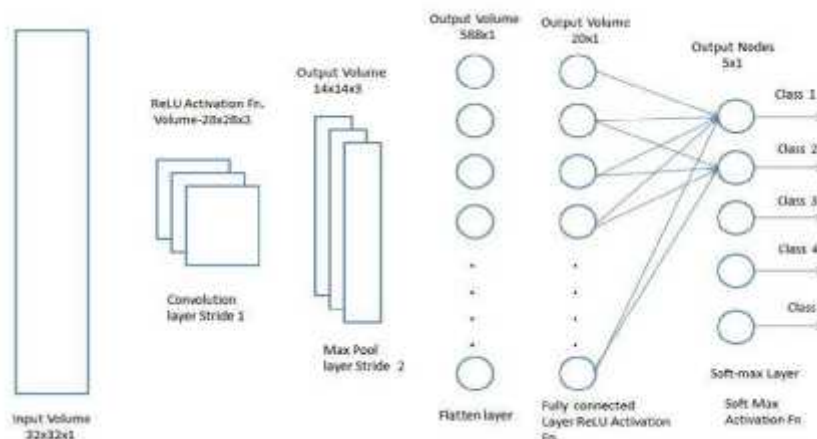
3. **Activation Function (Fungsi Aktivasi)**

Fungsi aktivasi sangat umum digunakan dalam *neural network*. Alasan utama menggunakan fungsi aktivasi adalah agar *neural network* mengenali data *non-linear*, karena *output* yang dihasilkan dari *neural network* jarang sekali bersifat *linear*. Fungsi aktivasi adalah fungsi *non-linear* yang membuat sebuah jaringan dapat mentransformasi data *input* ke dimensi yang lebih tinggi yang memungkinkan dilakukan klasifikasi. Pada CNN, fungsi aktivasi yang digunakan adalah fungsi *sigmoid*. Fungsi *sigmoid* berfungsi mentransformasi nilai dari *input* x menjadi antara 0 dan 1 dengan bentuk distribusi fungsi[9]. Fungsi *sigmoid* memiliki bentuk:

$$\sigma(x) = \frac{1}{(1+e^{-x})} \dots \dots \dots (5)$$

4. **Fully Connected Layer**

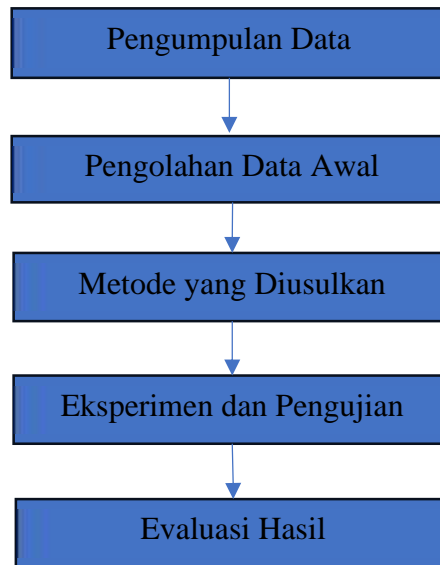
Fully connected layer menghubungkan semua *neuron* serupa seperti yang dimiliki oleh *multilayer perceptron* (MLP), yang bertujuan untuk mentransformasi dimensi data agar data dapat diklasifikasikan secara *linear*. Pada dasarnya lapisan ini sama halnya dengan lapisan *neural network* biasa, bisa dalam bentuk *single net* ataupun MLP. Tapi sebelum dilakukan proses klasifikasi, *feature map* yang dihasilkan dari *feature learning* tersebut masih berbentuk multi dimensi *array*, sehingga perlu mengubahnya menjadi bentuk *vector*, teknik ini disebut dengan *flatten*. *Flatten* merupakan teknik untuk *reshape feature map* menjadi sebuah *vektor* agar bisa digunakan sebagai *input* dari *fully connected layer*. Jadi *input* dari *fully connected layer* terdiri dari satu *neuron* hasil *reshape feature map* menjadi *vektor*. Setelah dilakukan *flatten*, semua bobot tersebut akan diklasifikasi sesuai dengan banyaknya kelas[25]. Proses *fully connected layer* dapat dilihat pada gambar 2.10 berikut:



Gambar 5. Proses Klasifikasi *Fully Connected Layer*

METODE PENELITIAN

Penelitian ini merupakan penelitian eksperimental dengan tahapan sebagai berikut:



Gambar 6. Tahapan Penelitian

1. Pengumpulan Data

Pada penelitian ini menggunakan data citra emosi yang telah dilabeli sebelumnya. Data tersebut berlabel emosi-emosi yang akan digunakan untuk membangun model penelitian. Emosi yang akan digunakan dalam penelitian ini antara lain; marah, sedih, senang, jijik, takut, terkejut dan netral. Data pelatihan digunakan dalam pelatihan hingga terbentuknya model, sedangkan data uji akan digunakan untuk mengetahui akurasi dari model yang telah dibuat. Penelitian ini menggunakan *dataset* citra emosi yaitu, *Facial Expression Recognition 2013 (FER2013)*

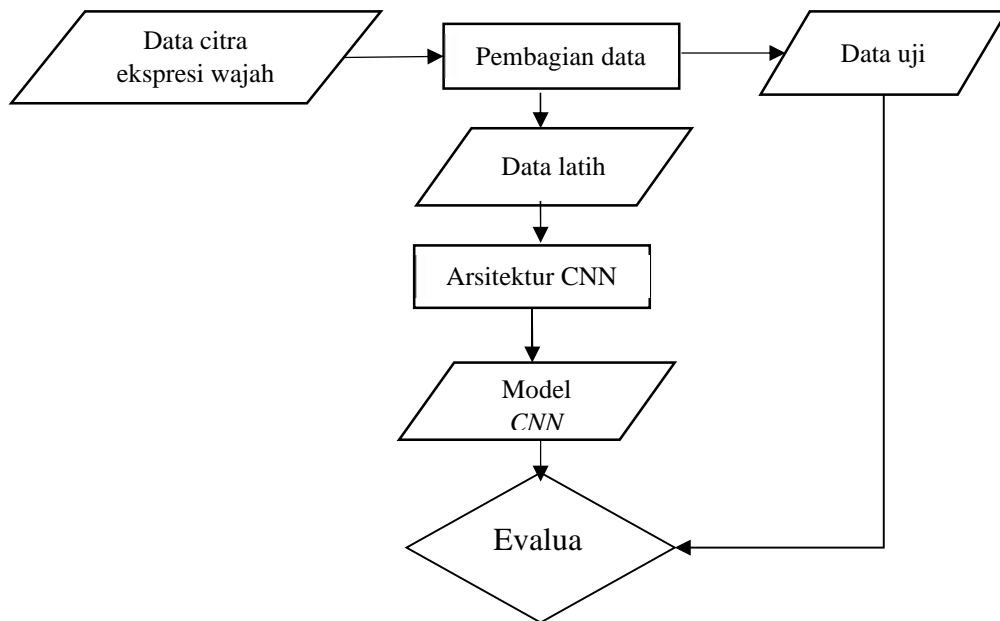
FER2013 merupakan *dataset* yang digunakan dalam kompetisi yang pernah diadakan oleh salah satu *website* yang bernama *Kaggle*. Kompetisi tersebut bernama “*Challenges in Representation Learning: Facial Expression Recognition Challenge*”(Carrier & Courville, 2013). Data yang digunakan dari kompetisi tersebut dipersiapkan oleh Pierre-Luc Carrier dan Aaron Courville. FER2013 sudah terbagi antara data latih dan data uji dengan perbandingan 90% dan 10%. Data yang sudah dikumpulkan akan diolah terlebih dahulu sebelum nantinya dilatih dengan model CNN yang sudah dibuat.

2. Pengolahan Data

Tahap ini merupakan tahap untuk mempersiapkan data yang telah diperoleh dari tahap pengumpulan data sebelum dilanjutkan ke tahap selanjutnya. Data yang dikumpulkan dibagi kedalam dua bagian untuk masing-masing kelas yaitu data latih (*training data*), dan data uji (*testing data*).

3. Metode Yang Diusulkan

Menggambarkan alur metode yang diusulkan kemudian menjelaskan cara kerja *model* tersebut. Metode ini akan digambarkan secara skematik dan disertai dengan formula perhitungan. *Model* akan dibentuk dari data yang telah diolah, dan hasil pengolahan *model* akan diukur dengan *model* yang ada saat ini. Metode CNN yang diterapkan pada penelitian ini dimulai dari tahap persiapan data, perancangan arsitektur, *setting* parameter, pengujian *model*, dan evaluasi yang dapat digambarkan dengan diagram alir berikut:




Gambar 6. Flowchart diagram Alir CNN

Berikut merupakan penjelasan Gambar 6:

a. Data Citra Ekspresi Wajah

Data citra ekspresi wajah terdiri atas 7 kelas seperti senang, sedih, marah, takut, jijik, terkejut dan netral, sesuai dalam batasan masalah penelitian. Data tersebut berukuran $48 \times 48 \text{ pixel}$. Citra emosi tersebut berwarna *greyscale* atau hanya berwarna abu-abu dan putih. FER2013 berisikan jenis kelamin laki-laki dan perempuan tetapi pada data ini tidak diketahui jumlah antara masing-masing jenis kelamin. Ras pada data ini juga tidak disebutkan oleh pembuat. Untuk umur orang pada data ini tidak diketahui tetapi dapat dilihat jika ada dari umur bayi hingga lanjut usia. Gambar 7 menunjukkan contoh citra dari FER2013:



Gambar 7. Citra FER2013

b. Pembagian Dataset

Tahap selanjutnya adalah pembagian data citra. Teknik pembagian data dalam penelitian ini dibagi menjadi dua bagian yaitu data pelatihan (*training*), dan pengujian (*testing*). Data pelatihan digunakan untuk melatih *model*, data validasi digunakan untuk mengoptimalkan parameter *model*, dan data pengujian digunakan untuk menguji performa *model* secara objektif. Dalam penelitian ini dilakukan pembagian data citra menjadi data latih, data uji dengan perbandingan 90:10 data, jumlah data citra yang diambil sebanyak 3500 citra gambar ekspresi wajah yang terbagi dalam 7 kategori.

c. Arsitektur Convolutional Neural Network Yang Diusulkan

Tahap selanjutnya adalah merancang arsitektur CNN. Arsitektur ini terdiri dari beberapa lapisan; konvolusi, *pooling*, dan *dropout* untuk menghindari *overfitting* dan lapisan *fully connected*. Jumlah dan ukuran lapisan akan ditentukan berdasarkan kompleksitas tugas dan ukuran *dataset*.

Setelah menentukan desain arsitektur yang akan digunakan, tahap selanjutnya adalah *setting* parameter, parameter yang akan ditentukan meliputi jumlah ukuran *batch*, jenis *optimasi*, ukuran *patience* dan *learning rate*. Penentuan nilai parameter tidak memiliki konsensus dengan kata lain tidak ada aturan pasti, nilai dan jenis dapat ditentukan sesuai dengan kebutuhan arsitektur yang dirancang.

d. Model CNN

Model CNN akan dilatih dengan menggunakan data pelatihan. Proses pelatihan melibatkan perhitungan *gradien* dan penyesuaian bobot agar *model* dapat mempelajari fitur-fitur yang relevan

dari data pelatihan. Pengoptimalan seperti *Adam* atau *stochastic gradient descent* (SGD) dapat digunakan selama pelatihan.

e. Evaluasi Pengujian

Evaluasi pengujian dilakukan menggunakan *confusion matrix*, pada tahap ini peneliti memasukan data baru ke dalam *model CNN* yang telah melalui proses pembelajaran dengan data latih. Setelah melakukan proses pembelajaran dengan data latih dan menghasilkan *model CNN*, kemudian data uji akan diolah pada *model* dan akan menghasilkan sebuah *output* sesuai jenis kelas, sehingga *model* yang telah dibuat diharapkan dapat melakukan identifikasi pada data uji kedalam kelas yang benar.

HASIL DAN PEMBAHASAN

A. Pelatihan Model

Tahap selanjutnya adalah *setting parameter*, sebelum melakukan proses *training* dan pembangunan model, pada tahap ini peneliti memulai eksperimennya dengan menentukan beberapa parameter awal yang akan digunakan pada proses *training* sebagai percobaan dengan harapan menghasilkan model dengan akurasi terbaik dan optimal, penentuan parameter akan disesuaikan dengan jenis arsitektur yang telah dirancang.


Proses pelatihan pada *Convolutional Neural Network* menggunakan beberapa parameter.

Tabel 1. Parameter Pelatihan

Nama Parameter	Jenis dan Nilai Parameter
<i>Epoch</i>	250
<i>Batch size</i>	32
<i>Optimizer</i>	Adam

B. Pengujian Model

Setelah melakukan proses *training* model tahap selanjutnya adalah tahap pengujian.. Didapatkan hasil *confusion matrix* sebagai berikut :



Gambar 8. *Confusion matrix*

Pada gambar *confusion matrix* di atas dapat dilihat bahwa kelas tertinggi dimiliki oleh kelas nomor 3 (senang), dimana memiliki nilai tertinggi dari data prediksi yang sesuai dengan data aktual. Hal ini bisa terjadi karena pada kelas senang memiliki data lebih banyak yang diprediksi oleh model. Sedangkan untuk kelas terendah dimiliki oleh kelas nomor 1(jijik) karena hanya sedikit data prediksi yang sesuai dengan data aktual. Hal ini bisa terjadi karena pada kelas jijik, data yang di prediksi hanya sedikit oleh model. Berikut rumus-rumus yang digunakan untuk menghitung TPR (*True Positive Rate/Sensitivity/Recall*), PPV (*Positive Predictive Value/Precision*), dan Accuracy:

$$S = \frac{T}{T + F}$$

$$P = \frac{T}{(T + F)}$$

$$A = \frac{2TP}{(2T + F + F)}$$

$$F1\ score = \frac{2TP}{2T + F + F}$$

Di mana:

TPR : True Positive Rate PPV : Positive Predictive Value

TP : True Positive

TN : True Negative

FP : False Positive F

N : False Negative

Berikut ini merupakan tabel kurva nilai *precision*, *recall* dan akurasi:

Tabel 2. kurva nilai *precision*, *recall* dan akurasi

<i>Clasification</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
0	0.31	0.46	0.37	491
1	0.15	0.76	0.25	55
2	0.27	0.27	0.27	528
3	0.73	0.58	0.65	879
4	0.26	0.17	0.20	626
5	0.37	0.22	0.28	594
6	0.51	0.74	0.68	416
<i>Accuracy</i>			0.42	3589
<i>Macro avg</i>	0.39	0.46	0.39	3589
<i>Weighted avg</i>	0.43	0.41	0.41	3589

KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan pembahasan dan hasil analisis yang telah dilakukan dalam penelitian ini, maka kesimpulannya adalah Berdasarkan pembahasan dan hasil analisis yang telah dilakukan dalam penelitian ini, dapat disimpulkan bahwa pemodelan CNN yang telah dibuat mampu menghasilkan nilai akurasi yang cukup tinggi, yaitu 95%.

B. Saran

Untuk pengembangan dari penelitian ini, penulis memberikan beberapa saran sebagai berikut:

1. Menambahkan jumlah *dataset* dan menambahkan objek gambar lain untuk melatih model CNN yang ada serta dapat mencapai akurasi yang tinggi.
2. Menambahkan objek gambar dengan memakai atribut pada sekitar area wajah yang berbeda dan dengan menggunakan ekspresi yang lebih banyak.

REFERENSI

- [1] K. Umi, "Pengenalan Kecerdasan Buatan (Artificial Intelligence) Kepada Para Remaja," *Univ. Bina Darma*, 2022, [Online]. Available: <http://eprints.binadarma.ac.id/15964/%0Ahttp://eprints.binadarma.ac.id/15964/1/UAS> METODOLOGI PENELITIAN Ummi Kalsum.pdf
- [2] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [3] L. M. R. Rere, S. Usna, and D. Soegijanto, "Studi Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network," *Semin. Nas. Teknol. Inf. dan Komun. STI&K*, vol. 3, 2019.
- [4] M. Ihsan, R. K. Niswatin, and D. Swanjaya, "Deteksi Ekspresi Wajah Menggunakan

- Tensorflow,” *Joutica*, vol. 6, no. 1, p. 428, 2021, doi: 10.30736/jti.v6i1.554.
- [5] Y. Hartiwi, E. Rasywir, Y. Pratama, and P. A. Jusia, “Eksperimen Pengenalan Wajah dengan fitur Indoor Positioning System menggunakan Algoritma CNN,” vol. 22, no. 2, 2020.
- [6] D. Alamsyah and D. Pratama, “Implementasi Convolutional Neural Networks (CNN) untuk Klasifikasi Ekspresi Citra Wajah pada FER-2013 Dataset,” *J. Teknol. Inf.*, vol. 4, no. 2, pp. 350–355, 2020, doi: 10.36294/jurti.v4i2.1714.
- [7] F. Felix, J. Wijaya, S. P. Sutra, P. W. Kosasih, and P. Sirait, “Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun,” *J. SIFO Mikroskil*, vol. 21, no. 1, pp. 1–10, 2020, doi: 10.55601/jsm.v21i1.672.
- [8] R. Kosasih, “Kombinasi Metode ISOMAP Dan KNN Pada Image Processing Untuk Pengenalan Wajah,” *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 5, no. 2, p. 166, 2020, doi: 10.24114/cess.v5i2.18982.
- [9] T. Tinaliah, “Penerapan Convolutional Neural Network Untuk Klasifikasi Citra Ekspresi Wajah Manusia Pada MMA Facial Expression Dataset,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 4, pp. 2051–2059, 2021, doi: 10.35957/jatisi.v8i4.1437.
- [10] S. Muhammad and A. T. Wibowo, “Klasifikasi Tanaman Aglaonema Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network (Cnn,” *e-Proceeding Eng.*, vol. 8, no. 5, pp. 10621–10636, 2021.
- [11] R. Julianto and D. Alamsyah, “Pengenalan ekspresi wajah menggunakan metode SVM dengan transformasi fourier dan PCA,” *Klik - J. Ilmu Komput.*, vol. 2, no. 1, pp. 1–12, 2021, [Online]. Available: <https://jurnal.uss.ac.id/index.php/klik/article/view/282>
- [12] D. S. Kusumaningrum, D. Wajah, and I. Pendahuluan, “Sistem Deteksi Wajah Keamanan Pintu Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Arduino,” vol. IV, pp. 15–23, 2023.
- [13] A. Kurniadi, “Implementasi Convolutional Neural Network Untuk Klasifikasi Varietas Pada Citra Daun Sawi Menggunakan Keras,” *DoubleClick J. Comput. Inf. Technol.*, vol. 4, no. 1, p. 25, 2020, doi: 10.25273/doubleclick.v4i1.5812.
- [14] S. P. Ristiawanto, B. Irawan, and C. Setianingsih, “Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network Menggunakan Arsitektur Residual Network -50 Facial Expression Recognition Based on Convolutional Neural Network Using Residual Network 50 Architecture,” vol. 8, no. 5, pp. 6455–6469, 2021.
- [15] M. Sobron and Lubis, “Implementasi Artificial Intelligence Pada System Manufaktur Terpadu,” *Semin. Nas. Tek. UISU*, vol. 4, no. 1, pp. 1–7, 2021, [Online]. Available: <https://jurnal.uisu.ac.id/index.php/semnastek/article/view/4134>
- [16] J. Fix, H. Frezza-Buet, M. Geist, and F. Pennerath, “Machine Learning.pdf.”
- [17] A. S. Diantika and Y. Firmanto, “Implementasi machine learning pada aplikasi penjualan produk digital (studi pada GrabKios),” *J. Ilm. Mhs. FEB*, vol. 53, no. 9, pp. 1689–1699, 2019.
- [18] D. Prasetyawan and R. Gatra, “Model Convolutional Neural Network untuk Mengukur Kepuasan Pelanggan Berdasarkan Ekspresi Wajah Convolutional Neural Network Model for Measuring Customer Satisfaction Based on Facial Expressions,” vol. 8, pp. 661–673, 2022.
- [19] D. Finaliamartha *et al.*, “Untuk Prediksi Tingkat Kemiskinan Di Provinsi Jawa Tengah Implementation of Backpropagation Artificial Neural Network,” *urnal Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 4, pp. 751–760, 2022, doi: 10.25126/jtiik.202294806.
- [20] P. Meliuwati and E. Kurniati, “Ekstraksi Data Digital Menggunakan Teknik Max Pooling dan Average Pooling,” *J. Ris. Mat.*, pp. 137–144, 2022, doi: 10.29313/jrm.v2i2.1338.
- [21] Z. Gao and X. Wang, “Deep learning,” *EEG Signal Process. Featur. Extr.*, pp. 325–333, 2019, doi: 10.1007/978-981-13-9113-2_16.
- [22] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 697–711, 2021, [Online]. Available: <http://ejurnal.tunasbangsa.ac.id/index.php/jsakti/article/view/369>
- [23] J. Jumadi, Y. Yupianti, and D. Sartika, “Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering,” *JST (Jurnal Sains dan Teknol.)*, vol. 10, no. 2, pp. 148–156, 2021, doi: 10.23887/jstundiksha.v10i2.33636.

- [24] B. C. L. Adiatma, E. Utami, and A. D. Hartanto, "Pengenalan Ekspresi Wajah Menggunakan Deep Convolutional Neural Network," *Explore*, vol. 11, no. 2, p. 75, 2021, doi: 10.35200/explore.v11i2.478.
- [25] Y. Lecun, L. Bottou, Y. Bengio, and P. Ha, "LeNet," *Proc. IEEE*, no. November, pp. 1–46, 1998.
- [26] P. Musa, W. K. Anam, and S. B. Musa, "Pembelajaran Mendalam Pengklasifikasi Ekspresi Wajah Manusia dengan Model Arsitektur Xception pada Metode Convolutional Neural Network," vol. 16, no. 1, pp. 66–73, 2023.
- [27] Z. B. Kizilkan, M. S. Sivri, I. Yazici, and O. F. Beyca, *Neural Networks and Deep Learning*. 2022. doi: 10.1007/978-3-030-93823-9_5.
- [28] R. Magdalena, S. Saidah, N. K. C. Pratiwi, and A. T. Putra, "Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN)," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, p. 335, 2021, doi: 10.26418/jp.v7i3.48195.
- [29] C. Geraldly and C. Lubis, "Pendeteksian Dan Pengenalan Jenis Mobil Menggunakan Algoritma You Only Look Once Dan Convolutional Neural Network," *J. Ilmu Komput. dan Sist. Inf.*, vol. 8, no. 2, p. 197, 2020, doi: 10.24912/jiksi.v8i2.11495.
- [30] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Computation*, vol. 11, no. 3, 2023, doi: 10.3390/computation11030052.
- [31] Efanntyo and A. R. Mitra, "Perancangan Aplikasi Sistem Pengenalan Wajah Dengan Metode Convolutional Neural Network (CNN) Untuk Pencatatan Kehadiran Karyawan," *J. Instrumentasi dan Teknol. Inform.*, vol. 3, no. 1, pp. 1–11, 2021.