

# Pengenalan Ekspresi Wajah dengan CNN dan Wavelet

Erwin Sentosa<sup>1</sup>, Hendrawan Armanto<sup>1</sup>, C. Pickerling<sup>1</sup>, Lukman Zaman PCSW<sup>1</sup>

<sup>1</sup>Departemen Informatika, Fakultas Sains dan Teknologi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia

**Corresponding author:** Erwin Sentosa (e-mail: erwinsentosa1@gmail.com).

**ABSTRACT** With the development of technology in modern times, it is hoped that computers will also be able to recognize human facial expressions with advances in machine learning. Machine learning has become a part of everyday life for many people worldwide. The discovery and implementation of machine learning allow computers to learn and predict possible patterns and can be used to help humans perform daily activities. One of them is Convolutional Neural Network. In this study, wavelet transform will be used to help improve the accuracy of the convolutional neural network and accelerate the increase in accuracy. Wavelets help compress images so that they are easier to process. The image generated by the wavelet is divided into 4 different frequencies. Each image generated by the wavelet is tested into a convolutional neural network. Based on the experiments' results, the best accuracy was obtained from the KDEF dataset using Low-Low (LL) frequency wavelet images with an accuracy of 79%. While the results of trials using self-made datasets obtained the best accuracy using Low-Low (LL) frequency wavelets with an accuracy of 36.925%.

**KEYWORDS** Convolutional Neural Network, Facial Expression, Machine Learning, Wavelet

**ABSTRAK** Dengan berkembangnya teknologi di jaman modern ini diharapkan komputer juga mampu mengenali ekspresi wajah manusia. Hal itu dapat terwujud dengan kemajuan machine learning. Machine learning telah menjadi bagian dari kehidupan sehari-hari bagi banyak orang di seluruh dunia. Penemuan dan implementasi machine learning memungkinkan komputer mempelajari dan memprediksi pola yang mungkin terjadi dan dapat digunakan untuk membantu manusia dalam aktivitas sehari-hari. Salah satunya yaitu Convolutional Neural Network. Pada penelitian ini akan digunakan wavelet transform untuk membantu meningkatkan akurasi dari convolutional neural network dan mempercepat peningkatan akurasi. Wavelet berguna untuk melakukan compressing pada gambar sehingga lebih mudah untuk diolah. Gambar yang dihasilkan oleh wavelet terbagi menjadi 4 frekuensi yang berbeda-beda. Setiap gambar yang dihasilkan oleh wavelet diuji cobakan kedalam convolutional neural network. Berdasarkan hasil uji coba yang dilakukan, akurasi terbaik didapatkan dari dataset KDEF dengan menggunakan gambar wavelet berfrekuensi Low-Low (LL) dengan akurasi yang didapatkan sebesar 79%. Sedangkan hasil uji coba menggunakan dataset buatan sendiri didapatkan akurasi terbaik dengan menggunakan wavelet berfrekuensi Low-Low (LL) dengan akurasi yang didapatkan sebesar 36,925%.

**KATA KUNCI** *Convolutional Neural Network, Ekspresi Wajah, Machine Learning, Wavelet.*

## I. PENDAHULUAN

Wajah merupakan bagian dari tubuh manusia yang menjadi fokus di dalam interaksi sosial. Wajah juga merupakan salah satu bagian unik dari tubuh manusia yang mempunyai karakteristik yang berbeda. Wajah memiliki peranan penting dengan menunjukkan emosi/ekspresi. Wajah manusia menyediakan banyak informasi, banyak hal menarik yang bisa diperhatikan, dan dipelajari secara

intensif.

Beberapa penelitian yang menggali informasi dari wajah manusia adalah pengenalan wajah dan pengenalan isyarat wajah. Ketika manusia berinteraksi satu sama lain, mereka menggunakan berbagai macam isyarat dari wajah untuk menyampaikan informasi. Isyarat wajah yang terbentuk bisa menyampaikan ekspresi wajah tertentu.

Dengan berkembangnya teknologi di jaman modern ini diharapkan komputer juga mampu mengenali ekspresi wajah

manusia. Ini dapat diwujudkan melalui kemajuan machine learning. Machine learning telah menjadi bagian dari kehidupan sehari-hari bagi banyak orang di seluruh dunia. Penemuan dan implementasi machine learning memungkinkan komputer mempelajari dan memprediksi pola yang mungkin terjadi dan dapat digunakan untuk membantu manusia dalam aktivitas sehari-hari. Salah satunya yaitu Convolutional Neural Network.

CNN adalah jenis neural network yang biasa digunakan untuk pengolahan data gambar. CNN dapat digunakan untuk mendeteksi dan mengidentifikasi objek pada citra. Secara umum CNN adalah varian dari Neural Network (NN) yang dibangun untuk memproses data dalam jumlah besar, sehingga prosesnya lebih efisien daripada menggunakan NN. CNN terdiri dari neuron yang memiliki weight, bias dan activation function. CNN dapat mempermudah pengklasifikasian ekspresi wajah yang sebelumnya cukup susah, dikarenakan pengambilan gambar dapat dari berbagai macam sudut dan perbedaan wajah dari setiap orang yang ada yang menyebabkan sulitnya untuk menemukan persamaan ekspresi dari setiap wajah orang.

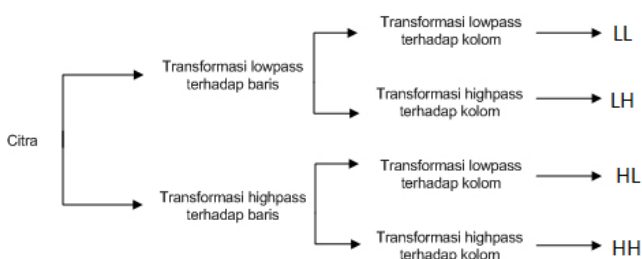
Tujuan utama dari penelitian ini adalah untuk membuat membuktikan penggunaan wavelet untuk preprocessing gambar dan CNN yang dapat mengklasifikasikan ekspresi wajah manusia berdasarkan gambar/foto wajah manusia yang diambil dari berbagai macam sudut sebagai input dan output berupa teks [1].

## II. TEORI PENUNJANG

### 1. Wavelet


Transformasi Wavelet Diskrit adalah proses fungsi wavelet yang memilih subset dari skala dan titik tertentu dalam proses komputasi. Dalam Transformasi ini, sinyal citra dapat dianalisis dengan melewatkannya melalui proses filtering. Proses filtering tersebut terdiri dari low-pass dan high-pass filter pada setiap langkah dekomposisi. Filtering dilakukan pada baris dan kolom.

Salah satu jenis dari transformasi wavelet diskrit yaitu haar wavelet. Wavelet Haar merupakan wavelet yang paling tua dan sederhana. Citra asli akan didekomposisi menjadi 4 gambar dengan frekuensi yang berbeda-beda. Gambar asli akan difilter berdasarkan baris dan kolom. Filter yang digunakan ada 2 macam yaitu low-pass dan high-pass. Berikut ilustrasi filtering dapat dilihat pada gambar di bawah ini.




GAMBAR 1. Ilustrasi Filtering Wavelet

Pada gambar diatas dapat dilihat terdapat 4 macam frekuensi yang dihasilkan dari proses filtering. Frekuensi yang akan dihasilkan yaitu Low-Low(LL), Low-High(LH), High-Low(HL), dan High-High(HH). Low-Low frekuensi dihasilkan dari hasil low-pass filtering terhadap baris dan kolom, Low-High frekuensi dihasilkan dari low-pass filtering terhadap baris dan high-pass filtering terhadap kolom, High-Low frekuensi dihasilkan dari high-pass filtering terhadap baris dan low-pass filtering terhadap kolom, dan High-High frekuensi dihasilkan dari high-pass filtering terhadap baris dan kolom. Berikut gambar ilustrasi output yang dihasilkan dapat dilihat pada gambar di bawah ini [2].



GAMBAR 2. Ilustrasi Output Wavelet

Setelah citra didekomposisi dengan melakukan langkah-langkah diatas maka akan menghasilkan citra baru dengan 4 macam frekuensi yang berbeda-beda. Output dari proses tersebut akan terlihat gambar terbagi menjadi 4 bagian dengan ukuran  $\frac{1}{4}$  dari gambar asli seperti pada gambar 2.2. Berikut contoh hasil proses dekomposisi haar wavelet dapat dilihat pada gambar 3 di bawah ini




GAMBAR 3. Hasil Wavelet

### 2. Convolutional Neural Network

CNN adalah pengembangan Multi Layer Perceptron (MLP) untuk memproses data dua dimensi. CNN diklasifikasikan sebagai jenis Deep Neural Network karena kedalaman jaringannya yang besar dan banyak digunakan untuk data citra. Dalam permasalahan klasifikasi citra, MLP tidak cocok karena tidak menyimpan informasi spasial dan mengasumsikan bahwa setiap pixel adalah fitur terpisah sehingga memberikan hasil yang buruk.

Asal mula penelitian yang menjadi dasar penemuan ini dilakukan oleh Hubel dan Wiesel. Mereka melakukan penelitian visual korteks pada penglihatan kucing. Penelitian ini sangat berguna dalam sistem pemrosesan visual yang ada. Sejak penelitian tersebut, banyak penelitian yang terinspirasi oleh mekanisme yang disajikan dan menghasilkan model-model baru seperti Neocognitron, HMAX, dan LeNet-5. Arsitektur CNN dibagi menjadi 2 bagian utama, Feature Learning/Extraction Layer dan Classification Layer, seperti yang ditunjukkan pada Gambar 4. [3]




**GAMBAR 4. Ilustrasi Filtering Wavelet**

Cara kerja CNN mirip dengan MLP, namun pada CNN setiap neuron direpresentasikan dalam dua dimensi, berbeda dengan MLP dimana setiap neuron hanya satu dimensi. Pada CNN, data yang disebarkan melalui jaringan selalu data dua dimensi, sehingga operasi linier dan bobot parameter CNN berbeda dengan MLP. Operasi Linier CNN menggunakan konvolusi, sedangkan bobot tidak lagi hanya satu dimensi, tetapi dalam bentuk empat dimensi yang mewakili kumpulan filter konvolusi. Karena sifat dari proses konvolusi, maka CNN hanya dapat digunakan untuk data yang memiliki struktur dua dimensi, seperti gambar.

1. Convolutional Layer


Convolutional Layer adalah salah satu jenis layer yang terdapat di dalam CNN dan dapat dikatakan sebagai layer inti. Convolutional Layer melakukan operasi konvolusi yang dimana operasi konvolusi ini merupakan sebuah kunci utama atau operasi utama dari CNN. Layer ini memiliki tujuan untuk melakukan ekstraksi untuk mendapatkan fitur-fitur penting

Dalam Convolutional Layer sendiri, terdapat sebuah proses utama yang biasa disebut dengan konvolusi, dimana konvolusi adalah istilah matematika yang berarti menerapkan fungsi berulang kali ke output fungsi lain. Berikut merupakan sebuah gambar yang menunjukkan sebuah contoh dari ilustrasi Convolutional Layer [4].




**GAMBAR 5. Contoh Convolutional Layer**

Pada convolutional layer terdapat beberapa hyperparameter antara lain stride, padding, dan fungsi aktivasi. Stride adalah parameter yang menentukan seberapa jauh jumlah pergeseran filter. Nilai 1, akan menggeser filter sebanyak 1 pixels. Nilai dari stride berlaku untuk pergeseran filter secara horisontal maupun secara vertical. Semakin kecil stride, semakin detail informasi yang didapatkan dari input, tetapi akan membutuhkan lebih banyak perhitungan dibandingkan dengan stride besar. Lihat gambar 6 untuk ilustrasi stride 1.




**GAMBAR 6. Ilustrasi Stride 1**

Padding adalah parameter yang menentukan jumlah pixel untuk ditambahkan ke setiap sisi input. Padding yang biasa digunakan yaitu zero padding. Zero padding akan menambahkan angka 0 pada setiap sisi input. Contoh zero padding dapat dilihat pada gambar 7 dibawah ini



**GAMBAR 7. Zero Padding**


Fungsi aktivasi menentukan apakah sebuah neuron harus aktif atau tidak berdasarkan bobot total input. Secara umum, ada 2 jenis fungsi aktivasi, yaitu fungsi aktivasi linear dan non linear. Contoh dari fungsi aktivasi non linear antara lain Rectified Linear Unit (ReLU), Softmax, dan Sigmoid, Tanh (lihat Gambar 8).



**GAMBAR 8. Zero Padding**

**2. Pooling Layer**


Pooling layer adalah proses untuk memperkecil ukuran citra. Dalam pengolahan citra, pooling juga bertujuan untuk meningkatkan invariansi karakteristik dari fitur. Max pooling adalah metode pooling yang digunakan di sebagian besar CNN. Max pooling membagi output dari convolution layer menjadi beberapa grid kecil kemudian mengambil nilai maksimum dari setiap grid untuk membentuk matriks citra yang lebih kecil. Contoh ilustrasi max pooling layer dapat dilihat pada gambar 9.



**GAMBAR 9. Max Pooling**

**3. Fully Connected Layer**


Fully connected layer adalah layer yang umum digunakan dalam MLP yang tujuannya untuk mentransformasi dimensi data agar data dapat diklasifikasikan secara linear. Pada CNN fully connected layer biasanya dilakukan setelah gambar sudah diproses pada convolutional layer dan pooling layer. Setiap neuron pada convolutional layer pertama-tama harus dikonversi menjadi data satu dimensi sebelum dapat dimasukkan ke dalam sebuah fully connected layer. Karena data kehilangan informasi spasialnya dan tidak dapat dibalik, maka fully connected layer hanya dapat diimplementasikan pada bagian akhir. Gambar 10 adaah Ilustrasi fully connected layer.



**GAMBAR 10. Fully Connected Layer**

**4. Dropout**

Dropout adalah proses untuk mencegah overfitting dan mempercepat proses pembelajaran. Dropout mengacu pada penghapusan neuron yang tersembunyi ataupun terlihat dalam jaringan. Melakukan penghapusan neuron, berarti menghilangkan sementara dari jaringan yang ada. Neuron yang akan dihapus dipilih secara random dengan probabilitas tertentu. Setiap neuron diberi p-probabilitas yang bernilai mulai dari 0 hingga 1.0. Untuk lebih jelasnya, ilustrasi mengenai proses dropout dapat di lihat pada gambar di bawah ini [5].




**GAMBAR 11. Dropout**

**III. Arsitektur [6]–[9]**

**A. Arsitektur Sistem**

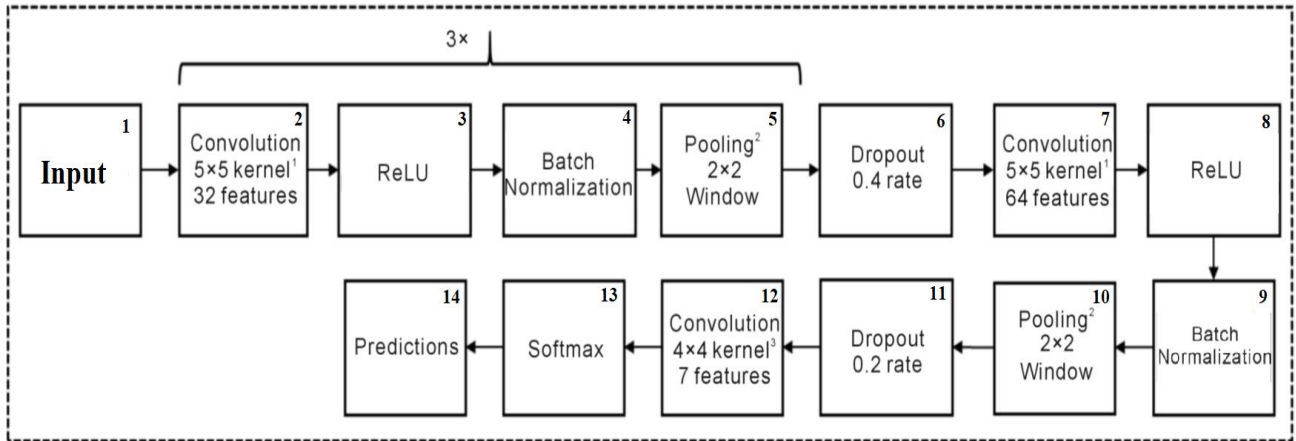
Struktur sistem yang akan dibuat secara garis besar akan dibagi menjadi 2 bagian yaitu bagian pelatihan dan bagian uji coba. Pada tahap pertama sistem akan melakukan proses pelatihan terlebih dahulu. Hal ini bertujuan agar nantinya dapat mengklasifikasikan ekspresi manusia secara tepat pada saat dilakukan proses uji coba. Agar lebih jelas struktur tahap pelatihan dapat dilihat pada gambar 12 di bawah ini.



**GAMBAR 12. Struktur Proses Pelatihan**

Proses pelatihan dimulai dengan memasukan dataset. Dataset yang digunakan untuk training berupa kumpulan gambar wajah manusia yang memiliki ekspresi berbeda-

Dapat kita lihat pada gambar diatas, setelah gambar dimasukkan kedalam CNN pada proses uji coba, program akan mendapatkan output berupa label dari ekspresi tersebut. Label tersebut berupa ekspresi dari wajah manusia yang



GAMBAR 14. Arsitektur CNN

beda. Dataset tersebut akan terlebih dahulu diproses menggunakan wavelet agar nantinya dapat diproses lebih cepat didalam CNN dan diharapkan dapat menaikkan akurasi. Gambar – gambar tersebut akan dimasukkan kedalam CNN untuk melakukan proses klasifikasi.

Model bobot filter yang didapatkan dari hasil proses pelatihan akan disimpan. Bobot ini kemudian akan dipakai ketika melakukan proses uji coba. Untuk struktur uji coba dapat dilihat pada gambar 13

diinputkan kedalam program pada saat proses uji coba. Tahap ini merupakan tujuan utama dari program ini yaitu untuk mengenali ekspresi wajah manusia.

*B. Arsitektur CNN*

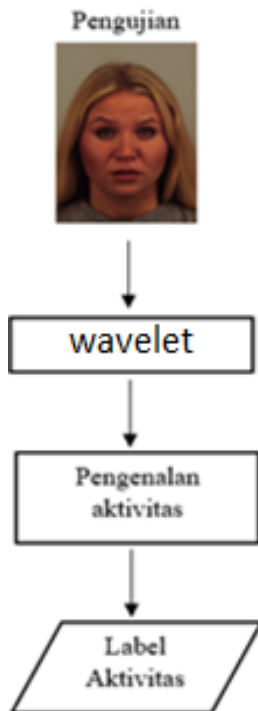
Arsitektur CNN merupakan struktur susunan layer yang akan digunakan untuk mengklasifikan data dua dimensi. Arsitektur CNN yang dibuat akan berupa susunan layer-layer pada CNN. Dalam pembuatan program ini arsitektur akan dibuat sedemikian rupa agar dapat mengklasifikasikan ekspresi wajah manusia dengan baik.

Arsitektur CNN yang akan digunakan terdiri dari convolutional layer, normalization, ReLU, pooling layer, dropout, dan softmax. Layer-layer tersebut disusun sedemikian rupa sehingga dapat mengklasifikan ekspresi wajah dengan tingkat akurasi yang tinggi. Untuk lebih jelasnya arsitektur CNN dapat dilihat pada gambar 14 di atas.

Dapat kita lihat pada arsitektur di gambar 14, terdapat 14 langkah dalam proses pengklasifikasian yang akan dijalankan. Setiap langkah yang dilakukan terdapat fungsi atau kegunaannya masing-masing. Fungsi dari setiap langkahnya akan membantu dalam proses klasifikasi yang akan dilakukan.

Langkah pertama yang dilakukan adalah menerima inputan. Inputan tersebut kemudian akan diproses ke dalam convolution layer dan data yang dihasilkan oleh convolutional layer akan diproses ke dalam ReLU. Setelah itu data yang di hasilkan dari ReLU akan diproses kedalam batch normalization dan pooling layer. Seperti yang dapat kita lihat pada gambar arsitektur CNN di atas, langkah nomor 2 hingga nomor 5 akan diulang sebanyak 3 kali.

Data-data yang dihasilkan dari proses diatas akan dimasukan ke dalam layer dropout. kemudian data yang didapat dari proses dropout akan dimasukkan ke dalam convolution layer, ReLU, dan batch normalization. Setelah



S

GAMBAR 13. Struktur Proses Uji Coba



itu data yang di hasilkan akan dimasukkan kedalam dropout layer lagi. Sama seperti sebelumnya data yang dihasilkan setelah proses dropout akan dimasukkan kembali kedalam convolutional layer, akan tetapi dengan nilai parameter convolutional layer yang berbeda dengan sebelumnya. Hasil dari convolutional layer tersebut kemudian akan dimasukkan kedalam softmax dan setelah itu kita dapat mendapatkan hasil yang didapat pada tahap prediction. Untuk lebih jelasnya langkah-langkah arsitektur CNN pada gambar 14 dapat dilihat pada tabel di bawah ini.

TABLE I  
ARSITEKTUR CNN

LAYER	FILTER SIZE	OUTPUT DEPTH	ACTIVATION FUNCTION
Input	-	-	-
Convolution Layer	5x5	32	ReLU
Batch Normalization	-	-	-
Max Pooling	2x2	-	-
Convolutional Layer	5x5	32	ReLU
Batch Normalization	-	-	-
Max Pooling	2x2	-	-
Convolutional Layer	5x5	32	ReLU
Batch Normalization	-	-	-
Max Pooling	2x2	-	-
Dropout	-	-	-
Convolutional Layer	5x5	64	ReLU
Batch Normalization	-	-	-
Max Pooling	2x2	-	-
Dropout	-	-	-
Convolutional Layer	4x4	7	Softmax

ekspresi tersebut yaitu netral, senang, marah, sedih, takut, jijik, dan kaget. untuk lebih jelasnya gambar ekspresi wajah dapat dilihat pada gambar di bawah ini



GAMBAR 16. Ekspresi Dataset


Selain memiliki 7 ekspresi, dataset yang digunakan juga diambil dari 5 sudut pengambilan foto yang berbeda. Sudut pengambilan foto tersebut yaitu kiri, serong kiri, depan, serong kanan, dan kanan, untuk lebih jelasnya dapat dilihat pada gambar di bawah ini.



GAMBAR 17. Sudut Pengambilan Foto Dataset

**IV. UJI COBA**

Uji coba dilakukan dengan menggunakan K-fold cross validation. K-fold cross validation merupakan metode uji coba dengan membagi data menjadi K bagian, kemudian akan diulang sebanyak K dengan mengganti bagian yang menjadi data testing. Untuk lebih jelasnya dapat dilihat pada gambar di bawah ini [10].

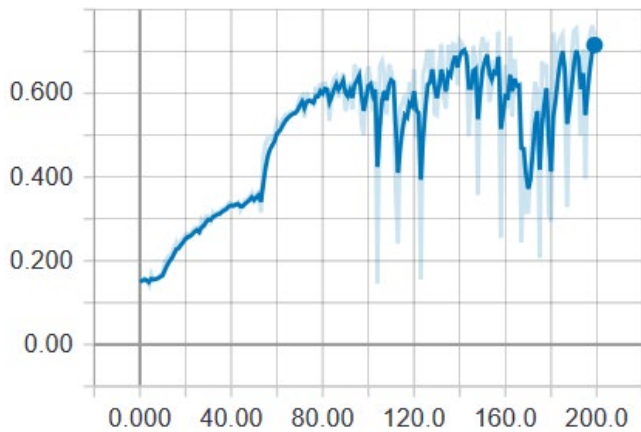


GAMBAR 15. K-fold cross validation

Gambar di atas merupakan contoh ilustrasi k-fold cross validation dengan nilai K=4. Data yang dimiliki akan dibagi menjadi 4 bagian. ¼ bagian akan menjadi data testing dan ¾ bagian akan menjadi data training. Kemudian untuk setiap iterasinya data testing akan berubah-ubah. Karena nilai K=4 maka jumlah uji coba yang dilakukan sebanyak 4 kali.


Dataset yang digunakan pada proses uji coba berupa foto wajah manusia dengan 7 macam ekspresi. Ketujuh macam

Data yang digunakan dalam proses uji coba yaitu data gambar gray scale dengan menggunakan dataset KDEF. Uji coba ini dilakukan sebanyak 200 epoch dan dilakukan sebanyak 4 kali menggunakan metode k-fold cross validation dengan nilai K=4. Berikut ini merupakan gambar dari grafik akurasi paling baik yang dihasilkan pada uji coba ini.



**GAMBAR 18.** Grafik Akurasi Gray Scale

Seperti yang dapat dilihat pada gambar di atas, grafik yang ditampilkan menunjukkan bahwa akurasi yang didapatkan dari data testing selama proses training berlangsung memiliki nilai akurasi tertinggi 73%. Gambar grafik di bawah merupakan salah contoh akurasi yang didapatkan dari salah satu proses uji coba yang dilakukan terhadap data asli. Kemudian dari hasil uji coba lainnya didapatkan nilai akurasi tertinggi mencapai 71%, 68,8% dan 72%. Sehingga dari hasil coba tersebut didapatkan akurasi rata-rata sebesar 71,2%. Setelah itu akan diuji cobakan gambar Low-Low frekuensi yang dihasilkan dari proses wavelet. Grafik akurasi yang dihasilkan dapat dilihat pada gambar di bawah ini



**GAMBAR 19.** Grafik Akurasi Low-Low

Seperti yang dapat dilihat pada gambar di atas, grafik akurasi pada data testing Low-Low Frekuensi menunjukkan bahwa dari awal proses training, grafik menunjukkan kenaikan yang cukup baik hingga mencapai akurasi sekitar 75%. Setelah itu, akurasi mulai stabil pada 75% hingga mencapai titik tertingginya yaitu 80%. Hasil uji coba lainnya mendapatkan akurasi sebesar 79,2%, 77%, dan 78% sehingga hasil rata-rata dari ke empat uji coba tersebut sebesar 78,5%.


Selain menggunakan dataset yang telah dijelaskan sebelumnya, juga di lakukan proses uji coba dengan

menggunakan dataset yang dibuat sendiri. Dataset buatan sendiri tersebut memiliki 7 ekspresi yaitu netral, senang, marah, sedih, jijik, takut, dan kaget. Untuk lebih jelasnya ekspresi wajah tersebut dapat dilihat pada gambar di bawah ini.



**GAMBAR 20.** Ekspresi Wajah Dataset Buatan Sendiri


Selain memiliki 7 ekspresi, dataset yang digunakan juga diambil dari 3 sudut pengambilan foto yang berbeda. Sudut pengambilan foto tersebut yaitu serong kiri, depan, dan serong kanan. Untuk lebih jelasnya dapat dilihat pada gambar di bawah ini



**GAMBAR 21.** Sudut Pengambilan Foto Dataset Buatan Sendiri


Sama dengan dataset sebelumnya dilakukan uji coba dengan menggunakan gambar asli yang di gray scale. Uji coba ini dilakukan sebanyak 200 epoch dengan menggunakan k-fold cross validation dengan nilai K=4. Berikut ini merupakan grafik yang didapatkan dari hasil uji coba tersebut.

Seperti yang dapat dilihat pada gambar di atas, grafik yang ditampilkan menunjukkan bahwa akurasi yang didapatkan dari data testing selama proses training berlangsung memiliki nilai akurasi tertinggi 38,8%. Setelah itu dari tiga proses uji coba lainnya didapatkan akurasi tertinggi sebesar 35%, 32,2%, dan 30% sehingga didapatkan hasil rata-rata dari semua uji coba tersebut sebesar 34,025%. Setelah itu akan diuji cobakan gambar Low-Low frekuensi yang dihasilkan dari proses wavelet. Grafik akurasi yang dihasilkan dapat dilihat pada gambar di bawah ini.



**GAMBAR 22.** Grafik Akurasi Gambar Asli Dataset Buatn Sendiri

Seperti yang dapat dilihat pada gambar di atas, grafik akurasi pada data testing Low-Low Frekuensi menunjukkan bahwa dari awal proses training, grafik menunjukkan kenaikan tetapi tidak terlalu stabil. Dari grafik di atas didapatkan akurasi maximal sebesar 39.8%. Kemudian dari 3 uji coba lainnya didapatkan akurasi tertinggi sebesar 35,9%, 38,1%, dan 33,9% sehingga mendapatkan hasil rata-rata akurasi sebesar 36,925%



**GAMBAR 23.** Grafik Akurasi Low-Low Dataset Buatn Sendiri

## V. KESIMPULAN

Pada bagian ini akan dijelaskan mengenai kesimpulan apa saja yang didapatkan dalam penelitian ini. Kesimpulan-kesimpulan yang didapatkan akan dijelaskan dalam beberapa poin di bawah ini.

- Dengan menggunakan haar Wavelet transform hasil akurasi yang didapatkan lebih tinggi dibandingkan dengan tanpa menggunakan haar wavelet transform.
- Akurasi terbaik yang didapatkan yaitu sebesar 79% dimana data yang digunakan merupakan data hasil dari haar wavelet transform yang berfrekuensi Low-Low.
- Dataset buatan sendiri memiliki akurasi rendah dibandingkan dataset KDEF, dikarenakan ketidak stabilan pengambilan gambar. Mayoritas gambar yang

diperoleh tidak konsisten. Sedangkan dataset KDEF, memiliki data yang konsisten untuk seluruh orang.

## PERAN PENULIS

Setiap penulis memiliki kontribusi yang sama dalam Analisis Formal, Investigasi, Administrasi Proyek, Sumber Daya, Perangkat Lunak, Validasi, Visualisasi, Penulisan Penyusunan Draf Asli, Penulisan Review & Penyuntingan.

## COPYRIGHT



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

## DAFTAR PUSTAKA

- [1] T. Williams, R. Li, and others, "An ensemble of convolutional neural networks using wavelets for image classification," *J. Softw. Eng. Appl.*, vol. 11, no. 02, p. 69, 2018.
- [2] L. Novamizanti and A. Kurnia, "Analisis Perbandingan Kompresi Haar Wavelet Transform dengan Embedded Zerotree Wavelet pada Citra," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. & Tek. Elektron.*, vol. 3, no. 2, p. 161, 2015.
- [3] K. O'Shea and R. Nash, "An Introduction to Convolutional Neural Networks," *CoRR*, vol. abs/1511.0, 2015, [Online]. Available: <http://arxiv.org/abs/1511.08458>.
- [4] A. Santoso and S. T. Gunawan Ariyanto, "Implementasi deep learning berbasis keras untuk pengenalan wajah," Universitas Muhammadiyah Surakarta, 2018.
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Adv. Neural Inf. Process. Syst.*, 2012, doi: <http://dx.doi.org/10.1016/j.protcy.2014.09.007>.
- [6] L. Wang and Y. Sun, "Image classification using convolutional neural network with wavelet domain inputs," *IET Image Process.*, 2022.
- [7] J.-W. Liu, F.-L. Zuo, Y.-X. Guo, T.-Y. Li, and J.-M. Chen, "Research on improved wavelet convolutional wavelet neural networks," *Appl. Intell.*, vol. 51, no. 6, pp. 4106–4126, 2021.
- [8] S. Gunasekaran, S. Rajan, L. Moses, S. Vikram, M. Subalakshmi, and B. Shudhersini, "Wavelet based CNN for diagnosis of COVID 19 using chest X ray," in *IOP Conference Series: Materials Science and Engineering*, 2021, vol. 1084, no. 1, p. 12015.
- [9] S. Fujieda, K. Takayama, and T. Hachisuka, "Wavelet convolutional neural networks for texture classification," *arXiv Prepr. arXiv1707.07394*, 2017.
- [10] W. Shang, K. Sohn, D. Almeida, and H. Lee, "Understanding and improving convolutional neural networks via concatenated rectified linear units," in *international conference on machine learning*, 2016, pp. 2217–2225.