

EKSPLORASI PENGGABUNGAN *STATIONARY WAVELET TRANSFORM* DAN *DISCRETE COSINE TRANSFORM* PADA KLASIFIKASI EKSPRESI WAJAH

Farkhan, Fetty Tri Anggraeny, Eva Yulia Puspaningrum
Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur
Jalan Raya Rungkut Madya No. 1 Surabaya, Indonesia
farkhanjayadi@gmail.com

ABSTRAK

Ekspresi wajah memainkan peran penting dalam komunikasi non-verbal, sehingga klasifikasi ekspresi wajah menjadi topik penelitian yang signifikan dalam pengenalan pola dan visi komputer. Tantangan utama dalam klasifikasi ini adalah mengekstraksi fitur yang efektif dari citra wajah, mengingat kompleksitas informasi spasial dan frekuensi yang perlu dipertahankan. *Stationary Wavelet Transform* (SWT) dikenal mampu mempertahankan kedua jenis informasi ini, tetapi menghasilkan fitur dengan dimensi yang tinggi yang dapat meningkatkan beban komputasi dan risiko *overfitting*. Penelitian ini mengeksplorasi dan membandingkan dua metode ekstraksi fitur untuk klasifikasi ekspresi wajah: penggabungan SWT dengan *Discrete Cosine Transform* (DCT) untuk mengurangi dimensi fitur, dan SWT saja, dengan evaluasi kinerja menggunakan *Multi-Layer Perceptron* (MLP). Dataset CKPLUS digunakan dalam penelitian ini, di mana citra wajah melalui *preprocessing* termasuk *histogram equalization*, *resize* ke 48x48 piksel, konversi ke *grayscale*, dan *denoising*. Hasil pengujian menunjukkan bahwa model yang menggunakan fitur dari SWT saja memberikan akurasi (95%), presisi (95%), *recall* (95%), dan F1-score (94%) yang lebih tinggi dibandingkan dengan model yang menggunakan fitur dari kombinasi SWT dan DCT, yang menghasilkan akurasi (91%), presisi (89%), *recall* (91%), dan F1-score (81%). Temuan ini menyarankan bahwa dalam konteks klasifikasi ekspresi wajah, penggunaan SWT saja lebih optimal dibandingkan dengan penggabungan DCT.

Kata kunci : *Stationary Wavelet Transform, Discrete Cosine Transform, Klasifikasi Ekspresi Wajah, Ekstraksi Fitur, Multi-Layer Perceptron.*

1. PENDAHULUAN

Wajah manusia merupakan bagian yang memiliki fungsi untuk menunjukkan ekspresi, identitas, dan komunikasi antar sesama [1]. Ekspresi wajah merupakan perubahan wajah yang terjadi sebagai reaksi terhadap keadaan emosional seseorang [2].

Klasifikasi ekspresi wajah merupakan salah satu bidang penelitian yang menarik dalam pengenalan pola dan visi komputer. Hal ini disebabkan oleh peran penting ekspresi wajah dalam komunikasi non-verbal dan aplikasinya yang luas, termasuk dalam sistem interaksi manusia-komputer, keamanan, dan analisis emosi [3].

Klasifikasi menjadi bagian penting dari analisis citra karena setiap citra akan dikelompokkan berdasarkan fitur atau karakteristik tertentu [4]. Untuk melakukan klasifikasi ekspresi wajah, dibutuhkan proses ekstraksi fitur untuk mengenali bentuk pola pada data citra beserta ciri-cirinya [5]. Metode ekstraksi fitur menjadi komponen penting dalam meningkatkan performa klasifikasi ekspresi wajah. *Stationary Wavelet Transform* (SWT) telah banyak diakui karena banyak kemampuannya untuk mengekstraksi fitur dari citra secara efisien, terutama dalam konteks pengolahan multi-resolusi yang mempertahankan informasi spasial dan frekuensi [6] [7]. SWT memiliki keunggulan dalam hal invariant translasi yang penting untuk menjaga konsistensi fitur yang diekstraksi dari citra yang memiliki translasi [8]. Namun, kendala utama SWT adalah dimensi fitur yang tinggi yang dapat menyebabkan beban komputasi yang

signifikan dan potensi *overfitting* pada model klasifikasi.

Untuk mengatasi masalah ini, *Discrete Cosine Transform* (DCT) dapat diterapkan bersama dengan SWT untuk mengurangi dimensi fitur. DCT dikenal karena kemampuannya untuk memadatkan energi sinyal pada beberapa koefisien penting, sehingga memungkinkan pengurangan dimensi tanpa kehilangan informasi yang signifikan [9]. Kombinasi antara SWT dan DCT diharapkan dapat memberikan representasi fitur yang lebih kompak, tetapi tetap informatif untuk tugas klasifikasi.

Beberapa studi sebelumnya telah menunjukkan bahwa penggabungan SWT dan DCT dapat meningkatkan performa dalam berbagai aplikasi pengenalan pola, termasuk dalam klasifikasi wajah [10]. Oleh karena itu, penelitian ini akan mengeksplorasi lebih lanjut efektivitas penggabungan SWT dan DCT dalam konteks ekstraksi fitur untuk klasifikasi ekspresi wajah. Hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan metode ekstraksi fitur yang lebih efektif untuk klasifikasi ekspresi wajah. Selain itu, penelitian ini juga diharapkan dapat memberikan wawasan baru mengenai strategi optimalisasi komputasi dalam pengenalan pola melalui kombinasi transformasi fitur.

2. TINJAUAN PUSTAKA

Berikut ini penjelasan mengenai berbagai literatur yang relevan dengan topik penelitian yang diangkat. Hal ini dilakukan untuk mendapatkan

gambaran secara menyeluruh tentang penelitian yang dilakukan.


2.1. Klasifikasi Ekspresi Wajah

Klasifikasi ekspresi wajah merupakan proses identifikasi dan pengenalan ekspresi emosi yang ditampilkan melalui gerakan atau perubahan pada wajah manusia. Ekspresi wajah merupakan salah satu bentuk komunikasi non-verbal yang sangat penting, memainkan peran krusial dalam interaksi manusia sehari-hari. Dalam konteks klasifikasi, ekspresi wajah telah menjadi subjek penelitian yang signifikan dengan aplikasi yang mencakup berbagai bidang, seperti sistem pengawasan, interaksi manusia-komputer, kesehatan mental, dan hiburan [2] [3].

2.2. Stationary Wavelet Transform

Stationary Wavelet Transform (SWT) adalah salah satu teknik transformasi yang digunakan dalam pengolahan sinyal dan citra untuk mengekstraksi informasi frekuensi dari berbagai resolusi tanpa kehilangan informasi spasial. Berbeda dengan *Discrete Wavelet Transform* (DWT) yang bersifat *shift-invariant*, SWT memiliki keunggulan dalam hal *shift-invariance*, yang membuatnya lebih sesuai untuk aplikasi di mana translasi dalam sinyal atau citra dapat mempengaruhi hasil analisis [11].

Secara teknis, SWT adalah varian dari DWT di mana proses *downsampling* yang biasa dilakukan pada DWT dihilangkan. Sebagai gantinya, SWT menggunakan filter *wavelet* dengan panjang yang meningkat secara eksponensial pada setiap level dekomposisi yang memungkinkan pengambilan sampel pada resolusi penuh pada setiap tahap [12]. Dengan tidak adanya *downsampling*, informasi spasial dan frekuensi dapat dipertahankan sepenuhnya, yang sangat penting dalam aplikasi pengolahan citra di mana detail halus dan fitur kecil harus diidentifikasi dengan presisi. Proses dekomposisi SWT akan menghasilkan empat *subband* berbeda yang dapat diilustrasikan seperti pada gambar 1 [13].



Gambar 1. Proses dekomposisi SWT

2.3. Discrete Cosine Transform

Discrete Cosine Transform (DCT) adalah salah satu teknik transformasi yang digunakan secara luas dalam pengolahan citra dan sinyal, terutama karena kemampuannya memfokuskan energi sinyal pada beberapa koefisien frekuensi yang signifikan. DCT bekerja dengan mengubah data spasial menjadi data frekuensi, yang memungkinkan pemisahan informasi penting dari detail yang kurang penting dalam sinyal


atau citra [14]. Dalam konteks pengolahan citra, DCT sangat efektif dalam kompresi citra karena mayoritas energi citra dapat direpresentasikan dengan sejumlah koefisien DCT yang membantu dalam mengurangi ukuran data secara signifikan tanpa kehilangan kualitas yang berarti [15]. Persamaan DCT 2 dimensi untuk setiap citra F dan koefisien matriks C dapat didefinisikan sebagai berikut [16].

$$\begin{cases} C_{pq} = \frac{2}{N} a_p a_q \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} f_{mn} \cos \frac{\pi(2m+1)p}{2N} \cos \frac{\pi(2n+1)q}{2N} \\ C_{pq} = \frac{2}{N} a_p a_q \sum_{p=0}^{N-1} \sum_{q=0}^{N-1} a_p a_q C_{pq} \cos \frac{\pi(2m+1)p}{2N} \cos \frac{\pi(2n+1)q}{2N} \end{cases} \quad (1)$$

di mana p, q, m , dan $n = 0, 1, 2, \dots, N-1$, dan jika $p = 0, q = 0, a_p = a_q = \frac{1}{\sqrt{2}}$; jika tidak, maka $a_p = a_q = 1$.

2.4. Multi-Layer Perceptron


Multi-Layer Perceptron (MLP) adalah salah satu jenis jaringan saraf tiruan yang paling mendasar dan telah digunakan secara luas dalam berbagai tugas klasifikasi. MLP terdiri dari beberapa lapisan neuron yang dihubungkan secara penuh antara lapisan *input*, lapisan tersembunyi (*hidden layers*), dan lapisan *output*. Setiap neuron dalam MLP menerapkan fungsi aktivasi pada kombinasi linear dari masukannya untuk menghasilkan *output* yang kemudian diteruskan ke lapisan berikutnya dalam jaringan [17]. Arsitektur MLP dapat diilustrasikan seperti pada gambar 2 dengan menggunakan 2 *hidden layers* [18].



Gambar 2. Arsitektur MLP dengan dua *hidden layers*

3. METODE PENELITIAN

Metode penelitian ini mencakup tahapan-tahapan mulai dari pengumpulan data, *preprocessing*, ekstraksi fitur, hingga implementasi dan evaluasi model klasifikasi.



Gambar 3. Alur Metode Penelitian

3.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah CKPLUS yang tersedia di Kaggle (<https://www.kaggle.com/datasets/shawon10/ckplus>).

Dataset ini adalah salah satu *dataset* yang sering digunakan dalam penelitian klasifikasi ekspresi wajah. CKPLUS berisi citra wajah dengan berbagai ekspresi, termasuk *anger*, *contempt*, *disgust*, *fear*, *happy*, *sadness*, dan *surprise*. Setiap citra dalam *dataset* dikelompokkan dalam folder yang diberi nama sesuai dengan ekspresi yang ditampilkan. Sebelum digunakan dalam pelatihan model, semua citra akan melalui tahap *preprocessing* dan ekstraksi fitur terlebih dulu.



Gambar 4. Contoh Citra Dataset

3.2. Preprocessing

Setelah data diambil dari *dataset* CKPLUS, langkah selanjutnya adalah *preprocessing* untuk meningkatkan kualitas citra dan mempersiapkannya untuk ekstraksi fitur. *Preprocessing* dimulai dengan *histogram equalization* yang bertujuan untuk meningkatkan kontras dengan meratakan distribusi intensitas piksel, sehingga detail wajah yang mungkin sulit terlihat pada citra dengan kontras rendah menjadi lebih jelas.

Selanjutnya, semua citra diubah ukurannya menjadi resolusi 48x48 piksel. Pemilihan resolusi ini dilakukan untuk memastikan konsistensi *input* ke model dan untuk mengurangi beban komputasi tanpa menghilangkan informasi penting dari citra. Tahap akhir dari *preprocessing* adalah *denoising* yang diterapkan untuk mengurangi *noise* pada citra. *Noise* pada citra dapat mengganggu proses ekstraksi fitur dan menurunkan akurasi klasifikasi, sehingga teknik *denoising* berbasis filter digunakan untuk menghilangkan *noise* sambil mempertahankan tepi dan detail penting pada citra wajah. Citra yang telah melalui tahap *preprocessing* ini kemudian siap untuk diekstraksi fiturnya.

3.3. Ekstraksi Fitur

Pada tahap ini, fitur-fitur penting dari citra wajah diekstraksi menggunakan dua pendekatan yang berbeda untuk kemudian digunakan dalam pelatihan model klasifikasi. Pendekatan pertama melibatkan penggabungan SWT dengan DCT. Proses ini dimulai dengan menerapkan SWT pada citra ekspresi wajah untuk menghasilkan representasi multi-resolusi yang mempertahankan informasi frekuensi dan spasial dari citra. Setelah koefisien SWT diperoleh, DCT kemudian diterapkan pada koefisien tersebut untuk mengompresi informasi menjadi koefisien *Direct Current* (DC). Koefisien DC yang dihasilkan digunakan sebagai fitur untuk model klasifikasi.

Pendekatan kedua hanya menggunakan SWT untuk mengekstraksi fitur dari citra wajah tanpa melibatkan DCT. Dalam metode ini, setelah SWT diterapkan pada citra, koefisien yang dihasilkan langsung digunakan sebagai fitur untuk pelatihan

model klasifikasi tanpa melalui tahap kompresi tambahan.

3.4. Pelatihan Model Klasifikasi

Setelah fitur-fitur diekstraksi dari citra wajah menggunakan kedua pendekatan yang berbeda, langkah selanjutnya adalah melatih model klasifikasi menggunakan MLP. Pelatihan model MLP dimulai dengan membagi *dataset* menjadi data latih dan data uji. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi kinerja model yang telah dilatih. Sebelum proses pelatihan, fitur-fitur yang diekstraksi dinormalisasi untuk memastikan bahwa semua fitur berada dalam rentang yang sama untuk menghindari masalah dominasi fitur dengan skala yang lebih besar selama proses pelatihan.

3.5. Evaluasi dan Perbandingan

Setelah model klasifikasi dilatih menggunakan fitur yang diekstraksi melalui dua pendekatan yang berbeda, langkah selanjutnya adalah melakukan evaluasi untuk menilai kinerja dari masing-masing model. Evaluasi dilakukan dengan menggunakan data uji yang tidak terlihat oleh model selama tahap pelatihan, untuk memastikan bahwa model dapat menggeneralisasi dengan baik terhadap data baru.

Kinerja model diukur menggunakan metrik evaluasi yang umum digunakan dalam tugas klasifikasi, yaitu akurasi, presisi, *recall*, dan *F1-score*. Hasil evaluasi menunjukkan bagaimana kinerja kedua pendekatan tersebut dalam klasifikasi ekspresi wajah.

4. HASIL DAN PEMBAHASAN

Pada bab ini, disajikan hasil dari penelitian yang telah dilakukan terkait dengan klasifikasi ekspresi wajah menggunakan dua metode ekstraksi fitur yang berbeda. Hasil dari setiap metode dievaluasi berdasarkan kinerja model klasifikasi yang dilatih menggunakan MLP. Analisis ini bertujuan untuk mengidentifikasi metode mana yang lebih efektif dalam menghasilkan model klasifikasi yang andal, serta untuk memberikan rekomendasi terkait penggunaan teknik ekstraksi fitur yang optimal dalam aplikasi praktis.

4.1. Hasil Preprocessing

Proses *preprocessing* yang diterapkan pada citra-citra dari *dataset* CKPLUS berhasil meningkatkan kualitas citra untuk keperluan ekstraksi fitur. Tahapan *preprocessing* meliputi *histogram equalization*, mengubah ukuran citra menjadi 48x48 piksel, konversi ke *grayscale*, dan *denoising*. Hasil dari *preprocessing* ini menunjukkan peningkatan kontras, pengurangan *noise*, serta penyesuaian ukuran dan format citra yang lebih konsisten.

Sebagai hasilnya, citra yang telah diproses memiliki detail wajah yang lebih jelas dan bebas gangguan *noise* yang sangat penting untuk meningkatkan akurasi dalam tahap ekstraksi fitur dan klasifikasi. Gambar 5 menampilkan perbandingan

antara citra asli dan citra yang telah melalui tahapan *preprocessing*, memperlihatkan bagaimana kualitas citra meningkat secara keseluruhan.



Gambar 5. Citra sebelum dan setelah *preprocessing*

4.2. Hasil Ekstraksi Fitur

Setelah menerapkan kedua metode ekstraksi fitur, yaitu penggabungan SWT dan DCT, serta SWT saja, didapatkan hasil fitur yang menunjukkan perbedaan signifikan dalam distribusi koefisien.

Pada metode SWT+DCT, hasil fitur menunjukkan bahwa DCT berhasil mengompresi informasi penting dari hasil *transformasi wavelet*, sehingga menghasilkan fitur yang lebih ringkas, tetapi tetap informatif. Sebaliknya, pada metode SWT saja, hasil fitur terdiri dari banyak koefisien dengan variasi yang lebih merata, yang menunjukkan bahwa informasi tidak dikompresi secara eksplisit, sehingga menghasilkan jumlah fitur yang lebih besar.

Tabel 1. Hasil ekstraksi fitur SWT+DCT

label	fitur1	fitur2	...	fitur71	fitur72
anger	0.128	0.279	...	-0.586	2.567
anger	0.203	2.431	...	-0.223	-1.345
...	...	...	...	...	...
surprise	0.135	1.398	...	-0.165	-0.022
surprise	0.076	1.324	...	-0.170	-0.003

Tabel 2. Hasil ekstraksi fitur SWT

label	fitur1	fitur2	...	fitur4606	fitur4607
anger	0	0	...	0.036	0.036
anger	0	0	...	0.518	0.290
...	...	...	...	...	...
surprise	0	0	...	0.009	-0.003
surprise	0	0	...	0.008	-0.001

4.3. Kinerja Model Klasifikasi

Kinerja model klasifikasi yang dilatih menggunakan fitur dari kedua pendekatan dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Tabel 1 di bawah ini merangkum hasil evaluasi model untuk setiap metode ekstraksi fitur.

Tabel 3. Hasil Kinerja Model Klasifikasi

Metode Ekstraksi Fitur	Akurasi	Presisi	Recall	F1-score
SWT + DCT	91%	89%	91%	81%
SWT Saja	95%	95%	95%	94%

Berdasarkan hasil di atas, model yang dilatih dengan fitur dari SWT saja menunjukkan kinerja yang

lebih baik dibandingkan dengan model yang menggunakan fitur dari SWT+DCT. Akurasi model dengan SWT saja mencapai 95%, lebih tinggi dibandingkan dengan 91% yang dicapai oleh model dengan SWT+DCT. Presisi, *recall*, dan *F1-score* juga menunjukkan peningkatan yang konsisten pada model dengan SWT saja.

Classification Report				
	precision	recall	f1-score	support
anger	0.25	0.33	0.29	3
contempt	0.00	0.00	0.00	2
disgust	1.00	0.70	0.82	10
fear	1.00	1.00	1.00	3
happy	0.96	1.00	0.98	24
sadness	0.92	1.00	0.96	12
surprise	0.91	1.00	0.95	20
accuracy			0.91	74
macro avg	0.72	0.72	0.71	74
weighted avg	0.89	0.91	0.89	74

Gambar 6. *Classification report* model dengan SWT+DCT

Classification Report				
	precision	recall	f1-score	support
anger	0.33	0.33	0.33	3
contempt	1.00	0.50	0.67	2
disgust	1.00	0.90	0.95	10
fear	1.00	1.00	1.00	3
happy	1.00	1.00	1.00	24
sadness	0.86	1.00	0.92	12
surprise	1.00	1.00	1.00	20
accuracy			0.95	74
macro avg	0.88	0.82	0.84	74
weighted avg	0.95	0.95	0.94	74

Gambar 7. *Classification report* model dengan SWT saja

Perbedaan kinerja ini dapat dikaitkan dengan karakteristik hasil ekstraksi fitur yang ditunjukkan pada tabel 1 dan tabel 2. Pada metode SWT+DCT, meskipun DCT berhasil mengompresi informasi penting dan menghasilkan fitur yang lebih ringkas, kompresi ini juga tampaknya mengurangi jumlah informasi yang tersedia bagi model untuk membedakan antara ekspresi yang berbeda. Hal ini terlihat dari hasil kinerja model yang lebih rendah pada semua metrik.

Sebaliknya, pada metode SWT saja, jumlah fitur yang lebih banyak dan distribusi koefisien yang lebih merata memungkinkan model untuk menangkap lebih banyak detail yang relevan untuk klasifikasi yang pada akhirnya meningkatkan kinerja model. meskipun fitur yang dihasilkan lebih banyak, model klasifikasi dapat memanfaatkan informasi yang lebih kaya untuk membuat prediksi yang lebih akurat dan konsisten.

4.4. Pembahasan Perbandingan Kinerja

Hasil evaluasi menunjukkan bahwa model yang menggunakan fitur dari SWT saja memiliki kinerja yang lebih baik dalam hal akurasi, presisi, *recall*, dan *F1-score* dibandingkan dengan model yang

menggunakan fitur dari kombinasi SWT dan DCT. Meskipun penggabungan SWT dan DCT bertujuan untuk mengurangi dimensionalitas fitur dan memfokuskan informasi pada beberapa koefisien penting, dalam kasus ini, pendekatan tersebut tampaknya tidak memberikan keuntungan signifikan dan malah menurunkan performa model.

Kemungkinan penyebab penurunan kinerja ini bisa disebabkan oleh hilangnya informasi penting selama proses kompresi oleh DCT, yang pada akhirnya mengurangi keefektifan model dalam mengenali pola yang relevan untuk klasifikasi ekspresi wajah. Sebaliknya, penggunaan SWT saja memungkinkan model untuk menangkap lebih banyak detail yang mungkin penting untuk meningkatkan akurasi dan konsisten prediksi.

4.5. Implikasi Hasil Penelitian

Hasil penelitian ini menunjukkan bahwa dalam kasus ini penggunaan SWT saja memberikan hasil yang lebih baik dalam klasifikasi ekspresi wajah dibandingkan dengan kombinasi SWT dan DCT. Ini menyiratkan bahwa kompresi informasi yang dilakukan oleh DCT mungkin tidak selalu bermanfaat, terutama jika informasi frekuensi yang dibuang ternyata penting untuk tugas klasifikasi.

Implikasi dari hasil ini mengarah pada pentingnya pemilihan metode ekstraksi fitur yang sesuai dengan karakteristik data dan tugas klasifikasi. Untuk aplikasi praktisi yang memerlukan akurasi tinggi, seperti dalam sistem pengenalan ekspresi wajah di lingkungan nyata, hasil ini menunjukkan bahwa pendekatan yang lebih sederhana dengan SWT saja dapat memberikan performa yang lebih baik. Rekomendasi untuk penelitian lebih lanjut adalah mengeksplorasi parameter dan kombinasi fitur yang berbeda untuk menemukan pendekatan yang optimal sesuai dengan kebutuhan spesifik aplikasi.

5. KESIMPULAN DAN SARAN

Penelitian ini telah mengevaluasi dan membandingkan kinerja dua metode ekstraksi fitur citra untuk klasifikasi ekspresi wajah, yaitu penggabungan SWT dengan DCT dan SWT saja. Hasil penelitian menunjukkan bahwa model klasifikasi yang menggunakan fitur dari SWT saja memberikan kinerja yang lebih baik dibandingkan dengan model yang menggunakan fitur dari kombinasi SWT dan DCT. Model dengan SWT saja mencapai akurasi yang lebih tinggi, menunjukkan kemampuan yang lebih konsisten dan akurat dalam mengklasifikasikan ekspresi wajah, sementara penambahan DCT tidak memberikan peningkatan kinerja yang signifikan dan justru dapat menurunkan efektivitas model. Kesimpulan ini mengindikasikan bahwa pendekatan yang lebih sederhana dengan hanya menggunakan SWT merupakan pilihan yang lebih optimal untuk klasifikasi ekspresi wajah. Sebagai saran, penelitian lebih lanjut disarankan untuk mengeksplorasi kombinasi lain dari teknik ekstraksi fitur atau mempertimbangkan pengaturan parameter yang lebih optimal untuk DCT agar dapat mempertahankan

informasi penting selama proses kompresi. Selain itu, pengujian pada dataset yang lebih beragam dan dalam kondisi lingkungan yang berbeda perlu dilakukan untuk memastikan generalisasi hasil penelitian ini dalam berbagai situasi.

DAFTAR PUSTAKA

- [1] AL Sigit Gunto, Edy Julianto, and Djoko Budiyanto, "Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network," *J. Inform. Atma Jogja*, vol. 3, no. 2, pp. 155–160, 2022, doi: 10.24002/jiaj.v3i2.6790.
- [2] A. D. W. M. Sidik *et al.*, "Pengenalan Ekspresi Wajah Menggunakan Teknik Filter Wavelet Gabor," *Fidel. J. Tek. Elektro*, vol. 3, no. 1, pp. 1–4, 2021, doi: 10.52005/fidelity.v3i1.84.
- [3] M. Sajjad *et al.*, "A comprehensive survey on deep facial expression recognition: challenges, applications, and future guidelines," *Alexandria Eng. J.*, vol. 68, pp. 817–840, 2023, doi: 10.1016/j.aej.2023.01.017.
- [4] A. N. Hilmi, E. Y. Puspaningrum, U. Pembangunan, N. Veteran, and J. Timur, "Implementasi Algoritma K-Nearest Neighbor (KNN) untuk Identifikasi Penyakit pada Tanaman Jeruk Berdasarkan Citra Daun Universitas Pembangunan Nasional ' Veteran ' Jawa Timur disebabkan oleh jamur Guignardia Citricarpa , penyakit Kanker yang disebabkan o," *Router J. Tek. Inform. dan Terap.*, no. 2, 2024.
- [5] S. P. Pratama, B. Rahmat, and F. T. Anggraeny, "Deteksi Ikan Dengan Menggunakan Algoritma ADABOOST-SVM," *J. Inform. dan Sist. Inf.*, vol. 1, no. 2, pp. 458–466, 2020.
- [6] A. Sadiq, I. F. Nizami, S. M. Anwar, and M. Majid, "Blind image quality assessment using natural scene statistics of stationary wavelet transform," *Optik (Stuttg.)*, vol. 205, no. March 2019, p. 164189, 2020, doi: 10.1016/j.ijleo.2020.164189.
- [7] A. Kumar, H. Tomar, V. K. Mehla, R. Komaragiri, and M. Kumar, "Stationary wavelet transform based ECG signal denoising method," *ISA Trans.*, vol. 114, pp. 251–262, Aug. 2021, doi: 10.1016/J.ISATRA.2020.12.029.
- [8] X. Y. Huang, M. S. Tan, H. R. Wu, L. Ouyang, and L. Liu, "An improved invariant wavelet transform," *Procedia Eng.*, vol. 29, pp. 1963–1968, 2012, doi: 10.1016/j.proeng.2012.01.244.
- [9] R. A. Alotaibi and L. A. Elrefaie, "Text-image watermarking based on integer wavelet transform (IWT) and discrete cosine transform (DCT)," *Appl. Comput. Informatics*, vol. 15, no. 2, pp. 191–202, 2019, doi: 10.1016/j.aci.2018.06.003.
- [10] S. S. Harakannavar, C. R. Prashanth, S. Patil, and K. B. Raja, "Face recognition based on SWT, DCT and LTP," *Stud. Comput. Intell.*, vol. 771, no. March, pp. 565–573, 2019, doi: 10.1007/978-981-10-8797-4_57.

- [11] C. Chonnaniyah, T. Osawa, and I. W. G. A. Karang, "Study of Internal Solitary Waves Feature Extraction Based on Stationary Wavelet Transform By Sentinel-1a Image in Lombok Strait," *ECOTROPHIC J. Ilmu Lingkungan. (Journal Environ. Sci.)*, vol. 13, no. 1, p. 29, 2019, doi: 10.24843/ejes.2019.v13.i01.p04.
- [12] G. P. Nason and B. W. Silverman, "The Stationary Wavelet Transform and some Statistical Applications," *Wavelets Stat.*, pp. 281–299, 1995, doi: 10.1007/978-1-4612-2544-7_17.
- [13] F. Umar and H. Darwis, "Watermarking Citra Digital Berwarna Menggunakan Stationary Wavelet Transform (Swt)," *Ilk. J. Ilm.*, vol. 11, no. 1, pp. 1–10, 2019, doi: 10.33096/ilkom.v11i1.409.1-10.
- [14] Anil K. Jain, *Fundamentals of Digital Image Processing*. 1989.
- [15] C. Zhao and C. Tong, "Research on DCT image compression algorithm based on dynamic energy analysis," *ACM Int. Conf. Proceeding Ser.*, 2019, doi: 10.1145/3358331.3358391.
- [16] C. Y. Pang, R. G. Zhou, B. Q. Hu, W. W. Hu, and A. El-Rafei, "Signal and image compression using quantum discrete cosine transform," *Inf. Sci. (Ny.)*, vol. 473, pp. 121–141, 2019, doi: 10.1016/j.ins.2018.08.067.
- [17] I. U. Rehman, M. M. Nasralla, and N. Y. Philip, "Multilayer perceptron neural network-based QoS-aware, content-aware and device-aware QoE prediction model: A proposed prediction model for medical ultrasound streaming over small cell networks," *Electron.*, vol. 8, no. 2, 2019, doi: 10.3390/electronics8020194.
- [18] M. Ramkumar, C. Ganesh Babu, K. Vinoth Kumar, D. Hepsiba, A. Manjunathan, and R. Sarath Kumar, "ECG Cardiac arrhythmias Classification using DWT, ICA and MLP Neural Networks," *J. Phys. Conf. Ser.*, vol. 1831, no. 1, 2021, doi: 10.1088/1742-6596/1831/1/012015.