



## Pengenalan Ekspresi Wajah Pengemudi Berbasis Fitur *Eigenface* dan *Gray Level Co-Occurance Matrice*

Sudirman S. Panna<sup>#1</sup>, Aprianto Alhamad<sup>#2</sup>, Kartika Chandra Pelangi<sup>#3</sup>

<sup>#</sup>Program Studi Teknik Informatika, Universitas Ichsan Gorontalo  
Jl. Achmad Najamudin 17, Kota Gorontalo, Indonesia

<sup>1</sup>sudirmanpanna@unisan.ac.id

<sup>2</sup>apriyanto86@gmail.com

<sup>3</sup>apelangie@gmail.com

**Abstrak**— Umumnya kecelakaan lalu lintas disebabkan oleh terjadinya penurunan konsentrasi saat berkendara yang diakibatkan oleh rasa kantuk yang dialami, terdapat 20% kecelakaan disebabkan oleh penurunan konsentrasi. Teknologi *computer vision* berupaya mengembangkan teknologi *driving assistance* dalam menyelesaikan persoalan kecelakaan lalu lintas. Penelitian sebelumnya terkait deteksi ekspresi wajah pengemudi menyimpulkan bahwa metode *eigenface* memiliki waktu komputasi yang cukup baik akan tetapi hanya mampu menghasilkan akurasi sebesar 80%, sehingganya dalam penelitian ini akan dilakukan pengabungan dua buah fitur ekstraksi (*eigenface* dan GLCM) serta algoritma ANN sebagai pengklasifikasi. Pada penelitian yang kami lakukan menunjukkan metode yang diusulkan dapat memberikan performa dengan nilai akurasi sebesar 83%, recall sebesar 86%, precision sebesar 81% dan F1-Score sebesar 83%.

**Kata kunci**— FER, Fatigue Detection, Eigenface, GLCM, ANN

### I. PENDAHULUAN

Pada umumnya, kecelakaan lalu lintas disebabkan oleh pengemudi yang mengalami penurunan konsentrasi saat berkendara, salah satu faktor penyebab terjadinya penurunan konsentrasi tersebut disebabkan oleh rasa mengantuk yang alami oleh seorang pengemudi [1], [2]. Data menunjukkan bahwa sekitar 20% kecelakaan yang terjadi disebabkan oleh penurunan konsentrasi pengemudi karena perasaan mengantuk yang dialami saat berkendara [2].

Saat ini kemajuan teknologi *computer vision* berupaya untuk mengembangkan sebuah teknologi *driving assistance* dalam menyelesaikan sejumlah persoalan di sektor transportasi yang salah satunya adalah deteksi rasa kantuk pada pengemudi [3]. Deteksi rasa kantuk sendiri merupakan salah satu masalah yang berkaitan pengenalan ekspresi wajah. Sebagaimana diketahui bahwa persoalan pengenalan ekspresi wajah pada beberapa penelitian terdahulu banyak dilakukan sejumlah penelitian untuk

pengembangan teknologi di bidang HCI, *surveillance system* dan *human entertainment* [3], [4].

Sejumlah penelitian telah dilakukan sebelumnya yang berkaitan dengan persoalan deteksi ekspresi wajah pada seorang pengemudi, seperti yang dilakukan oleh Irtija, Nafis, et al. dalam penelitian tersebut menggunakan pendekatan *face landmark* untuk mendeteksi rasa kantuk pada wajah pengemudi [1], dari hasil percobaan yang dilakukan telah diperoleh hasil evaluasi kinerja dari metode yang diusulkan yakni dengan nilai akurasi yang hanya berkisar di angka 80%. Pada penelitian lainnya yang dilakukan oleh Ahsan, MD Manjurul et al, pada penelitian tersebut disimpulkan bahwa penggunaan pendekatan *eigenface* mampu memberikan performa yang sangat baik dalam melakukan proses pengenalan ekspresi wajah hanya saja membutuhkan waktu komputasi yang cukup besar dalam prosesnya [5].

Pada penelitian ini akan mengusulkan pendekatan *eigenface* yang kemudian di kombinasikan dengan *Gray-Level Co-occurrence Matrice* (GLCM) untuk memperoleh fitur statistik dari hasil ekstraksi fitur wajah yang dilakukan oleh pendekatan *eigenface*, upaya penggabungan kedua tersebut merupakan solusi yang memadai untuk menutupi kekurangan dari kinerja penggunaan metode *eigenface* yang membutuhkan waktu komputasi yang besar dalam melakukan proses pengenalan, sebagaimana penelitian yang dilakukan oleh Garg, Meenakshi, disampaikan bahwa pendekatan GLCM mampu untuk mereduksi waktu komputasi suatu algoritma *machine learning* karena pendekatan GLCM dapat memberikan output hanya beberapa fitur saja berupa nilai-nilai statistik [6], [7], sehingganya jumlah dimensi data menjadi jauh lebih kecil dibandingkan dengan penggunaan metode *eigenface* secara mandiri. Selainnya melakukan penggabungan dua metode fitur ekstraksi sekaligus, pada penelitian ini juga akan menggunakan metode *artificial neural network* sebagai metode pengklasifikasi dalam melakukan pengenalan ekspresi wajah pengemudi, penggunaan metode *artificial*

neural network ini didasari dari sejumlah penelitian yang dilakukan sebelumnya yang menyatakan bahwa penggunaan algoritma ini mampu memberikan hasil yang baik karena dapat bekerja dengan baik pada data yang sifatnya *non-linear* [8], [9].

Tujuan akhir dari penelitian ini adalah untuk menghasilkan sebuah informasi mengenai kinerja dari penggunaan metode yang diusulkan, dengan harapan mampu memberikan masukan dalam pengembangan sebuah teknologi *driving assistance* guna mengurangi resiko kecelakaan pada sektor transportasi yang disebabkan oleh penurunan konsentrasi pada pangerudi.

II. METODE PENELITIAN

Penelitian yang dilaksanakan akan dilakukan dalam beberapa tahapan yang diawali dengan proses pengumpulan data, kemudian dilakukan proses pengolahan pra pengolahan data dan seterusnya hingga diperoleh hasil kinerja atau performa dari model yang dirancang yakni penggunaan pendekatan *eigenface* dan GLCM sebagai ekstraksi fitur dan algoritma *Artificial Neural Network* (ANN) sebagai pengklasifikasi. Secara jelas dapat digambarkan pada gambar dibawah ini.



Gambar 1. Metode penelitian

A. Hasil Pengumpulan Data

Sebagai bahan percobaan pada penelitian ini adalah dengan menggunakan *dataset* publik dengan nama *yawning detection dataset* (YAWDD). Adapun bahan data gambar yang digunakan adalah sebagai berikut :



Gambar 2. Yawning Detection Dataset [10]

B. Pra Pengolahan Data

Pada proses pra pengolahan data citra yang digunakan pada penelitian ini, kami melakukan dua buah proses untuk menyiapkan data citra yang ada sebelum dilakukan ekstraksi fitur, yakni :

1) *Peningkatan kualitas citra*: Operasi peningkatan kualitas citra ini perlu untuk dilakukan untuk mengatasi permasalahan yang terdapat pada data gambar yang digunakan pada penelitian ini memiliki tingkat pencahayaan yang beragam sehingganya akan mempengaruhi proses segmentasi citra wajah yang akan dilakukan pada proses selanjutnya.

Adapun proses peningkatan kualitas citra dilakukan dengan menggunakan cara oprasi perkalian secara spasial pada nilai-nilai pixel citra dengan kernel berukuran 3 x 3 yang ada, tentunya dengan komposisi tersebut akan menghasilkan citra yang lebih sesuai dengan kebutuhan sistem nantinya, karena pada data gambar yang digunakan pada penelitian ini masih banyak terdapat sejumlah noise, dengan proses peningkatam kualitas citra tersebut maka jumlah noise pada citra dapat di reduksi.

2) *Segmentasi citra wajah*: Pada proses segmentasi citra wajah, pada penelitian ini kami menggunakan modul *Dlib*, dimana modul *Dlib* menggunakan pendekatan atau metode *HoG* dan *SVM* untuk mendeteksi wajah pada suatu citra dengan memanfaatkan *face landmark*.

C. Ekstraksi Fitur

1) *Eigenface*: Pada umumnya pendekatan *eigenface* digunakan untuk melakukan ekstraksi fitur wajah dalam melakukan proses pengenalan wajah maupun pengenalan ekspresi wajah dan dapat memberikan hasil kinerja yang sangat baik [11]. pendekatan *eigenface* menggunakan sejumlah parameter dalam melakukan proses ekstraksi fitur wajah diantaranya *average image value* (persamaan 1), *covariance matrices* (persamaan 2), *mean image value* (persamaan 3), dan *eigenvalue* dan *eigenvalue* (persamaan 4) [12], seperti yang ditunjukkan pada persamaan berikut :

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma^i \tag{1}$$

Dimana  $\Gamma$  adalah *image vector* dan  $M$  adalah jumlah data gambar yang ada.

$$C = A^T A \tag{2}$$

Dimana  $A$  merupakan hasil proses persamaan ke 3

$$\Phi_i = \Gamma^i - \Psi \tag{3}$$

$$A^T A X_i = \lambda_i X_i \tag{4}$$

Dimana  $\lambda$  adalah *eigenvalue* dan  $X$  adalah *eigen vector*

2) *Gray-Level Co-Occurance Matrice (GLCM)*: Ekstraksi fitur dengan menggunakan pendekatan GLCM menjadi bagian dari sejumlah pendekatan yang ada yang paling umum digunakan dalam melakukan analisis citra dari sudut pandang tekstur pada sebuah citra. Pendekatan GLCM dalam proses ekstraksi fitur memanfaatkan hasil kalkulasi dari *matrix co-occurance* yang diperoleh dari proses perhitungan jumlah nilai-nilai pixel yang saling berelasi dengan merujuk pada dua parameter yakni nilai *angle* pixel citra dan jarak ketetanggaan antar pixel [13], [14], dalam metode GLCM dapat digunakan nilai *angle* 0, 45, 90 dan 135 derajat, sementara untuk jarak ketetanggaan antar pixel dapat digunakan nilai 1, 2, 3 dan seterusnya. Setelah terbentuknya matriks GLCM maka sudah dapat di hitung nilai-nilai fitur statistic diantaranya *contrast*, *homogeneity*, *correlation* dan *energy*[15].

Berikut ini persamaan yang dapat digunakan untuk menghasilkan nilai-nilai statistik pada metode GLCM.

$$homogeneity = \sum_i \sum_j \frac{1}{1+i-j^2} g_{ij} \tag{5}$$

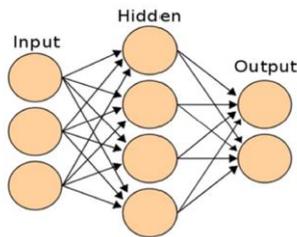
$$contrast = \sum_i \sum_j (i-j)^2 g_{ij} \tag{6}$$

$$Energy = \sum_i \sum_i g_{ij}^2 \tag{7}$$

$$correlation = \frac{\sum_i \sum_j (ij)g_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \tag{8}$$

D. Proses Klasifikasi menggunakan Artificial Neural Network (ANN)

Algoritma ANN merupakan salah satu algoritma pengklasifikasi yang cukup banyak digunakan dalam proses pengenalan wajah [9], algoritma ANN bekerja secara *non-linear* yang terdiri atas input layer, hidden layer dan output layer [8]. Salah satu proses *learning* yang paling populer digunakan untuk ANN adalah *backpropagation* [16]. Sehingga pada penelitian ini akan menggunakan pendekatan *backpropagation* dalam penerapan algoritma ANN untuk proses klasifikasi. Pada penelitian ini akan digunakan arsitektur jaringan yang terdiri dari 4 unit *input layer*, kemudian terdapat 3 unit *hidden layer* yang masing-masing memiliki jumlah *neuron* sebanyak 512 *neuron* pada *hidden layer* 1, dan 1024 *neuron* untuk *hidden layer* 2 dan 3, serta terdapat 1 unit *output layer* Secara umum arsitektur dari algoritma ANN digambarkan sebagai berikut :



Gambar 3. Gambaran umum arsitektur ANN [8]

E. Evaluasi Model

Proses evaluasi atau pengujian model yang digunakan pada penelitian ini akan menggunakan *confussion matrix*, evaluasi ini memiliki tujuan untuk mengetahui capaian kinerja dari model yang dihasilkan oleh metode yang digunakan pada penelitian ini. Beberapa parameter ukur dari kinerja pada model yang dihasilkan adalah nilai akurasi, *recall*, *precision* dan *F1-Score*. Adapun persamaan yang digunakan untuk masing-masing parameter tersebut di tunjukkan pada persamaan 9 s/d 12.

$$Accuracy = \frac{t_p + t_n}{t_p + t_n + f_p + f_n} \tag{9}$$

$$Recall = \frac{t_p}{t_n + f_p} \tag{10}$$

$$Precision = \frac{t_p}{t_p + f_p} \tag{11}$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{12}$$

III. HASIL DAN PEMBAHASAN

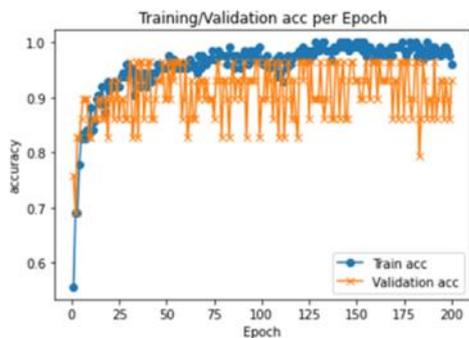
Pada sejumlah percobaan yang dilakukan pada penelitian tersebut, diperoleh hasil ekstraksi fitur wajah dengan cara melakukan penggabungan atau *combine output* hasil ekstraksi antara metode *eigenface* dan *GLCM*, sebagaimana telah diuraikan sebelumnya ekstraksi fitur menggunakan *eigenface* bekerja dengan menggunakan pendekatan *principle component analysis* untuk dapat menghasilkan nilai *eigen value* dan *eigen vector* yang kemudian menjadi sebagai nilai hasil fitur ekstraksi, kemudian dari hasil tersebut diproses kembali dengan menggunakan pendekatan *GLCM* dengan menentukan parameter *angle* nya sebesar 0 derajat dan nilai ketetanggan *pixel* nya adalah sebesar 2 *pixel* dengan proses pembentukan matriks nya menggunakan pendekatan *uniform*, sebagaimana diuraikan sebelumnya, penggunaan metode *GLCM* ini bertujuan untuk mereduksi jumlah fitur dari hasil proses ekstraksi fitur dengan *eigenface* dengan hanya menghasilkan empat unit nilai statistik diantaranya: *contrast*, *ASM*, *Correlation* serta *energy*. Tentunya dengan hanya empat unit fitur saja dapat diperoleh waktu proses komputasi yang lebih kecil pada saat proses klasifikasi sehingga lebih releavan ketika diimplementasikan secara *real time*. Berikut ini hasil proses ekstraksi fitur menggunakan *eigenface* dan *GLCM*.

TABEL I  
HASIL EKSTRAKSI FITUR *EIGENFACE* DAN *GLCM*

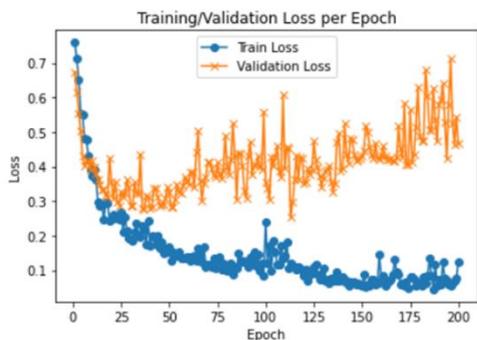
ID	X1	X2	X3	X4
data 1	0.029	0.064	0.099	0.418
data 2	0.073	0.059	0.199	0.434
data 3	0.053	0.001	0.158	0.258
data 4	0.055	0.217	0.163	0.774
data 5	0.049	0.086	0.150	0.696
...	...	...	...	...
data n	0.013	0.055	0.053	0.267

Dari hasil ekstraksi fitur yang disajikan diatas, menunjukkan bahwa seluruh data citra yang terdapat dalam dataset dapat didireduksi dimensinya menjadi lebih kecil yakni menjadi empat fitur nilai untuk setiap gambar, untuk proses ekstraksi fitur akan dilakukan pada setiap data *training* dan *testing*.

Kemudian untuk proses klasifikasi pada penelitian ini digunakan algoritma *Artificial Neural Network* (ANN) dengan proses pembelajaran yang digunakan pada algoritma tersebut adalah menggunakan *Backpropogation* yang terdiri atas 4 *input layer*, 512 *neuron* pada *hidden layer* 1, 1024 *neuran* pada *hidden layer* 2, 1024 *neuron* pada *hidden layer* 3 dan 1 *output layer*. Dalam proses *training* data untuk menemukan model terbaik dari algoritma ANN diperoleh nilai akurasi *training* dan validasi sebagaimana yang ditunjukkan pada grafik berikut.



Gambar 4. Grafik akurasi untuk data *training* dan validasi



Gambar 5. Grafik nilai *loss* untuk data *training* dan validasi

Pada grafik dalam gambar 5, menunjukkan bahwa data *training* yang digunakan mampu menghasilkan nilai akurasi sementara yang secara rata-rata berada pada angka 0.95 untuk data *training* dan 0.90 untuk data validasi. Sementara pada grafik dalam gambar 6 menunjukkan bahwa proses pemodelan yang dilakukan oleh algoritma ANN dengan proses learning dengan pendekatan *backpropagation* dapat menghasilkan nilai *loss* yang secara rata-rata berapa pada angka 0.1 untuk proses pada data *training* dan 0.4 poin untuk saat proses data validasi.

Setelah diperoleh model terbaik dari algoritma ANN, kemudian dilakukan proses klasifikasi terhadap sebanyak 30 data uji untuk proses evaluasi kinerja dari model yang telah diperoleh dari hasil *training* yang dilakukan. Pada proses klasifikasi yang dilakukan diperoleh data berikut yang disajikan pada *confusion matrix* di bawah ini.

TABEL II  
Matriks Hasil Proses Klasifikasi

Kelas	Normal	Mengantuk
Normal	13	2
Mengantuk	3	12

Pada tabel 2 dapat dijelaskan bahwa sebanyak 13 data berlabel “Normal” dapat diklasifikasikan dengan benar dan 12 data berlabel “Mengantuk” juga dapat diklasifikasikan dengan benar sehingga total data yang berhasil diklasifikasi dengan benar sebanyak 25 unit data. Sementara itu terdapat 5 data uji yang tidak dapat diklasifikasikan dengan benar.

Dari hasil proses klasifikasi yang dilakukan pada 30 data uji yang ada, maka dapat dilakukan proses evaluasi kinerja

dari model yang diperoleh. Hasil pengukuran kinerja model yang digunakan diuraikan pada tabel 3 dibawah ini.

TABEL III  
Hasil Pengukuran Kinerja Model

No	Pengukuran	Nilai
1	Accuration	83 %
2	Recall	86 %
3	Precision	81 %
4	F1-Score	83 %

Dari pengukuran kinerja model diatas dapat diketahui bahwa model yang diperoleh dari proses *training* yang dilakukan mampu menunjukkan kinerja yang cukup baik dengan nilai akurasi, *recall*, *Precision*, dan *F1-Score* yang memadai sebagaimana yang ditunjukkan pada tabel hasil pengukuran. Meskipun hasil pengukuran tersebut tergolong cukup baik, akan tetap nilai-nilai pengukuran tersebut mengalami sedikit penurunan saat diterapkan pada data uji ketika dibandingkan dengan pada saat proses *training* data yang mampu menghasilkan nilai akurasi sampai pada angka 94%, tentunya hal tersebut disebabkan oleh besarnya *gap* nilai *loss* antara data *training* dan data validasi yang diperoleh saat pelatihan model,

IV. KESIMPULAN

Dari eksperimen yang telah dilakukan pada penelitian ini, dapat disimpulkan bahwa metode yang diusulkan yakni penggunaan *eigenface* dan GLCM sebagai fitur ekstraksi dapat memberikan jumlah fitur yang lebih sedikit yang tentunya memiliki kontribusi dalam mereduksi jumlah waktu komputasi dari algoritma ANN yang digunakan sebagai algoritma pengklasifikasi untuk menentukan kelas ekspresi wajah pengemudi. Selain itu, dapat juga disimpulkan bahwa metode yang diusulkan secara keseluruhan dapat memberikan model dengan performa yang cukup memadai berdasarkan hasil pengukuran kinerja model menggunakan *confussion matrix*, dengan memperoleh nilai *accuracy* sebesar 83%, nilai *recall* sebesar 86%, nilai *precision* sebesar 81% dan nilai *F1-Score* sebesar 83%. Sehingga berdasarkan hasil pengukuran tersebut bahwa metode yang diusulkan dapat menjadi rujukan dalam mengembangkan sebuah teknologi *driving assistance* guna mengatasi persoalan kecelakaan lalu lintas yang diakibatkan oleh penurunan konsentrasi pengemudi dalam berkendara.

UCAPAN TERIMA KASIH / ACKNOWLEDGMENT

Terima kasih yang sebesar-besarnya kepada Direktorat Riset, Teknologi dan Pengabdian Pada Masyarakat (DRTPM) Pendidikan Tinggi yang telah membiayai penelitian ini.

## REFERENSI

- [1] N. Irtija, M. Sami, and M. A. R. Ahad, "Fatigue detection using facial landmarks," *Jt. Conf. ISASE-MAICS 2018 - 4th Int. Symp. Affect. Sci. Eng. 2018, 29th Mod. Artif. Intell. Cogn. Sci. Conf.*, pp. 1–6, 2020.
- [2] A. Bulygin and A. Kashevnik, "Image-Based Fatigue Detection of Vehicle Driver: State-of-the-Art and Reference Model," in *2021 30th Conference of Open Innovations Association FRUCT*, 2021, pp. 24–31.
- [3] S. A. Khan, S. Hussain, S. Xiaoming, and S. Yang, "An Effective Framework for Driver Fatigue Recognition Based on Intelligent Facial Expressions Analysis," *IEEE Access*, vol. 6, pp. 67459–67468, 2018.
- [4] H. Xiao *et al.*, "On-Road Driver Emotion Recognition Using Facial Expression," *Appl. Sci.*, vol. 12, no. 2, 2022.
- [5] M. M. Ahsan, Y. Li, J. Zhang, M. T. Ahad, and K. D. Gupta, "Evaluating the Performance of Eigenface, Fisherface, and Local Binary Pattern Histogram-Based Facial Recognition Methods under Various Weather Conditions," *Technologies*, vol. 9, no. 2, p. 31, 2021.
- [6] N. Yunari, E. M. Yuniarno, and M. H. Purnomo, "Indonesian batik image classification using statistical texture feature extraction Gray Level Co-occurrence Matrix (GLCM) and Learning Vector Quantization (LVQ)," *J. Telecommun. Electron. Comput. Eng.*, vol. 10, no. 2–3, pp. 67–71, 2018.
- [7] M. Garg and G. Dhiman, "A novel content-based image retrieval approach for classification using GLCM features and texture fused LBP variants," *Neural Comput. Appl.*, vol. 33, no. 4, pp. 1311–1328, 2021.
- [8] M. Islam, G. Chen, and S. Jin, "An overview of neural network," *Am. J. Neural Networks Appl.*, vol. 5, no. 1, pp. 7–11, 2019.
- [9] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, "State-of-the-art in artificial neural network applications: A survey," *Heliyon*, vol. 4, no. 11, p. e00938, 2018.
- [10] S. Abtahi, M. Omidyeganeh, S. Shirmohammadi, and B. Hariri, "YawDD: A yawning detection dataset," in *Proceedings of the 5th ACM multimedia systems conference*, 2014, pp. 24–28.
- [11] R. Chandra, S. An-Nissa, and E. M. Zamzami, "Comparative Analysis of Eigenface and Learning Vector Quantization (LVQ) to Face Recognition," *J. Phys. Conf. Ser.*, vol. 1566, no. 1, 2020.
- [12] Erwin, M. Azriansyah, N. Hartuti, M. Fachrurrozi, and B. Adhi Tama, "A study about principle component analysis and eigenface for facial extraction," *J. Phys. Conf. Ser.*, vol. 1196, no. 1, 2019.
- [13] Z. Abbas, M. Rehman, S. Najam, and S. M. D. Rizvi, "An efficient gray-level co-occurrence matrix (GLCM) based approach towards classification of skin lesion," in *2019 amity international conference on artificial intelligence (AICAI)*, 2019, pp. 317–320.
- [14] B. Dhruv, N. Mittal, and M. Modi, "Study of Haralick's and GLCM texture analysis on 3D medical images," *Int. J. Neurosci.*, vol. 129, no. 4, pp. 350–362, 2019.
- [15] A. Pariyandani, D. A. Larasati, E. P. Wanti, and Muhathir, "Klasifikasi Citra Ikan Berformalin Menggunakan Metode K-NN dan GLCM," *Pros. Semin. Nas. Teknol. Inform.*, vol. 2, no. 1, pp. 42–47, 2019.
- [16] O. I. Abiodun *et al.*, "Comprehensive review of artificial neural network applications to pattern recognition," *IEEE Access*, vol. 7, pp. 158820–158846, 2019.