

Klasifikasi Citra Elektrokardiogram untuk Deteksi Penyakit Jantung Menggunakan Metode GLCM dan SVM

Andreas Panangian Tamba^{a1}, I Gede Arta Wibawa^{a2}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Jalan Raya Kampus UNUD, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia
¹andreastamba04@gmail.com
²gede.arta@unud.ac.id

Abstract

Heart disease is a major cause of death worldwide. Electrocardiogram (ECG) is a common method used to detect heart abnormalities. Analyzing ECG signals requires expertise and can be time-consuming. This study investigated the use of machine learning to classify ECG images for heart disease detection. The proposed method utilizes Gray Level Co-occurrence Matrix (GLCM) for feature extraction such as Dissimilarity, contrast, energy, ASM, homogeneity and Correlation. Meanwhile using Support Vector Machine (SVM) for the classification. We achieved an accuracy of 99.61% using this approach. The results suggest that the combination of GLCM and SVM can be a valuable tool for ECG image classification and potentially aid in early and accurate diagnosis of heart disease.

Keywords: *Electrocardiography, Support Vector Machine, Gray Level Co-Occurrence Matrix, Classification, Myocardial Infarction*

1. Pendahuluan

Analisis dan interpretasi electrokardiogram (ECG) adalah prosedur yang sangat penting dalam diagnosa dan pengawasan berbagai kondisi kardiovaskular. ECG merekam aktivitas listrik jantung dan mencatat impuls listrik yang bergerak melalui otot jantung, memberikan gambaran rinci tentang fungsi jantung (sitasi). ECG sangat penting di Indonesia, di mana penyakit kardiovaskular telah menjadi penyebab kematian terbanyak sejak tahun 1996. Keterlambatan kesadaran masyarakat tentang pentingnya menjaga kesehatan jantung telah menyebabkan peningkatan kematian akibat penyakit kardiovaskular. Namun, dengan kemajuan teknologi, ECG telah menjadi metode yang paling umum digunakan untuk mendeteksi kondisi kardiovaskular, menawarkan cara non-invasif dan relatif murah untuk diagnosa dan pengawasan kesehatan jantung [1]. Sinyal ECG normal biasanya terdiri dari tiga komponen utama: gelombang P, kompleks QRS, dan gelombang T. Gelombang P merepresentasikan aktivitas listrik atria ketika mereka berkontraksi untuk mengumpulkan darah ke ventrikel. Kompleks QRS merepresentasikan aktivitas listrik ventrikel ketika mereka berkontraksi untuk mengumpulkan darah keluar dari jantung. Gelombang T merepresentasikan aktivitas listrik ventrikel ketika mereka mengalami kontraksi. Komponen-komponen ini sangat penting dalam diagnosa berbagai kondisi kardiovaskular, termasuk aritmia, penyakit koroner, dan gagal jantung [2]. Analisis sinyal ECG adalah prosedur yang kompleks yang memerlukan pemahaman yang lebih dalam tentang morfologi sinyal ECG itu sendiri. Ini termasuk morfologi gelombang P, hubungan antara gelombang P dan kompleks QRS, serta keberadaan defleksi abnormal dalam lead seperti avR. Analisis ini sangat penting dalam diagnosa kardiovaskular, karena memberikan informasi yang sangat berharga tentang aktivitas listrik jantung dan keberadaan abnormalitas potensial. Namun, tidak semua profesional medis memiliki kemampuan untuk menganalisis sinyal ECG dengan akurat, yang mengapa sangat penting untuk memiliki pemahaman yang lebih dalam tentang ECG dan komponen-komponennya [3]. Analisis ECG dengan teknologi komputasi menggunakan teknik machine learning dan simulasi komputer untuk menganalisis sinyal ECG secara otomatis dan mendeteksi

abnormalitas. Pendekatan ini telah ditunjukkan efektif dalam mendeteksi aritmia dan kondisi kardiovaskular lainnya, serta dapat membantu mengurangi beban kerja profesional medis sementara meningkatkan akurasi diagnosa. Analisis ECG dengan teknologi komputasi juga memungkinkan pengembangan simulasi ECG yang disesuaikan, yang dapat digunakan untuk menerjemahkan hasil ECG dan menghubungkan perubahan struktural atau elektrofisiologis dengan abnormalitas ECG [4]. Melihat pengaruh dari ECG pada kondisi jantung, penulis berasumsi bahwa citra yang didapatkan dari gelombang-gelombang pada ECG dapat digunakan untuk klasifikasi menggunakan machine learning. Penelitian sebelumnya bertujuan untuk mengenali gangguan jantung, terutama fibrilasi atrium dan aritmia, melalui pemeriksaan sinyal elektrokardiogram (EKG) [5]. Dalam penelitian sebelumnya, berhasil menerapkan metode Support Vector Machine (SVM) untuk mengklasifikasi fibrilasi atrium dengan tingkat keakuratan sebesar 92,9% untuk spesifisitas dan 80,5% untuk sensitivitas. Di sisi lain, penelitian lain menggunakan SVM untuk mengklasifikasikan aritmia dengan tingkat keakuratan mencapai 92% [6]. Dalam konteks penelitian ini, menekankan penggunaan Grey Level Co-Occurrence Matrix (GLCM) untuk mengekstrak fitur tekstur dari citra rekaman EKG. Penerapan GLCM untuk ekstraksi fitur memberikan peningkatan pada hasil akurasi klasifikasi meskipun studi sebelumnya lebih menitikberatkan pada analisis sinyal langsung dari EKG.[7] Mengikuti jejak penelitian-penelitian yang serupa, penelitian ini mengadopsi metode-metode yang telah digunakan dalam penelitian sebelumnya. Pendekatan tersebut melibatkan ekstraksi fitur dari dari gelombang ECG menggunakan Gray Level Co-Occurrence Matrix (GLCM), yang diikuti dengan klasifikasi menggunakan model SVM. Diharapkan bahwa dengan mengoptimalkan parameter SVM, penelitian ini akan menghasilkan tingkat akurasi yang signifikansi. Selain itu, diharapkan juga bahwa visualisasi yang diberikan dari Confusion Matrix akan memperjelas pemahaman terhadap hasil penelitian ini dalam konteks klasifikasi citra ECG.

2. Metode Penelitian


2.1. Akuisisi Data

Data yang digunakan pada penelitian ini adalah data sekunder. Data ini diakuisisi dari kaggle.com yaitu dataset ECG Image Dataset from the National Heart Foundation of Bangladesh. Dataset ini berisikan citra-citra yang dikategorikan menjadi 3 kelas: Abnormal Heartbeat Patients, Myocardial Infarction Patients, Normal Persons. Jumlah data tiap kelas adalah sebagai berikut:

Tabel 1. Jumlah Citra Pada Tiap Kelas

Kelas	Abnormal Heartbeat	Myocardial Infarction	Normal Person
Jumlah Citra	813	716	852


Dengan contoh citra gelombang ECG adalah sebagai berikut:



Gambar 1. Citra Gelombang ECG

2.2. Preprocessing

Setelah diberikan masukan berupa gambar dan label dari gambar-gambar tersebut, pada tahap *preprocessing image* akan dilakukan 3 proses seperti yang terdapat pada gambar 1.



Gambar 2. Flowchart Preprocessing

a. Cropping

Input berupa citra dari gambar gelombang, terdapat informasi yang tidak diperlukan yakni teks dari penjelasan citra tersebut. Hal itu tidak diperlukan karena tidak berpengaruh pada hasil klasifikasi. Maka akan dilakukan pemotongan yang akan menghasilkan area sebesar 2089x1217 px.

b. Resize

Image dengan ukuran 2089x1217 px tersebut merupakan ukuran yang berlebihan. Sehingga dilakukan *resize* citra menjadi lebih kecil dengan lebar 250. *Resize* dilakukan dengan tetap mempertahankan *aspect ratio* sehingga gambar hanya menjadi lebih kecil bukan dipotong.

c. Grayscale

Citra RGB yang merupakan matrix besar dengan 3 elemen di setiap pixelnya, diubah menjadi 1 dengan range 0-255 atau gambar menjadi hitam putih. Hal ini diperlukan untuk mendapatkan histogram dari agar dapat dilakukan ekstraksi fitur menggunakan GLCM.

2.3. Ekstraksi Fitur dengan GLCM

Level Co-occurrence Matrix (GLCM) adalah metode untuk mengekstrak fitur tekstur dari citra digital dengan menganalisis distribusi spasial dari intensitas piksel. GLCM memodelkan hubungan antara dua piksel pada jarak dan arah tertentu dalam citra [8]. Fitur-fitur seperti kontras, energi, homogenitas, dan korelasi dapat diekstrak dari GLCM untuk mewakili sifat tekstur citra. Ekstraksi Fitur menggunakan *glcm* disini menggunakan 4 sudut yang melambangkan arah yakni 135, 90, 45, dan 0 derajat [9][10]. Fitur yang diekstraksi dengan GLCM yakni *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *asm*, *energy*. Setiap fitur tersebut di dapatkan menggunakan persamaan:

Dissimilarity

$$\sum_{i,j=0}^{levels-1} P_{i,j} |i - j| \tag{1}$$

Correlation

$$\sum_{i,j=0}^{levels-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \tag{2}$$

Homogeneity

$$\sum_{i,j=0}^{levels-1} \frac{P_{i,j}}{1+(i-j)^2} \tag{3}$$

Contrast

$$\sum_{i,j=0}^{levels-1} P_{i,j} (i - j)^2 \tag{4}$$

ASM

$$\sum_{i,j=0}^{levels-1} P_{i,j}^2 \tag{5}$$

Energy

$$\sqrt{ASM} \tag{6}$$

2.4. Min-Max Normalization


Selanjutnya, dengan menggunakan metode normalisasi min-max, nilai hasil ekstraksi fitur Co-occurrence Matrix Gray Level (GLCM) diskalakan ke rentang 0 hingga 1 [11]. Rumus standar metode normalisasi min-max adalah sebagai berikut:

$$v' = \frac{v - \min A}{\max A - \min A} \tag{7}$$

Di mana nilai_asli nilai_asli adalah nilai yang diinginkan untuk dinormalisasi, nilai_minimum nilai_minimum adalah nilai minimum dari semua nilai, dan nilai_maksimum nilai_maksimum adalah nilai maksimum dari semua nilai. Untuk menghindari bias yang mungkin muncul akibat perbedaan skala di antara fitur yang diekstraksi, teknik ini berguna.

2.5. Support Vector Machine

Algoritma pembelajaran mesin yang disebut Support Vector Machine (SVM) digunakan untuk menyelesaikan masalah klasifikasi dan regresi. SVM bekerja dengan menemukan garis pemisah terbaik, juga dikenal sebagai hyperplane, yang memisahkan data, yang memiliki nilai positif jika berada di kanan garis pemisah atau negatif jika berada di kiri garis pemisah. SVM dapat menangani regresi, klasifikasi, dan bahkan klusterisasi. Performansi algoritma ini sangat dipengaruhi oleh pemilihan hyperparameter SVM. Untuk ilustrasi, prediksi error pada SVM non-linear dipengaruhi secara signifikan oleh parameter C dan gamma. [12]. Untuk melakukan klasifikasi citra, SVM menggunakan label dari citra yang telah ditentukan sebelumnya (*supervised learning*). Input vektor dapat diubah atau dipetakan ke dimensi yang lebih besar oleh SVM. Data dipecah oleh *hyperplane* optimal dan dua *hyperplane* paralel lainnya yang terletak di tiap sisi dari *hyperplane* optimal. *Hyperparameters* adalah tiga parameter yang dimiliki SVM: kernel, C, dan Gamma. SVM, yang pertama kali dibuat oleh Vapnik dan Cortes pada tahun 1992, adalah optimal margin classifier. Salah satu metode klasifikasi pembelajaran mesin yang paling penting saat ini adalah SVM.



Gambar 3. Visualisasi Hyperplane pada SVM (sumber: Dicoding.com)

2.6. Grid Search

Grid Search adalah metode yang digunakan dalam pengoptimalan parameter pada model SVM, khususnya pada Support Vector Machines (SVM). Metode ini melibatkan variasi sistematis parameter dalam rentang yang telah ditentukan dan evaluasi performa model untuk setiap kombinasi. Tujuan dari Grid Search adalah untuk menemukan set parameter terbaik yang menghasilkan performa terbaik pada model. Grid Search penting karena memungkinkan eksplorasi parameter yang sangat luas, yang sangat penting dalam menemukan kombinasi parameter terbaik untuk model. Hal ini sangat signifikan pada SVM, di mana performa model sangat dipengaruhi oleh pilihan parameter dan fungsi kernel. Grid Search memastikan bahwa semua kombinasi parameter dipertimbangkan, yang dapat menghasilkan hasil yang lebih baik dibandingkan dengan metode lain yang mungkin tidak mempertimbangkan seluruh ruang parameter [13]. Grid Search bekerja dengan mendefinisikan rentang untuk setiap parameter dan kemudian membagi setiap rentang menjadi beberapa langkah yang telah ditentukan. Proses ini diulangi untuk semua parameter, menghasilkan grid dari semua kombinasi yang mungkin. Setiap kombinasi kemudian dievaluasi menggunakan metrik performa, seperti akurasi cross-validation, untuk menentukan set parameter terbaik. Proses ini biasanya diulangi beberapa kali untuk memastikan bahwa kombinasi terbaik tidak terlewatkan karena fluktuasi acak dalam data [12].

2.7. Confusion Matrix

Confusion Matrix adalah sebuah tabel yang digunakan untuk menampilkan hasil perhitungan dari data yang diklasifikasi sebagai benar atau salah yang dibandingkan dengan label sebenarnya pada data yang telah diklasifikasi. Tabel ini memperlihatkan jumlah prediksi yang benar dan salah yang dibuat oleh model, serta jumlah yang sebenarnya dari setiap kelas. Dengan demikian, Confusion Matrix memberikan gambaran yang lebih jelas tentang performa model dalam memprediksi kelas data yang diklasifikasi.

Tabel 2. Confusion Matrix 2 Kelas

		Kelas Prediksi	
		Positif	Negatif
Kelas Sebenarnya	Positif	TP	FN
	Negatif	FP	TN

Namun dikarenakan terdapat 3 kelas maka Confusion Matrix yang dibuat adalah sebagai berikut:

Tabel 3. Confusion Matrix 3 Kelas

		Kelas Prediksi		
		Kelas 1	Kelas 2	Kelas 3
Kelas Sebenarnya	Kelas 1	T1	F2	F3
	Kelas 2	F1	T2	F3
	Kelas 3	F1	F2	T3

Dengan pengukuran akurasi adalah sebagai berikut

$$Accuracy = \frac{T1+T2+T3}{T1+F1+F1+T2+F2+F2+T3+F3+F3} \times 100\% \quad (8)$$

Dari confusion matriks tersebut, selain accuracy dapat dilakukan perhitungan nilai precision, recall, dan F1-Score, yang akan dijelaskan dengan persamaan dibawah ini [12]:

$$Precision_i = \frac{T_i}{T_i + \sum_{j \neq i} F_{ji}} \quad (9)$$

$$Recall_i = \frac{T_i}{T_i + \sum_{j \neq i} F_{ij}} \quad (10)$$

$$F1Score_i = \frac{2 \times Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (11)$$

Keterangan:

T_i : True Positif untuk kelas i

F_{ji} : False Positif untuk kelas j yang diprediksi dengan kelas i

F_{ij} : False Negatif untuk kelas i yang diprediksi sebagai kelas j

3. Hasil dan Diskusi

3.1. Penentuan Parameter

Dalam penelitian ini, dilakukan pengujian parameter pada metode Support Vector Machine (SVM) dengan kernel rbf untuk membandingkan citra pada data EKG. Parameter yang diuji adalah nilai C (0.1, 1, 10, 100, 1000) dan gamma (0.0001, 0.001, 0.01, 0.1, 1). Proses grid search dilakukan untuk menemukan kombinasi parameter terbaik yang menghasilkan model SVM dengan performa optimal.

Tabel 4. Akurasi C 0.1

Param C	Param Gamma	Kernel	Akurasi
0.1	1	rbf	0.710871806
0.1	0.1	rbf	0.710871806
0.1	0.001	rbf	0.878177286
0.1	0.0001	rbf	0.858125989

Tabel 5. Akurasi C 10

Param C	Param Gamma	Kernel	Akurasi
10	1	rbf	0.994621027
10	0.1	rbf	0.994621027
10	0.001	rbf	0.995108826
10	0.0001	rbf	0.991195647

Tabel 6. Akurasi C 100

Param C	Param Gamma	Kernel	Akurasi
100	1	rbf	0.994621027
100	0.1	rbf	0.994621027
100	0.001	rbf	0.995108826
100	0.0001	rbf	0.994619828

Tabel 7. Akurasi C 1000


Param C	Param Gamma	Kernel	Akurasi
1000	1	rbf	0.994621027
1000	0.1	rbf	0.994621027
1000	0.001	rbf	0.995108826
1000	0.0001	rbf	0.994619828

Grid search dilakukan untuk menemukan kombinasi parameter terbaik dalam model Support Vector Machine (SVM) dengan kernel rbf untuk membandingkan citra pada data elektrokardiogram (EKG). Parameter yang diuji adalah nilai C dan gamma, dengan variasi nilai tertentu untuk setiap parameter. Dalam proses grid search, berbagai kombinasi nilai C dan gamma dievaluasi menggunakan metode cross-validation pada data pelatihan. Setiap kombinasi parameter tersebut digunakan untuk melatih model SVM dan kemudian dievaluasi kinerjanya menggunakan data uji. Hasil grid search ditampilkan dalam tabel-tabel akurasi, yang menunjukkan performa model SVM dengan berbagai nilai C dan gamma. Dari hasil ini, dapat dilihat bahwa variasi akurasi terjadi tergantung pada kombinasi parameter yang digunakan. Dari hasil pengujian parameter pada SVM dengan kernel rbf untuk membandingkan citra pada data EKG, dapat disimpulkan bahwa terdapat variasi dalam akurasi model tergantung pada nilai-nilai C dan gamma yang dipilih. Namun, pada rentang nilai yang diuji, model SVM cenderung memberikan akurasi yang tinggi, mencapai nilai tertinggi sekitar 99.5% dengan beberapa kombinasi parameter. Oleh karena itu, penting untuk melakukan grid search untuk menemukan parameter terbaik yang menghasilkan model SVM dengan performa tertinggi dalam membandingkan citra pada data EKG.

3.2. Confusion Matrix

Setelah menyelesaikan *grid search*, langkah selanjutnya adalah melakukan pengujian model menggunakan data testing. Tujuannya adalah untuk mengevaluasi kinerja SVM dengan parameter terbaik yang telah ditentukan sebelumnya. Pengujian ini penting untuk memastikan bahwa model mampu menggeneralisasi pola dengan baik pada data testing yang belum diuji. Evaluasi menggunakan pendekatan perhitungan beberapa metrik evaluasi standar, termasuk precision, accuracy, dan F1 score, yang akan dihitung berdasarkan confusion matrix. Melalui langkah ini, kesesuaian model dalam membandingkan citra pada data EKG dapat dipahami

secara lebih komprehensif, yang mana kritis untuk memvalidasi hasil grid search sebelumnya serta untuk memastikan bahwa model yang dihasilkan dapat diandalkan dalam konteks aplikasi praktis.



Gambar 4. Confusion Matrix

Hasil evaluasi model menunjukkan kinerja yang sangat baik, dengan angka akurasi, presisi, recall, dan F1 score mencapai tingkat yang sangat tinggi. Akurasi sebesar 99.61% menunjukkan tingkat keseluruhan keakuratan model dalam memprediksi kelas. Presisi sebesar 99.61% menggambarkan tingkat keakuratan dalam mengidentifikasi kelas positif, sedangkan recall sebesar 99.61% mengukur kemampuan model dalam menangkap semua instance yang sebenarnya positif. F1 score, yang merupakan rata-rata harmonis antara presisi dan recall, juga sangat tinggi, mencapai 99.61%. Dari hasil confusion matrix, terlihat bahwa model hanya melakukan sedikit kesalahan, dengan hanya 2 prediksi salah pada kelas pertama dan tidak ada prediksi yang salah pada kelas kedua dan ketiga. Ini menunjukkan bahwa model sangat baik dalam membedakan antara kelas dan memiliki kemampuan yang sangat baik dalam mengidentifikasi kelas yang berbeda dalam data EKG.

4. Kesimpulan

Penelitian ini mengeksplorasi potensi metode GLCM dan SVM dalam mengklasifikasikan citra elektrokardiogram (EKG) untuk mendeteksi penyakit jantung. Hasil menunjukkan bahwa kombinasi GLCM dan SVM mampu mencapai akurasi klasifikasi yang tinggi, mencapai 99.61%. Hal ini menunjukkan efektivitas metode ini dalam membedakan antara kelas EKG yang berbeda, seperti Normal, Abnormal Heartbeat, dan Myocardial Infarction. Penggunaan parameter C dan gamma yang tepat dalam SVM terbukti penting untuk mencapai akurasi optimal. Meskipun penelitian ini menunjukkan hasil yang menjanjikan, beberapa keterbatasan perlu dipertimbangkan. Jumlah data yang digunakan relatif kecil dan hanya satu metode ekstraksi fitur (GLCM) yang dieksplorasi. Selain itu, model SVM belum diuji dengan data pasien nyata. Penelitian selanjutnya direkomendasikan untuk mengatasi keterbatasan ini. Penggunaan data yang lebih besar dan beragam, serta eksplorasi metode ekstraksi fitur lain, dapat meningkatkan keandalan dan generalisasi metode ini. Pengujian model SVM dengan data pasien nyata juga penting untuk memvalidasi efektivitasnya dalam konteks klinis. Secara keseluruhan, penelitian ini memberikan bukti awal bahwa metode GLCM dan SVM memiliki potensi sebagai alat bantu yang efektif untuk diagnosis penyakit jantung melalui analisis citra EKG.

Daftar Pustaka

- [1] M. Rifali and D. Irmawati, "Sistem Cerdas Deteksi Sinyal Elektrokardiogram (EKG) untuk Klasifikasi Jantung Normal dan Abnormal Menggunakan Jaringan Syaraf Tiruan (JST)," *Elinvo (Electronics, Informatics, Vocat. Educ.*, vol. 4, no. 1, pp. 49–55, 2019, doi: 10.21831/elinvo.v4i1.28242.
- [2] A. Lyon, A. Mincholé, J. P. Martínez, P. Laguna, and B. Rodriguez, "Computational techniques for ECG analysis and interpretation in light of their contribution to medical advances," *J. R. Soc. Interface*, vol. 15, no. 138, 2018, doi: 10.1098/rsif.2017.0821.
- [3] N. Rafie, A. H. Kashou, and P. A. Noseworthy, "ECG Interpretation: Clinical Relevance, Challenges, and Advances," *Hearts*, vol. 2, no. 4, pp. 505–513, 2021, doi: 10.3390/hearts2040039.
- [4] X. Xu, S. Jeong, and J. Li, "Interpretation of Electrocardiogram (ECG) Rhythm by Combined CNN and BiLSTM," *IEEE Access*, vol. 8, pp. 125380–125388, 2020, doi: 10.1109/ACCESS.2020.3006707.
- [5] M. Rofii, "Identifikasi Fibrilasi Atrium Pada Isyarat Elektrokardiogram (Ekg) Menggunakan Support Vector Machine (Svm)," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 9, no. 1, pp. 231–240, 2018, doi: 10.24176/simet.v9i1.2080.
- [6] Q. Ayuni, R. Cahya Wihandika, and N. Yudistira, "Klasifikasi Aritmia Dari Hasil Elektrokardiogram Menggunakan Metode Support Vector Machine," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 6, pp. 2163–2170, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [7] M. Sofie and A. Rizal, "Klasifikasi Citra Rekaman Sinyal Elektrokardiogram Menggunakan Metode Analisis Tekstur, K-Nn Dan Multilayer Perceptron," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 7, no. 1, p. 233, 2016, doi: 10.24176/simet.v7i1.509.
- [8] N. Neneng, K. Adi, and R. Isnanto, "Support Vector Machine Untuk Klasifikasi Citra Jenis Daging Berdasarkan Tekstur Menggunakan Ekstraksi Ciri Gray Level Co-Occurrence Matrices (GLCM)," *J. Sist. Inf. Bisnis*, vol. 6, no. 1, p. 1, 2016, doi: 10.21456/vol6iss1pp1-10.
- [9] S. Handayani, A. Zuhdi, and R. Shofiati, "Implementation of Gray Level Co-occurrence Matrix (GLCM) and Support Vector Machine (SVM) Methods for Recognition of Batik Bekasi Motifs Implementation of Gray Level Co-occurrence Matrix (GLCM) and Support Vector Machine (SVM) Methods for Recognition of B," *Intelmatiks*, vol. 2, no. 2, pp. 67–72, 2022, doi: 10.25105/itm.v2i2.14423.
- [10] L. M. Wisudawati, "Klasifikasi Tumor Jinak Dan Tumor Ganas Pada Citra Mammogram Menggunakan Gray Level Co-Occurrence Matrix (Glcm) Dan Support Vector Machine (Svm)," *J. Ilm. Inform. Komput.*, vol. 26, no. 2, pp. 176–186, 2021, doi: 10.35760/ik.2021.v26i2.4897.
- [11] I. B. W. B. Adi Putra, L. G. Astuti, A. E. Karyawati, I. W. Santiyasa, C. R. A. Pramarta, and I. G. S. Astawa, "Diagnosis Penyakit Retinopati Diabetes Menggunakan SVM dengan Optimasi Algoritma Genetika," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 11, no. 3, p. 457, 2022, doi: 10.24843/jlk.2023.v11.i03.p01.
- [12] M. Fajri and A. Primajaya, "Komparasi Teknik Hyperparameter Optimization pada SVM untuk Permasalahan Klasifikasi dengan Menggunakan Grid Search dan Random Search," *J. Appl. Informatics Comput.*, vol. 7, no. 1, pp. 14–19, 2023, doi: 10.30871/jaic.v7i1.5004.
- [13] I. Syarif, A. Prugel-Bennett, and G. Wills, "SVM Parameter Optimization using Grid Search and Genetic Algorithm to Improve Classification Performance," *TELKOMNIKA (Telecommunication Comput. Electron. Control.)*, vol. 14, no. 4, p. 1502, 2016, doi: 10.12928/telkomnika.v14i4.3956.

Halaman ini sengaja dibiarkan kosong