

Analisis Area Wajah Berdasarkan Tekstur Wajah untuk Mengidentifikasi Risiko Penyakit Jantung Koroner

Budi Sunarko¹, Agung Adi Firdaus², Yudha Andriano Rismawan², Anan Nugroho¹

¹ Program Studi Teknik Elektro, Fakultas Teknik, Universitas Negeri Semarang, Semarang, Jawa Tengah 50229, Indonesia

² Program Studi Pendidikan Teknik Informatika dan Komputer, Fakultas Teknik, Universitas Negeri Semarang, Semarang, Jawa Tengah 50229, Indonesia

[Diserahkan: 25 Juni 2024, Direvisi: 17 Januari 2025, Diterima: 6 Februari 2025]

Penulis Korespondensi: Budi Sunarko (email: budi.sunarko@mail.unnes.ac.id)

INTISARI — Belum memadainya skrining awal penyakit jantung koroner (PJK) menekankan perlunya alat skrining yang lebih efektif. Penelitian sebelumnya menunjukkan bahwa akurasi klasifikasi yang dicapai hanya sebesar 72,73%, yang masih dianggap belum memadai. Penelitian ini bertujuan mengembangkan dan mengevaluasi model pembelajaran mesin atau mendiagnosis PJK menggunakan fitur tekstur wajah dan membandingkan kinerjanya pada berbagai area wajah, sehingga rekomendasi perbaikan dapat diberikan. Penelitian ini meliputi pembuatan model pembelajaran mesin yang mengekstraksi fitur tekstur dari enam *regions of interest* (ROI) menggunakan *gray level co-occurrence matrix* (GLCM) dan algoritma *artificial neural network* (ANN). *Dataset* yang digunakan adalah citra wajah individu yang didiagnosis PJK (positif) dan individu yang sehat (negatif). Area wajah yang diidentifikasi antara lain kerutan di sudut luar mata (*crow's feet*) sebelah kanan, sudut dalam mata (*canthus*) kanan, pangkal hidung, dahi, *canthus* kiri, dan *crow's feet* kiri. Sebanyak 132 set data (72 positif dan 60 negatif PJK) dibagi menjadi 80% ($n = 160$) data latih dan 20% ($n = 26$) data uji. Model yang dikembangkan mencapai akurasi yang cukup baik, yaitu 76,9%. Hasil penelitian menunjukkan bahwa dua area wajah, yaitu *canthus* dan dahi, menunjukkan hasil yang sangat baik dengan akurasi masing-masing sebesar 80,97% dan 90%. Sementara itu, area *crow's feet* dan pangkal hidung menunjukkan akurasi yang baik, yaitu masing-masing 73,50% dan 65%. Berdasarkan hasil yang diperoleh, penelitian ini terbukti mampu menjadi model skrining awal PJK dengan akurasi yang baik dan waktu eksekusi yang lebih cepat.

KATA KUNCI — Penyakit Jantung Koroner, Fitur Tekstur Wajah, *Artificial Neural Network*, *Region of Interest*.

I. PENDAHULUAN

Penyakit jantung koroner (PJK) merupakan jenis penyakit kardiovaskular yang banyak terjadi dan merupakan salah satu penyebab utama kematian di seluruh dunia [1], [2]. Meskipun termasuk penyakit yang parah, terdapat gap yang signifikan antara kesadaran publik dan upaya skrining awal PJK. Banyak individu yang enggan untuk berpartisipasi dalam pemeriksaan kesehatan rutin karena kurangnya pemahaman, kesadaran, dan adanya kendala keuangan. Di wilayah pedesaan, sumber daya kesehatan sering kali terbatas, bahkan di pusat kota sekalipun masih ditemui kendala substansial, seperti biaya yang tinggi dan waktu tunggu yang lama [3]. Akibatnya, penyakit jantung dapat berkembang tanpa disadari hingga mencapai tahap kritis, sehingga berpotensi menyebabkan komplikasi yang parah. Oleh karena itu, strategi pencegahan, termasuk di antaranya adalah diagnosis dini, sangatlah penting.

Teknik diagnostik yang tersedia untuk PJK meliputi angiografi koroner, *electrocardiograms* (ECG), tes darah, tes *treadmill*, *computed tomography* (CT) *scans*, dan *magnetic resonance imaging* (MRI) *scans* [4]. Namun, sebagian besar metode-metode tersebut memiliki biaya tinggi dan efisiensi yang rendah, bahkan beberapa di antaranya bersifat invasif [5]. Faktor-faktor ini menyebabkan banyak orang mengalami kesulitan untuk mengakses pemeriksaan jantung dini, terutama karena adanya kendala ekonomi dan keterbatasan teknologi. Oleh karena itu, alat skrining PJK yang lebih efisien dan hemat biaya, yang dapat meningkatkan aksesibilitas dan kesadaran masyarakat terhadap deteksi dini PJK, merupakan kebutuhan yang mendesak.

Program pembelajaran mesin menawarkan metode yang konsisten, cepat, dan akurat untuk mendiagnosis PJK [5]. Dengan memanfaatkan kemampuan para ahli, sistem ini dapat

membantu dalam menilai risiko PJK dan memberikan rekomendasi tindak lanjut yang efektif dengan presisi yang tinggi. Teknologi yang dapat dicapai melalui kecerdasan buatan ini memastikan diagnosis yang efisien dan akurat. Sebagian besar penelitian kecerdasan buatan tentang prediksi penyakit jantung menggunakan data teks dalam bentuk catatan medis sebagai parameter untuk menentukan keputusan. Kekurangan dari metode tersebut adalah efisiensinya yang rendah. Menggunakan citra wajah dapat menjadi salah satu solusi untuk permasalahan ini [6], [7]. Penggunaan citra wajah dapat mempercepat proses diagnostik secara signifikan, sehingga dapat menjadi alat yang sangat efisien untuk skrining awal PJK.

Wajah setiap individu merupakan pengenalan *bioidentity* yang unik bagi manusia. Wajah memberikan informasi tentang usia, jenis kelamin, ras, kesadaran, suasana hati, dan kondisi kesehatan [8]. Teori utama penelitian ini adalah korelasi antara tekstur wajah dan status penyakit, sebagaimana dibuktikan dalam penelitian-penelitian berbasis kuantitatif dan kualitatif [3], [6]–[9]. Dalam penelitian sebelumnya, uji visualisasi menunjukkan bahwa dahi dan hidung lebih efektif sebagai *region of interest* (ROI) untuk mendeteksi risiko PJK dibandingkan area wajah lainnya [6]. Sebaliknya, daerah mata kiri dan kanan memberikan hasil yang tidak konsisten, sedangkan telinga yang paling tidak efektif. Beberapa penelitian telah menunjukkan hubungan yang kuat antara kadar kolesterol total plasma atau *low-density lipoprotein* (LDL) yang tinggi dan berbagai kondisi, seperti PJK, resistensi insulin, diabetes melitus (DM), hipertensi, stroke, dislipidemia, obesitas, dan hiperurisemia, terutama pada individu dengan *xanthelasma* [10], [11]. LDL berfungsi sebagai pengangkut utama kolesterol, trigliserida, dan lipid lainnya ke seluruh tubuh [12].

Xanthelasma palpebrarum (XP), yang ditandai dengan plak hitam di sudut dalam kelopak mata, terutama pada kelopak mata atas, terdiri atas sel *xanthoma*—histiosit berbusa dengan endapan lipid intraseluler di dermis retikuler atas [10], [12]. *Xanthelasma* dikenal sebagai penanda aterosklerosis, yaitu penyebab utama penyakit kardiovaskular [12]. Selain itu, pasien dengan PJK sering kali menunjukkan ciri-ciri wajah tertentu, seperti kerutan di dahi, pola kebotakan rambut yang khas, penebalan kelopak mata atas, dan lipatan telinga [11], [13]. Penelitian lain juga telah mengidentifikasi ciri-ciri lain yang ditemukan pada pasien PJK, termasuk lipatan preaurikular, lengkungan kornea, dan akrokordon [14].

Beberapa penelitian, khususnya di Tiongkok, telah mengeksplorasi aplikasi pencitraan wajah untuk mengidentifikasi PJK [6], [7]. Penelitian terkait masih menggunakan delapan area wajah, yaitu sudut luar mata (*crow's feet*) bagian kanan dan kiri, sudut dalam mata (*canthus*) bagian kanan dan kiri, hidung, dahi, daun telinga kanan, dan daun telinga kiri [6]. Kinerja model klasifikasi pada penelitian tersebut tergolong kurang tinggi, yakni sebesar 72,73%. ROI dengan kinerja yang buruk, seperti daun telinga, masih digunakan [6]. Penelitian terbaru [4] menggunakan enam area wajah bagian depan untuk mengembangkan beberapa model klasifikasi, yaitu *crow's feet* bagian kanan dan kiri, *canthus* bagian kanan dan kiri, hidung, dan dahi, tanpa menggunakan daun telinga. Kinerja model terbaik dicapai pada sekitar 92,8% dari *area under curve* (AUC). Berdasarkan temuan tersebut, diperlukan perbaikan untuk meningkatkan kinerja sistem secara keseluruhan melalui pemilihan ROI. Berdasarkan penelitian relevan sebelumnya, tidak semua area wajah menunjukkan atau memiliki korelasi dengan kondisi kesehatan kardiovaskular, sehingga hanya beberapa ROI yang berkorelasi positif yang dipilih. Memilih ROI yang tepat berdasarkan tekstur kulit wajah dapat memberikan hasil yang lebih baik untuk membedakan pasien PJK dan individu yang sehat [6].

Berdasarkan latar belakang tersebut, diperlukan analisis terhadap kinerja masing-masing ROI. Hal tersebut merupakan salah satu dasar teori untuk meningkatkan akurasi teknologi ini karena penggunaan komponen-komponen dengan akurasi rendah dapat menurunkan akurasi diagnostik. Penelitian ini penting dilakukan mengingat pemilihan area-area yang memiliki akurasi tinggi akan mengoptimalkan akurasi sistem diagnosis. Kebaruan yang diberikan melalui penelitian ini antara lain modifikasi penggunaan ROI sebanyak enam lokasi, yang dilakukan dengan tidak mengikutsertakan telinga. Dengan demikian, selain mencapai tujuan utama untuk meningkatkan kinerja, penelitian ini dapat meningkatkan efisiensi sistem. Oleh karena itu, penelitian tentang analisis pemilihan area wajah untuk keperluan diagnostik dasar merupakan salah satu upaya untuk meningkatkan kinerja dan efisiensi metode diagnostik PJK dengan memanfaatkan berbagai tekstur wajah.

Penelitian ini berupaya membuat dan mengevaluasi model pembelajaran mesin untuk mendiagnosis PJK dengan memanfaatkan citra wajah, khususnya pada fitur tekstur kulit wajah. Selain itu, penelitian ini berupaya membandingkan kinerja berbagai area wajah guna memberikan rekomendasi untuk meningkatkan efisiensi dan efektivitas aplikasi diagnosis PJK yang mengandalkan citra wajah. Melalui penelitian ini, model pembelajaran mesin dapat digunakan untuk mengembangkan teknologi skrining awal PJK yang sangat efisien, sehingga meningkatkan akses dan kesadaran masyarakat terhadap PJK.

II. PENELITIAN TERKAIT

Penelitian di Tiongkok baru-baru ini mempelajari tentang deteksi penyakit dengan teknologi kecerdasan buatan, khususnya dalam diagnosis PJK melalui citra wajah. Deteksi PJK telah dikembangkan dengan metode yang memanfaatkan delapan fitur wajah, meliputi *canthus* kanan dan kiri, *crow's feet* kanan dan kiri, pangkal hidung, dahi, serta dua cuping telinga [6]. Studi ini menggunakan *gray level co-occurrence matrix* (GLCM) sebagai algoritma ekstraksi fitur, kemudian mengklasifikasikannya ke dalam dua kelas (positif atau negatif) menggunakan algoritma *decision tree* dan *random forest*. Namun, metode ini masih belum mencapai akurasi yang tinggi, dengan akurasi tertinggi tercatat sekitar 72,73% saat memanfaatkan algoritma *random forest*. Akurasi yang lebih tinggi diperlukan, sehingga teknologi medis yang siap pakai di masyarakat dapat diciptakan. Selain itu, kenyataan bahwa beberapa kelompok orang menganggap cuping telinga sebagai area pribadi membuat metode ini tidak efektif.

Penelitian lain yang dilakukan adalah kelayakan model *deep learning* untuk mengklasifikasikan PJK menggunakan citra wajah [7]. Penelitian ini menunjukkan bahwa prediksi PJK dapat dilakukan menggunakan citra wajah dengan memanfaatkan *deep convolutional neural network* dan algoritma klasifikasi Diamond-Forrester. ROI yang digunakan dalam penelitian ini meliputi pipi, dahi, hidung, sekitar mata, mulut, cuping telinga, dan dagu. Pada penelitian ini, hasil tertinggi dicapai oleh AUC menggunakan metode *deep learning*, dengan akurasi sebesar 73%. Diperlukan penelitian lebih lanjut untuk meningkatkan kinerja prediksi, sehingga teknologi ini lebih bermanfaat dan dapat diaplikasikan dalam dunia medis.

Studi lain mengembangkan model pembelajaran mesin untuk mengevaluasi risiko PJK dengan menganalisis fitur tekstur wajah dengan memanfaatkan algoritma GLCM [4]. Studi ini berfokus pada ROI wajah tertentu, termasuk *crow's feet*, *canthus*, hidung, dan dahi. Fitur-fitur ini kemudian diklasifikasikan menggunakan algoritma *support vector machine* (SVM), *decision tree*, dan *artificial neural network* (ANN). Enam fitur GLCM—kontras, ketidakmiripan (*dissimilarity*), homogenitas, energi, korelasi, dan *angular second moment* (ASM)—diekstraksi dari citra ROI. Model ANN mengungguli model lain, mencapai kinerja tertinggi dengan skor AUC sebesar 92,8%. Penelitian terbaru menunjukkan bahwa diperlukan penelitian lebih lanjut untuk mengoptimalkan model prediksi PJK berdasarkan analisis wajah, sehingga area wajah paling relevan dan memiliki akurasi tinggi dapat teridentifikasi.

III. METODOLOGI

Penelitian ini dilaksanakan di Universitas Negeri Semarang, Indonesia pada tanggal 1 Juni 2021 sampai dengan bulan Juni 2022. Sebagian besar *dataset* diperoleh dari Rumah Sakit Dr. Kariadi dan Rumah Sakit Nasional Diponegoro di Semarang, Indonesia. Selain itu, *dataset* juga diperoleh dari penduduk yang berdomisili di Jawa Tengah dan memenuhi kriteria inklusi. Alat-alat yang digunakan dalam penelitian ini meliputi komputer pribadi ASUS Vivobook dengan prosesor Core i7 dan RAM 12 GB, *smartphone* iPhone 8 Plus dengan resolusi kamera 12 MP, dan kamera Fuji XA3. Sementara itu, perangkat lunak yang digunakan adalah aplikasi Anaconda Navigator versi 3, Spyder (Python 3.9), Orange Python 3, Microsoft Excel 2016, dan OpenCV. Metodologi penelitian ini terdiri atas

akuisisi data, prapemrosesan, ekstraksi fitur, pelatihan dan pengujian model, serta analisis klasifikasi.

A. DATASET

Kriteria inklusi untuk sampel positif meliputi pria dan wanita Indonesia berusia antara 20 sampai 59 tahun yang didiagnosis positif PJK oleh dokter spesialis jantung serta bersedia untuk mendukung dokumentasi medis. Citra wajah diambil menggunakan perangkat dengan resolusi minimal 13 MP jika menggunakan DSLR atau 48 MP jika menggunakan kamera belakang *smartphone*. Citra yang diambil memperlihatkan tampilan wajah penuh dari leher ke atas (depan, kanan, kiri, dan atas). Kriteria eksklusi untuk sampel positif mencakup individu yang memiliki penyakit atau kondisi serius pada wajah yang tampak jelas, serta individu yang memiliki citra wajah yang kabur atau tidak jelas, sehingga tekstur wajah tidak terlihat. Demikian pula, untuk sampel negatif, kriteria inklusi meliputi pria dan wanita Indonesia berusia antara 20 sampai 59 tahun, yang didiagnosis negatif PJK oleh dokter spesialis jantung. Sementara itu, persyaratan resolusi dan kualitas citra sama dengan kriteria sebelumnya. Kriteria eksklusi untuk sampel negatif serupa dengan sampel positif, yaitu tidak mengikutsertakan individu yang memiliki kondisi serius pada wajah yang tampak atau memiliki citra wajah yang tidak jelas.

Dataset yang dikumpulkan merupakan data primer dari peneliti, berupa citra wajah penuh pasien PJK (positif) dan individu yang sehat (negatif). Teknik pengambilan sampel yang digunakan adalah *accidental sampling*. Citra dipilih melalui kriteria inklusi dan eksklusi yang dirumuskan bersama dokter spesialis penyakit jantung dan pembuluh darah, sehingga data yang dikumpulkan valid. Kriteria inklusi merupakan kriteria yang digunakan untuk menyatakan bahwa subjek penelitian dapat dijadikan sampel penelitian karena memenuhi syarat sebagai sampel. Sebaliknya, kriteria eksklusi merupakan kriteria ketika sampel penelitian tidak dapat dijadikan sampel karena tidak memenuhi syarat sebagai sampel penelitian.

ROI merupakan area citra yang akan diproses lebih lanjut. Oleh karena itu, penelitian ini menggunakan ROI_m , yaitu ROI sebelum prapemrosesan yang diperoleh dari pemotongan manual; dan ROI_r , yaitu ROI setelah prapemrosesan yang diperoleh dari hasil segmentasi. Sebanyak enam ROI_m diambil secara manual untuk setiap responden. Bagian wajah yang diidentifikasi adalah *crow's feet*, *canthus* kanan dan kiri, hidung, dan dahi. ROI mempunyai resolusi 400×400 piksel. Gambar 1 menunjukkan ROI yang digunakan dalam penelitian ini. Keseluruhan *dataset* yang digunakan adalah 132 citra, yang terdiri atas 60 citra negatif dan 72 citra positif. *Dataset* tersebut kemudian dibagi secara acak menjadi 80% ($n = 106$) sebagai data latih dan 20% sisanya ($n = 32$) sebagai data uji. Karakteristik *dataset* yang digunakan tersaji pada Tabel I.


B. PRAPEMROSESAN

Citra yang awalnya berformat RGB diubah menjadi citra skala abu-abu (*grayscale*), dimulai dari melakukan *thresholding* pada setiap blok wajah. *Thresholding* dilakukan menggunakan nilai ambang sebagai patokan untuk menentukan piksel pada citra yang akan diubah menjadi hitam atau putih. *Thresholding* dilakukan menggunakan *kernel* 3×3 , sebagaimana ditunjukkan pada (1) [15].

$$T_h(x) = \begin{cases} x & \text{jika } |x| \geq \lambda \\ 0 & \text{yang lain} \end{cases} \quad (1)$$

TABEL I
KARAKTERISTIK *DATASET*

Kelas	Rata-Rata	Metode Diagnosis		Gender	
		Angiography (%)	Electrocardiogram (%)	Laki-Laki (%)	Perempuan (%)
PJK	21–62 (42,5) tahun	83,3	16,67	36,37	18,19
Sehat	22–36 (30) tahun	0,0	100,00	31,81	13,63



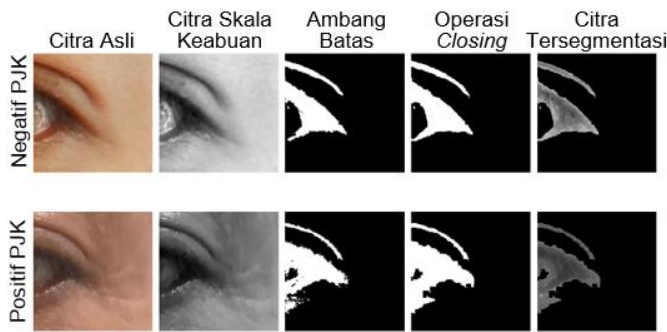
Gambar 1. ROI, (a) *crow's feet* kanan, (b) *canthus* kanan, (c) hidung, (d) dahi, (e) *canthus* kiri, (f) *crow's feet* kiri.

Selain kemiringan dan jarak warna, citra skala abu-abu juga disegmentasi berdasarkan ambang biner [16]. Pemeriksaan visual terhadap distribusi menunjukkan bahwa ambang fitur dapat menghasilkan klasifikasi yang lebih baik. Penelitian ini menggunakan *hard thresholding* dengan memilih koefisien yang melebihi ambang λ tertentu dan menetapkan semua koefisien lainnya ke nol. Operasi selanjutnya adalah operasi morfologi citra melalui proses *closing*, yang merupakan kombinasi dilasi dan pengikisan berkelanjutan. Proses ini digunakan untuk menutupi atau menghilangkan lubang-lubang kecil di permukaan. Proses *closing* berfungsi untuk menghaluskan kontur dan menutup lubang-lubang kecil, sehingga tekstur suatu objek lebih mudah dikenali. Proses *closing* didefinisikan dalam penjumlahan (\oplus) dan pengurangan (\ominus) Minkowski [17]. Setelah operasi *closing*, citra hitam putih digunakan sebagai area segmentasi citra skala abu-abu untuk mendapatkan ROI. Perbedaan antara tekstur responden yang sehat dan responden dengan PJK mungkin tidak dapat dilihat dengan mata telanjang, tetapi melalui metode kuantitatif klasifikasi ini dapat lebih dibedakan. Karakteristik yang difokuskan dan diperoleh dalam penelitian ini adalah tekstur kulit. Ciri tekstur merupakan keteraturan pola tertentu dari susunan piksel pada citra. Segmentasi tekstur wajah antara responden sehat dan responden dengan PJK ditunjukkan pada Gambar 2.

$$Closing(A, \sigma) = ((A \oplus \sigma) \ominus \sigma). \quad (2)$$

C. EKSTRAKSI FITUR TEKSTUR

Ekstraksi tekstur dilakukan dengan menggunakan algoritma GLCM, yang awalnya diperkenalkan oleh Haralick pada tahun 1973 untuk mengekstraksi fitur citra medan [18]. GLCM menganalisis pola spasial dalam suatu citra dengan memeriksa hubungan antara pasangan piksel dengan



Gambar 2. Segmentasi tekstur wajah antara responden sehat dan responden dengan PJK.

mempertimbangkan intensitas skala abu-abu, jarak, dan arahnya [18]. Pada arah sudut 0° , 45° , 90° , dan 135° , hubungan antarpixel dianalisis menggunakan pendekatan ini. Oleh karena itu, semua fitur dalam (3) hingga (8) dihitung di semua arah. Parameter jarak mengacu pada jarak antara pasangan piksel ini dalam arah tertentu. Pada citra halus, jarak yang lebih kecil menghasilkan tangkapan pola tekstur lokal yang lebih halus, sedangkan jarak yang lebih besar menangkap pola tekstur global yang lebih kasar. Penelitian ini menggunakan jarak 5 piksel. Meskipun tergolong relatif kecil bagi citra 400×400 piksel, jarak tersebut tidak dapat diabaikan karena GLCM akan menangkap pola tekstur lokal yang tersebar di area yang kecil. Matriks ini mampu memberikan kesan detail tekstur tanpa mencapai skala global yang sesungguhnya. Matriks ini dibuat dengan menghitung frekuensi kemunculan piksel dengan nilai tingkat keabuan i dalam hubungan spasial tertentu dengan piksel lain dengan nilai tingkat keabuan j . Setiap elemen (i, j) pada matriks tersebut merepresentasikan jumlah kemunculan pasangan piksel, yang menunjukkan distribusi spasial tingkat keabuan citra. Gambar 3 merupakan contoh matriks GLCM untuk sepasang piksel dalam arah sudut 0° dan dengan jarak 1 piksel [19].

Nilai kontras yang tinggi menunjukkan tingkat variabilitas yang lebih besar dalam citra. Ketidakmiripan mengukur jarak antara pasangan piksel dalam wilayah citra tertentu. Homogenitas, yang juga dikenal sebagai *inverse different moment* (IDM), menilai keseragaman elemen-elemen terdistribusi di seluruh area citra. Pada GLCM, energi dihitung sebagai jumlah elemen kuadrat dengan nilai antara 0 dan 1, dengan nilai yang lebih tinggi menunjukkan tekstur yang lebih seragam. Dengan nilai mulai dari 1 hingga -1, korelasi mengevaluasi hubungan antara piksel dan tetangganya di seluruh citra. Terakhir, ASM menilai tingkat keseragaman intensitas abu-abu pada citra; makin tinggi nilai ASM, makin besar kesamaan piksel dalam citra tersebut. Persamaan matematika fitur-fitur ini dijelaskan dalam (3) hingga (8) [4], [20].

$$\text{Kontras} = \sum_i \sum_j |i - j|^2 p(i, j) \tag{3}$$

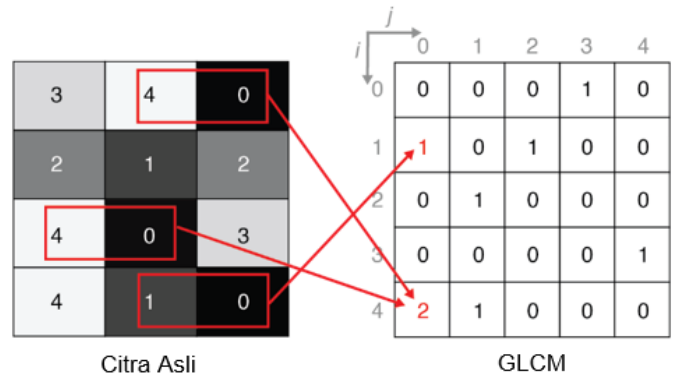

$$\text{Ketidakmiripan} = \sum_i \sum_j p_{i,j} |i - j| \tag{4}$$

$$\text{Homogenitas} = \sum_i \sum_j \frac{p_{i,j}}{1 + (i - j)^2} \tag{5}$$

$$\text{Energi} = \sum_{i,j} p_{i,j}^2 \tag{6}$$

$$\text{Korelasi} = \sum_i \sum_j \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \tag{7}$$

$$\text{Angular Second Moment} = \sum_i \sum_j p_{i,j}^2 \tag{8}$$



Gambar 3. Matriks GLCM untuk arah sudut 0° dan jarak 1 piksel.

dengan P menunjukkan matriks probabilitas pada GLCM, i menunjukkan piksel referensi, j menunjukkan piksel tetangga, dan $\mu_i, \mu_j, \sigma_i, \sigma$ menunjukkan rata-rata dan standar deviasi $P_{i,j}$.

D. MELATIH DAN MENGUJI MODEL

Uji pemisahan data (*dataset split*) dibagi menjadi 80% ($n = 106$) untuk data latih dan sisanya, 20% ($n = 26$), digunakan untuk data uji. Metode pemisahan dipilih karena metode ini memiliki tingkat akurasi pengujian data yang lebih tinggi selama simulasi. *Dataset* terdiri atas enam bagian yang diperoleh dari citra wajah. Distribusi data latih dan data uji dilakukan secara acak dan otomatis menggunakan perangkat lunak Orange Python 3. Data latih, yang juga disebut dengan pengembangan model, merupakan pengelompokan berdasarkan fitur unik yang diperoleh dari proses ekstraksi fitur.

Berdasarkan karakteristik nilai fitur dari beberapa matriks fitur di atas, model mempelajari cara membuat aturan klasifikasi. Algoritma ANN digunakan untuk membuat aturan klasifikasi saat model dilatih. Pada tahap pengujian, aturan klasifikasi menjadi dasar pengambilan keputusan untuk prediksi. ANN berfungsi dengan menyesuaikan bobot (w) dan *bias* (b) koneksi untuk memastikan bahwa keluaran selaras dengan masukan. Persamaan yang digunakan dalam proses ini ditunjukkan pada (9) hingga (12) [21].

$$y^1 = f^1(w^1p + b^1) \tag{9}$$

$$y^2 = f^2(w^2y^1 + b^2) \tag{10}$$

$$\vdots$$

$$O = y^n = f^n(w^ny^{n-1} + b^n), \tag{11}$$

dengan $p = \begin{bmatrix} p_1 \\ \vdots \\ p_r \end{bmatrix}$, $b^1 = \begin{bmatrix} b_1^i \\ \vdots \\ b_r^i \end{bmatrix}$, dan $w^i = \begin{bmatrix} w_{11}^i & \dots & w_{1r}^i \\ \vdots & \ddots & \vdots \\ w_{s1}^i & \dots & w_{sr}^i \end{bmatrix}$. (12)

Proses evaluasi melibatkan pengujian model klasifikasi pada *dataset* baru menggunakan aplikasi Orange 3 untuk mengukur efektivitasnya. Pada penilaian ini, 20% dari *dataset*

yang setara dengan 26 sampel dicadangkan untuk pengujian. Selama tahap ini, alat visual seperti *confusion matrix* dan kurva *receiver operating characteristic* (ROC) digunakan untuk menyajikan hasil. Visualisasi ini membantu menilai keakuratan setiap ROI dan memandu pemilihan ROI yang paling efektif. Hasil klasifikasi kemudian dianalisis, disortir, dan diinterpretasikan, sehingga kesimpulan dapat ditarik. *Confusion matrix* mencatat perbandingan antara label yang diprediksi dan yang sebenarnya, yang menunjukkan empat skenario potensial: a) *true positive* (TP), yang mewakili jumlah pasien PJK yang diprediksi dengan benar sebagai penderita PJK; b) *true negative* (TN), yang mewakili jumlah pasien sehat yang diprediksi dengan benar sebagai pasien sehat; c) *false positive* (FP), yang mewakili jumlah pasien sehat yang diprediksi secara tidak benar sebagai penderita PJK; d) *false negative* (FN), yang mewakili jumlah pasien PJK yang diprediksi secara tidak benar sebagai pasien sehat. Klasifikasi ini penting untuk mengevaluasi keakuratan dan keandalan model prediktif.

Kinerja model biasanya dievaluasi menggunakan beberapa metrik utama, termasuk *area under curve* (AUC) ROC, *classification accuracy* (CA), presisi, *recall*, dan *f1-score*. AUC menunjukkan efektivitas model dalam membedakan antara contoh positif dan negatif. *True positive rate* (TPR), yang dikenal juga sebagai *recall*, menunjukkan proporsi kasus positif sebenarnya yang diidentifikasi oleh model dengan benar. Di sisi lain, *false positive rate* (FPR) mengukur kasus negatif yang keliru diklasifikasikan sebagai positif. CA mengukur persentase prediksi yang benar, baik positif maupun negatif, di seluruh *dataset*. Presisi menilai akurasi prediksi positif dengan membandingkan jumlah TP dengan total prediksi positif yang dibuat. *F1-score* kemudian menyintesis *recall* dan presisi menjadi satu metrik, sehingga memberikan gambaran yang seimbang dari kinerja prediktif model. Akurasi memberikan gambaran keseluruhan tentang kinerja model. Namun, *dataset* yang tidak seimbang dapat memberikan kesan yang salah terhadap akurasi karena dominasi salah satu kelas dapat seolah-olah meningkatkan kinerja. Presisi, di sisi lain, menghitung proporsi prediksi TP dari semua prediksi positif yang dibuat, membuatnya berguna saat FP sangat perlu diminimalkan. Presisi sangat berguna dalam aplikasi seperti diagnosis penyakit langka karena mengurangi jumlah diagnosis positif yang salah sangat penting. *Recall* menilai kemampuan model untuk mengidentifikasi semua kasus positif yang sebenarnya, yang sangat penting saat meminimalkan FN. *Recall* biasanya diprioritaskan dalam bidang seperti deteksi penipuan atau penyakit, yaitu ketika mengidentifikasi sebanyak mungkin kasus TP merupakan hal yang penting. *F1-score* adalah rata-rata harmonis presisi dan *recall*, yang menawarkan ukuran yang seimbang saat terdapat pertukaran di antara kedua metrik ini. Detail formula untuk metrik ini ditunjukkan pada (13)–(17).

$$Recall = \frac{TP}{(FN+TP)} \quad (13)$$

$$False\ Positive\ Rate = \frac{FP}{(TN+FP)} \quad (14)$$

$$CA = \frac{(TP + TN)}{(TP+FP+FN+TN)} \quad (15)$$

$$Precision = \frac{TP}{(TP+FP)} \quad (16)$$

$$Skor\ F1 = \frac{2(Recall \times Precision)}{(Recall + Precision)} \quad (17)$$

Kurva ROC dihasilkan dari nilai yang diperoleh melalui perhitungan yang melibatkan *confusion matrix*, yang menggambarkan hubungan antara FPR dan TPR. Grafik ini digunakan untuk mengevaluasi efektivitas hasil prediksi. Dalam model klasifikasi, kurva ROC berfungsi sebagai alat visualisasi yang membantu menilai dan memilih kinerja klasifikasi pada skala biner, dari 0 hingga 1. Kurva ROC diagonal, yang sejajar dengan garis 45° atau garis dasar, menandakan kinerja model yang buruk. Sebaliknya, kurva di atas garis dasar menunjukkan model klasifikasi yang lebih efektif. Dengan demikian, makin besar AUC, makin baik kinerjanya. AUC sebesar 0,5 menandakan tidak adanya kemampuan untuk membedakan antarkelas, sedangkan AUC sebesar 1,0 menunjukkan akurasi klasifikasi yang sempurna. Gambar 4 mengilustrasikan konsep AUC [22].

E. ANALISIS AKURASI KLASIFIKASI

Analisis dilakukan melalui *data tabling* dan divisualisasikan dengan diagram batang. Analisis data dilakukan dengan menghitung akurasi setiap ROI dan mengategorikan nilai akurasi berdasarkan skala interval yang telah dirancang berdasarkan penelitian sebelumnya [23]. Skor yang berkisar antara 80% hingga 100% diklasifikasikan sebagai sangat baik, yang menunjukkan kinerja yang sangat baik. Skor antara 71% dan 80% dikategorikan sebagai baik, yang menunjukkan kinerja di atas rata-rata. Skor antar 61% hingga 70% dianggap cukup, yang menunjukkan kinerja sedang. Skor dalam kisaran 51% hingga 60% termasuk dalam kategori buruk, yang menunjukkan hasil di bawah rata-rata. Akhirnya, 0% hingga 50% dianggap sangat buruk, yang menandakan kinerja yang tidak memadai. Skala ini membantu menilai dan mengklasifikasikan kualitas atau keberhasilan suatu evaluasi. Akurasi adalah skor hasil prediksi dalam kaitannya dengan jumlah total prediksi yang telah dibuat. Ketika merekomendasikan ROI untuk penelitian masa depan, kategorisasi digunakan sebagai proses seleksi.


IV. HASIL DAN DISKUSI

A. PELATIHAN DAN PENGUJIAN MODEL

Model ini dibangun dengan mengekstraksi skor fitur tekstur dari data latih untuk membuat pedoman klasifikasi. ANN dilatih menggunakan pedoman ini untuk memprediksi kemungkinan PJK. Model ini membagi hasil potensial menjadi dua kategori risiko, yaitu risiko rendah yang negatif dan risiko tinggi yang positif.

Proses pelatihan melibatkan pemberian label pada *dataset* dengan indikator positif dan negatif PJK. Setelah langkah ini, *library* Keras diimpor. Keras digunakan untuk mengimplementasikan algoritma jaringan saraf di atas TensorFlow untuk membuat model pembelajaran mesin. Langkah berikutnya melibatkan konfigurasi lapisan tersembunyi (*hidden layer*) model, khususnya dengan menambahkan dua lapisan tersembunyi. Dua fungsi aktivasi ditetapkan, yaitu *rectified linear unit* (ReLU) untuk lapisan tersembunyi dan *sigmoid* untuk lapisan keluaran. Fungsi pencocokan (*fitting function*) selanjutnya digunakan untuk mengompilasi model ANN, yang dilatih selama 200 *epoch*. Nilai ini menunjukkan jumlah iterasi yang dieksekusi algoritma di seluruh *dataset* latih. Terakhir, metrik seperti CA, AUC, presisi, *recall*, dan *f1-score* digunakan untuk mengevaluasi kinerja model.

Jumlah data dalam *dataset* dan jumlah *epoch* yang dimasukkan ke dalam program menentukan lamanya proses



Gambar 4. Ilustrasi area under curve (AUC).

pembelajaran. Makin banyak *dataset* dan jumlah *epoch*, makin lama proses pembelajaran berlangsung. Waktu eksekusi model pada penelitian ini menunjukkan hasil yang relatif cepat, yaitu sebesar 20,13 s. Proses pembelajaran menampilkan nilai *loss* dan akurasi. Makin besar nilai *loss*, makin kecil akurasi, begitu pula sebaliknya. Setelah proses pembelajaran selesai, program langsung melanjutkan dengan menguji model dengan *dataset* uji yang ada, kemudian menampilkan hasil untuk setiap data.

B. EVALUASI MODEL

Confusion matrix yang diperoleh dari proses pengujian pada model dengan menggunakan algoritma ANN, yang diperoleh dari aplikasi Orange3, ditunjukkan pada Gambar 5. Hasil pengujian pada model dengan penerapan algoritma ANN, sebagaimana ditampilkan pada Gambar 5, menunjukkan hasil dari 26 data uji, yang terdiri atas 8 prediksi benar untuk data berlabel negatif dan 12 prediksi benar untuk data berlabel positif. Selain itu, ditemukan 1 prediksi salah untuk data berlabel positif dan 5 prediksi salah untuk data berlabel negatif. Secara total, model dapat membuat 20 prediksi benar dan 6 prediksi salah, dengan persentase akurasi 76,9%.

Selain CA, evaluasi model juga dapat dilakukan dengan melihat beberapa kuantitas hasil pengujian data lainnya, yaitu AUC, presisi, *recall*, dan *f1-score*. Nilai biner digunakan untuk mengukur kuantitas ini, dengan nilai terendah adalah 0 dan tertinggi adalah 1. Hasil evaluasi lengkap beserta rata-rata tertimbang untuk setiap kelas yang diperoleh dari aplikasi Orange3 ditunjukkan dalam diagram batang pada Gambar 6.

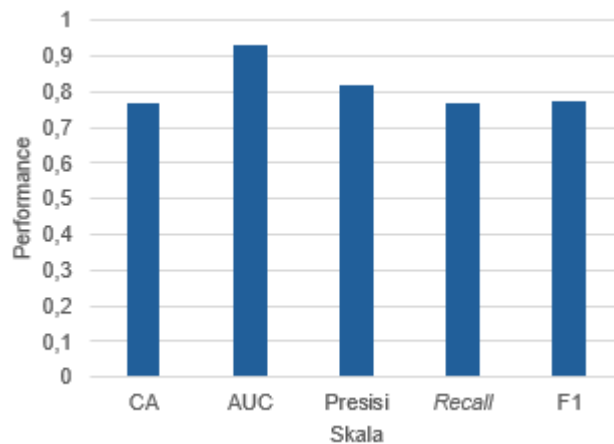
C. ANALISIS KINERJA ROI

Setiap data uji yang digunakan memiliki label atau kondisi aktual dari data tersebut, yaitu antara positif dan negatif, yang menunjukkan kondisi PJK. Prediksi merupakan nilai yang mewakili hasil tugas klasifikasi oleh model yang dibuat. Prediksi disimpulkan berdasarkan perbandingan nilai negatif dan positif. Hasil prediksi klasifikasi ditentukan oleh nilai yang lebih tinggi antara kategori positif dan negatif, yang akan menentukan hasil prediksi klasifikasi cenderung memiliki kesimpulan positif atau negatif.

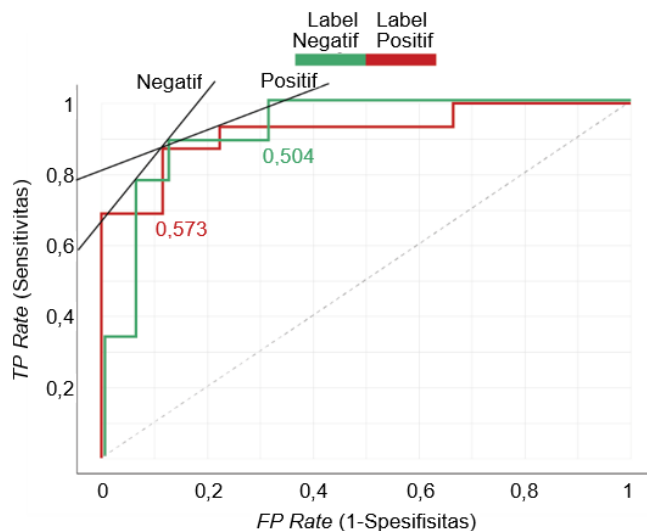
Kurva ROC model ditunjukkan pada Gambar 7. Kesesuaian antara label data (kondisi aktual) dan prediksi model menjadi dasar untuk menarik kesimpulan hasil prediksi. Ketika prediksi

		Prediksi		Σ
		Negatif	Positif	
Aktual	Negatif	8	1	9
	Positif	5	12	17
Σ		13	13	26

Gambar 5. Keluaran pada confusion matrix.



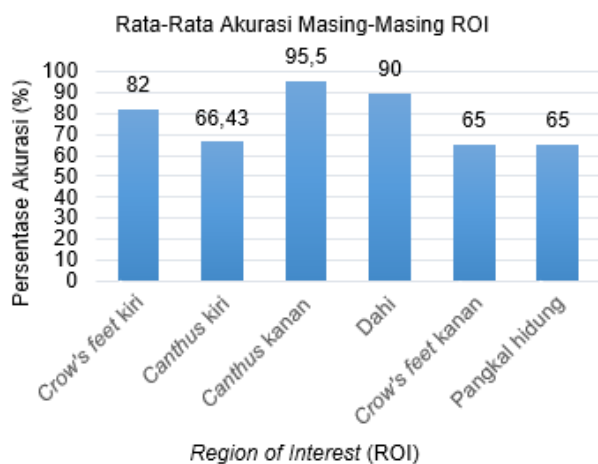
Gambar 6. Keluaran kinerja confusion matrix.



Gambar 7. Kurva ROC pada model ini.

cocok dengan label data, prediksi tersebut benar. Data setiap ROI diuji dengan memilih 26 *dataset* secara acak menggunakan metode *split*, dengan enam ROI untuk menghilangkan kemungkinan sistem aplikasi mengambil jumlah ROI yang tidak seimbang. Studi ini membahas secara rinci 6 *crow's feet* kiri, 7 *canthus* kiri, 2 *canthus* kanan, 4 dahi, 4 *crow's feet* kanan, dan 3 data pangkal hidung.

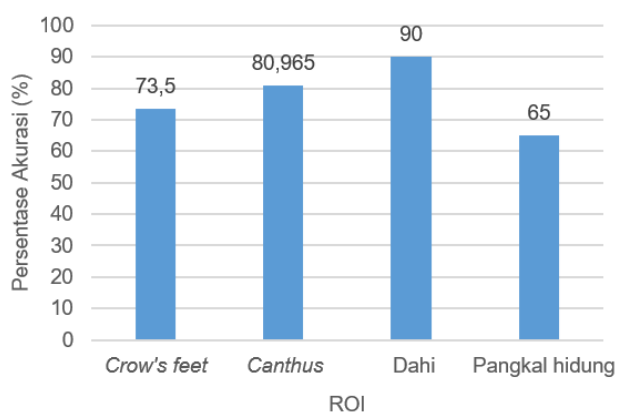
Hasil pengujian data selanjutnya dirata-rata sebanyak *n* untuk setiap ROI guna mengetahui kinerja prediksi pada setiap bagian citra wajah yang digunakan. Rata-rata akurasi setiap ROI menunjukkan bahwa dari keenam bagian yang dianalisis melalui eksperimen komputasional, terdapat tiga ROI yang memiliki akurasi prediksi dengan kategori sangat baik, yaitu *crow's feet* kiri, *canthus* kanan, dan dahi. Sementara itu, tiga ROI lainnya, yaitu *canthus* kiri, *crow's feet* kanan, dan pangkal hidung, masuk dalam kategori memiliki akurasi prediksi yang baik. *Canthus* kanan merupakan ROI dengan akurasi prediksi



Gambar 8. Bagan batang akurasi rata-rata setiap ROI.

TABEL II
RATA-RATA AKURASI ROI

ROIs	Rata-Rata Akurasi (%)
Crow's feet	73,50
Canthus	80,97
Dahi	90,00
Pangkal hidung	65,00



Gambar 9. Persentase rata-rata akurasi ROI.

tertinggi, yakni sebesar 95,50%, sedangkan *crow's feet* kanan dan pangkal hidung merupakan ROI dengan akurasi prediksi terendah, yakni sebesar 65%. Meskipun ketiga ROI tersebut masuk dalam kategori akurasi yang baik, skor akurasi yang diperoleh masih belum cukup tinggi, yakni sekitar 65%–66,43%. Sementara itu, tiga ROI lainnya yang memiliki akurasi yang sangat baik, yaitu *crow's feet* kiri, *canthus* kanan, dan dahi, masing-masing memiliki akurasi prediksi sebesar 82%, 95,50%, dan 90%. Keakuratan setiap ROI nilai-nilai ini ditunjukkan pada Gambar 8.

Nama-nama area wajah digunakan untuk mengelompokkan hasil setiap ROI berdasarkan temuan penelitian sebelumnya. Mengingat ROI *crow's feet* dan *canthus* memiliki dua sisi, yaitu kanan dan kiri, digunakan akurasi rata-rata untuk analisis kinerja ROI. Hasilnya ditunjukkan pada Tabel II

Hasil penelitian menunjukkan bahwa terdapat dua area wajah yang memiliki akurasi sangat tinggi, yaitu *canthus* dan dahi, dengan akurasi masing-masing sebesar 80,97% dan 90%. Sementara itu, dua area wajah lainnya masuk dalam kategori akurasi tinggi, yaitu *crow's feet* dan pangkal hidung, dengan akurasi masing-masing sebesar 73,50% dan 65%. Jika dibandingkan dengan penelitian sebelumnya, terdapat modifikasi atau perbedaan pada sistem yang dikembangkan

pada penelitian ini. Perbedaan tersebut terletak pada *dataset*, algoritma klasifikasi, dan pemilihan ROI yang digunakan. Penelitian sebelumnya menggunakan total 1.528 *dataset* ROI dari etnis Tionghoa, sedangkan penelitian ini menggunakan total 132 *dataset* ROI dari etnis Indonesia secara keseluruhan. Dari segi algoritma klasifikasi, penelitian ini menggunakan ANN, sedangkan penelitian sebelumnya menggunakan algoritma *random forest* dan *decision tree*. Terkait pemilihan ROI, penelitian sebelumnya menggunakan delapan ROI, sedangkan penelitian ini menggunakan enam ROI. Hasil rata-rata persentase akurasi untuk masing-masing ROI divisualisasikan pada Gambar 9.

Hasil penelitian juga menunjukkan perbedaan terkait modifikasi metode yang diusulkan. Penelitian ini memiliki ROI rata-rata yang sedikit lebih tinggi. Selain itu, setiap ROI yang digunakan dalam penelitian ini menghasilkan akurasi dengan perbedaan yang signifikan. Aspek ini perlu diteliti lebih lanjut melalui penelitian dengan menambah kuantitas dan keragaman *dataset* untuk melihat perbedaan atau pengaruh jumlah *dataset* terhadap akurasi. Seiring dengan pengembangan algoritma, penting dilakukan pengujian yang menggabungkan algoritma *deep-learning* yang dimodifikasi untuk mengamati perbedaannya.

V. KESIMPULAN

Hasil penelitian menunjukkan bahwa model pembelajaran mesin yang dirancang untuk mendiagnosis PJK, menggunakan fitur tekstur dari enam area wajah dan algoritma ANN, menunjukkan kinerja yang bagus dengan mencapai akurasi sebesar 76,9%. Hasil penelitian menunjukkan bahwa dua bagian wajah memiliki akurasi yang sangat baik, yaitu *canthus* dan dahi, dengan akurasi masing-masing 80,97% dan 90%. Dua bagian wajah lainnya dikategorikan ke dalam akurasi yang baik, yaitu *crow's feet* dan pangkal hidung, dengan akurasi masing-masing 73,50% dan 65%. Berdasarkan hasil penelitian, model pembelajaran mesin yang dikembangkan mampu mendiagnosis PJK hanya melalui citra wajah yang diunggah dan diproses dalam waktu singkat, yaitu sekitar 20,13 s. Dengan demikian, target perancangan model yang mudah digunakan dan cepat dalam eksekusi dibandingkan dengan metode klinis telah tercapai. Meskipun lebih mudah dan cepat, model diagnosis PJK saat ini tidak dapat menggantikan metode klinis yang ada, karena masih memerlukan pengembangan lebih lanjut sebelum dapat dianggap layak untuk diimplementasikan. Penelitian ini bermanfaat dalam menciptakan jalur penemuan yang lebih baik untuk penelitian selanjutnya. Selain itu, program ini terbukti mampu menjadi model skrining awal PJK dengan akurasi yang baik. Penelitian selanjutnya disarankan untuk menambah jumlah *dataset* dan melakukan uji coba penerapan algoritma *p* yang berpotensi meningkatkan akurasi model.

KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa dalam penelitian yang berjudul “Analisis Area Wajah untuk Mengidentifikasi Risiko Penyakit Jantung Koroner Berdasarkan Tekstur Wajah” ini tidak ada konflik kepentingan. Penulis menegaskan bahwa semua aspek penelitian, termasuk desain, metodologi, analisis data, dan interpretasi hasil, dilakukan secara independen dan tanpa pengaruh atau bias eksternal apa pun. Penulis selanjutnya menegaskan bahwa tidak ada hubungan finansial, pribadi, atau profesional yang dapat memengaruhi temuan penelitian ini, yang menjamin integritas dan objektivitas pekerjaan.

KONTRIBUSI PENULIS

Konseptualisasi, Yudha Andriano Rismawan dan Budi Sunarko; metodologi, Agung Adi Firdaus dan Budi Sunarko; analisis data, Agung Adi Firdaus dan Budi Sunarko; sumber daya, Yudha Andriano Rismawan dan Anan Nugroho; akuisisi data, Agung Adi Firdaus, Anan Nugroho, dan Yudha Andriano Rismawan; penulisan—penyusunan draf asli, Agung Adi Firdaus; penulisan—peninjauan dan penyuntingan, Yudha Andriano Rismawan; pengawasan, Budi Sunarko.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada Fakultas Teknik, Universitas Diponegoro; Rumah Sakit Dr. Kariadi; dan Rumah Sakit Nasional Diponegoro atas dukungan berharganya dalam pelaksanaan penelitian ini. Kontribusi dan bantuannya sangat penting bagi keberhasilan penelitian ini. Penulis sangat menghargai kerja sama dan komitmen mereka untuk memajukan penelitian ini.

REFERENSI

- [1] S.I. Ayon, M.M. Islam, dan M.R. Hossain, "Coronary artery heart disease prediction: A comparative study of computational intelligence techniques," *IETE J. Res.*, vol. 68, no. 4, hal. 2488–2507, Jul./Agu. 2022, doi: 10.1080/03772063.2020.1713916.
- [2] C. Shao, J. Wang, J. Tian, dan Y. Tang, "Coronary artery disease: From mechanism to clinical practice," dalam *Coronary Artery Disease: Therapeutics and Drug Discovery*, M. Wang, Ed., Singapura, Singapura: Springer, 2020, hal. 1–36.
- [3] B. Jin, L. Cruz, dan N. Gonçalves, "Deep facial diagnosis: Deep transfer learning from face recognition to facial diagnosis," *IEEE Access*, vol. 8, hal. 123649–123661, Jun. 2020, doi: 10.1109/ACCESS.2020.3005687.
- [4] Y.A. Rismawan dkk., "Development of coronary heart disease diagnosis system based on facial imagery," dalam *Proc. 3rd Conf. Fundam. Appl. Sci. Adv. Technol. 2022*, 2022, Paper 020003, doi: 10.1063/5.0180182.
- [5] J. Wang dkk., "A stacking-based model for non-invasive detection of coronary heart disease," *IEEE Access*, vol. 8, hal. 37124–37133, Feb. 2020, doi: 10.1109/ACCESS.2020.2975377.
- [6] S. Lin dkk., "Face analysis for coronary heart disease diagnosis," dalam *2019 12th Int. Congr. Image Signal Process. BioMed. Eng. Inform. (CISP-BMEI)*, 2019, hal. 1–5, doi: 10.1109/CISP-BMEI48845.2019.8966020.
- [7] S. Lin dkk., "Feasibility of using deep learning to detect coronary artery disease based on facial photo," *Eur. Heart J.*, vol. 41, no. 46, hal. 4400–4411, Des. 2020, doi: 10.1093/eurheartj/ehaa640.
- [8] J. Qiang dkk., "Review on facial-recognition-based applications in disease diagnosis," *Bioengineering*, vol. 9, no. 7, hal. 1–16, Jul. 2022, doi: 10.3390/bioengineering9070273.
- [9] U. Thirunavukkarasu, S. Umapathy, K. Janardhanan, dan R. Thirunavukkarasu, "A computer aided diagnostic method for the evaluation of type II diabetes mellitus in facial thermograms," *Phys. Eng. Sci. Med.*, vol. 43, no. 3, hal. 871–888, Sep. 2020, doi: 10.1007/s13246-020-00886-z.
- [10] S. Gondane, A. Maherda, dan R. Kothiwala, "To study the prevalence of metabolic syndrome and dyslipidemia in patients of xanthelasma palpebrarum at a tertiary care hospital," *Asian J. Diabetol.*, vol. 21, no. 3, hal. 10–14, Okt. 2020.
- [11] H.-C. Chang, C.-W. Sung, dan M.-H. Lin, "Serum lipids and risk of atherosclerosis in xanthelasma palpebrarum: A systematic review and meta-analysis," *J. Am. Acad. Dermatol.*, vol. 82, no. 3, hal. 596–605, Mar. 2020, doi: 10.1016/j.jaad.2019.08.082.
- [12] P. Kampar, Q. Anum, dan S. Lestari, "The correlation between lipid profile and xanthelasma," *Berk. Ilmu Kesehatan. Kulit Kelamin*, vol. 32, no. 2, hal. 119–125, Agu. 2020, doi: 10.20473/bikk.v32.2.2020.119-125.
- [13] A.K.I. Suman dkk., "Association of xanthelasma palpebrarum (XP) with cardiovascular disease (CVD) risk factors," *Asian J. Med. Biol. Res.*, vol. 5, no. 4, hal. 324–329, Des. 2019, doi: 10.3329/ajmbr.v5i4.45271.
- [14] B.I. Fitrasanti, A. Onggo, W. Sugirman, dan B. Ciptawan, "Prevalence of cutaneous markers in coronary artery disease cases," *Bali Med. J.*, vol. 10, no. 2, hal. 877–880, Agu. 2021, doi: 10.15562/bmj.v10i2.2531.
- [15] E.R. Dougherty, *Digital Image Processing Methods*. New York, NY, AS: CRC Press, 1994.
- [16] S. Ibrahim dkk., "Automated platelet counter with detection using k-means clustering," *Ann. Emerg. Technol. Comput. (AETIC)*, vol. 7, no. 5, hal. 39–49, Okt. 2023, doi: 10.33166/AETIC.2023.05.004.
- [17] S. Sellán, J. Kesten, A.Y. Sheng, dan A. Jacobson, "Opening and closing surfaces," *ACM Trans. Graph.*, vol. 39, no. 6, hal. 1–13, Des. 2020, doi: 10.1145/3414685.3417778.
- [18] R.M. Haralick, K. Shanmugam, dan I. Dinstein, "Textural features for image classification," *IEEE Trans. Syst. Man Cybern.*, vol. SMC-3, no. 6, hal. 610–621, Nov. 1973, doi: 10.1109/TSMC.1973.4309314.
- [19] B.M. Jebin, M.A. Rejula, dan G. Eberlein, "Neonatal Seizure detection using GLCM feature extraction & AlexNet classification," *Multimed. Tools Appl.*, Okt. 2024, doi: 10.1007/s11042-024-18779-8.
- [20] N. Iqbal, R. Mumtaz, U. Shafi, dan S.M.H. Zaidi, "Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms," *PeerJ Comput. Sci.*, vol. 7, hal. 1–26, Mei 2021, doi: 10.7717/PEERJ-CS.536.
- [21] M. Madanan, *Neural Network and Deep Learning*. New Delhi, Delhi, India: BlueRose Publishers, 2022.
- [22] S. Parodi, D. Verda, F. Bagnasco, dan M. Muselli, "The clinical meaning of the area under a receiver operating characteristic curve for the evaluation of the performance of disease markers," *Epidemiol. Health*, vol. 44, hal. 1–10, Okt. 2022, doi: 10.4178/epih.e2022088.
- [23] M.G. Nugraha, S. Utari, D. Saepuzaman, dan F. Nugraha, "Redesign of students' worksheet on basic physics experiment based on students' scientific process skills analysis in Melde's law," dalam *4th Int. Semin. Math. Sci. Comput. Sci. Educ.*, 2018, hal. 1–8, doi: 10.1088/1742-6596/1013/1/012038.