

ANALISIS KOMPONEN UTAMA - PENYESUAIAN HISTOGRAM ADAPTIF TERBATAS DAN ATT-UNET UNTUK SEGMENTASI RAMBUT

(*PRINCIPAL COMPONENT ANALYSIS - CONTRAST LIMITED ADAPTIVE HISTOGRAM
EQUALIZATION AND ATT-UNET FOR HAIR SEGMENTATION*)

Okky Darmawan Kostidjan¹, Dwi Sunaryono^{2*}, Yudhi Purwananto³

^{1, 2, 3}Teknik Informatika, Fakultas Teknik Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember,
Surabaya, Indonesia

e-mail: 602523001@student.its.ac.id¹, dwi@its.ac.id², yudhi@its.ac.id³

ABSTRAK

Dalam bidang analisis gambar medis, artefak seperti rambut dermal menjadi tantangan utama baik dalam interpretasi visual maupun pemrosesan gambar otomatis selama pemeriksaan dermoskopik. Rambut yang menutupi area lesi dapat menyamarkan batas lesi, mengurangi kualitas ekstraksi fitur, dan menyebabkan kesalahan segmentasi dan klasifikasi. Studi terbaru menunjukkan bahwa rambut dermal tetap menjadi salah satu artefak paling persisten yang memengaruhi analisis otomatis, bahkan dalam model segmentasi canggih. Artefak ini juga menurunkan kinerja sistem berbasis kecerdasan buatan yang bergantung pada informasi visual. Penelitian ini bertujuan untuk meningkatkan akurasi segmentasi rambut pada gambar dermoskopi melalui penerapan teknik prapemrosesan yang efektif dan efisien. Studi ini menerapkan Analisis Komponen Utama (PCA) sebagai metode penggabuan untuk mengurangi beban komputasi sambil mempertahankan fitur gambar esensial, serta Equalization Histogram Adaptif Terbatas Kontras (CLAHE) untuk meningkatkan kontras lokal dan memperjelas struktur rambut yang tipis atau berkontras rendah. Kombinasi PCA dan CLAHE berfungsi sebagai tahap prapemrosesan untuk meningkatkan kualitas gambar masukan pada model segmentasi berbasis deep learning. Kontribusi utama penelitian ini adalah pengintegrasian metode grayscale berbasis PCA dengan CLAHE dalam satu pipeline prapemrosesan sebelum segmentasi deep learning serta evaluasi pengaruhnya terhadap kinerja model segmentasi. Evaluasi dilakukan menggunakan arsitektur AttU-Net dengan metrik Dice Similarity Coefficient (DSC) dan Jaccard Index (JAC). Prasunting PCA–CLAHE yang diusulkan mencapai nilai DSC dan JAC sebesar 75,24% dan 61,04%, masing-masing, melebihi model tanpa prasunting. Hasil ini menunjukkan bahwa PCA–CLAHE secara efektif meningkatkan kualitas gambar dan akurasi segmentasi sambil mempertahankan efisiensi komputasi.

Kata Kunci: Gambar dermoskopi, CLAHE, PCA, Segmentasi

ABSTRACT

In the field of medical image analysis, artifacts such as dermal hair pose a major challenge to both visual interpretation and automated image processing during dermoscopic examinations. Hair covering the lesion area can obscure the lesion boundaries, reduce the quality of feature extraction, and lead to segmentation and classification errors. Recent studies have shown that dermal hair remains one of the most persistent artifacts affecting automated analysis, even in state-of-the-art segmentation models. These artifacts also degrade the performance of AI-based systems that rely on visual information. This study aims to improve the accuracy of hair segmentation in dermoscopic images through the application of effective and efficient preprocessing techniques. This study applies Principal Component Analysis (PCA) as a grayscale method to reduce the computational burden while preserving essential image features, and Contrast-Limited Adaptive Histogram Equalization (CLAHE) to enhance local contrast and highlight thin or low-contrast hair structures. The combination of PCA and CLAHE serves as a preprocessing stage to improve the quality of input images for deep learning-based segmentation models. The main contribution of this research is the integration of PCA-based grayscale methods with CLAHE in a single preprocessing pipeline before deep learning segmentation and the evaluation of their effects on the performance of the segmentation model. The evaluation is conducted using the AttU-Net architecture with Dice Similarity Coefficient (DSC) and Jaccard Index (JAC) metrics. The proposed PCA–CLAHE preprocessing achieves DSC and JAC values of 75.24% and 61.04%, respectively, outperforming the model without preprocessing. These results indicate that PCA–CLAHE effectively improves image quality and segmentation accuracy while maintaining computational efficiency.

Keywords: Dermoscopy images, CLAHE, PCA, Segmentation

I. PENDAHULUAN

Dalam bidang analisis gambar medis, keberadaan artefak seperti rambut dermal menjadi tantangan dalam interpretasi visual dan pemrosesan gambar otomatis selama pemeriksaan kulit menggunakan dermoskopi. Rambut yang menutupi area lesi dapat menyamarkan batas lesi, mengurangi kualitas ekstraksi fitur, dan menyebabkan kesalahan dalam segmentasi dan klasifikasi [1]. Tantangan serupa juga ditekankan oleh Jütte et al. [2], yang menekankan bahwa rambut dermal tetap menjadi salah satu artefak paling persisten yang memengaruhi analisis dermoskopi otomatis, sementara Lama et al. [3] menunjukkan bahwa bahkan model segmentasi canggih pun kesulitan saat artefak semacam itu hadir. Artefak ini tidak hanya mempersulit diagnosis manual oleh dermatolog, tetapi juga menyebabkan penurunan kinerja sistem berbasis kecerdasan buatan yang bergantung pada informasi visual. Oleh karena itu, segmentasi rambut merupakan bagian penting dari analisis gambar dermoskopi untuk meningkatkan akurasi analisis gambar dermoskopi.

Meningkatkan akurasi analisis gambar dermoskopi bukanlah hal yang mustahil, tetapi memerlukan teknik prapemrosesan gambar dan segmentasi yang mampu memisahkan rambut dari kulit dan lesi [4]. Langkah-langkah prapemrosesan gambar dilakukan untuk meningkatkan kontras gambar sehingga tepi objek seperti rambut dan lesi dapat terlihat lebih jelas, sehingga memudahkan dan meningkatkan kinerja segmentasi. Studi-studi terbaru, seperti Joseph & Olugbara [5], Alnaggar et al. [6], dan Ashour et al. [7], menekankan bahwa teknik prapemrosesan seperti peningkatan kontras adaptif dan pengurangan dimensi memainkan peran krusial dalam meningkatkan efisiensi komputasi dan akurasi model dalam segmentasi gambar medis. Selain itu, prapemrosesan gambar dermoskopi dapat mengurangi waktu dan beban komputasi proses segmentasi. Salah satu cara untuk mengurangi waktu dan beban komputasi proses segmentasi adalah dengan mengonversi gambar dermoskopi ke skala abu-abu, yang mengurangi jumlah kanal dari tiga kanal warna (merah, hijau, dan biru) menjadi skala abu-abu [8].

Sebagian besar penelitian sebelumnya masih berfokus pada penerapan teknik prapemrosesan secara terpisah atau langsung mengandalkan kompleksitas arsitektur deep learning tanpa mengoptimalkan tahap konversi *grayscale* secara adaptif. Metode *grayscale* konvensional umumnya menggunakan bobot tetap pada

kanal RGB sehingga berpotensi menghilangkan informasi variansi warna yang penting untuk membedakan struktur rambut dari jaringan kulit di sekitarnya. Selain itu, penelitian terdahulu belum banyak mengeksplorasi integrasi pengurangan dimensi berbasis variansi data dengan peningkatan kontras lokal dalam satu pipeline prapemrosesan yang terstruktur sebelum proses segmentasi. Berdasarkan celah tersebut, penelitian ini menawarkan kebaruan melalui penggabungan *Principal Component Analysis* (PCA) sebagai metode *grayscale* adaptif dengan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk memperkuat struktur rambut berkontras rendah, sehingga diharapkan mampu meningkatkan kualitas citra masukan dan performa segmentasi secara lebih konsisten tanpa menambah kompleksitas model.

Metode konversi gambar warna menjadi *grayscale* dapat memakan waktu dan memerlukan komputasi yang intensif karena menghilangkan informasi warna yang tidak selalu relevan dalam proses segmentasi. Oleh karena itu, penerapan metode *grayscale* yang tidak tepat berpotensi menyebabkan hilangnya detail penting, sehingga menurunkan kualitas segmentasi. Sebaliknya, metode *grayscale* yang tepat yang mempertahankan kontras dan struktur visual kunci sebenarnya dapat meningkatkan kinerja segmentasi [9].

Dalam dekade terakhir, segmentasi berbasis *deep learning* telah menjadi pendekatan utama dalam analisis gambar medis karena kemampuannya untuk secara otomatis mempelajari fitur gambar. Berbagai arsitektur seperti UNet [10], ResUNet [11], dan AttUNet [12] telah terbukti efektif dalam mengekstrak dan membedakan struktur kompleks pada gambar dermoskopi, termasuk lesi kulit dan artefak seperti rambut. Kemajuan terbaru, termasuk Xiong et al. [13] dan Chen et al. [14], menyoroti integrasi modul perhatian dan transformer yang lebih meningkatkan akurasi model segmentasi gambar medis. Model-model ini dapat mengenali pola spasial dan tekstur secara mendalam, memungkinkan mereka melakukan segmentasi dengan tingkat akurasi yang tinggi. Namun, kinerja model *deep learning* sangat dipengaruhi oleh kualitas data gambar masukan. Oleh karena itu, langkah-langkah prapemrosesan seperti pengubahan ke skala abu-abu dan peningkatan kualitas gambar masih diperlukan untuk mengurangi waktu dan beban komputasi serta gangguan visual yang dapat menurunkan kinerja.

Meskipun berbagai penelitian sebelumnya telah mengembangkan arsitektur segmentasi yang semakin kompleks melalui integrasi mekanisme perhatian dan transformer, sebagian besar pendekatan tersebut berfokus pada peningkatan kapasitas model tanpa secara eksplisit mengoptimalkan kualitas citra masukan melalui strategi prapemrosesan yang ringan dan efisien secara komputasi. Berbeda dengan penelitian-penelitian tersebut, studi ini berkontribusi dengan mengusulkan integrasi metode *grayscale* berbasis *Principal Component Analysis* (PCA) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sebagai tahapan prapemrosesan sebelum proses segmentasi deep learning. Pendekatan ini menekankan optimalisasi informasi visual pada tahap awal pemrosesan guna meningkatkan performa model tanpa menambah kompleksitas arsitektur. Dengan demikian, penelitian ini tidak hanya melengkapi pendekatan berbasis arsitektur yang telah ada, tetapi juga menunjukkan bahwa peningkatan kualitas citra masukan melalui teknik prapemrosesan yang terstruktur dapat memberikan peningkatan akurasi segmentasi secara konsisten dan efisien.

Studi ini bertujuan untuk mengembangkan dan mengevaluasi metode yang efektif dan efisien untuk segmentasi rambut pada gambar dermoskopi melalui kombinasi teknik PCA dan CLAHE. Metode ini dirancang untuk meningkatkan kualitas gambar *grayscale* dan memperkuat kontras rambut, sehingga meningkatkan akurasi proses segmentasi. Studi ini juga bertujuan untuk menganalisis sejauh mana teknik *grayscale* berbasis PCA dan peningkatan kualitas gambar CLAHE memengaruhi hasil segmentasi artefak rambut. Dengan pendekatan yang relatif sederhana dan ringan secara komputasi, diharapkan metode ini dapat menjadi solusi prapemrosesan yang andal dalam sistem analisis gambar lesi kulit berbasis kecerdasan buatan.

II. STUDI PUSTAKA

Beberapa penelitian sebelumnya telah mengkaji pemanfaatan *Principal Component Analysis* (PCA) dalam konteks segmentasi citra medis. Arous dkk. [15] mengusulkan pendekatan segmentasi berbasis komponen utama dan menunjukkan bahwa transformasi berbasis PCA mampu mempertahankan informasi visual penting sekaligus meningkatkan akurasi segmentasi dibandingkan pendekatan konvensional. Hasil penelitian tersebut menegaskan bahwa reduksi dimensi berbasis variansi dominan dapat membantu

memperjelas struktur objek pada citra medis, sehingga informasi yang relevan tetap terjaga meskipun dimensi data dikurangi. Sejalan dengan itu, Karimzadeh dkk. [16] melaporkan bahwa pemanfaatan PCA dalam pemrosesan citra medis mampu mempertahankan detail struktural penting yang berpengaruh terhadap performa model segmentasi berbasis pembelajaran mesin. Selain itu, penelitian lain menunjukkan bahwa transformasi kanal warna berbasis distribusi statistik dapat meningkatkan kemampuan sistem dalam membedakan struktur pembuluh darah retina, yang secara konseptual serupa dengan pemisahan struktur tipis seperti rambut pada citra dermoskopi [17]. Secara umum, penelitian-penelitian tersebut menempatkan PCA sebagai teknik reduksi dimensi yang efektif dalam mempertahankan ciri esensial citra, namun penerapannya masih berfokus pada peningkatan performa model secara umum dan belum secara spesifik diarahkan pada segmentasi artefak rambut dalam citra dermoskopi.

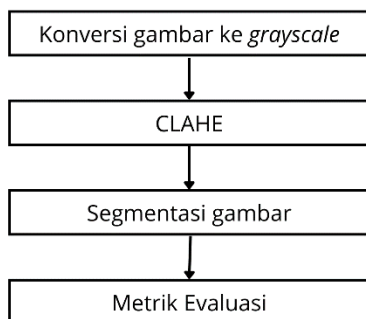
Dalam konteks peningkatan kualitas citra, Contrast Limited Adaptive Histogram Equalization (CLAHE) telah banyak diterapkan untuk meningkatkan kontras lokal pada citra medis. Penelitian lainnya mengintegrasikan CLAHE dalam pipeline analisis citra penyakit kulit dan melaporkan peningkatan visibilitas fitur tekstur yang berkontribusi pada akurasi segmentasi [18]. Penelitian lain menunjukkan bahwa kombinasi teknik peningkatan kontras berbasis CLAHE dengan pendekatan deep learning mampu meningkatkan performa segmentasi melalui perbaikan kualitas citra masukan [19], [20]. Secara khusus pada aplikasi medis lainnya, Yoshimi dkk. [21] membuktikan bahwa prapemrosesan menggunakan CLAHE meningkatkan performa segmentasi berbasis deep learning pada citra resonansi magnetik, terutama dalam mendeteksi struktur dengan kontras rendah, sedangkan Liu dan Nguyen [22] melaporkan bahwa integrasi CLAHE dengan teknik peningkatan lainnya mampu memperjelas struktur detail dan meningkatkan stabilitas hasil segmentasi. Meskipun demikian, sebagian besar studi tersebut menerapkan CLAHE sebagai teknik tunggal atau dikombinasikan dengan metode pembelajaran mendalam, tanpa mengintegrasikannya secara sistematis dengan pendekatan reduksi dimensi adaptif seperti PCA dalam satu rangkaian prapemrosesan terpadu.

Berdasarkan telaah terhadap penelitian-penelitian terdahulu tersebut, dapat disimpulkan bahwa PCA berpotensi mempertahankan informasi struktural

penting melalui reduksi dimensi adaptif, sementara CLAHE efektif dalam meningkatkan kontras lokal pada struktur berintensitas rendah. Namun, integrasi PCA sebagai metode grayscale adaptif dan CLAHE sebagai peningkatan kontras lokal dalam satu pipeline prapemrosesan sebelum segmentasi citra dermoskopi—khususnya untuk segmentasi artefak rambut—masih relatif terbatas dalam literatur. Dalam konteks yang lebih luas, perkembangan teknologi berbasis Artificial Intelligence (AI), termasuk penerapan Automated Decision Making (ADM) dan Agentic AI dalam sistem analisis citra medis, juga menghadirkan tantangan metodologis sekaligus normatif. Penelitian-penelitian sebelumnya di bidang regulasi AI menunjukkan bahwa kerangka hukum di Indonesia masih bersifat sektoral dan reaktif, belum sepenuhnya mengatur aspek akuntabilitas dan transparansi sistem otonom. Sejalan dengan itu, penelitian ini tidak hanya mengembangkan integrasi teknis PCA dan CLAHE sebagai kontribusi metodologis, tetapi juga memperkuat urgensi tata kelola AI yang adaptif terhadap sistem analisis citra berbasis keputusan otomatis. Dengan demikian, dibandingkan penelitian terdahulu yang cenderung memisahkan aspek teknis dan regulatif, penelitian ini menghadirkan pendekatan yang lebih komprehensif melalui integrasi inovasi prapemrosesan citra dan kesadaran terhadap implikasi sistem AI yang semakin otonom.

III. METODE PENELITIAN

Bab ini membahas tahap-tahap konversi gambar ke *grayscale*, prapemrosesan menggunakan CLAHE dan model *deep learning* berbasis U-Net, serta metrik evaluasi yang digunakan dalam studi ini.



Gambar 1. Diagram Alur Penelitian

A. Konversi Gambar ke Grayscale

Grayscale untuk mengurangi beban komputasi dan mempertahankan fitur gambar penting sambil menghilangkan yang tidak relevan.

1. Metode Luminositas

Metode Luminositas adalah metode *grayscale* yang umum digunakan dalam perpustakaan seperti OpenCV dan Pillow. Rumus yang digunakan untuk mengonversi nilai dari kanal warna merah, hijau, dan biru ditunjukkan dalam Rumus 1, di mana Gr adalah gambar *grayscale*, dan R , G , dan B masing-masing adalah tingkat warna merah, hijau, dan biru.

$$Gr = 0.299 R + 0.587 G + 0.114 B \quad (1)$$

2. Analisis Komponen Utama

Dalam studi ini, pengabuan gambar dermoskopi dilakukan menggunakan metode PCA yang diperkenalkan oleh Maćkiewicz A dan Ratajczak W. Langkah pertama adalah mendefinisikan ulang matriks gambar dermoskopi dari dimensi baris (H), kolom (W), dan 3 kanal menjadi N , 3 seperti pada Rumus 2, menghasilkan matriks X yang berisi nilai kecerahan pada kanal merah (R), hijau (G), dan biru (B) dengan N baris dan 3 kolom seperti pada Rumus 3.

$$H \cdot W = N \quad (2)$$

$$X = \begin{pmatrix} R_1 & G_1 & B_1 \\ R_2 & G_2 & B_1 \\ \vdots & \vdots & \vdots \\ R_N & G_N & B_N \end{pmatrix} \quad (3)$$

Langkah kedua adalah menemukan matriks X_{center} seperti pada Rumus 4 dengan mengurangi matriks tersebut dengan nilai rata-rata setiap baris dari setiap komponen pada baris yang sama sesuai dengan Rumus 5.

$$X_{center} = X - \mu \quad (4)$$

$$\mu = \text{mean}(X, \text{axis} = 0) \quad (5)$$

Kemudian temukan kovarian σ menggunakan Rumus 6 untuk mendapatkan nilai eigen

menggunakan metode dekomposisi eigen seperti pada Rumus 7, di mana λ adalah nilai eigen dan v adalah vektor eigen.

$$\sigma = \frac{1}{N-1} X_{center}^T X_{center} \quad (6)$$

$$\sigma \cdot v = \lambda \cdot v \quad (7)$$

Setelah mendapatkan vektor eigen, hasil PCA untuk komponen pertama Z dapat diperoleh dengan mengalikan X_{center} dengan vektor eigen pertama sesuai dengan Rumus 8.

$$Z = X_{center} \cdot v_1 \quad (8)$$

Akhirnya, matriks Z diubah menjadi gambar grayscale PCA (Gr_{PCA}) sesuai dengan Rumus 9, di mana k adalah indeks matriks Z sesuai dengan Rumus 10.

$$Gr_{PCA} = Z[k] \quad (9)$$

$$k = i \cdot w + j \quad (10)$$

dengan nilai i, w , dan j secara berurutan adalah $i \in [0, H-1], j \in [0, W-1]$ dan $k \in [0, N-1]$

B. CLAHE

CLAHE adalah teknik peningkatan kontras gambar yang bekerja secara lokal dengan membagi gambar menjadi blok-blok kecil (tile) dan menerapkan equalisasi histogram pada setiap blok [23]. Berbeda dengan metode equalisasi histogram global, CLAHE membatasi peningkatan kontras dengan parameter batas klip untuk mencegah peningkatan kontras berlebihan dan peningkatan *noise*, terutama di area homogen. Pendekatan adaptif ini memungkinkan peningkatan detail lokal yang lebih efektif, menjadikannya sangat cocok untuk gambar medis seperti dermoskopi, yang sering memiliki pencahayaan rendah dan variasi kontras. Dalam konteks segmentasi artefak seperti rambut, CLAHE dapat meningkatkan kontras

rambut dengan struktur tipis yang sebelumnya kurang terlihat atau memiliki tingkat abu-abu serupa dengan warna kulit atau lesi.


Dalam penelitian ini, parameter eksperimen CLAHE dirancang untuk memperoleh keseimbangan antara peningkatan detail lokal dan pengendalian *noise*. Parameter yang digunakan meliputi: (1) clip limit dengan variasi nilai 2.0, 3.0, dan 4.0 untuk menguji tingkat pembatasan kontras; (2) tile grid size sebesar 8×8 dan 16×16 untuk mengevaluasi pengaruh ukuran blok terhadap ketajaman detail rambut; serta (3) penerapan pada citra grayscale hasil transformasi adaptif sebelum tahap segmentasi. Nilai clip limit yang lebih rendah cenderung menghasilkan peningkatan kontras yang lebih halus dan stabil, sedangkan nilai yang lebih tinggi meningkatkan visibilitas struktur tipis namun berisiko memperkuat *noise*. Sementara itu, tile grid size yang lebih kecil (8×8) memberikan peningkatan detail lokal yang lebih tajam, sedangkan ukuran yang lebih besar (16×16) menghasilkan distribusi kontras yang lebih merata.

C. Segmentasi Gambar

Artefak dalam gambar digital adalah gangguan atau distorsi yang mengurangi kualitas visual gambar dan dapat menyembunyikan informasi penting di dalamnya. Dalam konteks gambar dermoskopi, objek lain seperti rambut yang menutupi area lesi kulit dapat dikategorikan sebagai artefak karena menyembunyikan tekstur dan batas lesi yang diperlukan untuk diagnosis lebih lanjut. Oleh karena itu, penting untuk menghilangkan artefak rambut secara efektif tanpa merusak informasi penting dalam gambar. *Deep learning* digunakan untuk memisahkan serat rambut dari area lesi kulit, dengan rambut didefinisikan sebagai artefak yang harus dipisahkan dari lesi kulit. Hal ini tidak hanya meningkatkan akurasi segmentasi lesi tetapi juga mempercepat proses analisis dengan mengurangi kebutuhan akan pra-pemrosesan manual. Pendekatan ini menjadikan *deep learning* sebagai alat yang sering digunakan untuk tugas segmentasi gambar medis, termasuk gambar dermoskopi yang mengandung rambut dan artefak lainnya.

1. U-Net

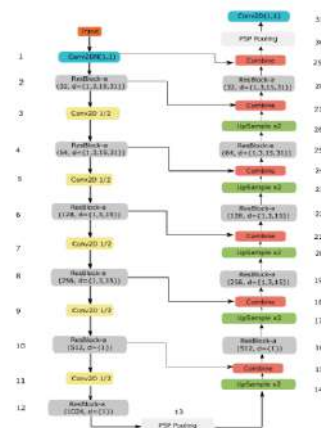
U-Net adalah arsitektur *deep learning* berbentuk U yang dirancang khusus untuk segmentasi gambar, pertama kali diperkenalkan oleh Ronneberger dkk (Ronneberger dkk., 2015). Arsitektur U-Net, seperti yang ditunjukkan pada Gambar 1, terdiri dari dua jalur: *encoder* untuk mengekstrak fitur penting dari gambar dan *decoder* untuk merekonstruksi peta segmentasi beresolusi tinggi. Keunggulan U-Net terletak pada koneksi skip-nya, yang memungkinkan transfer informasi detail dari *encoder* ke *decoder*. Selain itu, ekstraksi fitur dan rekonstruksi hasil gambar segmentasi rambut yang diprediksi dilakukan beberapa kali sesuai dengan jumlah pasangan *encoder* dan *decoder* yang digunakan, sehingga model dapat menghasilkan segmentasi yang akurat.



Gambar 2. Arsitektur U-Net (Ronneberger dkk., 2015)

2. ResU-Net

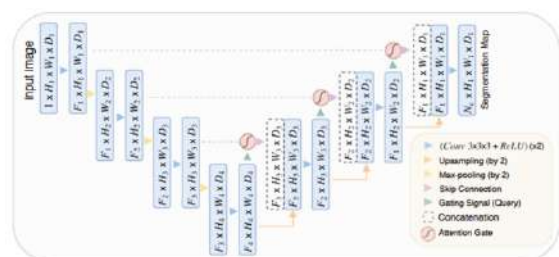
ResU-Net adalah model *deep learning* berbasis U-Net yang dikembangkan oleh Diakogiannis et al. [24] dengan lapisan pertama berupa lapisan konvolusi 1×1 sehingga tidak ada informasi gambar input yang hilang, serta blok residual sebagai *encoder* untuk mempercepat konvergensi dan mengatasi gradien yang menghilang selama *backpropagation*. Selain itu, penerapan *Pyramid Scene Parsing (PSP) Pooling* [25] dapat memperkaya fitur yang diekstraksi karena *PSP Pooling* menyaring input dengan membaginya menjadi 1, 4, 16, dan 64 partisi berukuran sama pada tahap *bottleneck*. Fitur-fitur tersebut kemudian digabungkan menggunakan metode *concatenation*.



Gambar 3 . Arsitektur ResU-Net [11]

3. AttU-Net

Attention U-Net adalah model yang dirancang oleh Oktay dkk. [12] untuk mengatasi kelemahan model U-Net selama proses *upsampling* di jalur ekspansi (*decoder*). Berbeda dengan U-Net, informasi spasial yang direkonstruksi selama *upsampling* tidak dievaluasi, sehingga hasilnya tidak akurat. Pada Gambar 2.3, untuk mengatasi masalah ini, model perhatian U-Net menerapkan gerbang perhatian (AG). AG bekerja dengan menyaring fitur yang melewati koneksi lompatan. Fitur disaring dalam AG menggunakan perhatian lunak sehingga fitur yang tidak relevan seperti artefak dapat dihilangkan sebelum proses *concatenation*. *Soft attention* bekerja dengan memberikan bobot pada area yang berbeda dalam gambar; area yang lebih relevan akan memiliki bobot yang lebih besar daripada area yang kurang relevan, sehingga dalam pelatihan model, seiring bertambahnya jumlah model pelatihan, model akan lebih fokus pada area dengan bobot yang lebih besar.



Gambar 4. Arsitektur Attention U-Net [26]

D. Metrik Evaluasi

Evaluasi penelitian ini dilakukan pada tahap segmentasi kualitatif dan numerik untuk mengukur kesamaan antara gambar segmen rambut *groundtruth* dan gambar segmen rambut yang diprediksi oleh model menggunakan *Dice Similarity Coefficient* (DSC) dan *Jaccard Index* (JAC) dengan membandingkan intensitas setiap piksel gambar dengan koordinat yang sama antara gambar segmen rambut *groundtruth* dan gambar segmen rambut yang diprediksi oleh model. Semakin tinggi nilai DSC dan JAC yang diperoleh, semakin mirip gambar segmen rambut yang diprediksi oleh model dengan gambar segmen rambut yang sebenarnya. Proporsi piksel rambut cenderung lebih kecil daripada piksel latar belakang kulit pada gambar dermoskopi, sehingga DSC cocok untuk digunakan. Hal ini karena DSC dapat membandingkan piksel rambut pada gambar *groundtruth* dan gambar prediksi tanpa memperhitungkan latar belakang. JAC digunakan untuk mengukur kesamaan piksel pada keseluruhan gambar *groundtruth* dan gambar prediksi, seperti yang didefinisikan dalam Persamaan 17 dan Persamaan 18.

$$DSC = \frac{2 \times |I_{Asli} \cap I_{Pred}|}{|I_{Asli}| + |I_{Pred}|} \quad (17)$$

$$JAC = \frac{|I_{Asli} \cap I_{Pred}|}{|I_{Asli} \cup I_{Pred}|} \quad (18)$$

IV. HASIL DAN PEMBAHASAN

Bab ini membahas lingkungan pengujian, hasil pengabuan abu-abu dengan citra PCA, hasil prapemrosesan citra dengan CLAHE dan pelatihan model pembelajaran mendalam, serta evaluasi hasil segmentasi rambut pada citra dermoskopi.

A. Lingkungan Uji

Lingkungan pengujian yang digunakan dalam studi ini dilakukan pada perangkat keras dan perangkat lunak. Perangkat keras yang digunakan ditampilkan dalam Tabel 1.

Tabel 1. Perangkat keras yang digunakan dalam studi

Platform	:	Kaggle Notebook
CPU	:	Intel(R) Xeon(R) CPU @ 2.20GHz
RAM	:	13 GB
GPU	:	NVIDIA Tesla T4 × 2
RAM GPU	:	16 GB × 2
Harddisk	:	57,6 GB

Selain itu, perangkat lunak yang digunakan adalah seperti yang tercantum dalam Tabel 2.

Tabel 2 Perangkat lunak yang digunakan dalam penelitian

Sistem Operasi	:	Windows 11 Home 64-bit
Browser	:	Mozilla Firefox versi 138.0.4 (64-bit)

B. Dataset

Kumpulan data terdiri dari 500 gambar dermoskopi dan anotasi segmen rambut, masing-masing dengan resolusi seragam 512 x 512 piksel, dengan saluran warna RGB untuk gambar dermoskopi dan biner (hitam dan putih) untuk gambar anotasi segmen rambut. Dataset ini bersumber dari ISIC (*International Skin Imaging Collaboration*) *Archive*, khususnya koleksi dermoskopi yang dikembangkan melalui kolaborasi internasional antara lembaga penelitian dermatologi dan organisasi seperti *International Skin Imaging Collaboration*. Data diakses melalui platform resmi ISIC Archive yang menyediakan citra lesi kulit terstandarisasi untuk keperluan penelitian dan pengembangan sistem berbasis kecerdasan buatan di bidang dermatologi. Data kemudian dibagi menjadi dua bagian: 450 pasang gambar dermoskopi dengan anotasi segmen rambut digunakan sebagai data pelatihan, dan 50 pasang gambar lainnya digunakan sebagai data validasi. Selain itu, untuk mencegah model pembelajaran mendalam menjadi *overfitted*, augmentasi dilakukan sesuai Tabel 3 pada gambar pelatihan pada setiap epoch.

Tabel 3 Augmentasi data pelatihan

Augmentasi	Rotasi
Rotation	Memutar gambar sebesar ± 90 derajat
Flip	Cerminkan gambar berdasarkan sumbu horizontal atau vertikal
Shear	Potong gambar sebesar $\pm 20\%$
Zoom	Perbesar gambar sebesar $\pm 20\%$ dari ukuran asli
Contrast change	Ubah kontras sebesar $\pm 15\%$ dari aslinya
Brightness change	Ubah kecerahan sebesar $\pm 15\%$ dari aslinya

Nilai *hyperparameter* yang digunakan dalam studi ini untuk melatih model ditampilkan dalam Tabel 4.

Tabel 4 Nilai *hyperparameter* yang digunakan


Hyperparameter	Description
activation_function	ReLU
batch_size	4
normalization	True
loss_function	DSC
epoch	75
optimizer	Adam
initial_learning_rate	0.001

C. Hasil Prapemrosesan Gambar

Gambar 4 menunjukkan gambar asli sebagai gambar dermoskopi asli dalam tiga kanal warna yang belum diproses. Gambar abu-abu adalah gambar dermoskopi yang telah dikonversi ke abu-abu tanpa proses tambahan. Gambar PCA-*grayscale* adalah gambar dermoskopi yang telah dikonversi ke *grayscale* menggunakan metode PCA. Gambar CLAHE adalah gambar *grayscale* yang telah diproses menggunakan metode CLAHE, dan gambar PCA-CLAHE adalah gambar *grayscale* dengan PCA yang telah diproses menggunakan metode CLAHE.

Pada Gambar 4, gambar *grayscale* memiliki kontras yang buruk karena terdapat area kulit dengan warna berbeda pada gambar asli yang tidak terlihat jelas. Gambar ini dapat mengubah warna rambut dan lesi kulit agar memiliki kontras yang lebih tinggi daripada warna kulit dibandingkan dengan gambar dermoskopi yang hanya *grayscale*. Pada gambar CLAHE, detail yang seharusnya ada pada gambar asli dan cenderung tidak terlihat pada gambar *grayscale* dapat terlihat meskipun masih memiliki tingkat kecerahan atau warna yang hampir sama dengan kulit. Pada gambar PCA dan

PCA-CLAHE, gambar dermoskopi seperti gambar terbalik, di mana warna yang semula gelap menjadi putih dan warna yang semula putih menjadi lebih gelap.



Gambar 4. Hasil Prapemrosesan

D. Hasil Segmentasi

Dalam studi ini, segmentasi dilakukan menggunakan model pembelajaran mendalam U-Net, ResU-Net, dan AttU-Net dengan data pelatihan menggunakan metode *grayscale Luminosity*, *grayscale PCA*, dan kombinasi metode *grayscale-CLAHE* dan *PCA-CLAHE*. Gambar 3 menunjukkan bahwa gambar segmen rambut yang dihasilkan dari prapemrosesan menggunakan PCA-CLAHE cenderung memetakan bagian rambut pada gambar dermoskopi dengan lebih baik dibandingkan gambar segmen rambut dengan skenario lain.

Gambar 5 (a) menunjukkan bahwa gambar segmen rambut yang diprediksi oleh model U-Net, ResU-Net, dan Att-Unet dari gambar *grayscale*, CLAHE, dan PCA kurang mampu mendeteksi rambut meskipun kepadatan rambut dalam gambar mencakup sebagian besar gambar dermoskopi. Setelah menerapkan CLAHE, setiap model dapat mendeteksi rambut yang sebelumnya tidak terdeteksi oleh model. Penerapan PCA-CLAHE menghasilkan gambar segmen rambut yang lebih

baik daripada PCA atau CLAHE saja karena jumlah segmen rambut yang dapat dideteksi oleh model lebih banyak dan lebih mirip dengan jumlah dan bentuk rambut dalam gambar dermoskopi asli.

Pada Gambar 5 (b), hasil segmentasi model U-Net, ResU-Net, dan Att-UNet tanpa PCA atau CLAHE pada gambar dermoskopi tidak dapat mendeteksi rambut dengan baik pada gambar input seperti yang ditunjukkan pada Gambar 5 (a). Namun, ketika CLAHE diterapkan, model tidak dapat mendeteksi rambut di sisi kanan gambar. Setelah menerapkan PCA, model dapat mengenali bagian rambut yang sebelumnya tidak teridentifikasi dengan lebih baik. Hasil terbaik diperoleh dengan PCA-CLAHE karena model dapat mengidentifikasi lebih banyak rambut dengan detail yang lebih baik.

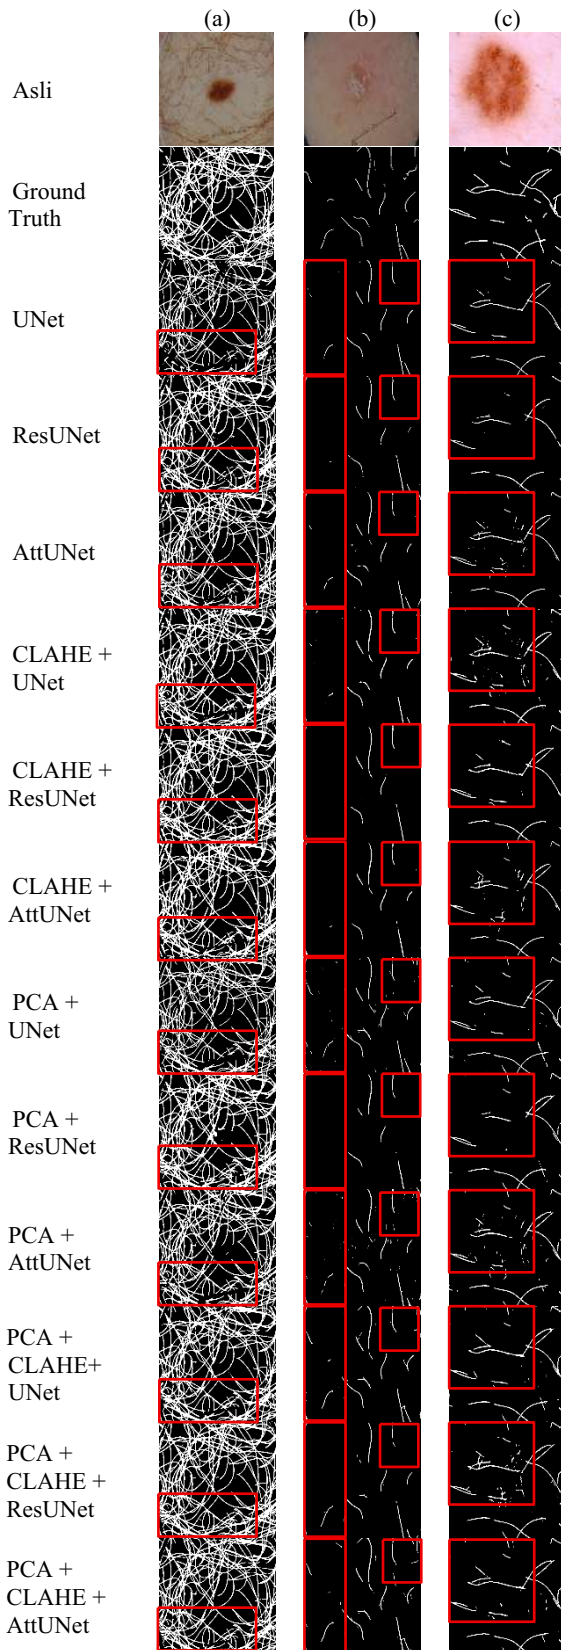
Pada Gambar 3 (c), baik CLAHE maupun PCA-CLAHE menghasilkan segmen rambut dengan lebih banyak *noise*, tetapi hasil segmentasi dari model AttUNet dan PCA-CLAHE mampu mengidentifikasi rambut terbanyak dengan artefak paling sedikit di antara hasil segmentasi dengan model UNet dan ResUNet.

E. Hasil Evaluasi

Evaluasi dilakukan dengan membandingkan nilai rata-rata indeks DSC dan Jaccard. Semakin tinggi nilai rata-rata DSC dan Jaccard, semakin mirip gambar segmen rambut hasilnya dengan *groundtruth*. Tabel 5 menunjukkan bahwa tahap prapemrosesan gambar sebelum segmentasi dengan *deep learning* dapat meningkatkan kinerja model.

Tabel 5. Hasil evaluasi gambar segmen rambut pada data validasi

Metode	Rata-rata DSC	Rata-rata JAC	Kerugian Pelatihan
U-Net	70,67	55,73%	27,70%
ResU-Net	72,30%	57,96%	25,88%
U-Net	70,67%	55,73%	27,70%
ResU-Net	72,30%	57,96%	25,88%
AttU-Net	74,61%	60,36%	24,17%
CLAHE + U-Net	74,45%	60,23%	24,93%
CLAHE + ResU-Net	73,91%	59,71%	24,64%
CLAHE + AttU-Net	74,41%	60,18%	24,80%
PCA + U-Net	73,56%	58,70%	26,32%
PCA + ResU-Net	74,58%	60,47%	26,79%
PCA + AttU-Net	72,88%	58,15%	27,45%
PCA + CLAHE + U-Net	74,48	60,16%	26,61%



Gambar 5. Hasil Segmentasi Rambut

Metode	Rata-rata DSC	Rata-rata JAC	Kerugian Pelatihan
PCA + CLAHE + ResU-Net	75,13	61,02%	25,57%
PCA + CLAHE + AttU-Net	75,24	61,04%	26,46%

Hasil evaluasi menunjukkan bahwa penerapan tahap prapemrosesan sebelum segmentasi berbasis deep learning berpengaruh terhadap peningkatan performa model. Berdasarkan Tabel 5, model dasar seperti U-Net dan ResU-Net memperoleh rata-rata DSC masing-masing sebesar 70,67% dan 72,30%, sedangkan AttU-Net mencapai 74,61%. Setelah diterapkan CLAHE, terjadi peningkatan performa pada U-Net (74,45%) dan ResU-Net (73,91%), meskipun peningkatan pada AttU-Net relatif stabil (74,41%). Penerapan PCA juga menunjukkan dampak positif, terutama pada ResU-Net (74,58%). Kombinasi PCA dan CLAHE memberikan hasil terbaik, khususnya pada ResU-Net (75,13%) dan AttU-Net (75,24%) dengan nilai Jaccard masing-masing sebesar 61,02% dan 61,04%. Hal ini menunjukkan bahwa integrasi reduksi dimensi adaptif dan peningkatan kontras lokal mampu menghasilkan segmentasi yang lebih mendekati ground truth dibandingkan metode tanpa prapemrosesan.

Perbedaan hasil tersebut disebabkan oleh beberapa faktor utama, yaitu kemampuan masing-masing arsitektur dalam mengekstraksi fitur spasial serta pengaruh kualitas citra masukan terhadap proses pembelajaran model. Model AttU-Net secara alami memiliki mekanisme attention yang lebih efektif dalam menyoroti fitur relevan seperti struktur rambut yang tipis, sehingga performanya relatif lebih tinggi dibanding U-Net standar. Sementara itu, CLAHE meningkatkan kontras lokal sehingga memperjelas batas rambut terhadap latar belakang, dan PCA membantu menekan redundansi informasi warna yang tidak relevan. Kombinasi PCA + CLAHE memberikan peningkatan paling konsisten karena keduanya bekerja secara komplementer: PCA menyederhanakan representasi fitur, sedangkan CLAHE meningkatkan visibilitas detail lokal. Namun, variasi kecil pada nilai training loss menunjukkan bahwa peningkatan akurasi segmentasi tidak selalu berbanding lurus dengan penurunan loss, karena model dapat mengalami sensitivitas terhadap noise atau perubahan distribusi intensitas setelah prapemrosesan.

V. KESIMPULAN

Dari hasil eksperimen yang dilakukan, dapat disimpulkan bahwa penerapan metode prapemrosesan gambar yang tepat dapat meningkatkan kinerja model deep learning dalam melakukan tugas segmentasi rambut pada gambar dermoskopi, dengan nilai tertinggi mencapai DSC 75,24% dan JAC 61,04% menggunakan prapemrosesan gambar PCA-CLAHE dan model *deep learning* AttU-Net. Penelitian ini masih memiliki potensi untuk dikembangkan guna memperoleh hasil segmentasi rambut yang lebih baik pada gambar dermoskopi dengan menerapkan prapemrosesan gambar, model *deep learning*, dan *hyperparameter* lainnya. Selain itu, penerapan metode pascapemrosesan juga dapat dipertimbangkan untuk memperoleh gambar segmentasi rambut yang lebih baik.

REFERENSI

- Z. Wang *et al.*, "Influence of Hair Presence on Dermoscopic Image Analysis by AI in Skin Lesion Diagnosis," *Comput. Biol. Med.*, vol. 183, p. 109335, Dec. 2024, doi: 10.1016/j.compbimed.2024.109335.
- L. Jütte, H. Patel, and B. Roth, "Advancing Dermoscopy Through a Synthetic Hair Benchmark Dataset and Deep Learning-Based Hair Removal," *J. Biomed. Opt.*, vol. 29, no. 11, Nov. 2024, doi: 10.1117/1.JBO.29.11.116003.
- N. Lama *et al.*, "ChimeraNet: U-Net for Hair Detection in Dermoscopic Skin Lesion Images," *J. Digit. Imaging*, vol. 36, no. 2, pp. 526–535, Nov. 2022, doi: 10.1007/s10278-022-00740-6.
- F. Pérez-García, R. Sparks, and S. Ourselin, "TorchIO: A Python Library for Efficient Loading, Preprocessing, Augmentation and Patch-Based Sampling of Medical Images in Deep Learning," *Comput. Methods Programs Biomed.*, vol. 208, p. 106236, Sep. 2021, doi: 10.1016/j.cmpb.2021.106236.
- S. Joseph and O. O. Olugbara, "Preprocessing Effects on Performance of Skin Lesion Saliency Segmentation," *Diagnostics*, vol. 12, no. 2, p. 344, Jan. 2022, doi: 10.3390/diagnostics12020344.
- O. A. M. F. Alnaggar *et al.*, "Efficient Artificial Intelligence Approaches for Medical Image Processing in Healthcare: Comprehensive Review, Taxonomy, and Analysis," *Artif. Intell. Rev.*, vol. 57, no. 8, p. 221, Jul. 2024, doi: 10.1007/s10462-024-10814-2.
- A. S. Ashour *et al.*, "Cascaded Hough Transform-Based Hair Mask Generation and Harmonic Inpainting for Automated Hair Removal from Dermoscopy Images," *Diagnostics*, vol. 12, no. 12, p. 3040, Dec. 2022, doi: 10.3390/diagnostics12123040.
- M. Doğan and İ. A. Özkan, "Automated Hair Segmentation in Dermoscopy Images with U-Net Based Approaches," in *2024 13th Mediterranean Conference on Embedded Computing (MECO)*, IEEE, Jun. 2024, pp. 1–4. doi: 10.1109/MECO62516.2024.10577890.
- R. K. Sidhu, J. Sachdeva, and D. Katoch, "Segmentation of Retinal Blood Vessels by a Novel Hybrid Technique- Principal Component Analysis (PCA) and Contrast Limited

- Adaptive Histogram Equalization (CLAHE),” *Microvasc. Res.*, vol. 148, p. 104477, Jul. 2023, doi: 10.1016/j.mvr.2023.104477.
- [10] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.
- [11] F. I. Diakogiannis, F. Waldner, P. Caccetta, and C. Wu, “ResUNet-a: A Deep Learning Framework for Semantic Segmentation of Remotely Sensed Data,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 162, pp. 94–114, Apr. 2020, doi: 10.1016/j.isprsjprs.2020.01.013.
- [12] Ozan Oktay *et al.*, “Attention U-Net: Learning Where to Look for the Pancreas,” *arXiv preprint arXiv:1804.03999*, 2018.
- [13] Y. Xiong, K. Yu, Y. Lan, Z. Lei, and D. Fan, “Hair Cluster Detection Model Based on Dermoscopic Images,” *Front. Phys.*, vol. 12, Feb. 2024, doi: 10.3389/fphy.2024.1364372.
- [14] J. Chen *et al.*, “TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation,” 2021, doi: 10.48550/arXiv.2102.04306.
- [15] D. Arous, S. Schrunner, I. Hanson, N. Frederike Jeppesen Edin, and E. Malinen, “Principal Component-Based Image Segmentation: a New Approach to Outline in vitro Cell Colonies,” *Comput. Methods Biomech. Biomed. Eng. Imaging Vis.*, vol. 11, no. 1, pp. 18–30, Jan. 2023, doi: 10.1080/21681163.2022.2035822.
- [16] Reza Karimzadeh, Emad Fatemizadeh, and Hossein Arabi, “A Novel Shape-Based Loss Function for Machine Learning-Based Seminal Organ Segmentation in Medical Imaging [pre-print],” 2022, doi: 10.48550/arXiv.2203.03336.
- [17] N. P. Singh and R. Srivastava, “Retinal Blood Vessels Segmentation by Using Gumbel Probability Distribution Function Based Matched Filter,” *Comput. Methods Programs Biomed.*, vol. 129, pp. 40–50, Jun. 2016, doi: 10.1016/j.cmpb.2016.03.001.
- [18] K. Shunmuga Priya and V. Selvi, “Enhanced Skin Disease Image Analysis Using Hybrid CLAHE-Median Filter and Salient K-Means Cluster,” 2024, pp. 459–471. doi: 10.1007/978-981-97-1488-9_34.
- [19] S. Chakraverti, P. Agarwal, H. S. Pattanayak, S. P. S. Chauhan, A. K. Chakraverti, and M. Kumar, “De-Noising the Image Using DBST-LCM-CLAHE: A Deep Learning Approach,” *Multimed. Tools Appl.*, vol. 83, no. 4, pp. 11017–11042, Jan. 2024, doi: 10.1007/s11042-023-16016-2.
- [20] S. Saifullah and R. Dreżewski, “Advanced Medical Image Segmentation Enhancement: A Particle-Swarm-Optimization-Based Histogram Equalization Approach,” *Applied Sciences*, vol. 14, no. 2, p. 923, Jan. 2024, doi: 10.3390/app14020923.
- [21] Y. Yoshimi *et al.*, “Image Preprocessing with Contrast-Limited Adaptive Histogram Equalization Improves the Segmentation Performance of Deep Learning for the Articular Disk of the Temporomandibular Joint on Magnetic Resonance Images,” *Oral Surg. Oral Med. Oral Pathol. Oral Radiol.*, vol. 138, no. 1, pp. 128–141, Jul. 2024, doi: 10.1016/j.oooo.2023.01.016.
- [22] X. Liu and T. D. C. Nguyen, “Medical Images Enhancement by Integrating CLAHE with Wavelet Transform and Non-Local Means Denoising,” *Academic Journal of Computing & Information Science*, vol. 7, no. 1, 2024, doi: 10.25236/AJCIS.2024.070108.
- [23] S. M. Pizer, R. E. Johnston, J. P. Ericksen, B. C. Yankaskas, and K. E. Muller, “Contrast-Limited Adaptive Histogram Equalization: Speed and Effectiveness,” in *[1990] Proceedings of the First Conference on Visualization in Biomedical Computing*, IEEE Comput. Soc. Press, 1990, pp. 337–345. doi: 10.1109/VBC.1990.109340.
- [24] F. I. Diakogiannis, F. Waldner, P. Caccetta, and C. Wu, “ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 162, pp. 94–114, Apr. 2020, doi: 10.1016/j.isprsjprs.2020.01.013.
- [25] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, “Pyramid Scene Parsing Network,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 6230–6239. doi: 10.1109/CVPR.2017.660.
- [26] O. Oktay *et al.*, “Attention U-Net: Learning Where to Look for the Pancreas,” Apr. 2018.