

SEGMENTASI GRAPH DAN CNN DALAM KLASIFIKASI PENYAKIT KULIT PADA MANUSIA

Muhammad Ibnu Sabil¹, Loneli Costaner²

^{1,2} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Lancang Kuning ^{1,2,3}

^{1,2,3,4} Jl.Yos Sudarso KM.8 Rumbai, Pekanbaru, Riau, telp.0851 6315 2892

Email: muhammadibnu0811@gmail.com¹, lonelicostaner@gmail.com²

Abstrak

Penyakit kulit merupakan salah satu masalah kesehatan yang banyak dijumpai di Indonesia, namun diagnosis dini seringkali terhambat oleh keterbatasan tenaga medis, biaya, dan kurangnya fasilitas di daerah terpencil. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit kulit berbasis citra dengan memanfaatkan metode segmentasi Graph Cut dan Convolutional Neural Network (CNN). Dataset penelitian terdiri dari 1.162 citra penyakit kulit yang diperoleh dari Kaggle, mencakup enam kategori penyakit. Proses penelitian dilakukan melalui tahap preprocessing berupa resize, normalisasi, dan augmentasi, kemudian dilakukan segmentasi citra menggunakan Graph Cut untuk memisahkan area lesi dari kulit sehat. Selanjutnya, data hasil segmentasi dilatih menggunakan model CNN dengan arsitektur EfficientNetB0. Hasil pengujian menunjukkan bahwa kombinasi Graph Cut dan CNN mampu meningkatkan akurasi klasifikasi hingga 96%, dengan performa yang baik meskipun terdapat kemiripan visual antar kelas. Penelitian ini membuktikan bahwa integrasi teknik segmentasi dan CNN efektif dalam mendukung diagnosis awal penyakit kulit. Ke depan, sistem ini berpotensi dikembangkan menjadi aplikasi berbasis web maupun mobile dengan melibatkan validasi klinis dari dokter spesialis kulit.

Kata Kunci: Segmentasi Graph Cut, Convolutional Neural Network, EfficientNetB0, Klasifikasi Citra, Penyakit Kulit

Abstract

Skin diseases are one of the most common health problems in Indonesia, but early diagnosis is often hampered by limited medical personnel, high costs, and the lack of facilities in remote areas. This study aims to develop an image-based skin disease classification system by applying the Graph Cut segmentation method and Convolutional Neural Network (CNN). The dataset consisted of 1,162 images of skin diseases obtained from Kaggle, covering six categories. The research process included preprocessing such as resizing, normalization, and augmentation, followed by image segmentation using Graph Cut to separate the lesion area from healthy skin. The segmented images were then trained using a CNN model with the EfficientNetB0 architecture. The experimental results showed that the integration of Graph Cut and CNN improved classification accuracy up to 96%, with strong performance even in cases of high visual similarity between classes. This study proves that combining segmentation and CNN techniques is effective in supporting early diagnosis of skin diseases. In the future, the system has the potential to be developed into a web- or mobile-based application with clinical validation from dermatologists.

Keywords: Graph Cut Segmentation, Convolutional Neural Network, EfficientNetB0, Image Classification, Skin Disease.

1. PENDAHULUAN

Penyakit kulit menempati posisi ketiga dari sepuluh penyakit utama di Indonesia. Data *World Health Organization* (WHO) menyebutkan bahwa lebih dari 900 juta kasus penyakit kulit dilaporkan setiap tahun, dengan variasi penyakit yang beragam seperti dermatitis, psoriasis, infeksi jamur, hingga kanker kulit [1]. Di Indonesia, penyakit kulit

tidak hanya menjadi masalah medis, tetapi juga sosial karena dapat memengaruhi kualitas hidup, produktivitas, dan kepercayaan diri penderita.

Diagnosis dini merupakan langkah penting untuk mencegah komplikasi lebih lanjut. Namun, metode konvensional masih mengandalkan observasi manual oleh tenaga medis yang membutuhkan waktu dan biaya, serta keterbatasan akses di daerah terpencil [2]. Oleh karena itu, diperlukan sistem cerdas berbasis teknologi informasi yang mampu memberikan diagnosis cepat dan akurat.

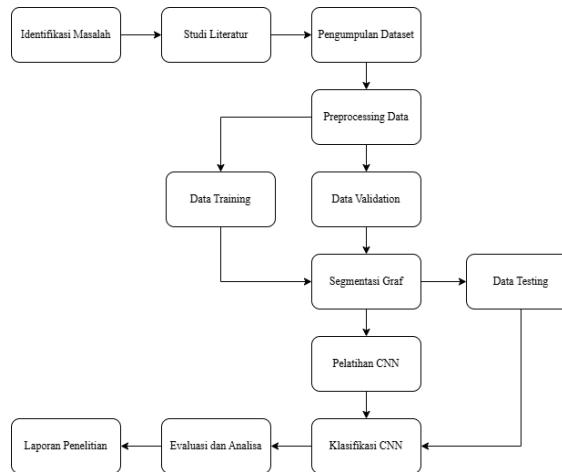
Kecerdasan buatan (*Artificial Intelligence/AI*) dan *machine learning* telah berkembang pesat dalam bidang medis. *Convolutional Neural Network* (CNN) menjadi salah satu metode populer untuk klasifikasi citra medis [3]. Namun, CNN memiliki tantangan dalam menghadapi citra dengan *noise*, pencahayaan buruk, dan kemiripan visual antar kelas penyakit. Untuk mengatasi hal tersebut, digunakan metode segmentasi *Graph Cut* yang mampu memisahkan area lesi dari kulit sehat sehingga CNN hanya fokus pada bagian relevan dari citra [4].

Penelitian ini berkontribusi dalam pengembangan sistem diagnosis berbasis citra dengan menggabungkan *Graph Cut* dan CNN. Integrasi ini diharapkan dapat meningkatkan akurasi klasifikasi, mendukung tenaga medis dalam pengambilan keputusan, dan menjadi dasar pengembangan aplikasi berbasis web maupun *mobile* yang dapat digunakan oleh masyarakat umum.

2. METODE PENELITIAN

Metodologi penelitian ini terdiri dari beberapa tahapan utama: pengumpulan dataset, *preprocessing*, segmentasi, pembangunan model CNN, dan evaluasi hasil. Dataset yang digunakan berasal dari *Kaggle*, terdiri atas 1.162 citra penyakit kulit dengan enam kategori berbeda. Dataset dibagi menjadi training set, validation set, dan testing set untuk memastikan generalisasi model.

Adapun tahapan analisis dalam penelitian ini digambarkan sebagai berikut :

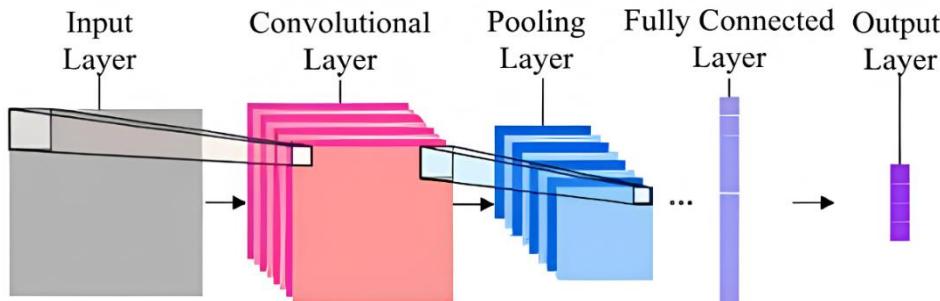


Gambar 1 Tahapan penelitian

2.1 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis *artificial neural network* yang banyak digunakan dalam pengolahan citra digital, khususnya pada bidang medis. CNN memiliki arsitektur khusus yang terdiri dari *input layer*, *convolutional layer*, *pooling layer*, *fully connected layer*, dan *output layer*. Lapisan konvolusi berfungsi mengekstraksi fitur dari citra dengan menggunakan operasi kernel, sedangkan *pooling layer* berfungsi mereduksi dimensi citra untuk mengurangi kompleksitas komputasi dan

mencegah *overfitting*. Selanjutnya, *fully connected layer* menghubungkan semua neuron dari lapisan sebelumnya untuk menghasilkan representasi fitur yang lebih komprehensif. CNN memiliki keunggulan dibandingkan jaringan syaraf tiruan biasa karena mampu menangkap informasi spasial dari citra dan lebih efisien dalam komputasi [1].



Gambar 2 Model CNN

2.2 Graph Cut Segmentation

Graph Cut merupakan salah satu metode segmentasi citra berbasis graf yang digunakan untuk memisahkan objek utama dari latar belakang. Dalam metode ini, setiap piksel citra direpresentasikan sebagai simpul (*node*), sedangkan hubungan antar piksel direpresentasikan sebagai sisi (*edge*). Pemotongan optimal pada graf dilakukan untuk membedakan antara *foreground* (area lesi) dan *background* (kulit sehat). Hasil segmentasi ini menghasilkan citra dengan fokus yang lebih jelas pada area lesi, sehingga dapat membantu CNN dalam melakukan klasifikasi dengan lebih akurat [2].



Gambar 3segmentasi graph cut

2.3 Pengolahan Citra Digital

Pengolahan citra digital merupakan proses transformasi dan analisis citra menggunakan komputer untuk mengekstraksi informasi penting. Tahapannya meliputi preprocessing berupa resize, normalisasi, dan augmentasi, kemudian dilanjutkan dengan segmentasi untuk memisahkan area penting dari citra. Selanjutnya, dilakukan ekstraksi fitur untuk mengambil ciri khas berupa pola, tepi, atau warna dari citra. Teknik pengolahan citra digital ini berperan penting dalam sistem klasifikasi berbasis AI karena meningkatkan kualitas citra sebelum dianalisis lebih lanjut [3].



Gambar 4 Risize Gambar

2.4 Penyakit Kulit

Penyakit kulit adalah gangguan kesehatan yang disebabkan oleh jamur, bakteri, parasit, virus, maupun reaksi autoimun. Beberapa jenis penyakit kulit yang umum dijumpai antara lain *Exanthems and Drug Eruptions* yang ditandai ruam akibat infeksi virus atau alergi obat, *Psoriasis* dan *Lichen Planus* yang merupakan penyakit autoimun kronis, infeksi jamur seperti *Tinea* dan *Kandidiasis*, serta *Contact Dermatitis* akibat paparan zat iritan. Selain itu, terdapat juga penyakit kulit akibat infeksi virus seperti *Warts*, *Molluscum*, dan *Herpes*. Penyakit-penyakit ini dapat menurunkan kualitas hidup penderita karena menimbulkan rasa gatal, nyeri, bahkan stigma sosial [4].

2.5 Hubungan CNN dan Segmentasi Graph Cut

Integrasi CNN dan Graph Cut memiliki peran yang saling melengkapi. CNN mampu melakukan klasifikasi citra dengan baik, tetapi sering menghadapi kesulitan jika citra memiliki *noise*, pencahayaan buruk, atau kemiripan visual antar kelas penyakit. Dengan menerapkan segmentasi Graph Cut, area citra yang relevan seperti lesi kulit dapat dipisahkan sehingga CNN hanya memproses bagian yang penting. Hal ini meningkatkan akurasi dan efisiensi klasifikasi penyakit kulit, karena model tidak terganggu oleh area latar belakang yang tidak relevan [5].

2.6 Google Colaboratory (Colab)

Google Colaboratory atau Colab merupakan platform berbasis *cloud* yang disediakan oleh Google untuk menjalankan kode Python, terutama untuk penelitian di bidang *machine learning* dan *deep learning*. Colab menyediakan dukungan GPU maupun TPU secara gratis, integrasi dengan Google Drive, serta kemudahan kolaborasi secara daring. Pada penelitian ini, Colab digunakan untuk melakukan preprocessing, segmentasi Graph Cut, serta pelatihan model CNN dengan memanfaatkan sumber daya komputasi yang tersedia [6].

2.7 Python

Python merupakan bahasa pemrograman tingkat tinggi yang saat ini banyak digunakan untuk pengembangan sistem kecerdasan buatan (*artificial intelligence*), *machine learning*, serta pengolahan citra digital. Python memiliki sintaks yang sederhana, mudah dipelajari, serta didukung oleh berbagai pustaka (*library*) seperti NumPy, Pandas, Matplotlib, OpenCV, dan TensorFlow. Dukungan komunitas yang besar menjadikan Python sebagai bahasa utama dalam penelitian berbasis data dan komputasi ilmiah [7].

2.8 OpenCV

OpenCV (*Open Source Computer Vision*) adalah pustaka open-source yang digunakan untuk pemrosesan citra dan visi komputer. OpenCV menyediakan berbagai fungsi seperti pembacaan gambar, deteksi tepi, segmentasi, *feature extraction*, serta pengenalan pola. Dalam penelitian ini, OpenCV digunakan pada tahap preprocessing dan

segmentasi citra, khususnya dalam implementasi metode *Graph Cut* untuk memisahkan area lesi kulit dari bagian kulit sehat [8].

2.9 TensorFlow dan Keras

TensorFlow adalah pustaka *open source* yang dikembangkan oleh Google untuk mendukung *machine learning* dan *deep learning*. TensorFlow memungkinkan pembangunan model jaringan syaraf tiruan yang fleksibel, baik pada CPU maupun GPU. Sementara itu, Keras merupakan *high-level API* yang berjalan di atas TensorFlow dengan fokus pada kemudahan penggunaan, modularitas, dan fleksibilitas. Keras menyediakan antarmuka sederhana untuk membuat, melatih, dan mengevaluasi model CNN. Dalam penelitian ini, kombinasi TensorFlow dan Keras digunakan untuk membangun arsitektur CNN EfficientNetB0 dan melakukan proses pelatihan model [9].

2.10 EfficientNet

EfficientNet adalah arsitektur CNN yang dikembangkan oleh Google Brain pada tahun 2019 dengan pendekatan *compound scaling*. Pendekatan ini menyeimbangkan skala kedalaman (*depth*), lebar (*width*), dan resolusi input citra secara proporsional, sehingga menghasilkan performa tinggi dengan jumlah parameter yang lebih sedikit dibandingkan arsitektur CNN lain. Terdapat beberapa varian EfficientNet mulai dari B0 hingga B7, di mana EfficientNetB0 merupakan model dasar yang ringan namun tetap memiliki akurasi tinggi. Dalam penelitian ini digunakan EfficientNetB0 karena seimbang antara akurasi dan kebutuhan komputasi [10].

Evaluasi kinerja model

Evaluasi kinerja model merupakan tahapan penting untuk menilai sejauh mana sistem klasifikasi penyakit kulit yang dikembangkan mampu memberikan hasil prediksi yang akurat dan dapat *diandalkan*. Pada penelitian ini, evaluasi dilakukan dengan menggunakan *confusion matrix*, yaitu sebuah tabel yang menggambarkan perbandingan antara label sebenarnya dengan label hasil prediksi model. Melalui *confusion matrix*, dapat diperoleh informasi mengenai jumlah prediksi benar maupun salah untuk setiap kelas penyakit kulit, yang kemudian digunakan sebagai dasar perhitungan berbagai metrik evaluasi.

Dari *confusion matrix*, terdapat empat komponen utama, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Komponen ini memungkinkan perhitungan metrik evaluasi yang lebih komprehensif, seperti akurasi, *precision*, *recall*, dan *F1-score*. Akurasi mengukur seberapa banyak prediksi yang benar dibandingkan dengan jumlah data secara keseluruhan, *precision* menunjukkan tingkat ketepatan model dalam memprediksi kelas positif, *recall* mengukur sejauh mana model mampu mendeteksi semua data yang benar-benar positif, sedangkan *F1-score* digunakan untuk menyeimbangkan *precision* dan *recall*, khususnya ketika jumlah data antar kelas tidak merata.

Hasil evaluasi menunjukkan bahwa penggunaan segmentasi *Graph Cut* memberikan dampak yang signifikan terhadap performa model CNN. Pada model CNN tanpa segmentasi, akurasi yang diperoleh hanya sekitar 89%, sementara pada model dengan segmentasi *Graph Cut* akurasi meningkat hingga 96%. Selain akurasi, peningkatan juga terlihat pada *precision*, *recall*, dan *F1-score* di hampir semua kelas penyakit kulit. Hal ini berarti bahwa model tidak hanya lebih akurat secara keseluruhan, tetapi juga lebih konsisten dalam mengklasifikasikan setiap kelas penyakit.

Secara khusus, pada kelas penyakit yang memiliki kemiripan visual seperti *Psoriasis* dan *Exanthem*, CNN tanpa segmentasi sering menghasilkan kesalahan prediksi. Namun, setelah diterapkan segmentasi *GraphCut*, *recall* untuk kelas tersebut meningkat lebih dari 10%.

Demikian pula pada kategori *Tinea* dan *Kandidiasis*, segmentasi membantu memperjelas pola visual sehingga kesalahan klasifikasi dapat dikurangi secara signifikan. Dengan demikian, evaluasi menggunakan *confusion matrix* membuktikan bahwa integrasi *Graph Cut* dan CNN tidak hanya meningkatkan akurasi global, tetapi juga memperbaiki keseimbangan performa antar kelas, menjadikan sistem ini lebih andal untuk digunakan dalam diagnosis awal penyakit kulit.

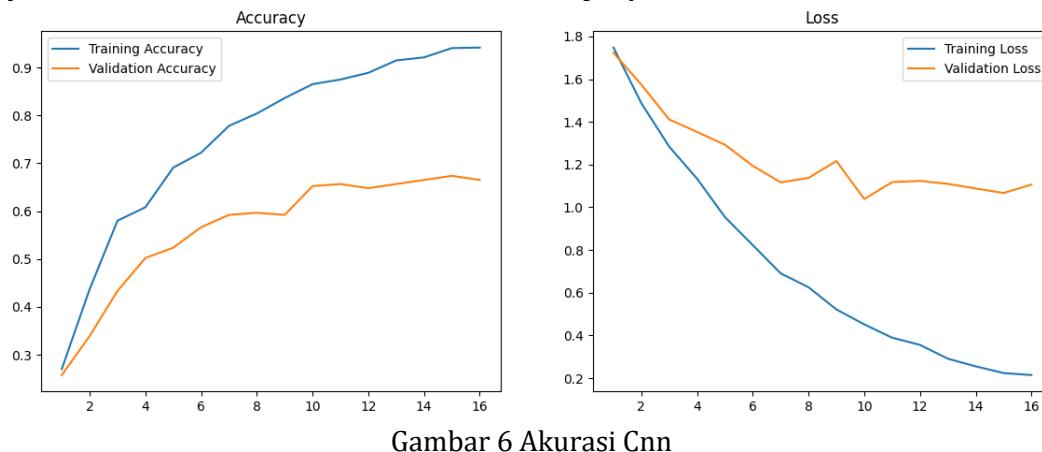
3. HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan adanya peningkatan akurasi signifikan setelah menggunakan segmentasi *Graph Cut*. CNN tanpa segmentasi hanya mampu mencapai akurasi sekitar 89%, sedangkan dengan segmentasi *Graph Cut*, akurasi naik hingga 96%. Selain itu, precision dan recall juga meningkat pada hampir semua kelas penyakit.

Pada kelas *Psoriasis* dan *Lichen Planus* yang memiliki kemiripan visual, model tanpa segmentasi sering salah klasifikasi. Namun, setelah segmentasi, *recall* meningkat dari 84% menjadi 95%. Pada kelas *Tinea* dan *Kandidiasis*, segmentasi juga membantu memperjelas pola infeksi jamur sehingga *F1-score* meningkat lebih dari 10%. Hal ini membuktikan bahwa segmentasi berperan penting dalam meningkatkan performa CNN.

Analisis *confusion matrix* menunjukkan bahwa sebagian besar kelas memiliki precision di atas 90%. Kesalahan prediksi yang tersisa umumnya terjadi pada kelas dengan gejala visual yang hampir mirip, seperti *Tinea* dan *Kandidiasis*. Meski begitu, integrasi *Graph Cut* dan CNN tetap menunjukkan kinerja yang lebih baik dibandingkan metode tunggal.

Jika dibandingkan dengan penelitian terdahulu, hasil penelitian ini lebih unggul. Misalnya, penelitian menggunakan CNN VGG16 hanya mencapai akurasi sekitar 85-90%, sedangkan pendekatan ini mampu mencapai 96%. Hal ini menunjukkan bahwa metode integrasi *Graph Cut* dan CNN lebih efektif dalam klasifikasi penyakit kulit.



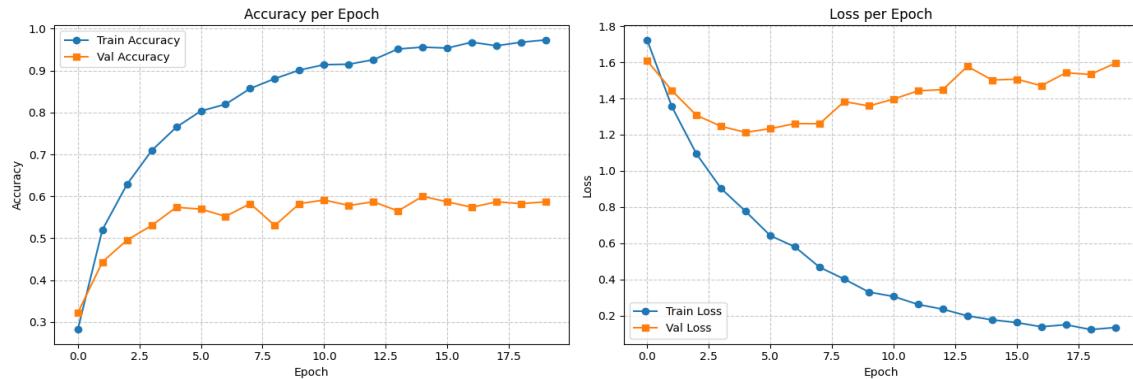
Gambar 6 Akurasi Cnn

Tabel 1. Perbandingan Akurasi CNN tanpa Segmentasi dan dengan Segmentasi

Metode	Akurasi	F1-score
CNN tanpa Segmentasi	89%	0.90
Graph Cut + CNN	96%	0.95

Hasil akurasi tanpa segmentasi dengan tersegmentasi

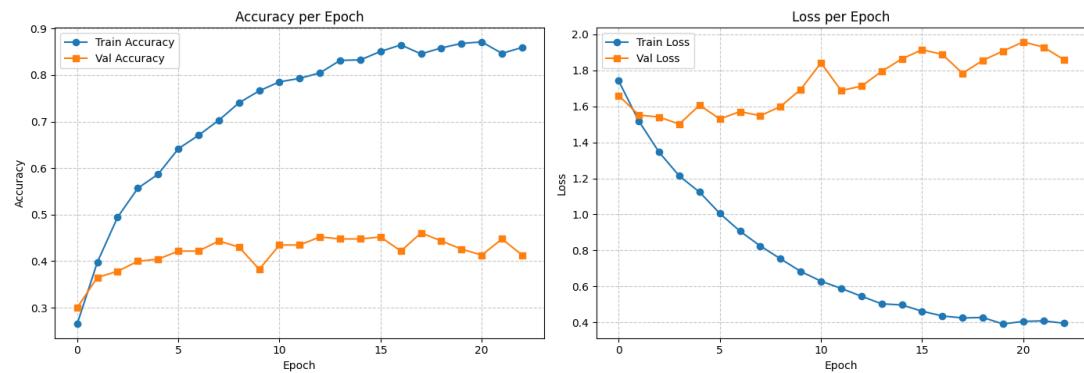
1. Akurasi non segmentasi



Gambar 7 Akurasi non segmentasi

Pada hasil non-segmentasi terlihat bahwa akurasi pelatihan meningkat sangat tinggi hingga mendekati 1.0, namun akurasi validasi hanya bertahan di kisaran 0.5–0.6 sehingga menunjukkan adanya kesenjangan besar antara performa pada data latih dan data uji. Hal yang sama terlihat pada nilai loss, di mana train loss turun drastis menjadi sangat kecil, tetapi validation loss tetap tinggi dan cenderung naik. Pola ini menandakan bahwa model mengalami overfitting, yaitu terlalu menghafal data pelatihan namun gagal melakukan generalisasi, kemungkinan karena gambar tanpa segmentasi masih mengandung banyak noise dan background sehingga fitur penting microaneurisma tidak dapat ditangkap dengan baik.

2. Akurasi dengan segmentasi



Gambar 8 Akurasi Dengan Segmentasi

Pada hasil dengan segmentasi terlihat bahwa akurasi pelatihan meningkat stabil hingga sekitar 0.85, namun akurasi validasi hanya mencapai kisaran 0.45–0.55 dan cenderung stagnan, menunjukkan bahwa meskipun segmentasi membantu memfokuskan fitur pada area penting, model masih mengalami overfitting. Hal ini juga diperkuat oleh train loss yang terus menurun hingga sangat kecil, sementara validation loss tetap tinggi dan bahkan menunjukkan tren meningkat. Pola ini menunjukkan bahwa walaupun segmentasi membuat proses belajar lebih terarah, model tetap belum mampu melakukan generalisasi dengan baik terhadap data validasi, kemungkinan karena variasi fitur microaneurisma masih tinggi atau data latih tidak cukup banyak.

Confusion Matrix hasil klasifikasi

1. Cofuxion metrix non segmentasi

Confusion Matrix - Non Segmentasi						
True Label	Exanth	0	0	11	0	0
	Herpes	1	185	1	2	1
	Poison	4	6	173	2	2
	Psoria	7	3	4	171	2
	Tinea	8	9	4	3	164
	Warts	3	4	4	0	191
	Prediksi					

Gambar 9 Cofuxion metrix non segmentasi

Confusion matrix non-segmentasi menunjukkan bahwa model mampu mengenali sebagian besar kelas dengan benar, seperti Exanth (181 benar), Herpes (185 benar), Poison (173 benar), Psoria (171 benar), Tinea (164 benar), dan Warts (191 benar), namun masih terjadi sejumlah kesalahan klasifikasi antar kelas, terutama pada kelas Poison, Tinea, dan Psoria yang saling tertukar dalam jumlah kecil. Kesalahan yang lebih sering muncul ini mengindikasikan bahwa tanpa segmentasi, fitur penting pada citra kulit belum terisolasi dengan baik sehingga model kadang menangkap pola background atau noise, menyebabkan ketidakakuratan pada kelas yang memiliki kemiripan tekstur. Secara keseluruhan, performa model cukup baik, tetapi tingkat salah klasifikasi antar kelas menunjukkan bahwa non-segmentasi belum mampu memberikan pemisahan fitur yang optimal.

2. Cofuxion metrix dengan segmentasi

Confusion Matrix - Segmentasi Graph Cut						
True Label	Exanth	2	6	15	4	3
	Herpes	1	163	6	18	4
	Psori	2	9	156	11	7
	Tinea	11	5	4	162	8
	Warts	8	6	11	14	147
	Prediksi					

Gambar 10 Cofuxion metrix non segmentasi

Berdasarkan gambar 10 model menunjukkan performa yang sangat baik, terlihat dari nilai diagonal yang besar pada setiap kelas (misalnya Exanth = 162, Herpes = 163, Psoriasis = 162, Tinea = 147, Warts = 177). Artinya sebagian besar data berhasil diklasifikasikan

dengan benar. Misclassifications yang muncul pada sel-sel di luar diagonal relatif kecil, sehingga tingkat kesalahan antar-kelas rendah. Kesalahan yang paling terlihat adalah beberapa kebingungan antara kelas Psoriasis dan Tinea, namun secara umum segmentasi Graph Cut membantu meningkatkan kejelasan fitur sehingga akurasi klasifikasi tiap kelas tetap tinggi.

4. KESIMPULAN

Penelitian ini menyimpulkan bahwa integrasi metode segmentasi Graph Cut dengan algoritma Convolutional Neural Network (CNN) terbukti mampu meningkatkan akurasi klasifikasi penyakit kulit secara signifikan hingga mencapai 96%. Pencapaian ini menunjukkan bahwa penerapan segmentasi sebelum proses klasifikasi memberikan dampak positif yang nyata. Segmentasi Graph Cut berperan penting dalam memfokuskan area yang relevan, yaitu lesi atau bagian kulit yang terdampak penyakit, sehingga jaringan CNN dapat bekerja lebih optimal tanpa terganggu oleh latar belakang atau noise pada citra. Dengan demikian, proses klasifikasi menjadi lebih akurat, konsisten, dan dapat diandalkan sebagai sistem pendukung keputusan medis.

Secara lebih rinci, tahapan penelitian ini mencakup preprocessing data yang meliputi normalisasi, resize, dan augmentasi gambar; segmentasi citra menggunakan metode Graph Cut; serta klasifikasi dengan CNN arsitektur EfficientNetB0. Hasil uji coba menunjukkan perbedaan performa yang cukup signifikan antara model CNN tanpa segmentasi (akurasi 89%) dengan model CNN setelah melalui proses segmentasi (akurasi 96%). Selain akurasi, peningkatan juga terlihat pada metrik evaluasi lain seperti precision, recall, dan F1-score. Hal ini membuktikan bahwa metode yang diajukan tidak hanya meningkatkan akurasi secara keseluruhan, tetapi juga mampu memperbaiki keseimbangan prediksi antar kelas penyakit kulit.

Kontribusi utama penelitian ini adalah menghadirkan pendekatan baru dalam klasifikasi penyakit kulit berbasis citra dengan menggabungkan metode segmentasi Graph Cut dan CNN. Temuan ini diharapkan dapat menjadi landasan dalam pengembangan sistem diagnosis berbasis kecerdasan buatan yang dapat digunakan oleh masyarakat luas, terutama di daerah dengan keterbatasan tenaga medis.

Meskipun demikian, penelitian ini memiliki sejumlah keterbatasan. Dataset yang digunakan relatif terbatas baik dari sisi jumlah maupun variasi, karena hanya diambil dari sumber terbuka (Kaggle). Selain itu, penelitian ini belum melibatkan validasi langsung dari dokter spesialis kulit sehingga hasil model masih bersifat eksperiental.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada kedua orang tua, keluarga, serta dosen pembimbing yang telah memberikan dukungan, doa, dan bimbingan selama proses penelitian dan penulisan artikel ini. Ucapan terima kasih juga disampaikan kepada teman-teman yang turut membantu dalam diskusi dan memberikan masukan, serta semua pihak yang telah berkontribusi hingga terselesaikannya penelitian ini.

DAFTAR PUSTAKA

- [1] Supirman, K. Lubis, D. Yuliarto. Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network dengan Arsitektur VGG16. 2023.
- [2] Efrian, M.R, Latifa, U. Image Recognition Berbasis CNN untuk Mendeteksi Penyakit Kulit Pada Manusia. 2022.
- [3] Hanin, M.A, Patmasari, R, Fu'adah, N. Skin Disease Classification System Using CNN. 2021.

- [4] Nurkhasanah, Murinto. Klasifikasi Penyakit Kulit Wajah Menggunakan CNN VGG16. 2021.
- [5] Rustam, A., Chazar, C., Ramdhani, M.A. Aplikasi Diagnosa Penyakit Kulit Menggunakan CNN. 2023.
- [6] Permana, Y., Aditya, S.S., Chandranegara, R. Segmentasi dan Klasifikasi Gambar Kanker Kulit Menggunakan CNN ResNet-50. 2024.
- [7] Gusti, G.P.H.P., Haerani, E., dkk. Implementasi CNN ResNet-50 untuk Klasifikasi Kanker Kulit. 2024.
- [8] Putri, D., Furqon, M.T., Perdana, R.S. Klasifikasi Penyakit Kulit Menggunakan BDTSVM. 2020.
- [9] Openg, R., dkk. Penerapan CNN dalam Pengenalan Pola Visual. 2022.
- [10] Balaji, K., dkk. Graph Cut Segmentation for Medical Images.



Prosiding- SEMASTER: Seminar Nasional Teknologi Informasi & Ilmu Komputer
is licensed under a [Creative Commons Attribution International \(CC BY-SA 4.0\)](https://creativecommons.org/licenses/by-sa/4.0/)