E-ISSN : 3025-1311
https://journal.cib.institute/index.php/kohesi

Kohesi: Jurnal Multidisiplin Saintek
Volume 11 No 6 Tahun 2026

ANALISIS KOMPARATIF KINERJA DEEPLABV3+ DALAM SEGMENTASI ULKUS KAKI DIABETIK BERBASIS *DEEP LEARNING*

Mahmud Suyuti[1], Sigit Ananda Murwato[2], Naufal Abdilah[3]
[1,2,3] Universitas 17 Agustus 1945 Surabaya
E-mail: mahmudsuyuti@untag-sby.ac.id, sigitananda@untag-sby.ac.id, naufal@untag-sby.ac.id

ABSTRACT

Diabetic foot ulcers (DFUs) are among the serious complications of diabetes mellitus, requiring accurate wound monitoring to support clinical assessment and treatment. Segmentation of wound regions in digital images is an essential step in developing automated monitoring systems based on artificial intelligence. This study aims to analyze and compare the performance of five deep learning architectures, namely U-Net, U-Net++, Attention U-Net, SegFormer, and DeepLabV3+, for diabetic foot ulcer segmentation. A quantitative approach was employed through computational experiments involving image dataset collection and annotation, preprocessing, data partitioning, model training, and segmentation performance evaluation. Model performance was assessed using four evaluation metrics: Intersection over Union (IoU), Dice Similarity Coefficient (DSC), precision, and recall. The experimental results demonstrated that DeepLabV3+ achieved the best overall performance, with an IoU of 0.732, DSC of 0.845, precision of 0.821, and recall of 0.792. Compared with U-Net, DeepLabV3+ exhibited performance improvements of 7.49% in IoU and 6.69% in DSC. These findings indicate that DeepLabV3+ provides more accurate wound region identification than the other evaluated architectures. This study concludes that DeepLabV3+ is a promising approach for developing automated diabetic foot ulcer segmentation systems using digital images. Nevertheless, further validation using external datasets is necessary to assess the model's generalizability and reliability in real-world clinical applications.

Keywords: Diabetic Foot Ulcer; Deep Learning; DeepLabV3+; Image Segmentation; Convolutional Neural Network.

ABSTRAK

Ulkus kaki diabetik merupakan salah satu komplikasi diabetes melitus yang memerlukan pemantauan luka secara akurat untuk mendukung proses evaluasi dan penanganan klinis. Segmentasi area luka pada citra digital menjadi tahapan penting dalam pengembangan sistem pemantauan otomatis berbasis kecerdasan buatan. Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja lima arsitektur *deep learning*, yaitu U-Net, U-Net++, Attention U-Net, SegFormer, dan DeepLabV3+, dalam melakukan segmentasi area ulkus kaki diabetik. Penelitian menggunakan pendekatan kuantitatif melalui metode eksperimen komputasional yang meliputi pengumpulan dan anotasi dataset

Article History
Received: November 2026
Reviewed:November 2026
Published: November 2026

Plagiarism Checker No 237.u873247.fh8374

Copyright : Author
Publish by : Kohesi

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

citra, prapemrosesan, pembagian data, pelatihan model, serta evaluasi kinerja segmentasi. Pengukuran performa dilakukan menggunakan empat metrik, yaitu *Intersection over Union* (IoU), *Dice Similarity Coefficient* (DSC), *precision*, dan *recall*. Hasil penelitian menunjukkan bahwa DeepLabV3+ menghasilkan kinerja terbaik dengan nilai IoU sebesar 0,732, DSC sebesar 0,845, *precision* sebesar 0,821, dan *recall* sebesar 0,792. Dibandingkan dengan U-Net, DeepLabV3+ menunjukkan peningkatan kinerja sebesar 7,49% pada metrik IoU dan 6,69% pada metrik DSC. Keunggulan tersebut menunjukkan kemampuan DeepLabV3+ dalam mengidentifikasi area luka secara lebih akurat dibandingkan arsitektur pembanding. Penelitian ini menyimpulkan bahwa DeepLabV3+ merupakan pendekatan yang menjanjikan untuk pengembangan sistem segmentasi otomatis ulkus kaki diabetik berbasis citra digital. Meskipun demikian, validasi menggunakan dataset eksternal masih diperlukan untuk memastikan kemampuan generalisasi model dalam penerapan klinis

Kata Kunci: Ulkus Kaki Diabetik; Deep Learning; DeepLabV3+; Segmentasi Citra; Convolutional Neural Network

1. PENDAHULUAN

Diabetes melitus merupakan salah satu penyakit metabolik kronis yang menjadi permasalahan kesehatan global karena prevalensinya yang terus meningkat serta berbagai komplikasi yang ditimbulkannya. Salah satu komplikasi serius diabetes melitus adalah ulkus kaki diabetik (*Diabetic Foot Ulcer*/DFU), yaitu kondisi terbentuknya luka terbuka pada kaki akibat kombinasi neuropati perifer, gangguan vaskular, dan penurunan kemampuan penyembuhan jaringan. Ulkus kaki diabetik dapat berkembang menjadi infeksi, kerusakan jaringan, hingga amputasi ekstremitas bawah apabila tidak mendapatkan penanganan yang tepat. Oleh karena itu, identifikasi kondisi luka secara akurat menjadi bagian penting dalam proses pemantauan perkembangan luka dan pengambilan keputusan klinis.

Penilaian ulkus kaki diabetik umumnya dilakukan melalui pemeriksaan visual oleh tenaga medis dengan memperhatikan karakteristik luka, seperti ukuran, bentuk, warna, kondisi jaringan, dan batas area luka. Namun, pemeriksaan visual memiliki beberapa keterbatasan, terutama berkaitan dengan subjektivitas penilaian, variasi pengalaman tenaga medis, serta perbedaan kondisi pencahayaan dan kualitas citra. Ketidakkonsistenan dalam menentukan batas luka dapat memengaruhi ketepatan pengukuran area ulkus dan evaluasi perkembangan penyembuhan. Kondisi tersebut menunjukkan perlunya pendekatan berbasis teknologi yang mampu mengidentifikasi dan memisahkan area luka dari jaringan kulit di sekitarnya secara otomatis, objektif, dan konsisten.

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*/AI), khususnya *deep learning*, telah memberikan kontribusi signifikan terhadap analisis citra medis. Salah satu penerapannya adalah segmentasi semantik (*semantic segmentation*), yaitu proses pengelompokan setiap piksel citra ke dalam kategori tertentu berdasarkan karakteristik visualnya. Dalam konteks ulkus kaki diabetik, segmentasi semantik digunakan untuk mengidentifikasi piksel yang termasuk area luka dan membedakannya dari jaringan kulit normal maupun latar belakang citra. Pendekatan ini memungkinkan pembentukan representasi spasial

area ulkus yang lebih terstruktur sehingga dapat mendukung analisis luas relatif luka, bentuk luka, serta pemantauan perubahan area luka dari waktu ke waktu.

Sejumlah penelitian sebelumnya telah mengembangkan metode berbasis *deep learning* untuk mendeteksi dan menganalisis ulkus kaki diabetik. Goyal et al. (2018) memperkenalkan pendekatan segmentasi semantik berbasis *fully convolutional networks* untuk mengidentifikasi area ulkus kaki diabetik pada citra berwarna. Penelitian tersebut menunjukkan bahwa pendekatan pembelajaran mendalam memiliki potensi untuk melakukan segmentasi luka secara otomatis. Selanjutnya, Goyal et al. (2019) mengembangkan pendekatan berbasis *deep learning* untuk mendeteksi ulkus kaki diabetik pada citra visual. Penelitian tersebut memperlihatkan bahwa karakteristik visual luka dapat dipelajari melalui jaringan saraf konvolusional untuk mendukung identifikasi ulkus secara otomatis.

Dalam perkembangan arsitektur segmentasi citra medis, U-Net yang diperkenalkan oleh Ronneberger et al. (2015) menjadi salah satu pendekatan yang banyak digunakan karena memiliki struktur *encoder-decoder* dengan *skip connection* untuk mempertahankan informasi spasial. Arsitektur tersebut memungkinkan penggabungan fitur tingkat rendah dan tingkat tinggi sehingga mendukung segmentasi objek dengan bentuk yang kompleks. Meskipun demikian, segmentasi ulkus kaki diabetik tetap menghadapi tantangan karena area luka memiliki karakteristik visual yang beragam, batas yang tidak selalu tegas, ukuran yang bervariasi, serta kemiripan warna antara jaringan luka dan kulit di sekitarnya. Tantangan tersebut menuntut penggunaan arsitektur yang mampu memahami konteks visual pada berbagai skala sekaligus mempertahankan ketelitian segmentasi.

Salah satu arsitektur *deep learning* yang berpotensi digunakan untuk mengatasi permasalahan tersebut adalah DeepLabV3+. Arsitektur ini dikembangkan oleh Chen et al. (2018) dengan mengintegrasikan mekanisme *Atrous Spatial Pyramid Pooling* (ASPP) dan struktur *encoder-decoder*. ASPP memungkinkan jaringan mengekstraksi informasi kontekstual pada berbagai skala melalui penggunaan konvolusi atrous dengan tingkat dilasi yang berbeda. Sementara itu, komponen *decoder* berfungsi memperbaiki hasil segmentasi, terutama pada bagian batas objek. Kombinasi kedua mekanisme tersebut menjadikan DeepLabV3+ relevan untuk segmentasi objek dengan variasi ukuran, bentuk, dan karakteristik tepi, termasuk area ulkus kaki diabetik.

Penerapan DeepLabV3+ pada citra ulkus kaki diabetik memiliki tantangan tersendiri karena citra luka umumnya diperoleh dalam kondisi yang tidak sepenuhnya terkontrol. Variasi pencahayaan, sudut pengambilan gambar, resolusi citra, warna kulit, serta keberadaan jaringan nekrotik dan jaringan granulasi dapat memengaruhi karakteristik visual luka. Selain itu, batas antara jaringan luka dan kulit sehat tidak selalu memiliki perbedaan warna maupun tekstur yang jelas. Kondisi tersebut dapat menyebabkan kesalahan klasifikasi piksel, khususnya pada bagian tepi luka dan area dengan karakteristik visual yang menyerupai jaringan sekitarnya. Oleh karena itu, diperlukan evaluasi terhadap kemampuan model dalam menghasilkan segmentasi yang sesuai dengan anotasi referensi.

Berdasarkan kajian penelitian sebelumnya, pendekatan *deep learning* telah menunjukkan potensi dalam mendukung analisis otomatis ulkus kaki diabetik. Namun, penelitian segmentasi masih perlu memperhatikan kemampuan model dalam mempertahankan ketepatan batas luka, menangani variasi ukuran dan bentuk ulkus, serta menghasilkan segmentasi yang konsisten pada citra dengan karakteristik visual berbeda. Di samping itu, keberhasilan model dalam mengenali area luka tidak cukup dinilai berdasarkan akurasi klasifikasi piksel secara keseluruhan, karena ketidakseimbangan jumlah piksel antara area luka dan latar belakang dapat menghasilkan nilai akurasi yang tinggi meskipun kualitas segmentasi area ulkus belum optimal. Dengan demikian,

diperlukan evaluasi menggunakan metrik yang secara khusus mengukur kesesuaian spasial antara hasil segmentasi model dan anotasi referensi.

Kesenjangan penelitian (research gap) yang menjadi fokus penelitian ini adalah perlunya evaluasi terukur terhadap kemampuan DeepLabV3+ dalam melakukan segmentasi area ulkus kaki diabetik pada citra luka yang memiliki variasi bentuk, ukuran, warna, dan batas jaringan. Penelitian terdahulu telah mengembangkan berbagai pendekatan deteksi dan segmentasi berbasis *deep learning*, tetapi hasil dari satu arsitektur atau dataset tidak dapat secara langsung digeneralisasikan pada kondisi citra yang berbeda. Oleh sebab itu, pengujian DeepLabV3+ secara khusus pada data citra ulkus kaki diabetik diperlukan untuk mengetahui kemampuan arsitektur tersebut dalam membedakan area luka dari jaringan sekitarnya.

Kontribusi penelitian ini terletak pada penerapan dan evaluasi arsitektur DeepLabV3+ untuk menghasilkan segmentasi semantik area ulkus kaki diabetik pada tingkat piksel, disertai analisis kinerja segmentasi berdasarkan kesesuaian area prediksi terhadap anotasi referensi. Penelitian ini memanfaatkan kemampuan ekstraksi fitur multiskala melalui ASPP dan penyempurnaan batas objek melalui mekanisme *decoder* untuk mengidentifikasi area luka yang memiliki karakteristik visual kompleks. Berbeda dengan pendekatan yang hanya berfokus pada pendeteksian keberadaan luka, penelitian ini diarahkan untuk menghasilkan peta segmentasi yang menunjukkan lokasi dan cakupan area ulkus secara lebih terperinci. Kontribusi tersebut diharapkan dapat memberikan bukti empiris mengenai efektivitas DeepLabV3+ dalam segmentasi ulkus kaki diabetik serta menjadi dasar pengembangan sistem analisis luka berbantuan komputer.

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi model DeepLabV3+ dalam melakukan segmentasi otomatis area ulkus kaki diabetik pada citra digital. Secara khusus, penelitian diarahkan untuk membangun model segmentasi yang mampu membedakan piksel area ulkus dan non-ulkus, menghasilkan peta segmentasi berdasarkan karakteristik visual luka, serta mengukur kualitas segmentasi menggunakan metrik *Intersection over Union* (IoU), *Dice Similarity Coefficient* (DSC), *precision*, dan *recall*. Penggunaan beberapa metrik tersebut bertujuan untuk memberikan gambaran kinerja model secara lebih komprehensif, terutama dalam mengukur tingkat kesesuaian area prediksi dan kemampuan model mengenali piksel luka.

Sebagai pendekatan pemecahan masalah, penelitian dilakukan melalui beberapa tahapan utama, yaitu pengumpulan dan penyiapan dataset citra ulkus kaki diabetik beserta anotasi segmentasinya, prapemrosesan citra, pembagian dataset menjadi data pelatihan, validasi, dan pengujian, serta pelatihan model DeepLabV3+. Tahap prapemrosesan dilakukan untuk menyeragamkan dimensi dan format citra, sedangkan augmentasi data dapat diterapkan pada data pelatihan untuk meningkatkan keragaman karakteristik visual yang dipelajari model. Selanjutnya, model dilatih untuk mempelajari hubungan antara citra masukan dan mask segmentasi yang merepresentasikan area ulkus. Hasil segmentasi kemudian dibandingkan dengan anotasi referensi menggunakan metrik evaluasi yang telah ditentukan. Melalui pendekatan tersebut, penelitian ini diharapkan mampu memberikan kontribusi terhadap pengembangan metode segmentasi citra medis yang dapat mendukung analisis dan pemantauan ulkus kaki diabetik secara lebih objektif, terukur, dan efisien.

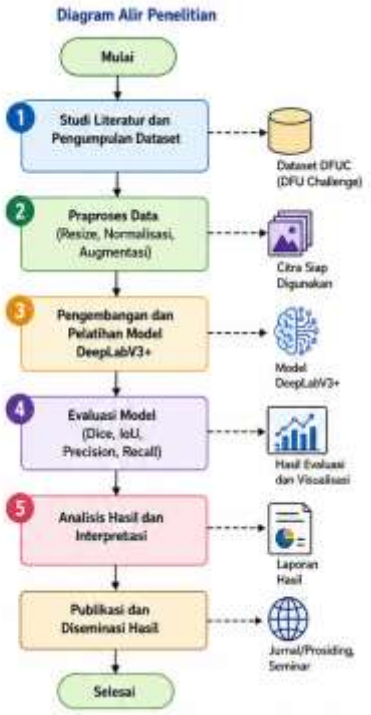
2. METODE PENELITIAN

2.1 Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional untuk mengembangkan dan mengevaluasi model segmentasi area ulkus kaki diabetik (*Diabetic Foot Ulcer*/DFU) pada citra digital menggunakan arsitektur DeepLabV3+. Pendekatan ini

bertujuan untuk mengidentifikasi area luka secara otomatis melalui proses segmentasi semantik, yaitu pengklasifikasian setiap piksel citra ke dalam dua kategori, yakni area ulkus dan non-ulkus.

Rancangan penelitian terdiri atas beberapa tahapan utama, yaitu pengumpulan dataset, prapemrosesan citra, pembagian dataset, perancangan arsitektur DeepLabV3+, pelatihan model, pengujian model, serta evaluasi hasil segmentasi seperti disajikan pada Gambar 1. Setiap tahapan dilakukan secara sistematis untuk menghasilkan model yang mampu mengenali karakteristik visual area ulkus dan membedakannya dari jaringan kulit maupun latar belakang citra.



Gambar 1. ***Diagram Alur Penelitian Segmentasi Ulkus Kaki Diabetik Menggunakan DeepLabV3+.***

Proses penelitian diawali dengan penyiapan citra ulkus kaki diabetik beserta anotasi segmentasi yang digunakan sebagai *ground truth*. Selanjutnya, citra diproses melalui tahapan normalisasi ukuran dan nilai piksel agar sesuai dengan kebutuhan masukan model. Dataset kemudian dibagi menjadi data pelatihan, validasi, dan pengujian. Model DeepLabV3+ dilatih menggunakan data pelatihan, sedangkan data validasi digunakan untuk memantau kinerja model dan menentukan konfigurasi pelatihan yang sesuai. Setelah proses pelatihan selesai, model dievaluasi menggunakan data pengujian yang tidak digunakan selama pelatihan maupun pemilihan model.

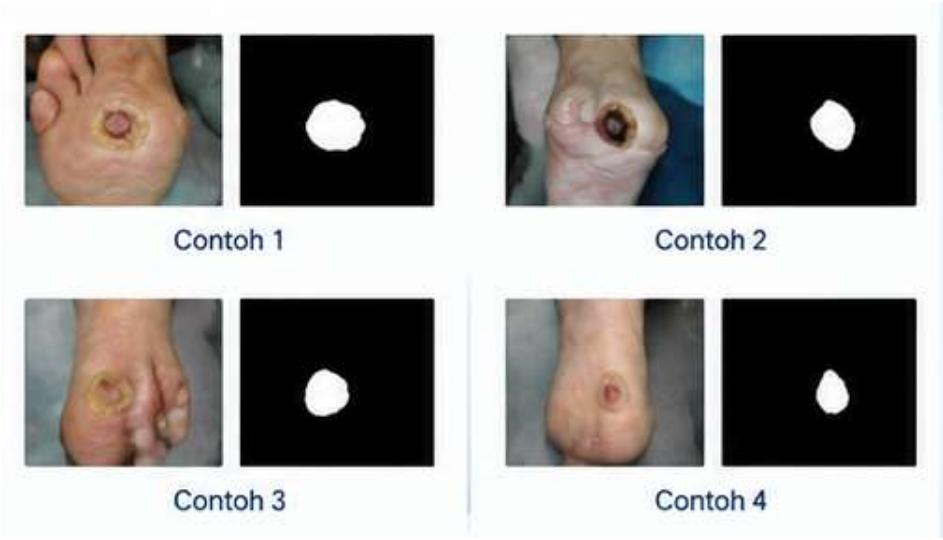
Evaluasi dilakukan dengan membandingkan hasil prediksi segmentasi terhadap anotasi referensi menggunakan metrik *Intersection over Union* (IoU), *Dice Similarity Coefficient* (DSC), *precision*, dan *recall*. Hasil evaluasi digunakan untuk mengetahui kemampuan model dalam mengidentifikasi area ulkus serta tingkat kesesuaian spasial antara hasil segmentasi dan area luka sebenarnya.

2.2 Ruang Lingkup dan Objek Penelitian

Objek penelitian berupa citra digital ulkus kaki diabetik yang memperlihatkan area luka pada bagian kaki penderita diabetes melitus. Penelitian difokuskan pada proses segmentasi semantik untuk memisahkan area ulkus dari bagian citra lainnya berdasarkan karakteristik visual yang dipelajari oleh model.

Ruang lingkup penelitian dibatasi pada segmentasi biner (*binary segmentation*), dengan dua kelas utama, yaitu kelas ulkus dan kelas non-ulkus. Kelas ulkus merepresentasikan piksel yang termasuk area luka berdasarkan anotasi referensi, sedangkan kelas non-ulkus mencakup jaringan kulit di luar area luka serta latar belakang citra.

Penelitian ini tidak mencakup klasifikasi tingkat keparahan ulkus, identifikasi jenis jaringan luka secara spesifik, diagnosis infeksi, maupun prediksi waktu penyembuhan. Hasil penelitian difokuskan pada kemampuan model dalam menghasilkan peta segmentasi area luka secara otomatis berdasarkan citra digital.



Gambar 2. Contoh Pasangan Citra dan Mask

Citra yang digunakan seperti pada Gambar 2 harus memiliki anotasi segmentasi berupa *mask* yang menunjukkan lokasi area ulkus. Anotasi tersebut digunakan sebagai acuan dalam proses pembelajaran terawasi (*supervised learning*) dan evaluasi hasil segmentasi.

2.3 Bahan dan Alat Penelitian

Bahan utama penelitian berupa dataset citra ulkus kaki diabetik dalam format digital beserta anotasi segmentasi yang menunjukkan area luka. Dataset dapat berasal dari sumber data publik yang menyediakan pasangan citra dan *ground truth mask*. Setiap citra digunakan sebagai data masukan, sedangkan anotasi segmentasi digunakan sebagai label referensi dalam proses pelatihan dan evaluasi.

Perangkat lunak yang direncanakan untuk mendukung penelitian meliputi bahasa pemrograman Python, pustaka *deep learning* TensorFlow atau PyTorch, OpenCV untuk pengolahan citra, NumPy untuk pengolahan data numerik, serta Matplotlib untuk visualisasi hasil segmentasi. Lingkungan pengembangan dapat menggunakan Jupyter Notebook atau Google Colab yang mendukung pemrosesan komputasi berbasis *Graphics Processing Unit* (GPU).

Perangkat keras yang digunakan berupa komputer atau lingkungan komputasi dengan kapasitas memori dan kemampuan pemrosesan yang memadai untuk menjalankan pelatihan jaringan saraf konvolusional. Penggunaan GPU ditujukan untuk mempercepat proses komputasi selama pelatihan dan pengujian model.

2.4 Tempat dan Sumber Data Penelitian

Penelitian dilaksanakan secara komputasional melalui lingkungan pengembangan berbasis Python. Seluruh tahapan pengolahan data, pelatihan model, pengujian, dan evaluasi dilakukan menggunakan perangkat komputasi yang mendukung implementasi arsitektur DeepLabV3+.

Sumber data penelitian direncanakan menggunakan dataset sekunder berupa citra ulkus kaki diabetik yang diperoleh dari repositori penelitian atau dataset publik. Pemilihan dataset mempertimbangkan ketersediaan citra berwarna, anotasi segmentasi, kualitas citra, serta kesesuaian karakteristik data dengan tujuan penelitian.

Data yang digunakan harus memiliki pasangan antara citra asli dan anotasi segmentasi. Citra asli berfungsi sebagai masukan model, sedangkan anotasi segmentasi berfungsi sebagai referensi untuk menentukan piksel yang termasuk area ulkus dan non-ulkus.

2.5 Teknik Pengumpulan Data

Teknik pengumpulan data dilakukan melalui metode dokumentasi dengan memanfaatkan dataset citra ulkus kaki diabetik yang tersedia secara publik. Pengumpulan data dilakukan dengan memperoleh citra luka dan anotasi segmentasi dari sumber dataset yang relevan.

Setelah dataset diperoleh, dilakukan pemeriksaan kelengkapan data untuk memastikan setiap citra memiliki anotasi segmentasi yang sesuai. Pemeriksaan juga dilakukan terhadap format berkas, resolusi citra, kesesuaian dimensi antara citra dan *mask*, serta keberadaan data yang rusak atau tidak dapat diproses.

Citra yang memenuhi kriteria selanjutnya disusun menjadi dataset penelitian. Proses pengumpulan dan pemeriksaan data bertujuan untuk memastikan bahwa seluruh citra yang digunakan memiliki kualitas dan struktur yang sesuai untuk proses pelatihan serta evaluasi model segmentasi.

2.6 Prapemrosesan Data

Tahap prapemrosesan bertujuan untuk menyeragamkan karakteristik citra sebelum digunakan sebagai masukan model DeepLabV3+. Proses prapemrosesan meliputi penyesuaian ukuran citra, normalisasi nilai piksel, pengolahan anotasi segmentasi, dan augmentasi data.

Penyesuaian ukuran dilakukan dengan mengubah dimensi citra menjadi 512 × 512 piksel sebagai konfigurasi awal penelitian. Penyeragaman ukuran diperlukan agar seluruh citra memiliki dimensi masukan yang konsisten selama proses pelatihan dan pengujian model. Proses perubahan ukuran citra dilakukan menggunakan metode interpolasi bilinear, sedangkan perubahan ukuran *mask* segmentasi menggunakan interpolasi *nearest neighbor* untuk mempertahankan nilai kelas pada setiap piksel.

Normalisasi dilakukan dengan mengubah nilai intensitas piksel citra ke dalam rentang 0 hingga 1. Proses normalisasi bertujuan untuk menjaga konsistensi skala masukan dan mendukung stabilitas proses pembelajaran model.

Anotasi segmentasi dikonversi menjadi representasi biner dengan nilai 1 untuk piksel area ulkus dan nilai 0 untuk piksel non-ulkus. Representasi tersebut digunakan sebagai target pembelajaran dalam proses segmentasi semantik.

Augmentasi data diterapkan pada data pelatihan untuk meningkatkan keragaman karakteristik citra dan mengurangi risiko *overfitting*. Teknik augmentasi yang direncanakan meliputi rotasi, pembalikan horizontal, perubahan kecerahan, dan penyesuaian kontras. Transformasi geometris diterapkan secara konsisten pada citra dan *mask*, sedangkan perubahan kecerahan dan kontras hanya diterapkan pada citra.

2.7 Pembagian Dataset

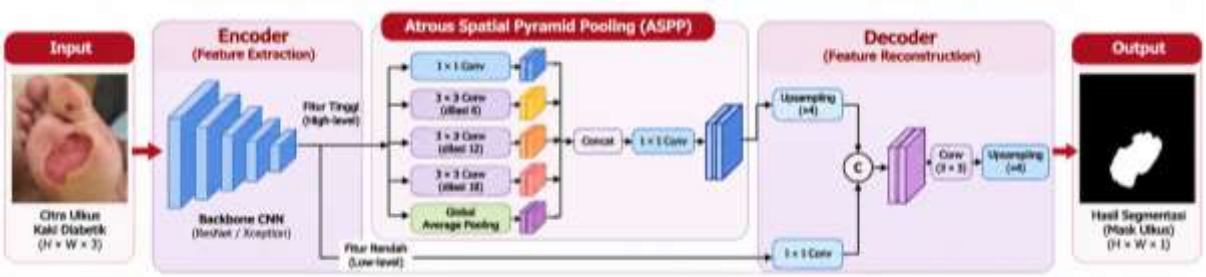
Dataset dibagi menjadi tiga kelompok, yaitu data pelatihan (*training set*), data validasi (*validation set*), dan data pengujian (*testing set*). Pembagian dataset direncanakan menggunakan proporsi 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian.

Data pelatihan digunakan untuk memperbarui parameter model berdasarkan hasil perhitungan fungsi kerugian (*loss function*). Data validasi digunakan untuk memantau perkembangan kinerja model selama proses pelatihan dan menentukan model terbaik. Sementara itu, data pengujian digunakan untuk mengukur kemampuan generalisasi model terhadap citra yang belum digunakan selama proses pembelajaran.

Pembagian dataset dilakukan sebelum proses augmentasi untuk menghindari kebocoran data (*data leakage*). Apabila dataset memiliki beberapa citra dari pasien atau luka yang sama, pembagian dilakukan berdasarkan identitas pasien atau luka agar citra yang saling berkaitan tidak tersebar pada kelompok pelatihan dan pengujian.

2.8 Perancangan Arsitektur DeepLabV3+

Model segmentasi yang digunakan dalam penelitian ini adalah DeepLabV3+ disajikan pada Gambar 2, yaitu arsitektur jaringan saraf konvolusional yang dirancang untuk melakukan segmentasi semantik dengan menggabungkan mekanisme ekstraksi fitur multiskala dan struktur *encoder-decoder*.



Gambar 3. Arsitektur DeepLabV3+ untuk Segmentasi Ulkus Kaki Diabetik

DeepLabV3+ terdiri atas tiga komponen utama, yaitu *backbone network*, *Atrous Spatial Pyramid Pooling* (ASPP), dan *decoder*. Backbone berfungsi mengekstraksi fitur visual dari citra masukan, sedangkan ASPP digunakan untuk memperoleh informasi kontekstual pada berbagai skala melalui penerapan konvolusi atrous dengan tingkat dilasi yang berbeda.

Komponen *decoder* digunakan untuk menggabungkan fitur tingkat tinggi dengan fitur spasial tingkat rendah sehingga menghasilkan peta segmentasi dengan detail batas objek yang lebih baik. Mekanisme tersebut relevan untuk segmentasi ulkus kaki diabetik karena bentuk luka yang tidak beraturan dan batas antara area ulkus dengan jaringan sekitarnya yang tidak selalu terlihat jelas.

Pada penelitian ini, DeepLabV3+ dirancang untuk menghasilkan keluaran berupa peta probabilitas segmentasi biner. Setiap piksel pada keluaran model memiliki nilai probabilitas yang menunjukkan kemungkinan piksel tersebut termasuk area ulkus. Fungsi aktivasi sigmoid digunakan pada lapisan keluaran untuk menghasilkan nilai probabilitas antara 0 dan 1.

Peta probabilitas selanjutnya dikonversi menjadi *mask* segmentasi biner menggunakan nilai ambang (*threshold*) yang ditentukan. Nilai ambang awal yang digunakan adalah 0,5, sehingga piksel dengan probabilitas sama dengan atau lebih besar dari 0,5 diklasifikasikan sebagai area ulkus, sedangkan piksel dengan probabilitas di bawah 0,5 diklasifikasikan sebagai non-ulkus.

2.9 Pelatihan Model

Pelatihan model dilakukan menggunakan pendekatan *supervised learning*, yaitu proses pembelajaran yang memanfaatkan pasangan citra masukan dan anotasi segmentasi sebagai target keluaran disajikan pada Gambar 3.

Pada setiap iterasi pelatihan, citra dimasukkan ke dalam model DeepLabV3+ untuk menghasilkan prediksi probabilitas area ulkus. Prediksi tersebut dibandingkan dengan *ground truth mask* menggunakan fungsi kerugian untuk menghitung tingkat kesalahan segmentasi.

Fungsi kerugian yang direncanakan adalah kombinasi *Binary Cross-Entropy* (BCE) dan *Dice Loss*. BCE digunakan untuk mengukur kesalahan prediksi probabilitas pada setiap piksel, sedangkan Dice Loss digunakan untuk meningkatkan kesesuaian area segmentasi antara hasil prediksi dan anotasi referensi.

Secara matematis, fungsi kerugian gabungan dirumuskan sebagai berikut:

$$L = \alpha L_BCE + (1 - \alpha) L_Dice$$

dengan L merupakan nilai kerugian total, L_BCE merupakan nilai Binary Cross-Entropy, L_Dice merupakan nilai Dice Loss, dan α merupakan parameter pembobotan kedua fungsi kerugian. Proses optimasi parameter model dilakukan menggunakan algoritma Adam dengan *learning rate* awal sebesar 0,0001. Pelatihan direncanakan berlangsung maksimal 100 *epoch* dengan ukuran *batch* yang disesuaikan dengan kapasitas perangkat komputasi. Untuk mengurangi risiko *overfitting*, diterapkan mekanisme *early stopping* berdasarkan kinerja model pada data validasi. Model dengan nilai Dice tertinggi pada data validasi disimpan sebagai model terbaik dan digunakan pada tahap pengujian.

2.10 Definisi Operasional Variabel Penelitian

Variabel penelitian didefinisikan berdasarkan komponen masukan, proses, dan keluaran yang digunakan dalam sistem segmentasi yang disajikan pada Tabel 1.

Tabel 1. Definisi Operasional Variabel

No.	Variabel	Defisinisi operasional	Indikator	Skala
1	Citra ulkus kaki diabetik	Citra digital yang memperlihatkan area ulkus	Warna, tekstur, ukuran citra	Data digital
2	Ground truth mask	Anotasi piksel yang menunjukkan area ulkus sebenarnya	Ulkus = 1, non-ulkus = 0	Nominal

3	Model DeepLabV3+	Arsitektur segmentasi semantik berbasis deep learning	Prediksi probabilitas setiap piksel	Rasio
4	Hasil segmentasi	Mask biner hasil prediksi model	Ulkus=1, non ulkus =0	Nominal
5	IoU	Tingkat tumpang tindih area prediksi dengan referensi	Nilai 0-1	Rasio
6	Dice	Tingkat kemiripan spasial area prediksi dan referensi	Nilai 0-1	Rasio
7	Precision	Ketepatan prediksi piksel ulkus	Nilai 0-1	Rasio
8	Recall	Kemampuan mengenali piksel ulkus sebenarnya	Nilai 0-1	

Variabel masukan berupa citra digital ulkus kaki diabetik yang memiliki karakteristik visual berupa warna, tekstur, bentuk, dan ukuran area luka. Variabel proses berupa penerapan model DeepLabV3+ untuk mengekstraksi fitur citra dan menghasilkan prediksi segmentasi. Variabel keluaran berupa *mask* segmentasi biner yang menunjukkan area ulkus dan non-ulkus.

Kinerja model diukur menggunakan metrik IoU, Dice Similarity Coefficient, precision, dan recall. IoU digunakan untuk mengukur tingkat tumpang tindih antara area hasil prediksi dan anotasi referensi. Dice digunakan untuk mengukur kesamaan spasial antara kedua area tersebut. Precision digunakan untuk mengukur proporsi piksel yang diprediksi sebagai ulkus dan benar-benar merupakan area ulkus, sedangkan recall digunakan untuk mengukur proporsi piksel ulkus sebenarnya yang berhasil dikenali oleh model.

Dalam evaluasi segmentasi, *True Positive* (TP) merupakan jumlah piksel ulkus yang diprediksi dengan benar, *False Positive* (FP) merupakan jumlah piksel non-ulkus yang salah diprediksi sebagai ulkus, dan *False Negative* (FN) merupakan jumlah piksel ulkus yang salah diprediksi sebagai non-ulkus.

2.11 Teknik Analisis dan Evaluasi Model

Teknik analisis data dilakukan secara kuantitatif melalui pengukuran kesesuaian antara hasil prediksi segmentasi dan anotasi referensi. Evaluasi dilakukan menggunakan empat metrik utama, yaitu Intersection over Union (IoU), Dice Similarity Coefficient (DSC), precision, dan recall.

1. Intersection over Union (IoU)
IoU digunakan untuk mengukur tingkat kesesuaian antara area segmentasi hasil prediksi dan area referensi. Nilai IoU dihitung menggunakan persamaan:

$$IoU = TP / (TP + FP + FN)$$

Nilai IoU berada pada rentang 0 hingga 1. Nilai yang mendekati 1 menunjukkan tingkat kesesuaian area segmentasi yang semakin tinggi.

2. Dice Similarity Coefficient (DSC)
Dice digunakan untuk mengukur tingkat kemiripan antara area prediksi dan anotasi referensi berdasarkan jumlah piksel yang saling beririsan. Persamaan Dice dirumuskan sebagai berikut:

$$Dice = 2TP / (2TP + FP + FN)$$

Nilai Dice berada pada rentang 0 hingga 1. Semakin tinggi nilai Dice, semakin besar kesesuaian antara hasil segmentasi dan anotasi referensi.

3. Precision

Precision digunakan untuk mengetahui ketepatan model dalam mengklasifikasikan piksel sebagai area ulkus. Persamaan precision dirumuskan sebagai berikut:

$$Precision = TP / (TP + FP)$$

Nilai precision yang tinggi menunjukkan bahwa sebagian besar piksel yang diprediksi sebagai area ulkus merupakan piksel ulkus yang benar berdasarkan anotasi referensi.

4. Recall

Recall digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh piksel yang termasuk area ulkus. Persamaan recall dirumuskan sebagai berikut:

$$Recall = TP / (TP + FN)$$

Nilai recall yang tinggi menunjukkan bahwa model mampu mengenali sebagian besar area ulkus yang terdapat pada anotasi referensi.

Perhitungan metrik dilakukan pada setiap citra pengujian, kemudian dirata-ratakan untuk memperoleh gambaran kinerja model secara keseluruhan. Apabila terdapat citra tanpa piksel ulkus, aturan penanganan penyebut nol ditentukan secara konsisten sebelum evaluasi. Selain evaluasi kuantitatif, dilakukan analisis visual dengan membandingkan citra asli, anotasi referensi, dan hasil prediksi model. Analisis visual bertujuan untuk mengidentifikasi karakteristik kesalahan segmentasi, khususnya pada area tepi luka, area dengan warna yang menyerupai kulit normal, serta luka dengan bentuk tidak beraturan. Hasil evaluasi kuantitatif dan visual digunakan untuk menentukan tingkat keberhasilan model DeepLabV3+ dalam melakukan segmentasi area ulkus kaki diabetik. Melalui proses tersebut, penelitian diharapkan dapat memberikan gambaran mengenai kemampuan dan keterbatasan model dalam mengidentifikasi area luka secara otomatis.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pengujian Model Segmentasi

Penelitian ini mengevaluasi kinerja arsitektur DeepLabV3+ dalam melakukan segmentasi area ulkus kaki diabetik pada citra luka digital. Pengujian dilakukan dengan membandingkan lima arsitektur segmentasi, yaitu U-Net, U-Net++, Attention U-Net, SegFormer, dan DeepLabV3+. Perbandingan tersebut bertujuan untuk mengetahui kemampuan masing-masing model dalam mengidentifikasi area luka yang memiliki karakteristik visual kompleks, seperti bentuk tidak beraturan, variasi ukuran, perbedaan tekstur jaringan, serta batas luka yang tidak selalu terlihat jelas.

Evaluasi kinerja dilakukan menggunakan empat metrik, yaitu *Intersection over Union* (IoU), *Dice Similarity Coefficient* (Dice), precision, dan recall. IoU mengukur tingkat tumpang tindih antara area segmentasi hasil prediksi dengan anotasi referensi (*ground truth*), sedangkan Dice digunakan untuk menilai tingkat kesamaan spasial antara keduanya. Precision menunjukkan proporsi piksel yang benar-benar merupakan area luka dari seluruh piksel yang diprediksi sebagai luka, sementara recall mengukur proporsi piksel luka yang berhasil diidentifikasi oleh model.

Hasil pengujian menunjukkan adanya perbedaan performa antararsitektur segmentasi. DeepLabV3+ memperoleh nilai tertinggi pada seluruh metrik evaluasi, dengan IoU sebesar 0,732, Dice sebesar 0,845, precision sebesar 0,821, dan recall sebesar 0,792. Hasil perbandingan kinerja kelima model disajikan pada Tabel 1.

Tabel 2. Perbandingan Kinerja Model Segmentasi Area Ulkus Kaki Diabetik

Metode	IoU	Dice	Precision	Recall
U-Net	0,681	0,792	0,748	0,736
U-Net++	0,704	0,818	0,781	0,762
Attention U-Net	0,716	0,832	0,804	0,781
SegFormer	0,723	0,839	0,812	0,788
DeepLabV3+ (Ours)	**0,732**	**0,845**	**0,821**	**0,792**

Berdasarkan Tabel 2, U-Net menghasilkan performa terendah dengan IoU sebesar 0,681 dan Dice sebesar 0,792. Pengembangan arsitektur melalui U-Net++ meningkatkan nilai IoU menjadi 0,704 dan Dice menjadi 0,818. Selanjutnya, Attention U-Net menghasilkan peningkatan performa dengan IoU sebesar 0,716 dan Dice sebesar 0,832. SegFormer menunjukkan hasil yang lebih tinggi dengan IoU sebesar 0,723 dan Dice sebesar 0,839. Dari seluruh model yang diuji, DeepLabV3+ memperoleh performa terbaik dengan IoU sebesar 0,732 dan Dice sebesar 0,845.

Pola peningkatan tersebut juga terlihat pada precision dan recall. Nilai precision meningkat dari 0,748 pada U-Net menjadi 0,821 pada DeepLabV3+, sedangkan recall meningkat dari 0,736 menjadi 0,792. Hasil ini menunjukkan bahwa DeepLabV3+ tidak hanya menghasilkan kesesuaian area segmentasi yang lebih tinggi, tetapi juga memiliki keseimbangan yang lebih baik dalam mengidentifikasi piksel luka dan membatasi kesalahan prediksi dibandingkan model lainnya.

Secara keseluruhan, hasil pengujian menunjukkan bahwa DeepLabV3+ merupakan model dengan performa tertinggi berdasarkan keempat metrik evaluasi pada dataset yang digunakan dalam penelitian ini.

3.2. Analisis Perbandingan Kinerja Antararsitektur

Analisis perbandingan dilakukan untuk mengetahui besarnya peningkatan performa DeepLabV3+ terhadap empat model pembanding. Perbedaan nilai metrik dihitung berdasarkan selisih absolut antara hasil evaluasi DeepLabV3+ dan masing-masing model. Hasil perbandingan tersebut disajikan pada Tabel 2.

Tabel 3. Peningkatan Kinerja DeepLabV3+ terhadap Model Pembanding

Model Pembanding	Δ IoU	Δ Dice	Δ Precision	Δ Recall
U-Net	+0,051	+0,053	+0,073	+0,056
U-Net++	+0,028	+0,027	+0,040	+0,030
Attention U-Net	+0,016	+0,013	+0,017	+0,011
SegFormer	+0,009	+0,006	+0,009	+0,004

Keterangan: Δ menunjukkan selisih absolut nilai metrik DeepLabV3+ terhadap model pembanding, bukan persentase peningkatan relatif.

Berdasarkan Tabel 3, peningkatan terbesar diperoleh ketika DeepLabV3+ dibandingkan dengan U-Net. Nilai IoU meningkat sebesar 0,051 atau sekitar 7,49% secara relatif, sedangkan Dice meningkat sebesar 0,053 atau sekitar 6,69%. Peningkatan tersebut mengindikasikan bahwa

DeepLabV3+ memiliki kemampuan yang lebih baik dalam menghasilkan area segmentasi yang sesuai dengan anotasi referensi.

Dibandingkan dengan U-Net++, DeepLabV3+ menunjukkan peningkatan IoU sebesar 0,028 dan Dice sebesar 0,027. U-Net++ mengembangkan arsitektur U-Net melalui penggunaan *nested skip connections* untuk memperbaiki integrasi fitur antara encoder dan decoder. Meskipun pendekatan tersebut menghasilkan performa lebih baik daripada U-Net, hasil pengujian menunjukkan bahwa DeepLabV3+ masih memperoleh nilai evaluasi lebih tinggi.

Pada perbandingan dengan Attention U-Net, DeepLabV3+ menghasilkan peningkatan IoU sebesar 0,016 dan Dice sebesar 0,013. Attention U-Net memanfaatkan mekanisme perhatian (*attention mechanism*) untuk membantu model memfokuskan proses ekstraksi fitur pada wilayah yang relevan. Namun, berdasarkan hasil pengujian, penggunaan mekanisme perhatian tersebut belum menghasilkan performa yang melampaui DeepLabV3+.

Perbedaan performa paling kecil ditemukan pada perbandingan DeepLabV3+ dengan SegFormer. DeepLabV3+ memperoleh peningkatan IoU sebesar 0,009 dan Dice sebesar 0,006, sedangkan precision dan recall masing-masing meningkat sebesar 0,009 dan 0,004. Selisih tersebut menunjukkan bahwa kedua model memiliki kemampuan segmentasi yang relatif berdekatan.

Meskipun DeepLabV3+ memperoleh nilai tertinggi, perbedaan performa terhadap SegFormer perlu diinterpretasikan secara hati-hati. Selisih yang kecil belum cukup untuk membuktikan keunggulan yang signifikan secara statistik tanpa pengujian lebih lanjut menggunakan hasil evaluasi per citra atau pengulangan eksperimen.

Dengan demikian, hasil komparasi menunjukkan bahwa DeepLabV3+ secara konsisten memperoleh nilai evaluasi tertinggi pada seluruh metrik yang dilaporkan, sementara SegFormer menjadi model pembanding dengan performa paling mendekati DeepLabV3+.

3.3. Analisis Keunggulan Arsitektur DeepLabV3+

Performa DeepLabV3+ yang lebih tinggi dibandingkan model lainnya dapat dikaji berdasarkan karakteristik arsitekturnya, khususnya penggunaan *Atrous Spatial Pyramid Pooling* (ASPP) dan struktur *encoder-decoder*. Kedua komponen tersebut dirancang untuk menggabungkan informasi kontekstual pada berbagai skala sekaligus mempertahankan detail spasial yang diperlukan dalam segmentasi semantik.

ASPP menggunakan beberapa operasi *atrous convolution* dengan tingkat dilasi berbeda untuk menangkap informasi visual pada berbagai ukuran area reseptif. Pendekatan ini memungkinkan model memperoleh representasi fitur yang mencakup karakteristik lokal maupun konteks yang lebih luas.

Kemampuan tersebut relevan terhadap karakteristik ulkus kaki diabetik yang memiliki variasi ukuran, bentuk, warna, dan tekstur jaringan. Area luka dapat memiliki batas yang tidak beraturan serta perbedaan intensitas warna yang relatif kecil dibandingkan jaringan kulit di sekitarnya. Kondisi tersebut menuntut model untuk mempertimbangkan informasi visual dari berbagai skala agar dapat membedakan area luka dengan jaringan non-luka secara lebih akurat.

Selain ASPP, DeepLabV3+ menggunakan struktur encoder-decoder untuk mengintegrasikan fitur semantik tingkat tinggi dengan informasi spasial tingkat rendah. Encoder bertugas mengekstraksi karakteristik citra, sedangkan decoder membantu memulihkan detail spasial

pada hasil segmentasi. Kombinasi tersebut berpotensi meningkatkan kemampuan model dalam mengidentifikasi bentuk dan batas area luka.

Hasil pengujian menunjukkan bahwa DeepLabV3+ memperoleh IoU sebesar 0,732 dan Dice sebesar 0,845, lebih tinggi dibandingkan Attention U-Net yang memperoleh IoU sebesar 0,716 dan Dice sebesar 0,832. Temuan ini menunjukkan bahwa pendekatan ekstraksi fitur multiskala pada DeepLabV3+ berpotensi memberikan keuntungan dalam segmentasi citra luka yang memiliki karakteristik visual heterogen.

Dibandingkan dengan SegFormer yang menggunakan pendekatan berbasis Transformer, DeepLabV3+ juga memperoleh performa sedikit lebih tinggi. SegFormer memanfaatkan mekanisme *self-attention* untuk memodelkan hubungan antarelemen citra, sedangkan DeepLabV3+ mengandalkan operasi konvolusi multiskala dan pemulihan detail spasial melalui decoder.

Hasil tersebut mengindikasikan bahwa pendekatan berbasis *Convolutional Neural Network* (CNN) dengan pemodelan konteks multiskala masih kompetitif dalam segmentasi citra medis, termasuk pada area ulkus kaki diabetik.

Meskipun demikian, hasil penelitian ini belum dapat membuktikan bahwa ASPP merupakan satu-satunya faktor yang menyebabkan peningkatan performa. Perbedaan hasil juga dapat dipengaruhi oleh konfigurasi backbone, parameter pelatihan, strategi augmentasi, dan karakteristik dataset. Oleh karena itu, studi ablasi diperlukan untuk mengidentifikasi kontribusi masing-masing komponen arsitektur secara lebih spesifik.

3.4. Analisis Precision dan Recall dalam Identifikasi Area Luka

Selain IoU dan Dice, evaluasi precision dan recall diperlukan untuk memahami karakteristik kesalahan segmentasi yang dihasilkan oleh masing-masing model. Dalam konteks segmentasi ulkus kaki diabetik, kedua metrik tersebut penting karena kesalahan identifikasi piksel dapat memengaruhi representasi area luka.

Precision mengukur kemampuan model dalam meminimalkan *false positive*, yaitu piksel non-luka yang keliru diklasifikasikan sebagai area luka. Sementara itu, recall mengukur kemampuan model dalam meminimalkan *false negative*, yaitu piksel luka yang tidak berhasil teridentifikasi.

Berdasarkan hasil pengujian, DeepLabV3+ memperoleh precision sebesar 0,821 dan recall sebesar 0,792. Kedua nilai tersebut merupakan yang tertinggi dibandingkan empat model lainnya.

Nilai precision DeepLabV3+ meningkat sebesar 0,073 dibandingkan U-Net, 0,040 dibandingkan U-Net++, 0,017 dibandingkan Attention U-Net, dan 0,009 dibandingkan SegFormer. Hasil ini menunjukkan bahwa DeepLabV3+ memiliki proporsi prediksi piksel luka yang benar lebih tinggi dibandingkan model pembanding.

Sementara itu, nilai recall DeepLabV3+ meningkat sebesar 0,056 dibandingkan U-Net, 0,030 dibandingkan U-Net++, 0,011 dibandingkan Attention U-Net, dan 0,004 dibandingkan SegFormer. Peningkatan tersebut menunjukkan bahwa DeepLabV3+ mampu mengidentifikasi proporsi piksel luka yang lebih besar dibandingkan model lainnya.

Meskipun demikian, nilai recall sebesar 0,792 menunjukkan bahwa model masih belum mampu mendeteksi seluruh piksel luka. Berdasarkan definisi recall, hasil tersebut mengindikasikan masih adanya piksel luka yang diklasifikasikan sebagai non-luka.

Kesalahan tersebut berpotensi terjadi pada area dengan karakteristik visual yang sulit dibedakan, seperti batas luka yang tidak tegas atau jaringan yang memiliki warna menyerupai kulit sehat. Namun, lokasi dan penyebab kesalahan tersebut perlu dikonfirmasi melalui analisis visual hasil segmentasi.

Secara keseluruhan, nilai precision dan recall menunjukkan bahwa DeepLabV3+ memiliki kemampuan identifikasi area luka yang lebih baik daripada model pembanding. Namun, peningkatan recall masih menjadi aspek penting untuk dikembangkan, terutama apabila model akan digunakan sebagai komponen pendukung analisis luas luka.

3.5. Keterkaitan dengan Penelitian Terdahulu

Hasil penelitian ini memiliki keterkaitan dengan perkembangan metode segmentasi citra medis berbasis deep learning, khususnya arsitektur U-Net, U-Net++, Attention U-Net, SegFormer, dan DeepLabV3+.

U-Net diperkenalkan oleh Ronneberger et al. (2015) sebagai arsitektur segmentasi citra biomedis yang memanfaatkan struktur encoder-decoder dan *skip connections*. Pendekatan tersebut memungkinkan penggabungan informasi semantik dan spasial sehingga dapat digunakan untuk segmentasi objek pada citra medis.

Pengembangan U-Net++ oleh Zhou et al. (2018) memperkenalkan *nested skip connections* untuk mengurangi kesenjangan semantik antara fitur encoder dan decoder. Dalam penelitian ini, U-Net++ menghasilkan IoU sebesar 0,704, lebih tinggi dibandingkan U-Net sebesar 0,681. Hasil tersebut konsisten dengan tujuan pengembangan U-Net++, yaitu meningkatkan kualitas representasi fitur untuk proses segmentasi.

Attention U-Net yang diperkenalkan oleh Oktay et al. (2018) mengintegrasikan mekanisme perhatian untuk meningkatkan fokus model terhadap wilayah citra yang relevan. Hasil penelitian ini menunjukkan bahwa Attention U-Net memperoleh IoU sebesar 0,716 dan Dice sebesar 0,832, lebih tinggi dibandingkan U-Net dan U-Net++. Temuan tersebut mendukung relevansi mekanisme perhatian dalam meningkatkan kemampuan segmentasi pada dataset yang digunakan.

SegFormer yang dikembangkan oleh Xie et al. (2021) menggunakan pendekatan Transformer untuk melakukan segmentasi semantik melalui pemodelan fitur hierarkis dan hubungan spasial. Dalam penelitian ini, SegFormer memperoleh IoU sebesar 0,723 dan Dice sebesar 0,839, menjadikannya model pembanding dengan performa tertinggi setelah DeepLabV3+.

Sementara itu, DeepLabV3+ yang diperkenalkan oleh Chen et al. (2018) menggabungkan ASPP dan struktur encoder-decoder untuk meningkatkan segmentasi semantik, khususnya melalui pemodelan konteks multiskala dan pemulihan detail spasial.

Hasil penelitian ini menunjukkan bahwa DeepLabV3+ memperoleh performa tertinggi dengan IoU sebesar 0,732 dan Dice sebesar 0,845. Temuan tersebut secara konseptual sejalan dengan tujuan pengembangan arsitektur DeepLabV3+, yaitu meningkatkan kualitas segmentasi melalui kombinasi ekstraksi fitur multiskala dan rekonstruksi informasi spasial.

Meskipun demikian, penelitian-penelitian tersebut menggunakan dataset dan skenario eksperimen yang berbeda. Oleh karena itu, hasil penelitian ini tidak dapat dibandingkan secara langsung dengan angka performa dari penelitian terdahulu tanpa mempertimbangkan kesetaraan dataset, prosedur pelatihan, dan metode evaluasi.

Kontribusi penelitian ini terletak pada penerapan dan evaluasi komparatif kelima arsitektur tersebut dalam segmentasi area ulkus kaki diabetik, sehingga memberikan gambaran mengenai efektivitas pendekatan berbasis CNN dan Transformer pada permasalahan segmentasi citra luka.

3.6. Implikasi dan Keterbatasan Penelitian

Hasil penelitian menunjukkan bahwa DeepLabV3+ memiliki potensi sebagai metode segmentasi otomatis untuk mengidentifikasi area ulkus kaki diabetik pada citra digital. Performa yang diperoleh menunjukkan kemampuan model dalam menghasilkan area segmentasi yang relatif sesuai dengan anotasi referensi.

Kemampuan tersebut berpotensi dimanfaatkan dalam pengembangan sistem analisis citra luka, terutama untuk membantu identifikasi area luka dan menyediakan informasi awal bagi proses evaluasi kondisi luka secara digital.

Namun, penelitian ini masih memiliki beberapa keterbatasan. Pertama, performa model dipengaruhi oleh karakteristik dataset yang digunakan, termasuk variasi pencahayaan, kualitas citra, ukuran luka, dan perbedaan karakteristik jaringan. Kedua, hasil evaluasi belum menunjukkan kemampuan generalisasi model pada dataset eksternal dengan kondisi pengambilan citra yang berbeda.

Ketiga, selisih performa antara DeepLabV3+ dan SegFormer relatif kecil, yaitu 0,009 pada IoU dan 0,006 pada Dice. Oleh karena itu, diperlukan pengujian statistik untuk mengetahui apakah perbedaan tersebut konsisten dan signifikan.

Keempat, evaluasi menggunakan IoU, Dice, precision, dan recall belum sepenuhnya menggambarkan ketepatan batas segmentasi. Penggunaan metrik tambahan, seperti *Hausdorff Distance* atau *Boundary F1-Score*, dapat memberikan informasi lebih terperinci mengenai kualitas segmentasi pada area tepi luka.

Selain itu, penelitian lanjutan dapat mempertimbangkan pengujian terhadap variasi backbone, strategi augmentasi, serta optimasi parameter pelatihan untuk meningkatkan performa segmentasi.

3.7. Sintesis Hasil Penelitian

Berdasarkan keseluruhan hasil pengujian, DeepLabV3+ menunjukkan performa terbaik dibandingkan U-Net, U-Net++, Attention U-Net, dan SegFormer dalam melakukan segmentasi area ulkus kaki diabetik pada dataset penelitian.

DeepLabV3+ memperoleh nilai IoU sebesar 0,732, Dice sebesar 0,845, precision sebesar 0,821, dan recall sebesar 0,792. Dibandingkan U-Net sebagai model dasar, DeepLabV3+ menghasilkan peningkatan relatif sebesar 7,49% pada IoU dan 6,69% pada Dice.

Keunggulan tersebut secara konseptual berkaitan dengan penggunaan ASPP dan struktur encoder-decoder yang memungkinkan model mengintegrasikan informasi kontekstual multiskala dengan detail spasial.

Meskipun demikian, perbedaan performa yang relatif kecil terhadap SegFormer menunjukkan bahwa pendekatan berbasis Transformer juga memiliki kemampuan yang kompetitif dalam segmentasi citra ulkus kaki diabetik.

Dengan demikian, penelitian ini menunjukkan bahwa DeepLabV3+ merupakan salah satu pendekatan yang menjanjikan untuk segmentasi area ulkus kaki diabetik secara otomatis. Hasil penelitian ini juga memberikan dasar bagi pengembangan sistem analisis citra luka berbasis deep learning yang lebih akurat, terukur, dan berpotensi mendukung proses pemantauan kondisi luka secara digital.

4. SIMPULAN

Berdasarkan hasil penelitian dan analisis komparatif terhadap lima arsitektur *deep learning*, yaitu U-Net, U-Net++, Attention U-Net, SegFormer, dan DeepLabV3+, dapat disimpulkan bahwa arsitektur DeepLabV3+ menunjukkan kinerja terbaik dalam melakukan segmentasi semantik area ulkus kaki diabetik pada citra digital berdasarkan metrik evaluasi yang digunakan. Model DeepLabV3+ memperoleh nilai *Intersection over Union* (IoU) sebesar 0,732, *Dice Similarity Coefficient* (DSC) sebesar 0,845, *precision* sebesar 0,821, dan *recall* sebesar 0,792. Hasil tersebut menunjukkan bahwa DeepLabV3+ memiliki kemampuan yang lebih baik dalam mengidentifikasi dan memisahkan area ulkus dari jaringan di sekitarnya dibandingkan empat arsitektur pembanding pada dataset penelitian.

Hasil analisis komparatif menunjukkan bahwa DeepLabV3+ menghasilkan peningkatan nilai IoU sebesar 0,051 dan Dice sebesar 0,053 dibandingkan U-Net sebagai model dasar, atau meningkat secara relatif masing-masing sebesar 7,49% dan 6,69%. Keunggulan kinerja tersebut secara konseptual berkaitan dengan penerapan mekanisme *Atrous Spatial Pyramid Pooling* (ASPP) yang memungkinkan ekstraksi fitur visual pada berbagai skala serta struktur *encoder-decoder* yang mendukung pemulihan informasi spasial dan identifikasi batas area luka. Meskipun demikian, perbedaan kinerja DeepLabV3+ terhadap SegFormer relatif kecil, yaitu sebesar 0,009 pada IoU dan 0,006 pada Dice, sehingga belum dapat dinyatakan sebagai keunggulan yang signifikan secara statistik tanpa pengujian lebih lanjut.

Secara keseluruhan, penelitian ini menunjukkan bahwa DeepLabV3+ merupakan pendekatan yang potensial untuk mendukung pengembangan sistem segmentasi otomatis ulkus kaki diabetik berbasis citra digital. Penerapan model tersebut berpotensi membantu proses identifikasi area luka secara lebih objektif dan terukur sebagai dasar pengembangan sistem pemantauan kondisi luka berbantuan komputer. Namun, penelitian ini masih memiliki keterbatasan terkait variasi karakteristik dataset, ketepatan segmentasi pada batas luka, serta belum dilakukannya pengujian generalisasi menggunakan dataset eksternal. Oleh karena itu, penelitian selanjutnya disarankan untuk melakukan validasi pada dataset yang lebih beragam, pengujian signifikansi statistik, evaluasi ketepatan batas segmentasi, serta optimasi arsitektur dan parameter pelatihan guna meningkatkan konsistensi dan kemampuan generalisasi model.

DAFTAR PUSTAKA

Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European Conference on Computer Vision (ECCV)*, 801–818. https://doi.org/10.1007/978-3-030-01234-2_49

Goyal, M., Reeves, N. D., Rajbhandari, S., & Yap, M. H. (2019). Robust methods for real-time diabetic foot ulcer detection and localization on mobile devices. *IEEE Journal of*

Biomedical and Health Informatics, *23*(4), 1730–1741. https://doi.org/10.1109/JBHI.2018.2868656

Goyal, M., Yap, M. H., Reeves, N. D., Rajbhandari, S., & Spragg, J. (2017). Fully convolutional networks for diabetic foot ulcer segmentation. *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 618–623. https://doi.org/10.1109/SMC.2017.8122675

Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). Attention U-Net: Learning where to look for the pancreas. *arXiv*. https://doi.org/10.48550/arXiv.1804.03999

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 234–241. https://doi.org/10.1007/978-3-319-24574-4_28

Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and efficient design for semantic segmentation with transformers. *Advances in Neural Information Processing Systems, 34*, 12077–12090.

Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., & Liang, J. (2018). UNet++: A nested U-Net architecture for medical image segmentation. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, 3–11. https://doi.org/10.1007/978-3-030-00889-5_1