

SEGMENTASI ULKUS KORNEA PADA CITRA OFTALMOLOGI MENGGUNAKAN GHOST U-NET

Michael Wijaya, Meiriyama

Teknik Informatika, Universitas Multi Data Palembang
Jl. Rajawali 14, 30113 Palembang - Sumatera Selatan
Michaelwijaya_2226250046@mhs.mdp.ac.id

ABSTRAK

Ulkus kornea merupakan luka pada permukaan kornea yang dapat menyebabkan gangguan penglihatan permanen apabila tidak ditangani secara tepat. Identifikasi area ulkus pada citra slit-lamp fluorescein secara manual memerlukan waktu dan sangat bergantung pada pengalaman klinis, sehingga diperlukan pendekatan otomatis yang akurat dan efisien. Penelitian ini membandingkan kinerja arsitektur U-Net dan Ghost U-Net dalam melakukan segmentasi ulkus kornea pada citra oftalmologi. Dataset yang digunakan adalah SUSTech-SYSU Corneal Ulcer Dataset yang terdiri dari 354 citra dengan *ground truth* segmentasi, dan evaluasi dilakukan dengan menggunakan skema 4-fold cross-validation. Kedua model dilatih dengan konfigurasi yang identik untuk memastikan perbandingan yang adil. Evaluasi performa dilakukan secara kuantitatif menggunakan metrik Dice Similarity Coefficient (DSC) dan Intersection over Union (IoU), serta analisis efisiensi berdasarkan jumlah parameter jaringan dan waktu inferensi per citra. Hasil eksperimen menunjukkan bahwa U-Net menghasilkan performa segmentasi yang sedikit lebih tinggi, sedangkan Ghost U-Net mampu mempertahankan performa yang kompetitif dengan pengurangan jumlah parameter yang signifikan. Temuan ini menunjukkan bahwa Ghost U-Net berpotensi menjadi alternatif arsitektur segmentasi yang lebih ringan dan efisien untuk aplikasi segmentasi ulkus kornea berbasis *deep learning*.

Kata kunci : ulkus kornea, segmentasi citra medis, U-Net, Ghost U-Net, *deep learning*

1. PENDAHULUAN

Ulkus kornea merupakan luka terbuka pada permukaan kornea yang dapat menyebabkan gangguan penglihatan serius hingga kebutaan permanen apabila tidak ditangani secara tepat [1]. Penyakit ini umumnya disebabkan oleh infeksi bakteri, jamur, atau trauma pada mata, dan sering dijumpai pada negara berkembang dengan keterbatasan akses layanan kesehatan mata [2]. Pemeriksaan klinis ulkus kornea biasanya dilakukan menggunakan citra slit-lamp fluorescein, di mana area ulkus tampak sebagai bagian yang berpendar akibat penyerapan zat fluorescein. Identifikasi luas dan batas area ulkus menjadi faktor penting dalam menentukan tingkat keparahan penyakit serta strategi penanganan yang tepat.

Namun demikian, proses identifikasi dan penentuan batas ulkus kornea secara manual masih sangat bergantung pada pengalaman dan subjektivitas dokter mata [3], [4]. Proses ini juga memerlukan waktu yang relatif lama, terutama ketika jumlah pasien tinggi atau pada kondisi dengan keterbatasan tenaga medis. Selain itu, perbedaan tingkat pengalaman antar praktisi dapat menyebabkan variasi hasil penilaian. Kondisi tersebut mendorong perlunya sistem bantu berbasis komputasi yang mampu melakukan segmentasi area ulkus kornea secara otomatis, akurat, dan konsisten.

Perkembangan *deep learning*, khususnya convolutional neural network (CNN), telah memberikan kontribusi signifikan dalam bidang segmentasi citra medis [5]. Berbagai arsitektur CNN telah dikembangkan dan diaplikasikan untuk memisahkan region of interest pada citra medis dengan tingkat akurasi yang tinggi [6]. Salah satu arsitektur

yang paling banyak digunakan adalah U-Net, yang memiliki struktur encoder-decoder dengan skip connection untuk mempertahankan informasi spasial [13]. U-Net telah terbukti efektif pada berbagai tugas segmentasi biomedis, termasuk segmentasi organ dan lesi pada citra medis.

Meskipun demikian, U-Net memiliki jumlah parameter yang relatif besar, sehingga membutuhkan sumber daya komputasi yang tinggi [4]. Hal ini menjadi kendala tersendiri untuk implementasi pada sistem dengan keterbatasan perangkat keras atau pada aplikasi yang memerlukan efisiensi komputasi. Untuk mengatasi permasalahan tersebut, dikembangkan Ghost U-Net, yaitu varian U-Net yang mengintegrasikan Ghost Module pada bagian encoder [10]. Ghost Module dirancang untuk mengurangi redundansi fitur dengan menghasilkan feature map tambahan melalui operasi linear sederhana, sehingga jumlah parameter jaringan dapat ditekan tanpa mengorbankan performa secara signifikan [12].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membandingkan performa dan efisiensi arsitektur U-Net dan Ghost U-Net dalam melakukan segmentasi ulkus kornea pada citra oftalmologi. Evaluasi dilakukan menggunakan SUSTech-SYSU Corneal Ulcer Dataset dengan skema 4-fold cross-validation, serta konfigurasi pelatihan yang identik pada kedua model [11]. Performa segmentasi dievaluasi secara kuantitatif menggunakan metrik Dice Similarity Coefficient (DSC) dan Intersection over Union (IoU), sementara efisiensi model dianalisis berdasarkan jumlah parameter jaringan dan waktu inferensi per citra.

Kontribusi utama dari penelitian ini adalah penyajian evaluasi komprehensif terhadap arsitektur Ghost U-Net pada kasus segmentasi ulkus kornea dengan perbandingan langsung terhadap U-Net dalam kondisi pelatihan yang sama [10]. Hasil penelitian diharapkan dapat memberikan gambaran mengenai trade-off antara akurasi dan efisiensi model, serta menjadi dasar pertimbangan dalam pengembangan sistem segmentasi ulkus kornea berbasis deep learning yang lebih ringan dan aplikatif.

2. TINJAUAN PUSTAKA

Tinjauan Pustaka ini membahas konsep dan penelitian yang relevan dengan segmentasi citra medis berbasis deep learning, khususnya pada bidang oftalmologi. Pembahasan difokuskan pada konsep dasar segmentasi citra medis, arsitektur U-Net sebagai model dasar segmentasi, pengembangan Ghost U-Net sebagai arsitektur yang lebih efisien, serta metrik evaluasi yang digunakan untuk menilai performa model segmentasi. Tinjauan Pustaka ini disusun untuk memberikan landasan teoritis yang mendukung metode dan analisis hasil penelitian.

2.1. Penelitian Terdahulu

Sejumlah penelitian sebelumnya telah mengkaji pemanfaatan metode berbasis deep learning untuk analisis dan segmentasi ulkus kornea pada citra oftalmologi. Sevlı [5] melakukan klasifikasi ulkus kornea pada citra fluorescein menggunakan arsitektur CNN dan menunjukkan bahwa pendekatan deep learning mampu mencapai akurasi diagnosis yang tinggi dibandingkan metode tradisional berbasis fitur manual. Namun, penelitian tersebut masih sangat berfokus pada klasifikasi citra secara global tanpa melakukan segmentasi area ulkus secara detail.

Qasmieh et al. [6] mengusulkan pendekatan deteksi ulkus kornea dengan mengombinasikan teknik pengolahan citra dan deep learning. Metode ini mampu meningkatkan sensitivitas deteksi, tetapi akurasi segmentasi masih terbatas karena ketergantungan pada tahap pra-pemrosesan konvensional. Hal ini menunjukkan bahwa segmentasi berbasis end-to-end CNN masih menjadi tantangan tersendiri.

Wang et al. [8] memperkenalkan metode Semi-MsST-GAN, yaitu pendekatan semi-supervised berbasis GAN untuk segmentasi ulkus kornea pada citra slit-lamp. Pendekatan ini mampu meningkatkan performa segmentasi pada kondisi keterbatasan anotasi, tetapi kompleksitas model relatif tinggi sehingga kurang efisien untuk implementasi pada sistem dengan sumber daya terbatas.

Penelitian lain oleh Manawongsakul dan Patanukhom [9] mengembangkan sistem penilaian tingkat keparahan ulkus kornea berbasis segmentasi menggunakan CNN dan transformasi Hough. Meskipun sistem ini mampu melakukan grading ulkus kornea secara otomatis, arsitektur yang digunakan memiliki jumlah parameter yang besar dan memerlukan waktu komputasi yang relatif tinggi.

Di sisi lain, Ronneberger et al. [13] memperkenalkan arsitektur U-Net yang hingga saat ini menjadi standar de-facto dalam segmentasi citra biomedis karena kemampuannya mempertahankan informasi spasial melalui skip connection. Namun, U-Net memiliki kompleksitas parameter yang cukup besar. Untuk mengatasi permasalahan tersebut, Han et al. [12] memperkenalkan Ghost Module yang kemudian diadaptasi oleh Kazerouni et al. [10] menjadi Ghost U-Net, sebuah arsitektur segmentasi yang lebih ringan dengan pengurangan parameter signifikan.


Berdasarkan tinjauan terhadap penelitian terdahulu, dapat disimpulkan bahwa sebagian besar penelitian segmentasi ulkus kornea masih berfokus pada peningkatan akurasi tanpa mempertimbangkan efisiensi model. Oleh karena itu, penelitian ini mengisi celah tersebut dengan melakukan perbandingan langsung antara U-Net dan Ghost U-Net pada dataset yang sama, konfigurasi pelatihan identik, serta evaluasi kinerja dan efisiensi yang komprehensif.

2.2. Segmentasi Citra Medis

Segmentasi citra medis merupakan proses pemisahan citra menjadi beberapa region berdasarkan karakteristik tertentu, dengan tujuan untuk mengidentifikasi area penting atau *region of interest* (ROI) [4]. Pada bidang medis, segmentasi digunakan untuk menentukan batas anatomis organ atau area patologis secara presisi pada tingkat piksel [7]. Pendekatan ini sangat penting karena kesalahan kecil dalam segmentasi dapat berdampak signifikan pada interpretasi klinis dan pengambilan keputusan medis.

Dalam konteks oftalmologi, segmentasi citra digunakan untuk mengidentifikasi area kelainan pada struktur mata, seperti kornea, retina, dan pembuluh darah [7]. Pada kasus ulkus kornea, segmentasi bertujuan untuk menentukan batas area luka yang ditandai oleh fluoresensi akibat pewarnaan fluorescein. Segmentasi otomatis berbasis *deep learning* mampu mengurangi ketergantungan pada interpretasi subjektif dokter serta meningkatkan konsistensi hasil analisis, terutama pada dataset berskala besar.

2.3. Arsitektur U-Net




Gambar 1. Arsitektur U-Net dengan struktur encoder-decoder dan skip connection.

U-Net merupakan arsitektur *convolutional neural network* (CNN) yang diperkenalkan untuk tugas segmentasi citra biomedis [13]. Arsitektur ini memiliki struktur *encoder-decoder* simetris yang dirancang untuk mengekstraksi fitur kontekstual sekaligus mempertahankan informasi spasial citra. Bagian encoder berfungsi untuk mengekstraksi fitur melalui operasi konvolusi dan downsampling, sedangkan bagian decoder melakukan upsampling untuk merekonstruksi peta segmentasi ke resolusi semula.

Keunggulan utama U-Net terletak pada penggunaan *skip connection* yang menghubungkan lapisan encoder dan decoder pada tingkat resolusi yang sama. Mekanisme ini memungkinkan informasi detail dari tahap awal pemrosesan tetap dipertahankan dan digabungkan kembali pada tahap rekonstruksi, sehingga menghasilkan segmentasi yang lebih akurat, terutama pada dataset medis dengan jumlah data terbatas [13].

2.4. Ghost Module dan Ghost U-Net



Gambar 2. Diagram blok bottleneck Ghost U-Net: (kiri) encoder bottleneck berbasis Ghost Module dengan Depthwise Convolution dan Squeeze-Expand (opsional), serta (kanan) decoder bottleneck menggunakan Transposed Double Convolution (TDL)

Ghost Module diperkenalkan untuk mengurangi redundansi fitur pada jaringan konvolusional, di mana banyak *feature map* yang dihasilkan memiliki kemiripan tinggi sehingga meningkatkan beban komputasi. Seperti ditunjukkan pada Gambar 2, blok encoder pada Ghost U-Net memanfaatkan Ghost Module untuk membentuk fitur utama (*primary feature*) dan menghasilkan fitur tambahan melalui operasi yang lebih ringan, seperti *depthwise convolution* dan transformasi linier sederhana. Pada sisi decoder, digunakan blok *Transposed Double Convolution* (TDL) untuk membantu rekonstruksi peta segmentasi ke resolusi yang lebih tinggi. Dengan


rancangan blok seperti ini, Ghost U-Net bertujuan mempertahankan performa segmentasi sekaligus menekan kompleksitas model [19], [12].

$$Y = \{y_1, y_2, \dots, y_m\} \cup \{g(y_1), g(y_2), \dots, g(y_s)\} \quad (1)$$

Dengan:

- y_i merupakan *primary feature* hasil konvolusi utama,
- $g(\cdot)$ merupakan operasi linear sederhana (*cheap operation*),
- Y merupakan *feature map* hasil Ghost Module.

Secara umum, Ghost Module bekerja dengan dua tahap utama. Tahap pertama menghasilkan *primary feature map* menggunakan konvolusi standar. Tahap kedua menghasilkan *ghost feature* melalui operasi linear ringan (*cheap operations*), seperti konvolusi *depthwise* atau transformasi linier sederhana. Dengan pendekatan ini, jumlah parameter dan operasi komputasi dapat dikurangi secara signifikan tanpa mengorbankan kemampuan representasi fitur.



Gambar 3. Arsitektur Ghost U-Net yang terdiri dari encoder berbasis Ghost Module, skip connection dan decoder bergaya U-Net untuk segmentasi citra.

Ghost U-Net merupakan pengembangan dari arsitektur U-Net yang mengintegrasikan Ghost Module pada bagian encoder [10]. Integrasi ini bertujuan untuk menghasilkan arsitektur segmentasi yang lebih ringan dan efisien, namun tetap mempertahankan performa segmentasi yang

kompetitif. Penggunaan Ghost Module pada encoder memungkinkan pengurangan jumlah parameter jaringan, sehingga Ghost U-Net lebih sesuai untuk implementasi pada lingkungan dengan keterbatasan sumber daya komputasi [10].

2.5. Metrik Evaluasi Segmentasi

Evaluasi performa model segmentasi citra dilakukan menggunakan metrik yang mengukur tingkat kesesuaian antara hasil prediksi dan *ground truth*. Pada penelitian ini digunakan dua metrik utama, yaitu Dice Similarity Coefficient (DSC) dan Intersection over Union (IoU), yang umum digunakan pada tugas segmentasi citra medis.

Dice Similarity Coefficient mengukur tingkat tumpang tindih antara hasil segmentasi prediksi dan *ground truth*. Nilai DSC berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan kesesuaian segmentasi yang lebih baik.

$$DSC = \frac{2|A \cap B|}{|A| + |B|} \quad (2)$$

Dengan:

- d. A merupakan area hasil prediksi,
- e. B merupakan area *ground truth*.

Intersection over Union mengukur rasio antara area irisan dan area gabungan dari hasil prediksi dan *ground truth*. Metrik ini memberikan gambaran seberapa besar kesesuaian area segmentasi yang dihasilkan model.

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

Dengan:

- a. A merupakan area hasil prediksi,
- b. B merupakan area *ground truth*.

3. METODE PENELITIAN

Penelitian ini bertujuan untuk membandingkan performa dan efisiensi dua arsitektur deep learning, yaitu U-Net dan Ghost U-Net, dalam melakukan segmentasi ulkus kornea pada citra oftalmologi. Dataset yang digunakan dalam penelitian ini adalah SUSTech-SYSU Corneal Ulcer Dataset yang terdiri dari 354 citra slit lamp fluorescein yang telah dilengkapi dengan *ground truth* segmentasi area ulkus kornea [11]. Dataset ini dipilih karena menyediakan anotasi piksel-level yang akurat serta telah digunakan secara luas pada penelitian segmentasi ulkus kornea, sehingga memungkinkan perbandingan yang objektif dan reliabel.

Seluruh citra pada dataset terlebih dahulu melalui pra-pemrosesan. Setiap citra diubah ukurannya menjadi 512 x 512 piksel untuk menyesuaikan dengan kebutuhan input arsitektur U-Net dan Ghost U-Net serta menjaga konsistensi dimensi selama proses pelatihan. Normalisasi nilai piksel dilakukan dengan menskalakan intensitas ke rentang [0,1] guna meningkatkan stabilitas numerik dan mempercepat proses konvergensi model selama pelatihan jaringan.

Untuk meningkatkan keragaman data dan mengurangi risiko overfitting akibat jumlah data yang relative terbatas, dilakukan proses augmentasi data. Teknik augmentasi yang diterapkan meliputi rotasi citra dan horizontal flip. Augmentasi ini bertujuan untuk memperkaya variasi bentuk, ukuran, dan orientasi ulkus kornea yang dipelajari model, sehingga diharapkan dapat meningkatkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya [9].

Penelitian ini menggunakan dua arsitektur segmentasi citra medis, yaitu U-Net sebagai model baseline dan Ghost U-Net sebagai model dengan kompleksitas yang lebih ringan [13], [10]. U-net digunakan sebagai acuan karena arsitektur ini telah terbukti efektif pada berbagai tugas segmentasi biomedis. Sementara itu, Ghost U-Net mengintegrasikan Ghost Module pada bagian encoder untuk mengurangi redundansi fitur dan jumlah parameter jaringan tanpa mengorbankan performa segmentasi secara signifikan [12]. Untuk memastikan perbandingan yang adil, kedua model dilatih menggunakan konfigurasi dan skema pelatihan yang identik.

Proses pelatihan dilakukan dengan menggunakan batch size sebesar 4 dan jumlah epoch maksimum sebanyak 150. Optimasi parameter jaringan dilakukan menggunakan algoritma Stochastic Gradient Descent (SGD) dengan Nesterov momentum sebesar 0,9 serta weight decay sebesar 0,0001. Learning rate awal ditetapkan sebesar 0,01 dan disesuaikan secara adaptif menggunakan learning rate scheduler ReduceLROnPlateau dengan factor penurunan sebesar 0,5 dan patience 10 epoch. Selain itu, mekanisme early stopping diterapkan dengan nilai patience 20 epoch untuk mencegah terjadinya overfitting apabila tidak terjadi peningkatan performa pada data validasi.

Fungsi loss yang digunakan dalam penelitian ini merupakan kombinasi dari Binary Cross Entropy (BCE) dan Dice loss dengan bobot yang seimbang. Kombinasi kedua fungsi loss ini dipilih karena mampu menangani ketidakseimbangan kelas antara area ulkus dan latar belakang sekaligus mengoptimalkan kesesuaian area segmentasi yang dihasilkan model terhadap *ground truth* [4], [8].

Evaluasi kinerja model dilakukan menggunakan metode 4-fold cross-validation. Dataset dibagi menjadi empat bagian yang sama, di mana pada setiap iterasi satu bagian digunakan sebagai data uji dan tiga bagian lainnya digunakan sebagai data latih. Proses ini diulang sebanyak empat kali sehingga setiap bagian dataset memiliki kesempatan yang sama untuk menjadi data uji. Pendekatan ini digunakan untuk memperoleh hasil evaluasi yang lebih stabil dan representative serta mengurangi bias akibat pembagian data tertentu.

Performa segmentasi dievaluasi secara kuantitatif menggunakan dua metrik utama, yaitu Dice Similarity Coefficient (DSC) dan Intersection over union (IoU), yang umum digunakan dalam evaluasi

semngnetasi citra medis. DSC digunakan untuk mengukur Tingkat tumpang tindih antara hasil segmentasi prediksi dan ground truth pada Tingkat piksel, sehingga mampu merepresentasikan kesesuaian bentuk dan luas area ulkus kornea yang tersegmentasi. Sementara itu, IoU digunakan untuk mengukur rasio antara area irisan dan area gabungan dari hasil segmentasi prediksi dan ground truth, yang memberikan Gambaran ketepatan model dalam menentukan batas area ulkus kornea secara spasial. Penggunaan kedua metrik ini secara bersamaan bertujuan untuk memperoleh evaluasi performa segmentasi yang lebih komprehensif, baik dari sisi kesesuaian area maupun presisi batas segmentasi.

Selain evaluasi akurasi segmentasi, dilakukan pula analisis efisiensi model untuk menilai kelayakan penerapan pada sistem dengan keterbatasan sumber daya komputasi. Analisis efisiensi dilakukan berdasarkan jumlah parameter jaringan sebagai indikator kompleksitas model serta waktu inferensi rata-rata per citra sebagai indikator kecepatan pemrosesan. Waktu inferensi dihitung sebagai rata-rata waktu yang dibutuhkan model untuk menghasilkan hasil segmentasi dari satu citra pada data uji. Evaluasi efisiensi ini penting untuk mengkaji trade-off antara performa segmentasi dan kompleksitas model, khususnya dalam konteks penerapan model segmentasi ulkus kornea pada lingkungan klinis atau sistem komputasi dengan keterbatasan sumber daya komputasi.

Seluruh eksperimen dijalankan pada lingkungan komputasi local dengan spesifikasi perangkat keras berupa GPU AMD Radeon RX 6700XT dengan 12GB VRAM, CPU AMD Ryzen 5 5600, dan RAM sebesar 16GB. Pemanfaatan akselerasi GPU digunakan untuk mempercepat proses pelatihan dan evaluasi model.

4. HASIL DAN PEMBAHASAN

Hasil eksperimen diperoleh dari proses pelatihan dan pengujian menggunakan skema *4-fold cross-validation* pada dua arsitektur segmentasi, yaitu U-Net dan Ghost U-Net. Evaluasi performa dilakukan secara kuantitatif menggunakan metrik Dice Similarity Coefficient (DSC) dan Intersection over Union (IoU). Selain itu, analisis efisiensi model dilakukan berdasarkan jumlah parameter dan waktu inferensi per citra. Pendekatan ini bertujuan untuk memberikan gambaran yang komprehensif mengenai kinerja dan kompleksitas masing-masing arsitektur.

Tabel 1 menunjukkan hasil evaluasi model U-Net pada setiap fold. Model U-Net memiliki jumlah parameter sebesar 7.763.041 dan menunjukkan performa segmentasi yang sangat tinggi dengan nilai rata-rata DSC sebesar 0,9948 dan IoU sebesar 0,9897. Waktu inferensi rata-rata yang dibutuhkan untuk memproses satu citra adalah sekitar 0,705 ms. Hasil ini menunjukkan bahwa U-Net memiliki kemampuan segmentasi yang sangat baik pada kasus ulkus kornea,

dengan kinerja yang konsisten pada seluruh fold pengujian.

Tabel 1. Hasil evaluasi U-Net menggunakan 4-fold cross-validation

Fold	Jumlah Parameter	DSC	IoU	Waktu Inferensi (ms)
1	7.763.041	0,9928	0,9859	0,696
2	7.763.041	0,9950	0,9902	0,676
3	7.763.041	0,9960	0,9921	0,720
4	7.763.041	0,9952	0,9906	0,729
Rata-rata	7.763.041	0,9948	0,9897	0,705

Tabel 2 menunjukkan hasil evaluasi model Ghost U-Net menggunakan skema pengujian yang sama. Model ini memiliki jumlah parameter yang lebih sedikit, yaitu 5.602.353 parameter, atau berkurang sekitar 27,9% dibandingkan U-Net. Nilai rata-rata DSC yang diperoleh adalah 0,9922 dan IoU sebesar 0,9850, dengan waktu inferensi rata-rata sebesar 1,687 ms per citra. Meskipun performa segmentasi Ghost U-Net sedikit lebih rendah dibandingkan U-Net, perbandingannya relatif kecil dan masih berada pada tingkat performa yang kompetitif.

Tabel 2. Hasil evaluasi Ghost U-Net menggunakan 4-fold cross-validation

Fold	Jumlah Parameter	DSC	IoU	Waktu Inferensi (ms)
1	5.602.353	0,9935	0,9872	1,701
2	5.602.353	0,9951	0,9904	1,640
3	5.602.353	0,9855	0,9724	1,714
4	5.602.353	0,9948	0,9898	1,691
Rata-rata	5.602.353	0,9922	0,9850	1,687

Berdasarkan perbandingan rata-rata hasil evaluasi, U-Net menunjukkan performa segmentasi yang sedikit lebih tinggi dibandingkan Ghost U-Net pada metrik DSC dan IoU. Namun, Ghost U-Net mampu mengurangi jumlah parameter jaringan secara signifikan tanpa penurunan performa yang drastis. Hal ini menunjukkan bahwa Ghost U-Net memiliki efisiensi model yang lebih baik dari sisi kompleksitas jaringan.

Analisis stabilitas performa antar fold menunjukkan bahwa kedua model memiliki kemampuan generalisasi yang baik. Nilai DSC dan IoU pada setiap fold tidak menunjukkan fluktuasi yang signifikan, baik pada U-Net maupun Ghost U-Net. Stabilitas ini mengindikasikan bahwa model tidak mengalami *overfitting* pada subset data tertentu dan mampu mempertahankan kinerja yang konsisten pada data uji yang berbeda. Pada Ghost U-Net, meskipun terdapat variasi nilai IoU pada salah satu fold, nilai rata-rata yang dihasilkan tetap menunjukkan performa segmentasi yang dapat diandalkan.

Dari sisi efisiensi komputasi, Ghost U-Net menunjukkan keunggulan dalam hal pengurangan jumlah parameter jaringan. Namun, waktu inferensi yang lebih tinggi dibandingkan U-Net pada penelitian ini diduga dipengaruhi oleh implementasi Ghost Module dan overhead operasi tambahan, seperti *depthwise convolution*. Meskipun demikian, rasio antara performa segmentasi dan kompleksitas model menunjukkan bahwa Ghost U-Net tetap memiliki potensi sebagai arsitektur segmentasi yang lebih efisien. Dengan optimasi implementasi dan dukungan perangkat keras yang sesuai, performa waktu inferensi Ghost U-Net berpotensi untuk ditingkatkan.

Berdasarkan keseluruhan hasil evaluasi kuantitatif yang diperoleh, kedua model menunjukkan karakteristik kinerja yang berbeda namun saling melengkapi. Temuan ini menegaskan bahwa pemilihan arsitektur segmentasi tidak hanya bergantung pada tingkat akurasi, tetapi juga perlu mempertimbangkan aspek kompleksitas dan efisiensi model, terutama untuk pengembangan sistem segmentasi ulkus kornea berbasis *deep learning* pada lingkungan dengan keterbatasan sumber daya komputasi.

5. KESIMPULAN DAN SARAN

Penelitian ini membandingkan performa U-Net dan Ghost U-Net untuk segmentasi ulkus kornea pada citra oftalmologi menggunakan metode 4-fold cross-validation. Hasil eksperimen menunjukkan bahwa Ghost U-Net mampu memberikan performa segmentasi yang kompetitif dibandingkan U-Net, dengan potensi efisiensi komputasi yang lebih tinggi. Dengan demikian, Ghost U-Net dapat dipertimbangkan sebagai alternatif arsitektur ringan untuk aplikasi segmentasi ulkus kornea. Penelitian selanjutnya dapat mengembangkan evaluasi pada perangkat dengan sumber daya terbatas atau mengintegrasikan model ke dalam sistem pendukung diagnosis klinis.

Dengan jumlah parameter yang lebih rendah dan performa segmentasi yang tetap kompetitif, Ghost U-Net berpotensi untuk diterapkan pada sistem pendukung diagnosis oftalmologi berbasis citra medis, khususnya pada perangkat dengan keterbatasan sumber daya komputasi.

DAFTAR PUSTAKA

- [1] S. A. Setiawan, M. Firdaus, and S. A. Anugrahsari, "Tinjauan Pustaka terhadap Tatalaksana Terkini Ulkus Kornea Jamur Akibat Salah Penggunaan Lensa Kontak," *Jurnal MedScientiae*, vol. 2, no. 2, pp. 1–10, 2023, doi: 10.36452/jmedscientiae.v2i2.2842.
- [2] M. J. Burton *et al.*, "The Lancet Global Health Commission on Global Eye Health: vision beyond 2020," *The Lancet Global Health*, vol. 9, no. 4, pp. e489–e551, 2021, doi: 10.1016/S2214-109X(20)30488-5.
- [3] J. F. Assaf *et al.*, "Applications of Computer Vision for Infectious Keratitis: A Systematic Review," *Ophthalmology Science*, 2025.
- [4] Z. Z. Ong *et al.*, "Diagnostic Performance of Deep Learning for Infectious Keratitis: A Systematic Review and Meta-Analysis," *EClinicalMedicine*, 2024.
- [5] O. Sevlı, "A Deep Learning-Based Classification Study for Diagnosing Corneal Ulcers on Ocular Staining Images," *Acta Infologica*, vol. 7, no. 2, pp. 281–292, 2023, doi: 10.26650/acin.1173465.
- [6] I. A. Qasmieh *et al.*, "Automated Detection of Corneal Ulcer Using Combination Image Processing and Deep Learning," *Diagnostics*, vol. 12, no. 7, p. 1550, 2022, doi: 10.3390/diagnostics12071550.
- [7] S. Wang *et al.*, "AES-CSFS: an automatic evaluation system for corneal sodium fluorescein staining based on deep learning," *Therapeutic Advances in Chronic Disease*, vol. 14, pp. 1–12, 2023, doi: 10.1177/20406223221148266.
- [8] T. Wang *et al.*, "Semi-MsST-GAN: A Semi-Supervised Segmentation Method for Corneal Ulcer Segmentation in Slit-Lamp Images," *Frontiers in Neuroscience*, vol. 15, pp. 1–11, 2022, doi: 10.3389/fnins.2021.793377.
- [9] D. Manawongsakul and K. Patanukhom, "A Segmentation-Based Automated Corneal Ulcer Grading System for Ocular Staining Images Using Deep Learning and Hough Circle Transform," *Algorithms*, vol. 17, no. 6, p. 235, 2024, doi: 10.3390/a17060235.
- [10] I. A. Kazerouni, G. Dooly, and D. Toal, "Ghost-UNet: An Asymmetric Encoder-Decoder Architecture for Semantic Segmentation from Scratch," *IEEE Access*, vol. 9, pp. 37543–37558, 2021, doi: 10.1109/ACCESS.2021.3064747.
- [11] L. Deng *et al.*, "The SUSTech-SYSU Dataset for Automatically Segmenting and Classifying Corneal Ulcers," *Scientific Data*, vol. 7, pp. 1–7, 2020, doi: 10.1038/s41597-020-0360-7.
- [12] K. Han *et al.*, "GhostNet: More Features From Cheap Operations," in *Proc. IEEE/CVF CVPR*, 2020, pp. 1577–1586, doi: 10.1109/CVPR42600.2020.00165.
- [13] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Proc. MICCAI*, 2015, pp. 234–241.