

Klasifikasi Lesi Pra-Kanker Serviks Berbasis Ekstraksi Fitur Tepi

Zahra Maharani Putri
Jurusan Sistem Komputer
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia

Muhammad Naufal Rachmatullah*
Intelligent Systems Research Group
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
naufalrachmatullah@gmail.com

Akhiair Wista Arum
Intelligent Systems Research Group
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
wistaarum16@gmail.com

Intelligent Systems Research Group
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
zhmrhnputri2001@gmail.com

Ade Iriani Sapitri
Intelligent Systems Research Group
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
adeirianisapitri13@gmail.com

Anggun Islami
Intelligent Systems Research Group
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
anggunislami2@gmail.com

Ringkasan— Kanker serviks merupakan salah satu penyebab utama kematian pada wanita di seluruh dunia, dan deteksi dini lesi pra-kanker melalui citra *colposcopy* berperan penting dalam mencegah perkembangannya ke tahap yang lebih parah. Namun, variasi pencahayaan dan kompleksitas tekstur jaringan sering menyebabkan kesulitan dalam mengidentifikasi batas dan tingkat keparahan lesi. Penelitian ini mengusulkan penerapan ekstraksi fitur berbasis dalam mengklasifikasikan tingkat keparahan lesi pra-kanker serviks. Proses dimulai dengan penggunaan model YOLOv11 hasil penelitian sebelumnya untuk menghasilkan citra segmentasi lesi serviks, yang kemudian diolah menggunakan algoritma *Canny Edge Detection* untuk menonjolkan struktur tepi morfologis. Citra hasil ekstraksi tepi selanjutnya diklasifikasikan menggunakan arsitektur *DenseNet121* menjadi tiga kelas, yaitu kelas 0, 1, dan 2. Model terbaik diperoleh pada konfigurasi *learning rate* 0.0001 dan 200 *epoch*, dengan akurasi sebesar 60.46% dan *macro F1-score* 0.53. Hasil ini menunjukkan bahwa fitur berbasis tepi mampu membantu model mengenali pola morfologis pada area lesi, meskipun performa masih dipengaruhi oleh ketidakseimbangan jumlah data antar kelas dan kompleksitas pola tepi. Penelitian ini memberikan kontribusi awal terhadap pengembangan sistem *Computer-Aided Diagnosis* (CAD) berbasis tepi untuk mendukung klasifikasi lesi pra-kanker serviks secara lebih fokus dan interpretatif.

Kata Kunci—*Canny Edge Detection, Computer-Aided Diagnosis, Deep Learning, DenseNet121, Ekstraksi Fitur, Kanker Serviks.*

I. PENDAHULUAN

Kanker serviks masih menjadi salah satu penyebab utama kematian wanita di seluruh dunia, khususnya di negara-

negara dengan sumber daya terbatas [1]. Hal ini dapat dicegah dengan deteksi dini pra-kanker melalui metode klinis standar. Namun, pada pemeriksaan ini dapat terjadi ketidakpastian diagnosis dikarenakan variasi pencahayaan, kualitas gambar, dan latar belakang jaringan yang dapat menyebabkan tidak teridentifikasinya tingkat keparahan lesi dengan baik [2].

Maka dari itu, beberapa tahun terakhir banyak peneliti yang sudah mengembangkan sistem *computer-aided diagnosis* (CAD) berbasis *deep learning* untuk membantu klasifikasi lesi serviks dari citra serviks. Seperti penelitian [3], [4] yang melakukan klasifikasi lesi serviks menggunakan *Convolution Neural Network* (CNN). Juga penelitian [5], [6] yang melakukan klasifikasi lesi serviks dengan arsitektur modern.

Meskipun demikian, kebanyakan penelitian menggunakan pendekatan *end-to-end* dengan citra utuh (*whole image*) sebagai *input* [7], tanpa mempertimbangkan teknik ekstraksi fitur berbasis tepi yang secara khusus menonjolkan batas lesi sebagai indikator morfologis penting. Studi menunjukkan bahwa integrasi peta tepi (*edge map*) mampu memperbaiki akurasi klasifikasi pada berbagai domain citra medis [8] namun penerapan pada citra serviks masih terbatas.

Sehingga penelitian ini mengusulkan penerapan ekstraksi fitur berbasis tepi menggunakan algoritma *Canny Edge Detector* untuk menonjolkan area batas lesi pada citra serviks. Hasilnya kemudian diklasifikasikan menggunakan arsitektur *DenseNet* untuk mengidentifikasi tingkat keparahan lesi pra-kanker serviks. Dengan pendekatan ini, diharapkan penelitian dapat membantu pengembangan sistem CAD yang lebih menyesuaikan dengan karakteristik morfologi lesi serviks juga dalam meningkatkan akurasi dalam menganalisis citra serviks.

II. METODOLOGI

A. Alur Kerja Penelitian

Alur penelitian pada Gambar1, dimulai dari pengumpulan citra *colposcopy* pra-kanker serviks yang kemudian diproses melalui model *You Only Look Once v11* (YOLOv11) yang telah dilatih pada penelitian sebelumnya untuk mendeteksi dan segmentasi area lesi. Hasil dari tahapan ini berupa citra yang telah terpotong dan hanya berisi area lesi. Selanjutnya, citra lesi diproses menggunakan algoritma *Canny Edge Detector* untuk mengekstraksi fitur batas morfologis dan menghasilkan citra *edge map*.



Gambar 1. Alur Penelitian

Citra *edge maps* kemudian dijadikan sebagai input pada arsitektur DenseNet, yang bertugas mengklasifikasikan tingkat keparahan lesi pra-kanker serviks menjadi tiga kelas. Proses diakhiri dengan tahap evaluasi model untuk menilai performa klasifikasi berdasarkan beberapa metrik penilaian.

B. Segmentasi Menggunakan YOLOv11

Segmentasi citra merupakan proses pemisahan area penting dari latar belakang untuk memperoleh representasi yang terfokus terhadap objek yang diteliti [9]. Pada penelitian ini, proses segmentasi dilakukan menggunakan model YOLOv11, yang termasuk keluarga YOLO. YOLO sendiri merupakan salah satu arsitektur *object detection* yang mengintegrasikan deteksi dan klasifikasi secara bersamaan pada satu jaringan konvolusional [10] Model YOLOv11 ini populer karena kecepatan dan kemampuannya melakukan deteksi dan segmentasi skala ganda pada citra beresolusi tinggi.

C. Fitur Ekstraksi Berbasis Tepi

Fitur ekstraksi merupakan tahapan penting dalam sistem berbasis pembelajaran mesin yang bertujuan mengekstraksi karakteristik penting dari data mentah untuk meningkatkan kinerja model klasifikasi. Salah satu pendekatan yang efektif untuk memperkuat morfologis pada citra medis adalah deteksi tepi, karena batas struktural sering kali menjadi indikator utama perubahan patologis.

Algoritma *Canny Edge Detector* dikenal sebagai salah satu metode klasifikasi deteksi tepi paling stabil terhadap *noise* dan mampu mengekstraksi kontur dengan presisi tinggi [11]. Prosesnya meliputi empat tahap utama, yaitu *gaussian smoothing* untuk reduksi *noise*, perhitungan gradien intensitas, *non-maximum suppression* untuk mempertahankan tepi utama, serta *hysteresis thresholding* untuk membedakan tepi kuat dan lemah. Besarnya gradien pada titik (x,y) dihitung menggunakan Persamaan (1):

$$G(x,y) = \sqrt{\{G_x^2 + G_y^2\}} \quad (1)$$

dan arah gradiennya ditentukan oleh Persamaan (2):


$$\theta = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (2)$$

Di mana G_x dan G_y masing-masing menunjukkan komponen horizontal dan vertikal dari gradien intensitas.

Citra hasil proses ini berupa citra *edge map* yang menonjolkan batas lesi pra-kanker. Peta tepi ini telah terbukti meningkatkan kemampuan model *deep learning* dalam mengidentifikasi pola morfologi halus pada berbagai citra medis [12].

D. Arsitektur DenseNet121

Arsitektur *DenseNet121* merupakan salah satu varian CNN modern yang menghubungkan setiap lapisan dengan seluruh lapisan sebelumnya melalui mekanisme *dense connections*. Pendekatan ini dirancang untuk memperbaiki efisiensi aliran informasi dan mengurangi kehilangan gradien selama pelatihan [13]. Struktur koneksi padat memungkinkan setiap lapisan menggunakan kembali fitur yang telah dipelajari sebelumnya, sehingga memperkaya representasi fitur tanpa perlu menambah jumlah parameter secara signifikan.



Gambar 2. Arsitektur DenseNet121

Arsitektur *DenseNet121* pada Gambar 2 terdiri dari sejumlah *dense block* yang dipisahkan oleh *transition layer*. Setiap *dense block* memuat beberapa lapisan konvolusi berukuran 3×3 , yang masing-masing diikuti oleh proses *batch normalization* dan aktivasi ReLU. Sementara itu, *transition layer* berperan dalam melakukan *downsampling* melalui teknik *average pooling* serta penyesuaian dimensi fitur. Di bagian akhir jaringan, terdapat *global average pooling* yang dilanjutkan dengan *fully connected layer* dan aktivasi *softmax* untuk menghasilkan *output* klasifikasi. Dengan desain ini, *DenseNet121* memiliki keseimbangan optimal antara kedalaman jaringan dan efisiensi komputasi, menjadikannya cocok untuk aplikasi medis yang memerlukan generalisasi kuat meskipun data terbatas [14].

III. EKSPERIMEN DAN HASIL

Proses eksperimen mencakup persiapan *dataset*, pelatihan model, serta pengujian menggunakan metrik evaluasi. Eksperimen ini didesain untuk menguji apakah fitur ekstraksi berbasis tepi pada area lesi yang telah disegmentasi dapat meningkatkan klasifikasi tingkat keparahan lesi pra-kanker serviks menggunakan *DenseNet121*.


A. Persiapan Dataset

Dataset yang digunakan dalam penelitian ini berasal dari *International Agency for Research on Cancer (IARC) Colposcopy Dataset*, yang berisi 200 kasus citra *colposcopy* serviks dengan berbagai tingkat keparahan pra-kanker. Langkah awal dilakukan dengan mengekstraksi metadata yang memuat label klinis tiap kasus, kemudian data diklasifikasikan menjadi tiga kelas, yaitu:

- Kelas 0 : *Nil or diffuse*
- Kelas 1 : *Sharp but irregular, jagged, satellites*
- Kelas 2 : *Sharp and even, difference in level*


Dari setiap kasus dalam kelas, hanya citra dengan tipe "after acetic acid" yang dipilih, karena fase tersebut memberikan kontras paling jelas antara jaringan normal dan lesi akibat reaksi asam asetat terhadap epitel abnormal [15].

Setelah citra dipilih, selanjutnya dilakukan tahapan segmentasi menggunakan model YOLOv11, hasil pengembangan dari penelitian sebelumnya, yang telah dilatih pada citra *colposcopy* untuk mendeteksi tiga area utama: *Cervical Area*, *Columnar Area (CA)*, dan *Lession*. Setiap kasus citra dari dataset IARC diprediksi menggunakan YOLOv11 untuk menghasilkan *bounding box* dan *segmentation mask*. Hasil prediksi berupa citra dengan label seperti pada Gambar 3. Dari hasil tersebut, hanya *mask* lesi yang dipertahankan, sementara area lain dihitamkan (*binary masking*).




Gambar 3. Proses *Predict* Menggunakan YOLOv11

Hasil segmentasi kemudian diproses kembali untuk mengisolasi area lesi saja, sedangkan seluruh bagian lain diubah menjadi latar belakang hitam. Proses ini menghasilkan citra baru yang hanya menampilkan lesi secara terisolasi, tanpa gangguan jaringan sekitarnya. Pendekatan ini penting, karena memungkinkan model klasifikasi fokus pada pola morfologis lesi tanpa dipengaruhi variasi anatomi serviks yang tidak relevan [16]. Dari tahapan ini menghasilkan dataset baru berupa citra berisi area lesi murni yang menjadi fokus utama penelitian seperti Gambar 4.



Gambar 4. Dataset Baru (*Lesion Only Image*)

B. Ekstraksi Fitur Berbasis Tepi (*Canny Edge Detection*)



Gambar 5. Fitur Ekstraksi Menggunakan *Canny Edge Detection*

Gambar 5 merupakan citra hasil isolasi lesi yang kemudian diproses menggunakan algoritma *Canny Edge Detection* untuk mengekstraksi dan menonjolkan fitur batas morfologis. Sebelum proses deteksi tepi dilakukan, citra hasil isolasi lesi terlebih dahulu melalui tahap peningkatan kualitas untuk menstabilkan pencahayaan dan mengurangi *noise*. Langkah ini dilakukan agar deteksi tepi tidak salah tangkap pada area dengan teksur lembut atau kontras rendah. Tahapan pemrosesan citra yang digunakan adalah sebagai berikut:

1. *Denoising* dengan metode *Fast Non-Local Means* untuk menghilangkan *noise* halus tanpa mengaburkan batas lesi.
2. *Contrast enhancement* menggunakan *Contrast Limited Adaptive Histogram Equalization (CLAHE)* agar perbedaan intensitas antara jaringan lesi dan latar belakang lebih jelas.
3. *Edge detection* menggunakan algoritma *Canny Edge Detection* dengan ambang bawah 50 dan ambang atas 150 untuk menentukan area dengan perubahan intensitas signifikan.

Pendekatan kombinasi *denoising*, *CLAHE*, juga *Canny Edge Detection* ini terbukti memperkuat struktur kontur dan mempertahankan detail tepi lesi yang halus tanpa kehilangan informasi spasial penting [17].

C. Pembagian Data

Setelah melalui pengolahan fitur ekstraksi menggunakan *Canny Edge Detection*, dataset dibagi menjadi dua subset utama, yaitu 80% data latih (*training set*) dan 20% data uji (*testing set*). Proses pembagian ini dilakukan berdasarkan kasus tiap kelas, bukan per gambar, untuk memastikan tidak ada kebocoran data antara dua subset tersebut. Dengan pendekatan ini, citra yang berasal dari satu case hanya muncul pada satu subset, sehingga model benar-benar dievaluasi pada kasus yang belum pernah dilihat sebelumnya [18].

Tabel 1. Distribusi *Splitting Data*

	Kelas	Jumlah Case
Train Set	0	47
	1	23
	2	48
Test Set	0	12
	1	6
	2	13

Dari Tabel 1 dapat dilihat, jika distribusi jumlah data pada kelas 1 hanya sekitar setengah dari kelas lainnya, sehingga dataset memiliki *imbalance distribution* yang perlu diperhitungkan pada tahap pelatihan dan evaluasi.

D. Pemodelan dan Klasifikasi Menggunakan DenseNet121

Tahapan klasifikasi dilakukan dengan menggunakan arsitektur *DenseNet121*, yang dikenal efisien dan memiliki kemampuan propogasi fitur yang baik pada *dataset* medis yang terbatas [19]. Arsitektur *DenseNet* memiliki koneksi langsung antar setiap lapisan (*dense connectivity*), sehingga setiap lapisan menerima masukan dari seluruh lapisan sebelumnya.

1. Struktur dan Modifikasi Arsitektur

Model *DenseNet121* diinisialisasi menggunakan *pretrained weights* dari *ImageNet* untuk memanfaatkan keunggulan *transfer learning*. Lapisan akhir (*classifier*) dimodifikasi dari:

Linear(*in_features* = 1024, *out_features* = 1000)

Menjadi

Linear(*in_features* = 1024, *out_features* = 3)

Untuk menyesuaikan dengan tiga kelas target klasifikasi, yaitu kelas 0, 1, dan 2.

DenseNet dipilih karena memiliki *feature reuse mechanism* yang efisien, di mana setiap lapisan konvolusional menggunakan hasil fitur dari lapisan sebelumnya tanpa perlu parameter baru yang besar. Mekanisme ini terbukti dapat meningkatkan akurasi dengan kompleksitas parameter yang lebih rendah dibandingkan arsitektur seperti *ResNet* atau *VGG* [20].

2. Transformasi Data dan Augmentasi

Sebelum masuk ke jaringan, citra *edge map* hasil ekstraksi tepi dikonversi menjadi *grayscale* satu kanal, lalu diubah menjadi tiga kanal menggunakan kelas *Duplicate Channel Transform* agar kompatibel dengan *DenseNet121* yang membutuhkan input RGB. Setiap citra kemudian di-*resize* ke ukuran 224×224 piksel, dan dilakukan normalisasi berdasarkan nilai rata-rata dan deviasi standar *dataset ImageNet*:

Untuk meningkatkan generalisasi model, diterapkan augmentasi ringan berupa *horizontal flip*, *vertical flip*, dan *random rotation* ($\pm 15^\circ$) pada data latih. Pendekatan augmentasi sederhana ini mampu meningkatkan keanekaragaman data tanpa mengubah pola morfologi tepi yang menjadi fokus penelitian [21].

3. Penanganan Ketidakseimbangan Data

Dikarenakan distribusi kelas tidak seimbang, penelitian ini menggunakan *weighted loss function* untuk memberikan bobot lebih besar pada kelas dengan jumlah data lebih sedikit. Bobot dihitung berdasarkan invers jumlah sampel tiap kelas dan diimplementasikan pada *Cross Entropy Loss* di *PyTorch*. Pendekatan ini efektif untuk menjaga sensitivitas model terhadap kelas minoritas dan mengurangi bias prediksi terhadap kelas mayoritas [22].

4. Proses Pelatihan Model

Proses pelatihan dilakukan menggunakan *optimizer Adam* dengan *learning rate* awal $\eta=0.001$, *batch size* = 4, dan

jumlah *epoch* antara 50 hingga 200 sesuai variasi eksperimen. Fungsi kehilangan yang digunakan adalah *Weighted Cross-Entropy Loss* untuk menyeimbangkan pengaruh antar kelas.

Selain itu, digunakan *scheduler Reduce LR On Plateau* untuk menurunkan *learning rate* ketika *validation loss* tidak membaik selama lima *epoch* berturut-turut. Pelatihan model dilakukan dalam dua fase pada setiap *epoch*:

- Fase *training* : model dalam mode *train()* dan melakukan pembaruan bobot berdasarkan *backpropagation*.
- Fase *testing* : model beralih ke mode *eval()* untuk mengukur *test loss* dan *test accuracy* tanpa pembaruan gradien.

Model terbaik disimpan secara otomatis menggunakan mekanisme *checkpointing* berdasarkan akurasi tertinggi pada data uji.

E. Evaluasi Hasil

Evaluasi hasil dilakukan untuk menilai kinerja model *DenseNet121* dalam mengklasifikasikan tingkat keparahan lesi serviks berdasarkan citra hasil ekstraksi tepi. Tahapan ini menjadi bagian penting untuk memastikan bahwa model mampu mengenali pola morfologis pada citra *edge map* yang dihasilkan dari tahap deteksi tepi menggunakan metode *Canny Edge Detection*. Evaluasi dilakukan terhadap beberapa kombinasi *epoch* (50, 100, 150, dan 200) serta *learning rate* (0.0001, 0.0005, dan 0.001) guna menemukan konfigurasi parameter terbaik.

Berdasarkan hasil pelatihan dan pengujian, performa model diukur menggunakan teknik akurasi (*accuracy*), presisi (*precision*), sensitivitas atau *recall*, serta skor F1 (*F1-score*). Pendekatan evaluasi ini menekankan pentingnya penggunaan beberapa metrik sekaligus untuk mengukur kinerja model pada *dataset* medis yang tidak seimbang [23], [24]. Rumus dari masing-masing metrik ditunjukkan pada Persamaan (3)–(6).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$\text{Precision}_i = \frac{TP_i}{TP_i+FP_i} \quad (4)$$

$$\text{Recall}_i = \frac{TP_i}{TP_i+FN_i} \quad (5)$$

$$F1_i = 2 \times \frac{\text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (6)$$

Untuk memperoleh hasil yang seimbang antar kelas, rata-rata dari setiap metrik dihitung menggunakan pendekatan *macro average*, seperti ditunjukkan pada Persamaan (7):

$$\text{MacroF1} = \frac{1}{N} \sum_{i=1}^N F1_i \quad (7)$$

dengan N adalah jumlah kelas (tiga dalam penelitian ini). Pendekatan *macro average* dipilih karena memberikan bobot yang sama terhadap setiap kelas, sehingga hasil evaluasi tidak didominasi oleh kelas mayoritas [25].

Tabel 2. Hasil Evaluasi Klasifikasi

Epoch	LR	Acc	Precision	Recall	F1
-------	----	-----	-----------	--------	----

50	0.0001	0.5116	0.4873	0.4	0.3787
100	0.0001	0.5348	0.4955	0.4158	0.3918
150	0.0001	0.5116	0.4646	0.4761	0.4615
200	0.0001	0.6046	0.6111	0.5904	0.5307
50	0.001	0.3953	0.3984	0.4285	0.3885
100	0.001	0.4883	0.3268	0.3904	0.3526
150	0.001	0.5813	0.5912	0.5301	0.5241
200	0.001	0.4883	0.1627	0.3333	0.2187
50	0.0005	0.5116	0.4519	0.4507	0.4502
100	0.0005	0.5581	0.3695	0.4444	0.40250.
150	0.0005	0.4651	0.3475	0.0.4	0.3302
200	0.0005	0.5116	0.4176	0.4063	0.3938

Berdasarkan Tabel 2 hasil percobaan yang dilakukan dengan beberapa kombinasi *epoch* dan *learning rate*, performa model terbaik diperoleh pada konfigurasi *DenseNet121* dengan 200 *epoch* dan *learning rate* sebesar 0.0001. Model ini mencapai akurasi sebesar 60.46%, dengan nilai *Precision_macro* sebesar 0.6111, *Recall_macro* sebesar 0.5905, dan *F1_macro* sebesar 0.5307. Nilai-nilai ini menunjukkan bahwa meskipun akurasi model belum mencapai tingkat optimal, model mampu mempertahankan keseimbangan antara presisi dan sensitivitas pada ketiga kelas, terutama mengingat adanya ketidakseimbangan jumlah data pada kelas 1.

IV. DISKUSI

Dalam penelitian ini, saya telah mengeksplorasi fitur ekstraksi berbasis tepi untuk klasifikasi tingkat keparahan lesi pra-kanker serviks menggunakan arsitektur *DenseNet121*. Pendekatan ini menjadi langkah baru karena penelitian sebelumnya umumnya berfokus pada klasifikasi citra *colposcopy* utuh tanpa melakukan segmentasi dan penonjolan batas morfologis terlebih dahulu. Dengan memanfaatkan hasil segmentasi yang hanya menampilkan area lesi, model diharapkan dapat lebih fokus terhadap informasi bentuk dan kontur yang relevan dengan tingkat keparahan lesi.

Hasil evaluasi yang ada menunjukkan bahwa meskipun model dapat mengenali pola batas lesi dengan cukup baik, performanya masih belum optimal. Hal ini dapat disebabkan oleh beberapa faktor, antara lain ketidakseimbangan jumlah data pada tiap kelas, terutama pada kelas 1, yang menyebabkan model cenderung bias terhadap kelas dengan jumlah data lebih banyak. Selain itu, kompleksitas pola tepi pada citra medis juga dapat memengaruhi kemampuan model dalam menangkap fitur yang benar-benar merepresentasikan tingkat keparahan lesi.

Kinerja yang belum maksimal juga dipengaruhi oleh keterbatasan variasi data pelatihan dan belum digunakannya strategi mekanisme *attention* yang dapat memperkuat fokus model pada area penting. Meskipun demikian, hasil ini menunjukkan bahwa fitur berbasis tepi mampu memperkaya informasi morfologis penting yang sebelumnya kurang dieksplorasi pada penelitian klasifikasi citra serviks.

V. KESIMPULAN

Penelitian ini berhasil menerapkan feature ekstraksi berbasis tepi menggunakan algoritma *Canny Edge Detection* pada citra hasil segmentasi lesi serviks untuk klasifikasi

tingkat keparahan lesi pra-kanker menggunakan arsitektur *DenseNet121*. Hasil terbaik diperoleh pada konfigurasi *learning rate* 0.0001 dan 200 *epoch* dengan akurasi sebesar 60.46% dan *F1-score* 0.53, yang menunjukkan bahwa model mampu mengenali pola morfologis lesi dengan cukup baik meskipun performanya belum optimal. Hal ini disebabkan oleh beberapa faktor, antara lain ketidakseimbangan jumlah data antar kelas, keterbatasan variasi data pelatihan, serta kompleksitas pola tepi yang serupa antar tingkat keparahan lesi, yang membuat model sulit membedakan karakteristik visual antar kelas. Meskipun demikian, pendekatan ini memberikan kontribusi awal terhadap pengembangan sistem klasifikasi citra serviks berbasis tepi, dan hasilnya menunjukkan potensi untuk ditingkatkan lebih lanjut melalui penyeimbangan data, serta integrasi mekanisme *attention* agar performa klasifikasi dan kemampuan generalisasi model menjadi lebih baik pada penelitian selanjutnya.

REFERENSI

- [1] M. K. I. Hamid, S. Hasneen, A. K. Lima, S. R. Shawon, M. Shahriar, and R. Anjum, "Cervical cancer trends, HPV vaccine utilization, and screening in low- and lower-middle-income countries: an updated review," *Ther Adv Vaccines Immunother*, vol. 13, 2025, doi: 10.1177/25151355251356646.
- [2] J. Fan, J. Liu, S. Xie, C. Zhou, and Y. Wu, "Cervical lesion image enhancement based on conditional entropy generative adversarial network framework," *Methods*, vol. 203, no. November 2021, pp. 523–532, 2022, doi: 10.1016/j.ymeth.2021.11.004.
- [3] J. Li, P. Hu, H. Gao, N. Shen, and K. Hua, "Classification of cervical lesions based on multimodal features fusion," *Comput Biol Med*, vol. 177, no. November 2023, p. 108589, 2024, doi: 10.1016/j.compbimed.2024.108589.
- [4] Y. L. 4 Yinuo Fan 1, Huizhan Ma 2, Yuanbin Fu 3, Xiaoyun Liang 2, Hui Yu 1 2, "Colposcopic multimodal fusion for the classification of cervical lesions," *Phys Med Biol*, vol. 67, 2022, doi: https://doi.org/10.1088/1361-6560/ac73d4.
- [5] X. Chen *et al.*, "Application of EfficientNet-B0 and GRU-based deep learning on classifying the colposcopy diagnosis of precancerous cervical lesions," *Cancer Med*, vol. 12, no. 7, pp. 8690–8699, 2023, doi: 10.1002/cam4.5581.
- [6] H. Yang, W. Aydi, N. Innab, M. E. Ghoneim, and M. Ferrara, "Classification of cervical cancer using Dense CapsNet with Seg-UNet and denoising autoencoders," *Sci Rep*, vol. 14, no. 1, pp. 1–16, 2024, doi: 10.1038/s41598-024-82489-2.
- [7] S. Fang, J. Yang, M. Wang, C. Liu, and S. Liu, "An Improved Image Classification Method for Cervical Precancerous Lesions Based on ShuffleNet," *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/9675628.
- [8] Y. Jia, L. Dong, and Y. Jiao, "Medical image classification based on contour processing attention mechanism," *Comput Biol Med*, vol. 191, no. March, p. 110102, 2025, doi: 10.1016/j.compbimed.2025.110102.

- [9] C. M. Girondi, S. L. P. de Castro Lopes, C. M. Ogawa, P. H. Braz-Silva, and A. L. F. Costa, "Texture Analysis of Temporomandibular Joint Disc Changes Associated with Effusion Using Magnetic Resonance Images," *Dent J (Basel)*, vol. 12, no. 3, 2024, doi: 10.3390/dj12030082.
- [10] J. Luo, Z. Liu, Y. Wang, A. Tang, H. Zuo, and P. Han, "Efficient Small Object Detection You Only Look Once: A Small Object Detection Algorithm for Aerial Images," *Sensors*, vol. 24, no. 21, 2024, doi: 10.3390/s24217067.
- [11] Y. Song, C. Li, S. Xiao, Q. Zhou, and H. Xiao, "A parallel Canny edge detection algorithm based on OpenCL acceleration," vol. 19, no. 1 January. 2024. doi: 10.1371/journal.pone.0292345.
- [12] T. Zhang, Y. Liu, Q. Zhao, G. Xue, and H. Shen, "Edge-guided multi-scale adaptive feature fusion network for liver tumor segmentation," *Sci Rep*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-79379-y.
- [13] A. De, N. Mishra, and H. T. Chang, "An approach to the dermatological classification of histopathological skin images using a hybridized CNN-DenseNet model," *PeerJ Comput Sci*, vol. 10, pp. 1–33, 2024, doi: 10.7717/peerj-cs.1884.
- [14] A. Bello, S. C. Ng, and M. F. Leung, "Skin Cancer Classification Using Fine-Tuned Transfer Learning of DENSENET-121," *Applied Sciences (Switzerland)*, vol. 14, no. 17, 2024, doi: 10.3390/app14177707.
- [15] J. Kim, C. M. Park, S. Y. Kim, and A. Cho, "Convolutional neural network-based classification of cervical intraepithelial neoplasias using colposcopic image segmentation for acetowhite epithelium," *Sci Rep*, vol. 12, no. 1, pp. 1–11, 2022, doi: 10.1038/s41598-022-21692-5.
- [16] W. J. Yang, S. H. Lee, Y. J. Kim, and K. G. Kim, "Comparison of performance of cervical cancer grading based on acetowhite areas," *Sci Rep*, vol. 15, no. 1, pp. 1–8, 2025, doi: 10.1038/s41598-025-13205-x.
- [17] H. Duan, S. Yi, and Y. Ren, "DCA-YOLOv8 : A Novel Framework Combined with AICI Loss Function for Coronary Artery Stenosis Detection," 2024.
- [18] J. Sobek *et al.*, "MedYOLO: A Medical Image Object Detection Framework," *Journal of Imaging Informatics in Medicine*, vol. 37, no. 6, pp. 3208–3216, 2024, doi: 10.1007/s10278-024-01138-2.
- [19] A. W. Salehi *et al.*, "A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope," *Sustainability (Switzerland)*, vol. 15, no. 7, 2023, doi: 10.3390/su15075930.
- [20] T. Zhou, X. Ye, H. Lu, X. Zheng, S. Qiu, and Y. Liu, "Review Article Dense Convolutional Network and Its Application in Medical Image Analysis," vol. 2022, 2022.
- [21] K. Alomar, H. I. Aysel, and X. Cai, "Data Augmentation in Classification and Segmentation: A Survey and New Strategies," *J Imaging*, vol. 9, no. 2, 2023, doi: 10.3390/jimaging9020046.
- [22] D. A. Tarzanagh, B. Hou, B. Tong, Q. Long, and L. Shen, "Fairness-Aware Class Imbalanced Learning on Multiple Subgroups," *Proc Mach Learn Res*, vol. 216, pp. 2123–2133, 2023.
- [23] S. A. Hicks *et al.*, "On evaluation metrics for medical applications of artificial intelligence," *Sci Rep*, vol. 12, no. 1, pp. 1–9, 2022, doi: 10.1038/s41598-022-09954-8.
- [24] M. Ghanem *et al.*, "Limitations in Evaluating Machine Learning Models for Imbalanced Binary Outcome Classification in Spine Surgery: A Systematic Review," *Brain Sci*, vol. 13, no. 12, 2023, doi: 10.3390/brainsci13121723.
- [25] O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Sci Rep*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-56706-x.