

**MODIFIKASI ARSITEKTUR *U-NET* MENGGUNAKAN
EFFICIENTNET DAN ATTENTION GATE UNTUK
SEGMENTASI SEMANTIK KANKER SERVIKS PADA
CITRA PAP SMEAR**

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Sains Bidang Studi Matematika**

Oleh :
DWI RANTI
08011182126002



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA**

2025

LEMBAR PENGESAHAN

MODIFIKASI ARSITEKTUR *U-NET* MENGGUNAKAN *EFFICIENTNET* DAN *ATTENTION GATE* UNTUK SEGMENTASI SEMANTIK KANKER SERVIKS PADA CITRA *PAP SMEAR*

SKRIPSI

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Matematika

Oleh

DWI RANTI
08011182126002

Pembimbing Kedua

Prof. Yulia Resti, S.Si., M.Si., Ph.D
NIP. 197307191997022001

Indralaya, 22 Mei 2025
Pembimbing Utama

Dr. Anita Desiani, S.Si., M.Kom
NIP. 197712112003122002

Mengetahui,
Ketua Jurusan Matematika



Dr. Dian Cahyawati Sukanda, S.Si., M.Si.
NIP. 197303212000122001

LEMBAR PERSEMPAHAN

“Only those who dare to step out of their comfort zone and face risks are able to grasp the big dreams that once seemed like mere fantasies”

-Dwi Ranti

Skripsi ini saya persembahkan kepada :

- **Allah Subhanahu Wa Ta’ala**
- **Orang Tuaku Tercinta**
- **Saudara-saudaraku**
- **Keluarga Besarku**
- **Seluruh Dosenku**
- **Sahabat-sahabatku**
- **Almamaterku**

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Dwi Ranti

NIM : 08011182126002

Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat didalam skripsi ini yang berasal dari penulis lain baik yang dipublikasi atau telah diberikan penghargaan dengan mengutip nama sumber penulis yang secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 22 Mei 2025

Penulis



Dwi Ranti

NIM. 08011182126002

KATA PENGANTAR

Puji syukur atas kehadirat Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “Modifikasi Arsitektur *U-Net* Menggunakan *EfficientNet* dan *Attention Gate* Untuk Segmentasi Semantik Kanker Serviks pada Citra *Pap Smear*”. Skripsi ini ditulis sebagai salah satu syarat untuk memperoleh gelar sarjana matematika studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya, semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Dengan segala hormat dan kerendahan hati, penulis mengucapkan terima kasih dan penghargaan kepada:

1. Kedua orang tuaku tercinta, **Ekhwan Mulyadi** dan **Susilawati** serta Kakak laki-lakiku **Redi Nedika, S.T.**, Kakak Perempuanku **Veti Vera, S.Tr.T** dan Adik Perempuanku **Widya Frisca** yang tak pernah lelah memberikan dukungan, doa, perhatian, kasih sayang, sehingga penulis dapat menyelesaikan skripsi ini.
2. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya beserta jajarannya. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua Jurusan serta Ibu **Des Alwine Zayanti, S.Si., M.Si** selaku Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

3. Ibu **Dr. Anita Desiani, S.Si., M.Kom** dan Ibu **Prof. Yulia Resti, S.Si., M.Si., Ph.D** selaku Dosen Pembimbing yang telah bersedia meluangkan waktu, tenaga dan pikiran untuk memberikan bimbingan, didikan dan arahan yang berharga selama pembuatan skripsi, proses perkuliahan dan perlombaan. Ibu **Dr. Yuli Andriani, S.Si., M.Si** dan Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.**, selaku dosen pembahas yang telah memberikan saran, tanggapan dan kritik yang sangat bermanfaat untuk penyelesaian dan perbaikan skripsi ini. Terima kasih atas segala waktu, tenaga, pikiran dan didikan yang sangat berharga bagi penulis selama masa perkuliahan.
4. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staff administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
5. **Himpunan Mahasiswa Matematika Universitas Sriwijaya, Kakak-kakak tingkat dan Adik-adik Tingkat bidang minat Komputasi, Teman-teman angkatan 2021 bidang minat Komputasi dan Keluarga Matematika 2021** yang telah banyak membantu, berbagi ilmu, dan berjuang bersama selama masa perkuliahan dan pembuatan skripsi ini.
6. Untuk seseorang yang belum bisa penulis tuliskan namanya dengan jelas disini, namun telah tertulis jelas di Lauhul Mahfudz untukku.Terima kasih sudah menjadi salah satu sumber motivasi penulis dalam menyelesaikan skripsi ini. Seperti yang dikatakan oleh Imam Asy-Syafi'i, "Apa yang

menjadi takdirmu akan mencarimu, bahkan jika kamu bersembunyi darinya.

Dan apa yang bukan takdirmu tidak akan pernah menjadi milikmu, meskipun itu sedekat apapun kepadamu."

7. Dwi Ranti, ya! diri saya sendiri. Terima kasih telah bertahan dan berjuang melewati perjalanan panjang yang penuh luka, air mata, tawa, dan bahagia. Terima kasih karena tak pernah menyerah, meski jalan ini terjal dan penuh tekanan. Skripsi ini bukanlah proses yang mudah, tapi telah dilalui dengan sungguh-sungguh. Ini adalah pencapaian yang layak dibanggakan. Mari terus melangkah tetap semangat, dan jangan pernah menyerah.
8. Semua pihak yang telah membantu penulis dalam masa perkuliahan dan permbuatan skripsi ini. Semoga segala kebaikan yang diberikan mendapatkan balasan terbaik dari Allah SWT.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/i Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan seluruh pihak yang membutuhkan.

Indralaya, 23 Mei 2025

Penulis

**MODIFICATION OF U-NET ARCHITECTURE USING EFFICIENTNET
AND ATTENTION GATE FOR SEMANTIC SEGMENTATION OF
CERVICAL CANCER IN PAP SMEAR IMAGES**

by:

Dwi Ranti

08011182126002

ABSTRACT

Cervical cancer is a type of cancer that develops in the cervix area due to infection by the Human Papillomavirus (HPV). Early diagnosis of cervical cancer can be performed through several methods, one of which is the Pap smear test. In Pap smear images, abnormal changes can be observed in the nucleus, cytoplasm, and folded cytoplasm of the cells. To accurately separate these cells, an image segmentation process is required. Manual image segmentation is time-consuming and prone to errors, hence the need for automatic image segmentation using deep learning methods, specifically Convolutional Neural Networks (CNNs). One CNN architecture commonly used for image segmentation is U-Net. This study proposes a modified U-Net architecture by incorporating EfficientNet in the *encoder* and Attention Gate in the *decoder* for semantic segmentation of Pap smear images. EfficientNet addresses the issue of shallow learning layers in the *encoder*, which limit the model's ability to learn from complex images. The Attention Gate in the *decoder*'s skip connections helps reduce the inclusion of irrelevant information. The proposed architecture achieved an accuracy of 93.82%, indicating that the model can accurately segment almost all labels in the image. The sensitivity of 83.14% shows that the model performs well in predicting relevant labels in Pap smear images. A specificity of 95.85% indicates strong performance in identifying non-cancerous labels. The *F1-Score* of 83.03% reflects a good balance between sensitivity and specificity across all labels. The Intersection over Union (IoU) score of 72% suggests a fairly good match between the prediction and the ground truth. Overall, the results show that the model performs well in segmenting cervical cancer in Pap smear images. However, improvements in sensitivity, *F1-Score*, and IoU are needed to further optimize performance.

Keywords: Semantic Segmentation, Cervical Cancer, Pap Smear Image, U-Net, EfficientNet, Attention Gate

**MODIFIKASI ARSITEKTUR *U-NET* MENGGUNAKAN *EFFICIENTNET*,
DAN *ATTENTION GATE* UNTUK SEGMENTASI SEMANTIK KANKER
SERVIKS PADA CITRA *PAP SMEAR***

Oleh:

Dwi Ranti

08011182126002

ABSTRAK

Kanker serviks adalah jenis kanker yang berkembang di area leher rahim akibat infeksi *Human Papillomavirus* (HPV). Diagnosa awal Kanker serviks dapat dilakukan dengan beberapa metode, salah satunya adalah pemeriksaan *Pap Smear*. Pada citra *Pap Smear* dapat terlihat adanya perubahan abnormal pada sel nukleus, sitoplasma dan sitoplasma terlipat (*folded cytoplasm*). Untuk dapat memisahkan sel-sel secara detail diperlukan proses segmentasi citra. Segmentasi citra manual memakan waktu dan rentan terhadap kesalahan, sehingga dibutuhkan segmentasi citra otomatis dengan memanfaatkan metode *deep learning* yaitu *Convolution Neural Network* (CNN). Salah satu arsitektur CNN yang diterapkan dalam segmentasi citra adalah *U-Net*. Penelitian ini mengusulkan modifikasi arsitektur *U-Net* dengan *EfficientNet* pada *encoder* dan *Attention Gate* pada *decoder* untuk segmentasi semantik citra *Pap Smear*. *EfficientNet* diterapkan untuk mengatasi lapisan pembelajaran yang relatif dangkal yang mengurangi kemampuan model dalam mempelajari citra kompleks. *Attention Gate* pada *skip connection* di *decoder* untuk mengatasi pencampuran informasi yang tidak relevan. Hasil penerapan arsitektur yang memperoleh akurasi sebesar 93,82%. Hal ini menunjukkan bahwa model mampu melakukan segmentasi dengan tepat pada hampir seluruh label dalam citra. Sensitivitas 83,14%. Hal ini menunjukkan model bekerja dengan baik dalam memprediksi label pada citra *Pap Smear*. Spesifisitas 95,85%, Hal ini menunjukkan model dapat memprediksi dengan sangat baik pada label yang bukan bagian dari kanker serviks. *F1-Score* 83,03%. Hal ini menunjukkan keseimbangan yang baik antara Sensitivitas dan spesifisitas pada setiap label. Nilai IoU 72%. Hal ini menunjukkan model memiliki kesesuaian yang cukup baik antara hasil prediksi dan *ground truth*. Hasil penelitian ini menunjukkan bahwa model memprediksi dan bekerja dengan baik dalam melakukan segmentasi kanker serviks pada citra *Pap Smear*. Namun, peningkatan sensitivitas, *F1-Score*, dan IoU diperlukan untuk meningkatkan performa menjadil optimal.

Kata Kunci: Segmentasi Semantik, Kanker Serviks, Citra *Pap Smear*, *U-Net*, *EfficientNet*, *Attention Gate*

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERSEMPAHAN	iii
KATA PENGANTAR.....	iv
ABSTRACT	vii
ABSTRAK	viii
DAFTAR ISI.....	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.3 Pembatasan Masalah.....	5
1.4 Tujuan	5
1.5 Manfaat	6
BAB II TINJAUAN PUSTAKA.....	7
2.1 Kanker Serviks.....	7
2.2 Citra Digital	8
2.3 Segmentasi Citra	8
2.4 <i>Preprocessing</i> Data.....	8
2.4.1 Augmentasi Data	9
2.4.2 Perbaikan Kualitas Citra : <i>Gaussian Blur</i>	10
2.5 U-Net	11
2.6 <i>EfficientNet</i>	12
2.7 <i>Encoder EfficientNet</i>	13
1. <i>Compound Scaling</i>	14
2. <i>Padding Same</i>	14
3. <i>Convolutional layer</i>	15
4. <i>Batch Normalization</i>	17
5. <i>Mobile Inverted Bottleneck Convolution</i> (MBConv)	18
7. <i>Average Pooling</i>	20
2.8 <i>Decoder U-Net</i> dan <i>Attention Gate</i>	21
1. <i>Upsampling</i>	22

2.	<i>Attention Gate</i>	22
3.	<i>Concatenate Layer</i>	25
2.9	Fungsi Aktivasi <i>Softmax</i>	25
2.10	<i>Loss Function: Categorical Cross-Entropy</i>	26
2.11	<i>Optimization Function: Adaptive Momen Estimation (Adam)</i>	27
2.12	<i>Confusion Matrix</i>	28
BAB III METODOLOGI PENELITIAN		31
3.1	Tempat	31
3.2	Waktu.....	31
3.3	Alat.....	31
3.4	Tahapan Penelitian.....	31
3.4.1	Data	31
3.4.2	<i>Preprocessing Data</i>	32
3.4.3	Rancangan Modifikasi Arsitektur <i>U-Net</i> menggunakan <i>EfficientNet</i> , dan <i>Attention Gate</i>	32
3.4.4.	Implementasi Modifikasi Arsitektur <i>U-Net</i> menggunakan <i>EfficientNet</i> , dan <i>Attention Gate</i>	34
BAB IV HASIL DAN PEMBAHASAN		38
4.1	Deskripsi <i>Dataset</i>	38
4.2	<i>Preprocessing Data</i>	39
4.3	Rancangan Modifikasi Arsitektur <i>U-Net</i> Menggunakan <i>EfficientNet</i> dan <i>Attention Gate</i>	45
4.4	Implementasi Modifikasi Arsitektur <i>U-Net</i> menggunakan <i>EfficientNet</i> dan <i>Attention Gate</i>	46
4.4.1	<i>Encoder EfficientNet</i>	46
4.4.2	<i>Decoder U-Net</i>	59
4.4.3	Fungsi Aktivasi <i>Softmax</i>	64
4.4.4	<i>Loss Function: Categorical Cross Entropy</i>	67
4.4.5	<i>Optimization Function: Adaptive Moment Estimation (Adam)</i> 68	
4.5	Hasil Implementasi Modifikasi Arsitektur <i>U-Net</i> Menggunakan <i>EfficientNet</i> dan <i>Attention Gate</i>	70
4.5.1	<i>Training</i>	71
4.5.2	<i>Testing Data</i>	73

4.5.3 Evaluasi Kinerja Model dan Interpretasi Hasil	77
BAB V KESIMPULAN DAN SARAN	87
5.1 Kesimpulan	87
5.2 Saran	87
DAFTAR PUSTAKA	88

DAFTAR TABEL

Tabel 2. 1 Kategori Evaluasi Kinerja Model.....	30
Tabel 4. 1 <i>Dataset</i> Citra <i>Pap Smear</i> pada <i>Dataset Herlev</i>	38
Tabel 4. 2 Perbandingan Citra Asli, <i>Ground truth</i> , dan Hasil Segmentasi	73
Tabel 4. 3 Confusion matrix dari Proses <i>Testing</i>	74
Tabel 4. 4 Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lain.....	85

DAFTAR GAMBAR

Gambar 2. 1 Citra <i>Pap Smear</i>	7
Gambar 2. 2 Proses Augmentasi Citra	9
Gambar 2. 3 Ilustrasi arsitektur <i>U-Net</i>	12
Gambar 2. 4 Arsitektur <i>EfficientNet</i>	13
Gambar 2. 5 Proses <i>Padding Same</i>	15
Gambar 2. 6 Ilustrasi <i>convolution layer</i>	15
Gambar 2. 7 Ilustrasi <i>average pooling</i>	20
Gambar 2. 8 Ilustrasi <i>upsampling</i>	22
Gambar 2. 9 Ilustrasi Modul <i>Attention Gate</i>	23
Gambar 2. 10 Ilustrasi <i>Concatenate</i>	25
Gambar 4. 1 Segmentasi Semantik Citra <i>Pap Smear</i>	39
Gambar 4. 2 Proses Augmentasi dan Perbaikan Citra	40
Gambar 4. 3 Rancangan Modifikasi Arsitektur <i>U-Net</i> menggunakan <i>EfficientNet</i> dan <i>Attention Gate</i>	45
Gambar 4. 4 Proses <i>Concatenate</i>	64
Gambar 4. 5 Grafik Akurasi Proses Training	71
Gambar 4. 6 Grafik <i>Loss</i> Proses Training	72

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kanker serviks adalah jenis kanker kedua yang paling umum terjadi pada wanita di seluruh dunia, dengan angka kematian yang signifikan. Penyakit ini berkembang akibat infeksi berkepanjangan oleh *Human Papillomavirus* (HPV) (Desiani *et al.*, 2023). Diagnosa awal Kanker serviks dapat dilakukan dengan beberapa metode, salah satunya adalah pemeriksaan *Pap Smear*. *Pap Smear* merupakan proses pemeriksaan medis dengan menggunakan *Aylesbury spatula* dan *cytobrush* untuk mengambil sampel sel serviks yang menghasilkan citra *Pap Smear*. Adapun sel-sel yang terdapat pada citra *Pap Smear* yaitu sel nukleus, sitoplasma, dan sitoplasma terlipat (*folded cytoplasm*). Nukleus merupakan inti sel yang terdapat di dalam sel serviks, sementara sitoplasma adalah bagian sel yang mengelilingi nukleus. Sitoplasma terlipat adalah kondisi dimana sitoplasma menunjukkan lipatan atau kerutan yang tampak pada bagian ujungnya. Ketidaknormalan pada sel nukleus, sitoplasma dan sitoplasma terlipat dapat digunakan untuk mengetahui adanya sel kanker serviks atau tidak pada pasien. Untuk dapat memisahkan sel-sel secara detail diperlukan proses segmentasi citra.

Segmentasi citra pada citra *Pap Smear* bertujuan untuk memisahkan area nukleus, sitoplasma dan sitoplasma terlipat dari *background*. Segmentasi citra manual oleh tenaga medis memakan waktu dan rentan terhadap kesalahan, sehingga memerlukan bantuan komputer untuk melakukan proses segmentasi citra otomatis (Li *et al.*, 2020). Segmentasi citra otomatis dengan memanfaatkan metode *deep*

learning yaitu *Convolution Neural Network* (CNN) (Bhatt *et al.*, 2021). Salah satu arsitektur CNN yang banyak digunakan dalam segmentasi citra adalah *U-Net* (Desiani *et al.*, 2022). Desiani *et al.*, (2024) menerapkan *U-Net* pada segmentasi citra *Pap Smear* dengan akurasi 92%. Namun, penelitian tersebut hanya melakukan segmentasi pada dua label yaitu nukleus dan sitoplasma. Pan *et al.*, (2019) menerapkan *U-Net* pada segmentasi citra *Pap Smear* dengan akurasi 92,44%. Namun, penelitian tersebut hanya melakukan segmentasi pada nukleus. Rudiansyah *et al.*, (2024) menerapkan *U-Net* pada segmentasi citra *Pap Smear* dengan memperoleh akurasi 89%. Namun, penelitian tersebut hanya melakukan segmentasi dua label yaitu nukleus dan sitoplasma.

Arsitektur *U-Net* terdiri dari dua bagian yaitu *encoder* dan *decoder*. *Encoder* berfungsi melakukan ekstraksi fitur dengan lapisan konvolusi melalui proses *downsampling* (Tatli & Budak, 2023). Namun, bagian *encoder* *U-Net* memiliki lapisan pembelajaran yang relatif dangkal (Desiani *et al.*, 2022). Lapisan didalam *U-Net* hanya berjumlah 2-5 lapisan. Pembelajaran yang dangkal dapat mengurangi kemampuan model dalam mempelajari citra kompleks (Desiani *et al.*, 2022). Selain itu, penambahan lapisan pada arsitektur *U-Net* dapat meningkatkan jumlah parameter (Desiani *et al.*, 2022). Salah satu arsitektur yang memiliki bagian *encoder* dengan lapisan yang lebih dalam dan dapat mempelajari citra yang lebih kompleks tanpa meningkatkan jumlah parameter secara signifikan adalah *Efficient Convolutional Network (EfficientNet)* (Ahmed & Nandi., 2024). Arsitektur *EfficientNet* merupakan arsitektur untuk klasifikasi yang hanya memiliki bagian *encoder*. *EfficientNet* didukung oleh dua modul yaitu *compound scaling* dan

Mobile Inverted Bottleneck Convolution (MBConv) (Baheti *et al.*, 2022).

Compound scaling merupakan teknik skala yang digunakan untuk meningkatkan ukuran model secara seimbang pada tiga dimensi utama yaitu *depth*, *width* dan *resolution* (Tan & Le, 2019). Sementara itu, MBConv adalah blok konvolusi yang menggabungkan *depthwise convolution* dan *pointwise convolution*, sehingga dapat menangkap fitur dengan lebih baik dan parameter yang digunakan lebih sedikit. Kombinasi kedua teknik ini membuat *EfficientNet* lebih ringan namun tetap memiliki kinerja tinggi (Wang *et al.*, 2020).

Modifikasi arsitektur *EfficientNet* dengan *U-Net* telah banyak diterapkan dalam berbagai penelitian. Del *et al.*, (2023) menerapkan *EfficientNet* sebagai *encoder* dalam *U-Net* untuk segmentasi citra *Pap Smear* menghasilkan sensitivitas sebesar 92%, spesifitas 96%, dan IoU 85%. Namun, penelitian tersebut hanya melakukan segmentasi dua label yaitu nukleus, sitoplasma. Maarouf *et al.*, (2022) menerapkan *EfficientNet* sebagai *encoder* dalam *U-Net* untuk segmentasi citra *Pap Smear* menghasilkan *F1-Score* 83%. Namun, penelitian tersebut hanya melakukan segmentasi dua label yaitu nukleus, sitoplasma. Selain bagian *encoder*, *U-Net* juga memiliki bagian *decoder* yang berfungsi untuk mengembalikan *featur map* yang diproses oleh *encoder* ke resolusi asli citra melalui proses *upsampling* (Tatli & Budak, 2023). Fitur yang diekstraksi oleh *encoder* diteruskan ke *decoder* *U-Net* menggunakan *skip connection*, yang memungkinkan pemanggilan kembali fitur-fitur dari *encoder* yang mungkin terlewat selama konvolusi (Le *et al.*, 2020). Namun, *skip connection* tidak melakukan seleksi fitur, sehingga fitur yang tidak penting juga dapat terbawa ke dalam *decoder*. (Ying *et al.*, 2020). Mekanisme pada

CNN yang dapat melakukan seleksi fitur relevan dan tidak relevan adalah *Attention Gate*. *Attention Gate* merupakan mekanisme yang digunakan untuk meningkatkan fokus model pada bagian penting dari input (Shen *et al.* 2019). *Attention Gate* menerima dua input dan melakukan seleksi fitur pada dua input yang masuk dengan cara memberikan bobot setiap fitur melalui operasi konvolusi 1×1 yang melibatkan dua fungsi aktivasi yaitu ReLU dan *sigmoid* (Yan & Zhang, 2021). Fungsi aktivasi ReLu dan *sigmoid* akan memberikan bobot-bobot pada setiap fitur. Bobot yang tertinggi menandakan fitur tersebut relevan (Oktay *et al.*, 2018). Penelitian Zhang *et al.*, (2020) menerapkan *Attention Gate* pada *decoder U-Net* pada segmentasi citra *Pap Smear* dan memperoleh akurasi 91,7% serta sensitivitas 93%. Namun, penelitian ini hanya melakukan segmentasi dua label yaitu nukleus, sitoplasma. Zhao *et al.*, (2023) menerapkan *Attention Gate* pada arsitektur *U-Net* dalam segmentasi pembuluh darah retina menghasilkan akurasi yang sangat baik sebesar 95%.

Penelitian ini mengimplementasikan modifikasi *U-Net* menggunakan *EfficientNet* dan *Attention Gate*. Modifikasi arsitektur ini meliputi penggunaan *EfficientNet* sebagai *Encoder* pada *U-Net* bertujuan untuk meningkatkan kemampuan model dalam mengekstrak fitur dari Gambar dengan cara yang lebih efisien, tanpa meningkatkan jumlah parameter secara signifikan. Pada bagian *decoder* dilakukan modifikasi dengan ditambahkan *Attention Gate* pada *upsampling* yang bertujuan untuk memfokuskan model pada fitur-fitur penting. Penelitian ini melakukan segmentasi semantik sel pada citra *Pap Smear* dengan empat label yaitu nukleus, sitoplasma, sitoplasma terlipat dan *background*. Untuk

mengukur kinerja arsitektur yang diusulkan dalam segmentasi citra *Pap Smear* secara semantik digunakan metrik kinerja berdasarkan nilai akurasi, sensitivitas, spesifitas, IoU dan *F1-Score*.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini adalah bagaimana hasil kinerja modifikasi arsitektur *U-Net* menggunakan *EfficientNet* pada bagian *encoder* dan *Attention Gate* pada bagian *decoder* dalam segmentasi semantik citra *Pap Smear*.

1.3 Pembatasan Masalah

Pembatasan masalah dalam penelitian ini, yaitu antara lain:

1. Melakukan segmentasi pada empat label yaitu nukleus, sitoplasma, sitoplasma terlipat dan *background*.
2. Metode evaluasi kinerja yang digunakan pada segmentasi semantik citra *Pap Smear* yaitu akurasi, sensitivitas, spesifitas, *F1-Score*, dan *IoU*.

1.4 Tujuan

Tujuan dari penelitian ini adalah untuk mengetahui hasil kinerja modifikasi arsitektur *U-Net* menggunakan *EfficientNet* menggunakan *EfficientNet* pada bagian *encoder* dan *Attention Gate* pada bagian *decoder* dalam segmentasi citra *Pap Smear*.

1.5 Manfaat

Adapun manfaat penelitian ini adalah:

1. Dapat memperoleh hasil segmentasi semantik yang mampu membedakan antara sel nukleus, sitoplasma, dan sitoplasma terlipat (*folded cytoplasm*) pada citra *Pap Smear*.
2. Dapat digunakan sebagai referensi dalam pengembangan segmentasi nukleus, sitoplasma, dan sitoplasma terlipat (*folded cytoplasm*) secara otomatis untuk diagnosis medis, mengurangi ketergantungan pada metode manual yang memakan waktu dan biaya.

DAFTAR PUSTAKA

- Ahmed, H. O., & Nandi, A. K. (2024). High Performance Breast Cancer Diagnosis from Mammograms Using Mixture of Experts with EfficientNet Features (MoEffNet). *IEEE Access*.
- Alawad, M., Aljouie, A., Alamri, S., Alghamdi, M., Alabdulkader, B., Alkanhal, N., & Almazroa, A. (2022). Machine learning and deep learning techniques for optic disc and cup segmentation--a review. *Clinical Ophthalmology*, 747–764. <https://doi.org/10.2147/OPTH.S348479>.
- Alhamad, H. A., Shehab, M., Shambour, M. K. Y., Abu-Hashem, M. A., Abuthawabeh, A., Al-Aqrabi, H., Daoud, M. S., & Shannaq, F. B. (2024). Handwritten Recognition Techniques: A Comprehensive Review. *Symmetry*, 16(6), 1–25. <https://doi.org/10.3390/sym16060681>.
- Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., & Alajlan, N. A. (2021). Classification of remote sensing images using EfficientNet-B3 CNN model with attention. *IEEE access*, 9, 14078–14094.d oi: 10.1109/ACCESS.2021.3051085.
- Baheti, B., Innani, S., Gajre, S., & Talbar, S. (2020). Eff-U-Net: A novel architecture for semantic segmentation in unstructured environment. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, 358–359. <https://doi.org/10.1109/CVPRW50498.2020.00187>.
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). Cnn variants for computer vision: History, architecture, application, challenges and future scope. *Electronics (Switzerland)*, 10(20), 1–28. <https://doi.org/10.3390/electronics10202470>.
- Chen, W., Yang, B., Li, J., & Wang, J. (2020). An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks. *IEEE Access*, 8, 178552–178562. <https://doi.org/10.1109/ACCESS.2020.3027794>.
- Cheng, B., Girshick, R. B., Doll’ar, P., Berg, A. C., & Kirillov, A. (2021). Boundary IoU: improving object-centric image segmentation evaluation. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 15329–15337. <https://doi.org/10.48550/arXiv.2103.16562>.
- Dai, Y., Li, C., Su, X., Liu, H., & Li, J. (2023). Multi-scale depthwise separable convolution for semantic segmentation in street-road scenes. *Remote Sensing*, 15(10), 1–18. <https://doi.org/10.3390/rs15102649>.
- Darenoh, N. V., Prasetyo, Y., Alfarakh, M. G., & Sari, Y. A. (2018). Segmentasi Semantik Citra Dengan Convolutional Neural Network Menggunakan Arsitektur U-Net. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIIK)*, X(30), 2. <https://doi.org/10.25126/jtiik>.

- Del Moral-Argumedo, M. J., Ochoa-Zezzati, C. A., Posada-Gómez, R., & Aguilar-Lasserre, A. A. (2023). A Deep Learning approach for automated Cytoplasm and Nuclei cervical segmentation. *Biomedical Signal Processing and Control*, 81, 104483. <https://doi.org/10.1016/j.bspc.2022.104483>.
- Desai, M., & Shah, M. (2021). An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical EHealth*, 4(2021), 1–11. <https://doi.org/10.1016/j.ceh.2020.11.002>.
- Desiani, A., Erwin, Suprihatin, B., Wahyudi, Y., Cahyono, E. S., & Arhami, M. (2022). BVU-Net: A U-Net modification by VGG-Batch Normalization for retinal blood vessel segmentation. *International Journal of Intelligent Engineering and Systems*, 15(6), 303–314. <http://dx.doi.org/10.22266/ijies.2022.1231.29>.
- Desiani, A., Kresnawati, E. S., Arhami, M., Resti, Y., Eliyati, N., Yahdin, S., Charisa, T. J., & Nawawi, M. (2023). Majority Voting as Ensemble Classifier for Cervical Cancer Classification. *Science and Technology Indonesia*, 8(1), 84–92. <https://doi.org/10.26554/sti.2023.8.1.84-92>.
- Desiani, A., Rini, D. P., Kesuma, L. I., Salamah, F., & Putri, S. C. (2024, November). Median Filter and U-Net Architecture for Robust Segmentation Nucleus and Cytoplasm on Pap Smear. In *2024 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)* (pp. 779–784). IEEE.
- Devi, T. G., Patil, N., Rai, S., & Philipose, C. S. (2023). Gaussian Blurring technique for detecting and classifying acute lymphoblastic leukemia cancer cells from microscopic biopsy images. *Life*, 13(2), 348. <https://doi.org/10.3390/life13020348>.
- Djohar, M. A., Desiani, A., Amran, A., Yahdin, S., Dwi Putri, D. L., Zayanti, D. A., & Dewi, N. R. (2022). Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture. *Journal of Informatics and Telecommunication Engineering*, 6(1), 221–234. <https://doi.org/10.31289/jite.v6i1.6751>.
- Fostiropoulos, I., & Boehm, B. (2022). Implicit feature decoupling with depthwise quantization. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2022-June, 396–405. <http://dx.doi.org/10.1109/CVPR52688.2022.00049>.
- Garbin, C., Zhu, X., & Marques, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools and Applications*, 79(19–20), 12777–12815. <https://doi.org/10.1007/s11042-019-08453-9>.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference*

- Library* (Vol. 172, Issue 6). https://doi.org/10.1007/978-3-030-32644-9_36.
- Hashemi, M. (2019). Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation. *Journal of Big Data*, 6(1), 1–13. <https://doi.org/10.1186/s40537-019-0263-7>.
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 1–9. <https://doi.org/10.1038/s41598-022-09954-8>.
- Huang, W., Wang, J., Xin, X., Wan, X., dan Li, M. (2020). Channel-modulated multibranch convolutional neural network. 2020 Chinese Automation Congress (CAC), 1854–1859.
- Hussain, E., Mahanta, L. B., Das, C. R., & Talukdar, R. K. (2020). A comprehensive study on the multi-class cervical cancer diagnostic prediction on *Pap Smear* images using a fusion-based decision from ensemble deep convolutional neural network. *Tissue and Cell*, 65(November 2019), 101347. <https://doi.org/10.1016/j.tice.2020.101347>.
- Jiang, Z. P., Liu, Y. Y., Shao, Z. E., & Huang, K. W. (2021). An improved VGG16 model for pneumonia image classification. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/app112311185>.
- Jin, T., & Liu, J. (2025). A text classification method by integrating mobile inverted residual bottleneck convolution networks and capsule networks with adaptive feature channels. *Scientific Reports*, 15(1), 855. <https://doi.org/10.1038/s41598-025-85237-2>.
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>.
- Kim, Y., & Panda, P. (2021). Revisiting Batch Normalization for Training Low-Latency Deep Spiking Neural Networks From Scratch. *Frontiers in Neuroscience*, 15(December), 1–13. <https://doi.org/10.3389/fnins.2021.773954>.
- Kingma, D. P., & Ba, J. L. (2015). ADAM: A method for stochastic optimization. *ICLR 2015 - Conference Track Proceedings*, 1–15. <https://doi.org/10.48550/arXiv.1412.6980>
- Li, C., Tan, Y., Chen, W., Luo, X., Gao, Y., Jia, X., & Wang, Z. (2020). Attention U-Net++ : A Nested Attention-Aware U-Net for Liver CT *Image Segmentation*. *IEEE International Conference on Image Processing (ICIP)*, 345–349. <http://dx.doi.org/10.1109/ICIP40778.2020.9190761>.
- Lv, H., Chen, J., Pan, T., Zhang, T., Feng, Y., & Liu, S. (2022). Attention mechanism in intelligent fault diagnosis of machinery: A review of technique and application. *Measurement*, 199, 111594. <https://doi.org/10.1016/>

- j.measurement.2022.111594
- Maarouf, C., Benomar, M. L., & Settoufi, N. (2022). Pre-trained Backbones Effect on Nuclei Segmentation Performance. *Communications in Computer and Information Science, 1543 CCIS*(May), 108–118. https://doi.org/10.1007/978-3-031-04112-9_8.
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91–99. <https://doi.org/10.1016/j.gltip.2022.04.020>.
- Maiyanti, S. I., Desiani, A., Lamin, S., Puspitasati, Arhami, M., Gofar, N., & Cahyana, D. (2023). Rotation-gamma correction augmentation on cnn-dense block for soil image classification. *Applied Computer Science*, 19(3), 96–115.
- Msonda, P., Uymaz, S. A., & Karaağaç, S. S. (2020). Spatial pyramid pooling in deep convolutional networks for automatic tuberculosis diagnosis. *Traitemen Du Signal*, 37(6), 1075–1084. <https://doi.org/10.18280/TS.370620>.
- Nethaji, V., & Shanmugasundaram, A. P. (2020). The analysis and manipulation of a digitized image processing. *ACCENTS Transactions on Image Processing and Computer Vision*, 6(18), 17–22. <https://doi.org/10.19101/TIPCV.2020.618015>.
- Oktay, O., Schlemper, J., Folgoc, L. Le, 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. *Medical Imaging with Deep Learning*, 3, 1–10. <https://doi.org/10.48550/arXiv.1804.03999>.
- Oza, P. R., Sharma, P., & Patel, S. (2022). A transfer representation learning approach for breast cancer diagnosis from mammograms using efficientnet models. *Scalable Computing: Practice and Experience*, 23(2), 51-58. <https://doi.org/10.12694/scpe.v23i2.1975>.
- Padhi, J., Korada, L., Dash, A., Sethy, P. K., Behera, S. K., & Nanthaamornphong, A. (2024). Paddy leaf disease classification using EfficientNet B4 With compound scaling and swish activation: A deep learning approach. *IEEE Access*.
- Pan, X., Li, L., Yang, D., He, Y., Liu, Z., & Yang, H. (2019). An Accurate Nuclei Segmentation Algorithm in Pathological Image Based on Deep Semantic Network. *IEEE Access*, 7, 110674–110686. <https://doi.org/10.1109/ACCESS.2019.2934486>.
- Peña, L. E. R., Calderon, H. A., & Carsteanu, A. A. (2022). Digital image processing in C++ in SEM images. *Microscopy and Microanalysis*, 28, 2186–2188. <https://doi.org/10.1017/S1431927622008443>.
- Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., & Rahadjeng, I. R. (2020). *Sigmoid*

- activation function in selecting the best model of artificial neural networks. *Journal of Physics: Conference Series*, 1471(1), 1–7. <https://doi.org/10.1088/1742-6596/1471/1/012010>.
- Rudiansyah, R., Iryani, L., Kesuma, L. I., Sari, P., & Alamsyah, A. (2024). Combination of Image Enhancement and U-Net Architecture for Cervical Cell Semantic Segmentation. *Journal of Informatics and Telecommunication Engineering*, 7(2), 575–586. <https://doi.org/10.31289/jite.v7i2.10399>.
- Sarwar, A., Sheikh, A. A., Manhas, J., & Sharma, V. (2020). Segmentation of cervical cells for automated screening of cervical cancer: a review. *Artificial Intelligence Review*, 53(4), 2341–2379. <https://doi.org/10.1007/s10462-019-09735-2>.
- Sharma, S., Sharma, S., & Anidhya, A. (2020). Understanding Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310–316.
- Shen, Y., Fang, Z., Gao, Y., Xiong, N., Zhong, C., & Tang, X. (2019). Coronary Arteries Segmentation Based on 3D FCN with Attention Gate and Level Set Function. *IEEE Access*, 7, 42826–42835. <https://doi.org/10.1109/ACCESS.2019.2908039>
- Shi, J., Dang, J., Cui, M., Zuo, R., Shimizu, K., Tsunoda, A., & Suzuki, Y. (2021). Improvement of damage segmentation based on pixel-level data balance using vgg-U-Net. *Applied Sciences*, 11(2), 518.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *ArXiv Preprint ArXiv*, 97, 10691–10700.
- Tatli, U., & Budak, C. (2023). Biomedical image segmentation with modified U-Net. *International Information And Engineering Technology Association*, 40, 523–531. <https://doi.org/10.18280/ts.400211>
- Wang, S., Hou, X., & Zhao, X. (2020). Automatic Building Extraction from High-Resolution Aerial Imagery via Fully Convolutional Encoder-Decoder Network with Non-Local Block. *IEEE Access*, 8, 7313–7322. <https://doi.org/10.1109/ACCESS.2020.2964043>.
- Yan, Y., dan Zhang, D. (2021). Multi-scale u-like network with attention mechanism for automatic pancreas segmentation. *PLoS One*, 16(5), e0252287.
- Ying, W., Li, J., Wu, Y., Zheng, K., Deng, Y., & Li, J. (2020). U-Net with Dense Encoder, Residual Decoder and Depth-wise Skip Connections. *Proceedings of the International Joint Conference on Neural Networks*, 0–5. <https://doi.org/10.1109/IJCNN48605.2020.9207371>.
- Zhang, H., Zhu, H., & Ling, X. (2020). Polar coordinate sampling-based segmentation of overlapping cervical cells using attention U-Net and random walk. *Neurocomputing*, 383, 212–223. <https://doi.org/10.1016/j.neucom.2019.12.036>.

- Zhao, M., Wang, H., Han, Y., Wang, X., Dai, H. N., Sun, X., Zhang, J., & Pedersen, M. (2021). SEENS: Nuclei segmentation in *Pap Smear* images with selective edge enhancement. *Future Generation Computer Systems*, 114, 185–194. <https://doi.org/10.1016/j.future.2020.07.045>
- Zhao, T., Guan, Y., Tu, D., Yuan, L., & Lu, G. (2023). Neighbored-attention u-net (NAU-net) for diabetic retinopathy image segmentation. *Frontiers in Medicine*, 10, 1–12. <https://doi.org/10.3389/fmed.2023.1309795>