

**SEGMENTASI KANKER PAYUDARA PADA *BREAST*
ULTRASOUND IMAGES MENGGUNAKAN MODIFIKASI
ARSITEKTUR DEEPLABV3+, SQUEEZE AND EXCITATION
*NETWORKS DAN ATTENTION GATE***

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana
di Jurusan Matematika pada Fakultas MIPA**

Oleh :

NUR DEVITA AZZAHRA

NIM. 08011282126026



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

**SEGMENTASI KANKER PAYUDARA PADA *BREAST ULTRASOUND*
IMAGES MENGGUNAKAN MODIFIKASI ARSITEKTUR DEEPLABV3+,
SQUEEZE AND EXCITATION NETWORKS DAN ATTENTION GATE**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar
Sarjana di Jurusan Matematika pada Fakultas MIPA**

Oleh

**NUR DEVITA AZZAHRA
NIM. 08011282126026**

Indralaya, 10 Juli 2025

Pembimbing Kedua



**Dr. Yuli Andriani, S.Si., M.Si.
NIP. 197207021999032001**

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**

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa: Nur Devita Azzahra

NIM : 08011282126026

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 di dalam 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, 10 Juli 2025
Penulis



Nur Devita Azzahra
NIM. 08011282126026

HALAMAN PERSEMPAHAN

Kupersembahkan skripsi ini untuk :

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku tersayang,

Saudara-saudariku,

Keluarga besarku,

Semua guru dan dosenku,

Teman-teman yang kubanggakan,

Almamaterku.

Motto

“Apabila akal tidak sempurna, maka kurangilah berbicara”

-Ali bin Abi Thalib

KATA PENGANTAR

Puji syukur ke hadirat Allah Subhanahu Wa Ta’ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Segmentasi Kanker Payudara pada *Breast Ultrasound Images* menggunakan Modifikasi Arsitektur *DeepLabV3+*, *Squeeze-and-Excitation Networks* dan *Attention Gate*” sebagai salah satu syarat memperoleh gelar sarjana sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih sebesar-besarnya kepada orang tua tercinta, ibuku **Sri Agustini** dan ayahku **Effran Armanto** yang tidak pernah lelah memberikan doa serta memberikan pengajaran terbaiknya. Penulis juga ingin menyampaikan ucapan terima kasih sebesar-besarnya dan setinggi-tingginya kepada :

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku dekan Fakultas MIPA Universitas Sriwijaya, beserta seluruh **staf Dekanat FMIPA. Ibu Dr. Dian Cahyawati Sukanda, S.Si., M.Si.** selaku Ketua Jurusan Matematika dan 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.
2. Ibu **Dr. Anita Desiani, S.Si., M.Kom.** selaku Dosen Pembimbing Utama dan Ibu **Dr. Yuli Andriani, S.Si., M.Si.** selaku Dosen Pembimbing Pendamping

yang telah menyediakan waktu, tenaga, dan pikiran dalam memberikan bimbingan, arahan, motivasi, ide, serta kritik dan saran yang sangat berarti selama proses perkuliahan dan pembuatan skripsi. Ibu **Dr. Ir. Herlina Hanum, M.Si.** selaku Dosen Pembimbing Akademik dan Dosen Pembahas Pertama dan Ibu **Dr. Endang Sri Kresnawati, S.Si., M.Si.** selaku Dosen Pembahas Kedua yang telah memberikan tanggapan, kritik dan saran yang bermanfaat untuk perbaikan dan penyelesaian skripsi ini.

3. Seluruh **Dosen Jurusan Matematika FMIPA Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu selama perkuliahan. **Seluruh Guru** yang telah memberikan ilmu yang bermanfaat hingga mengantarkan penulis pada pendidikan ini.
4. **Kakak-kakak dan adik-adik tingkat bidang minat komputasi, Laboratorium Komputasi FMIPA, teman-teman bidang minat komputasi angkatan 2021, keluarga besar matematika 2021** yang telah berbagi ilmu dan memberikan banyak bantuan selama perkuliahan dan proses pembuatan skripsi ini.
5. Kakak laki-laki dan adik perempuanku, **Muhammad Hafizh Raihan** dan **Nur Azalia Ramadhani**, keluarga besar, serta teman-teman terbaik yang selalu mendukung penulis.
6. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah SWT.

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

Indralaya, Juli 2025

Penulis

**BREAST CANCER SEGMENTATION IN BREAST ULTRASOUND
IMAGES USING MODIFIED DEEPLABV3+ ARCHITECTURE,
SQUEEZE AND EXCITATION NETWORKS AND ATTENTION GATE**

By :

Nur Devita Azzahra

08011282126026

ABSTRACT

Breast cancer is a type of cancer characterized by a lump due to the growth of abnormal cells in the breast. The process of separating between abnormal cells and healthy breast tissue can be performed through segmentation. Segmentation can be done using Convolutional Neural Networks (CNN). One of the CNN architecture that can be used for image segmentation is DeepLabV3+. The DeepLabV3+ architecture consists of an encoder and decoder. The encoder DeepLabV3+ consists of a backbone layer and Atrous Spatial Pyramid Pooling (ASPP) module. In the backbone layer, the DenseNet architecture is utilized due to its capability to minimize the vanishing gradient problem by reusing previously learned features. However, passing DenseNet output directly to the ASPP module can result in information redundancy due to repeated feature usage, which increases memory usage and computation time. This research modified the DeepLabV3+ architecture by Squeeze-and-Excitation Networks (SENet) and Attention Gate for breast cancer segmentation in Breast Ultrasound Images (BUSI). SENet is inserted between the DenseNet backbone and ASPP module to reduce information redundancy by filtering and enhancing feature representation. Attention Gate is inserted in the decoder part to filter and highlight spatially relevant information in the image. This research performs image segmentation with two labels, cancer and background. The proposed architecture achieved an accuracy of 99,6%, indicates the architecture strong overall performance in predicting all label correctly. The sensitivity of 97.4% and specificity of 99.74% show the architecture is able to identify cancerous areas and background very well. IoU of 94,42% indicates segmentation result overlap with the ground truth. F1-score of 97,13% reflects an excellent balance between sensitivity and specificity. The results indicate that incorporating SENet and Attention Gate into DeepLabV3+ architecture provides excellent performance in breast cancer segmentation by effectively distinguishing between cancer and background areas.

Keywords : Breast Cancer, Segmentation, DeepLabV3+, SENet, Attention Gate

SEGMENTASI KANKER PAYUDARA PADA *BREAST ULTRASOUND IMAGES* MENGGUNAKAN MODIFIKASI ARSITEKTUR *DEEPLABV3+, SQUEEZE AND EXCITATION NETWORKS* DAN *ATTENTION GATE*

Oleh :

Nur Devita Azzahra

08011282126026

ABSTRAK

Kanker payudara adalah jenis kanker yang ditandai dengan adanya benjolan akibat pertumbuhan sel-sel abnormal pada payudara. Proses pemisahan sel abnormal dan jaringan sehat pada payudara dapat dilakukan dengan segmentasi. Segmentasi dapat dilakukan dengan menggunakan *Convolutional Neural Networks* (CNN). Salah satu arsitektur CNN yang dapat digunakan dalam proses segmentasi citra adalah *DeepLabV3+*. Arsitektur *DeepLabV3+* terdiri dari *encoder* dan *decoder*. *Encoder DeepLabV3+* terdiri atas lapisan *backbone* dan *Atrous Spatial Pyramid Pooling* (ASPP). Pada lapisan *backbone* digunakan arsitektur *DenseNet*, karena kemampuannya dalam meminimalkan terjadinya *vanishing gradient* melalui pemanfaatan kembali fitur yang telah dipelajari. Namun, ketika hasil *DenseNet* diteruskan pada ASPP dapat menyebabkan terjadinya redudansi informasi akibat memanfaatkan kembali fitur yang berdampak pada peningkatan memori dan waktu komputasi. Penelitian ini menerapkan modifikasi arsitektur *DeepLabV3+* dengan menambahkan modul *Squeeze-and-Excitation Networks* (*SENet*) dan *Attention Gate* untuk segmentasi kanker payudara pada *Breast Ultrasound Images* (BUSI). *SENet* disisipkan diantara lapisan *backbone DenseNet* dan ASPP untuk mencegah terjadinya redudansi informasi dengan menyaring dan meningkatkan representasi fitur. *Attention Gate* disisipkan pada bagian *decoder* untuk menyaring dan menonjolkan informasi spasial yang relevan pada citra. Penelitian ini melakukan segmentasi citra dengan dua label, yaitu kanker dan *background*. Hasil segmentasi kanker payudara dengan menggunakan arsitektur yang diusulkan memperoleh akurasi 99,6% menunjukkan arsitektur sangat baik dalam memprediksi semua label dengan benar secara keseluruhan. Sensitivitas 97,4% dan spesifisitas 99,74% menunjukkan arsitektur mampu memprediksi area kanker dan *background* dengan sangat baik. IoU 94,42% menunjukkan arsitektur sangat baik dalam menghasilkan hasil segmentasi yang mirip dengan *ground truth*. F1-score 97,13% menunjukkan model memiliki keseimbangan sangat baik antara sensitivitas dan spesifisitas. Hasil penelitian ini menunjukkan bahwa penerapan *SENet* dan *Attention Gate* pada arsitektur *DeepLabV3+* memberikan kinerja sangat baik dalam segmentasi kanker payudara karena mampu membedakan antara area kanker dan area *background*.

Kata Kunci : Kanker Payudara, Segmentasi, *DeepLabV3+*, *SENet*, *Attention Gate*

DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH	iii
HALAMAN PERSEMBERAHAN	iv
KATA PENGANTAR.....	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Pembatasan Masalah	6
1.4 Tujuan.....	6
1.5 Manfaat.....	6
BAB II TINJAUAN PUSTAKA.....	8
2.1 Citra USG Kanker Payudara	8
2.2 <i>Preprocessing Data</i>	8
2.2.1 Perbaikan Kualitas Citra	9
2.2.2 Augmentasi data	10
2.2.3 Normalisasi Data.....	10
2.3 Segmentasi Citra.....	11
2.4 <i>DeepLabV3+</i>	11
2.4.1 <i>Encoder DeepLabV3+</i>	13
2.4.2 <i>Decoder DeepLabV3+</i>	22
2.5 <i>Loss Function : Binary Cross-Entropy</i>	25
2.6 <i>Optimization Function : Adaptive Moment Estimation (Adam)</i>	26
2.7 <i>Confusion Matrix</i>	27

BAB III METODOLOGI PENELITIAN	30
3.1 Tempat.....	30
3.2 Waktu	30
3.3 Alat	30
3.4 Tahapan Penelitian	31
BAB IV HASIL DAN PEMBAHASAN	39
4.1 Deskripsi Data	39
4.2 <i>Preprocessing</i> Data	40
4.3 Modifikasi Arsitektur <i>DeepLabV3+, SENet</i> dan <i>Attention Gate</i>	46
4.4 Perhitungan Manual	47
4.4.1 <i>Encoder DeepLabV3+</i>	47
4.4.2 <i>Decoder DeepLabV3+</i>	64
4.4.3 <i>Loss Function : Binary Cross-Entropy</i>	70
4.4.4 <i>Optimization Function : Adaptive Moment Estimation (Adam)</i>	71
4.5 Hasil Implementasi Modifikasi Arsitektur <i>DeepLabV3+, SENet</i> dan <i>Attention Gate</i>	75
4.5.1 <i>Training</i>	75
4.5.2 <i>Testing</i>	78
4.5.3 Evaluasi Kinerja Model	79
4.6 Pembahasan, Analisis dan Interpretasi Hasil	81
BAB V KESIMPULAN DAN SARAN	85
5.1 Kesimpulan.....	85
5.2 Saran	85
DAFTAR PUSTAKA.....	86

DAFTAR TABEL

Tabel 2.1 Confusion matrix.....	28
Tabel 2.2 Kategori evaluasi kinerja model	29
Tabel 4.1 Sampel citra dan ground truth dataset BUSI.....	39
Tabel 4.2 Sampel citra sebelum dan sesudah augmentasi.....	44
Tabel 4.3 Perbandingan citra asli, ground truth dan hasil segmentasi	78
Tabel 4.4 Confusion matrix dari proses testing	79
Tabel 4.5 Perbandingan hasil evaluasi kinerja, waktu dan memori GPU pada arsitektur DeepLabV3+ dan Modifikasi arsitektur DeepLabV3+.....	81
Tabel 4.6 Perbandingan hasil evaluasi kinerja dengan penelitian lain	83

DAFTAR GAMBAR

Gambar 2.1 Hasil USG kanker payudara	8
Gambar 2.2 Arsitektur <i>DeepLabV3+</i>	12
Gambar 2.3 Arsitektur <i>DenseNet</i>	13
Gambar 2.4 Ilustrasi <i>padding same</i>	14
Gambar 2.5 Fungsi aktivasi ReLU.....	17
Gambar 2.6 Ilustrasi <i>average pooling</i>	17
Gambar 2.7 <i>Squeeze-and-excitation Networks</i>	18
Gambar 2.8 Ilustrasi <i>atrous convolution</i>	21
Gambar 2.9 Ilustrasi <i>spatial pyramid pooling</i>	22
Gambar 2.10 Ilustrasi <i>upsampling</i>	23
Gambar 2.11 <i>Attention Gate</i>	24
Gambar 3.1 Tahapan implementasi arsitektur	35
Gambar 4.1 Segmentasi biner kanker payudara.....	40
Gambar 4.2 Modifikasi arsitektur <i>DeepLabV3+, SENet</i> dan <i>Attention Gate</i>	46
Gambar 4.3 Grafik akurasi proses <i>training</i>	76
Gambar 4.4 Grafik loss proses <i>training</i>	77

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kanker payudara merupakan jenis kanker yang paling umum didiagnosis dan menjadi penyebab utama kematian pada wanita akibat kanker di seluruh dunia (Michael *et al.*, 2021). Kanker payudara ditandai dengan adanya benjolan yang muncul akibat pertumbuhan sel-sel abnormal pada jaringan ikat payudara (Lukong, 2017). Diagnosa awal kanker payudara dapat dilakukan dengan menggunakan alat ultrasonografi yang menghasilkan citra *Breast Ultrasound Images* (BUSI) (Aggarwal *et al.*, 2024). Pemisahan antara sel-sel abnormal dan jaringan sehat pada citra BUSI dapat dianalisis dengan melakukan segmentasi. Segmentasi adalah teknik pemrosesan citra yang memisahkan citra berdasarkan objek dan latar belakang (Desiani, *et al.*, 2022).

Segmentasi secara manual membutuhkan peran para ahli berpengalaman yang jumlahnya terbatas dan berpotensi terjadinya kesalahan diagnosis akibat kondisi individu dan pengalaman, sehingga diperlukan segmentasi secara otomatis (Aggarwal *et al.*, 2024). Pemanfaatan *deep learning* dengan metode *Convolutional Neural Networks* (CNN) dapat diterapkan pada segmentasi secara otomatis (Li *et al.*, 2020). CNN memanfaatkan operasi konvolusi untuk mengekstraksi fitur dengan menggabungkan informasi spasial dan saluran dalam area lokal (Hu *et al.*, 2018). Salah satu arsitektur CNN yang dapat diterapkan dalam segmentasi citra adalah

DeepLabV3+. Arsitektur *DeepLabV3+* terdiri dari *encoder* dan *decoder* (Nastase *et al.*, 2024).

Encoder DeepLabV3+ berfungsi untuk mengekstraksi fitur penting pada citra *input* dengan mengubah citra menjadi representasi fitur yang mengandung informasi konteks dan spasial (Chen *et al.*, 2018). *Decoder DeepLabV3+* berfungsi untuk memulihkan batas objek dengan mengembalikan resolusi asli citra melalui proses *upsampling* (Chen *et al.*, 2018). Chung *et al.*, (2024) menerapkan arsitektur *DeepLabV3+* pada segmentasi kanker payudara dengan nilai *f1-score* sebesar 86,4%. Deepak & Bhat (2024) menerapkan arsitektur *DeepLabV3+* pada segmentasi kanker payudara dengan nilai akurasi sebesar 82,3%. Nguyen (2024) menerapkan arsitektur *DeepLabV3+* pada segmentasi kanker payudara dengan nilai akurasi sebesar 95%. Ketiga penelitian tersebut memperoleh nilai IoU yang masih di bawah 80%.

Pada *encoder DeepLabV3+* terdapat lapisan *backbone* dan modul *Atrous Spatial Pyramid Pooling* (ASPP) (Aggarwal *et al.*, 2024). Lapisan *backbone* *DeepLabV3+* menggunakan arsitektur klasifikasi untuk mengekstraksi fitur penting dari citra *input* sebelum dilanjutkan pada modul ASPP. Salah satu arsitektur klasifikasi yang dapat digunakan sebagai *backbone DeepLabV3+*, yaitu *DenseNet*. *DenseNet* merupakan arsitektur klasifikasi yang terdiri dari beberapa *dense-block* yang saling terhubung melalui *transition layer* (Huang *et al.*, 2022). Setiap lapisan pada *dense-block* menerima *input* berupa *output* yang dihasilkan dari semua lapisan sebelumnya. Hal ini membuat *DenseNet* mampu memanfaatkan kembali fitur yang telah dipelajari (Huang *et al.*, 2022). Zhang *et al.*, (2023) menerapkan *backbone*

DenseNet pada arsitektur *UNet* untuk segmentasi kanker payudara dengan *f1-score* sebesar 89,9%. Ji *et al.*, (2024) menerapkan *backbone DenseNet* pada arsitektur *BGRD-TransUNet* untuk segmentasi kanker payudara dengan akurasi 97,14%, sensitivitas 87,62%, *f1-score* 85,08%. Kedua penelitian tersebut memperoleh nilai IoU yang masih di bawah 80%. Namun, ketika *output* dari *DenseNet* langsung diteruskan ke modul ASPP dapat terjadi peningkatan penggunaan memori dan waktu komputasi. Hal ini disebabkan oleh fitur yang dihasilkan *DenseNet* cenderung padat karena adanya pemanfaatan fitur secara berulang yang dapat menimbulkan redundansi informasi (Yang *et al.*, 2020; Zhang *et al.*, 2021). Salah satu modul yang dapat digunakan untuk menyaring dan meningkatkan representasi fitur adalah *Squeeze-and-Excitation Networks (SENet)* (Hu *et al.*, 2020).

SENet merupakan modul yang terdiri dari operasi *squeeze* dan *excitation* (Hu *et al.*, 2020; Khan *et al.*, 2020; Li, 2021). Operasi *squeeze* berfungsi untuk mengubah nilai *feature map* dua dimensi menjadi bilangan riil per *channel* menggunakan *Global Average Pooling(GAP)* (Li, 2021). Hasil operasi *squeeze* digunakan dalam operasi *excitation* untuk menentukan bobot masing-masing *channel*. Proses ini bertujuan untuk memperkuat fitur yang penting dengan memberikan bobot yang lebih tinggi dan melemahkan fitur yang kurang relevan dengan memberikan bobot yang lebih rendah dalam representasi citra (Li, 2021). Chen *et al.* (2023) menerapkan *SENet* pada arsitektur *Attention UNet* dalam segmentasi kanker payudara dengan spesifikasi 97,42%, namun sensitivitas masih di bawah 85%. You *et al.* (2024) menerapkan *SENet* pada arsitektur *EfficientUNet* dalam

segmentasi kanker payudara dengan spesifisitas 98,56% dan sensitivitas 87,59%, namun IoU masih di bawah 80%.

Decoder DeepLabV3+ terdiri dari proses *upsampling*, penggabungan fitur *high-level* dan *low-level* serta peningkatan resolusi spasial melalui operasi konvolusi. Fitur *high level* yang dihasilkan pada tahap *encoder* memiliki resolusi spasial yang rendah akibat proses *downsampling* (Aggarwal *et al.*, 2024). Untuk mengatasi hal ini, fitur *high-level* diperbesar kembali melalui proses *upsampling* sebelum digabungkan dengan fitur *low-level*. Proses penggabungan ini bertujuan untuk mengkombinasikan informasi global dari fitur *high-level* dengan detail spasial lokal dari fitur *low-level* (Aggarwal *et al.*, 2024). Fitur *low-level* dari lapisan *backbone* dikirimkan langsung ke *decoder* melalui *skip connection*. *Skip connection* merupakan jalur yang digunakan untuk mentransfer kembali fitur-fitur yang mungkin terlewatkan selama proses konvolusi (Kamath *et al.*, 2023). Penggunaan *skip connection* tanpa filter memiliki risiko terpanggilnya fitur yang kurang penting, sehingga mengurangi informasi spasial citra. Salah satu modul yang berperan dalam menyaring fitur dan mempertahankan informasi spasial, yaitu *Attention Gate* (Khanh *et al.*, 2020).

Attention Gate merupakan modul yang berfungsi untuk memfokuskan perhatian pada fitur spasial yang penting seperti kanker sekaligus menekan informasi yang tidak penting pada citra (Oktay *et al.*, 2018). Proses seleksi fitur pada *Attention Gate* melibatkan dua *input* utama, yaitu fitur dari *skip connection* dan fitur dari *decoder*. Kedua *input* ini kemudian diproses menggunakan operasi konvolusi 1×1 dan dua fungsi aktivasi, yaitu ReLU dan *sigmoid* (Oktay *et al.*, 2018). ReLU berperan dalam

memperkuat fitur-fitur relevan dengan menekan nilai negatif. *Sigmoid* berperan dalam mengidentifikasi fitur relevan dengan nilai mendekati 1 dan mengabaikan fitur yang tidak relevan dengan nilai mendekati 0. Zhuang *et al.* (2019) menerapkan *Attention Gate* pada arsitektur *Residual Dilated UNet* dalam segmentasi kanker payudara dengan akurasi 96,68% dan spesifitas 99,35%, namun sensitivitas dan f1-score masih di bawah 85%. Laghami *et al.* (2023) menerapkan *Attention Gate* pada arsitektur *UNet* dalam segmentasi kanker payudara dengan akurasi yang tinggi, yaitu 98,54%, namun IoU masih di bawah 50%.

Penelitian ini menerapkan modifikasi arsitektur *DeepLabV3+* dengan menggunakan *SENet* diantara lapisan *backbone DenseNet* dan modul ASPP pada bagian *encoder* dan menerapkan *Attention Gate* pada bagian *decoder*. Penggunaan *SENet* bertujuan untuk meningkatkan representasi fitur melalui *channel-wise attention*, sehingga model dapat lebih fokus pada fitur-fitur penting pada citra. *Attention Gate* diterapkan pada bagian *decoder* dengan tujuan menyaring dan menonjolkan informasi spasial yang relevan, sehingga dapat meningkatkan ketepatan dalam memetakan area kanker dan mengurangi informasi yang tidak relevan. Penelitian ini melakukan proses segmentasi biner kanker payudara dengan memisahkan objek berupa kanker dan latar belakang (*background*). Metode evaluasi yang digunakan untuk mengukur keberhasilan kinerja kombinasi arsitektur ini terdiri dari akurasi, sensitivitas, spesifitas, IoU dan f1-score.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini adalah bagaimana penerapan modifikasi arsitektur *DeepLabV3+* dengan menambahkan *SENet* di antara *backbone DenseNet*

dan ASPP serta menambahkan *Attention Gate* pada bagian *decoder* dalam segmentasi kanker payudara menggunakan ukuran evaluasi kinerja arsitektur berdasarkan nilai akurasi, sensitivitas, spesifisitas, IoU dan f1-score.

1.3 Pembatasan Masalah

Pembatasan masalah pada penelitian ini adalah :

1. Penelitian ini hanya melakukan segmentasi dengan 2 label, yaitu kanker dan *background*.
2. Ukuran evaluasi kinerja pada segmentasi kanker payudara yang dilakukan menggunakan nilai akurasi, sensitivitas, spesifisitas, IoU dan f1-score.

1.4 Tujuan

Tujuan penelitian ini adalah menerapkan modifikasi arsitektur *DeepLabV3+* dengan menambahkan modul *SENet* untuk memperbaiki hasil *backbone DenseNet*, serta menambahkan *Attention Gate* pada *decoder* untuk memperoleh hasil kinerja segmentasi kanker payudara yang akurat berdasarkan nilai akurasi, sensitivitas, spesifisitas, IoU dan f1-score.

1.5 Manfaat

Manfaat dari hasil penelitian ini adalah :

1. Hasil segmentasi yang diperoleh dapat digunakan pada proses klasifikasi kanker payudara.

2. Penelitian ini menghasilkan model baru yang dapat digunakan sebagai referensi pada penelitian lainnya, khususnya dalam proses segmentasi kanker payudara.

DAFTAR PUSTAKA

- Aggarwal, S., Garg, M., Kumar, A., & Kapila, R. (2024). Breast lesions segmentation from ultrasound images using DeepLabV3 + model with channel and spatial attention mechanism. *Discover Sustainability*, 5(1), 217. <https://doi.org/10.1007/s43621-024-00424-x>
- Alsalem, M. A., Zaidan, A. A., Zaidan, B. B., Hashim, M., Albahri, O. S., Albahri, A. S., Hadi, A., & Mohammed, K. I. (2018). Systematic review of an automated multiclass detection and classification system for acute leukaemia in terms of evaluation and benchmarking, open challenges, issues and methodological aspects. *Journal of Medical Systems*, 42(11), 1–36. <https://doi.org/10.1007/s10916-018-1064-9>
- Chen, G., Liu, Y., Qian, J., Zhang, J., Yin, X., Cui, L., & Dai, Y. (2023). DSEU-Net: A novel deep supervision SEU-net for medical ultrasound image segmentation. *Expert Systems with Applications*, 223, 119939. <https://doi.org/https://doi.org/10.1016/j.eswa.2023.119939>
- 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)*, 11211, 833–851. https://doi.org/10.1007/978-3-030-01234-2_49
- Cheyi, J., & Çetin-Kaya, Y. (2024). Advanced CNN-based classification and segmentation for enhanced breast cancer ultrasound imaging. *GU J Sci, Part A*, 11(4), 647–667. <https://doi.org/10.54287/gujsa.1529857>
- Chung, D. T., Dang, M.-A., Vu, M.-A., Nguyen, M. T., Nguyen, T.-H., & Dinh, V. Q. (2024). Beyond traditional approaches: multi-task network for breast ultrasound diagnosis. <https://doi.org/https://doi.org/10.48550/arXiv.2401.07326>
- Deepak, G. D., & Bhat, S. K. (2024). A comparative study of breast tumour detection using a semantic segmentation network coupled with different pretrained CNNs. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 12(1), 2373996. <https://doi.org/10.1080/21681163.2024.2373996>
- Desiani, A., Adrezo, M., Chika Marselina, N., Arhami, M., Salsabila, A., & Gibran Al-Filambany, M. (2022). A combination of image enhancement and U-Net architecture for segmentation in identifying brain tumors on CT-SCAN images. *2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 423–428. <https://doi.org/10.1109/ICIMCIS56303.2022.10017519>
- Desiani, A., Erwin, Suprihatin, B., Efriliyanti, F., Arhami, M., & Setyaningsih, E. (2022). VG-DropDNet a robust architecture for blood vessels segmentation on retinal image. *IEEE Access*, 10(6), 92067–92083. <https://doi.org/10.1109/ACCESS.2022.3202890>

- Desiani, A., Erwin, Suprihatin, B., Yahdin, S., Putri, A. I., & Husein, F. R. (2021). Bi-path architecture of CNN segmentation and classification method for cervical cancer disorders based on pap-smear images. *IAENG International Journal of Computer Science*, 48(3), 1–9. https://www.iaeng.org/IJCS/issues_v48/issue_3/IJCS_48_3_37.pdf
- Dombrowski, M., Reynaud, H., Baugh, M., & Kainz, B. (2023). Foreground-background separation through concept distillation from generative image foundation models. *Proceedings of the IEEE International Conference on Computer Vision*, 988–998. <https://doi.org/10.1109/ICCV51070.2023.00097>
- Dumitrescu, D., & Boiangiu, C. A. (2019). A study of image upsampling and downsampling filters. *Computers*, 8(2), 30. <https://doi.org/10.3390/computers8020030>
- Guo, Q., Wang, C., Xiao, D., & Huang, Q. (2023). A novel multi-label pest image classifier using the modified Swin Transformer and soft binary cross entropy loss. *Engineering Applications of Artificial Intelligence*, 126, 107060. <https://doi.org/10.1016/j.engappai.2023.107060>
- Han, J., Kamber, M., & Pei, J. (2011). Data mining: concepts and techniques. In *Morgan Kaufmann* (3rd ed.). Morgan Kaufmann. <https://doi.org/10.1016/C2009-0-61819-5>
- Hoang, N. D. (2020). Image processing-based spall object detection using gabor filter, texture analysis, and adaptive moment estimation (ADAM) optimized logistic regression models. *Advances in Civil Engineering*, 2020(1), 8829715. <https://doi.org/10.1155/2020/8829715>
- Hu, J., Shen, L., Albanie, S., Sun, G., & Wu, E. (2020). Squeeze-and-excitation networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(8), 2011–2023. <https://doi.org/10.1109/TPAMI.2019.2913372>
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. *IEEE Conference on Computer Vision and Pattern Recognition*, 7132–7141. <https://doi.org/https://doi.org/10.48550/arXiv.1709.01507>
- Huang, G., Liu, Z., Maaten, L. van der, & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708. <https://doi.org/10.1109/CVPR.2017.243>
- Huang, G., Liu, Z., Pleiss, G., Van Der Maaten, L., & Weinberger, K. Q. (2022). Convolutional networks with dense connectivity. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(12), 8704–8716. <https://doi.org/10.1109/TPAMI.2019.2918284>
- Huang, L., Yang, D., Lang, B., & Deng, J. (2018). Decorrelated batch normalization. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 791–800. <https://doi.org/10.1109/CVPR.2018.00089>
- Ji, Z., Sun, H., Yuan, N., Zhang, H., Sheng, J., Zhang, X., & Ganchev, I. (2024).

- BGRD-TransUNet: a novel TransUNet-Based model for ultrasound breast lesion segmentation. *IEEE Access*, 12, 31182–31196. <https://doi.org/10.1109/ACCESS.2024.3368170>
- Job, M. S., Bhateja, P. H., Gupta, M., Bingi, K., & Prusty, B. R. (2022). Fractional rectified linear unit activation function and its variants. *Mathematical Problems in Engineering*, 2022(1), 1860779. <https://doi.org/10.1155/2022/1860779>
- Kamath, A., Willmann, J., Andratschke, N., & Reyes, M. (2023). Do we really need that skip-connection? understanding its interplay with task complexity. *International Conference on Medical Image Computing and Computer Assisted Intervention*, 302–311. https://doi.org/10.1007/978-3-031-43901-8_29
- Khalifa, N. E., Loey, M., & Mirjalili, S. (2022). A comprehensive survey of recent trends in deep learning for digital images augmentation. *Artificial Intelligence Review*, 55(3), 2351–2377. <https://doi.org/10.1007/s10462-021-10066-4>
- 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>
- Khanh, T. L. B., Dao, D. P., Ho, N. H., Yang, H. J., Baek, E. T., Lee, G., Kim, S. H., & Yoo, S. B. (2020). Enhancing U-net with spatial-channel attention gate for abnormal tissue segmentation in medical imaging. *Applied Sciences (Switzerland)*, 10(17), 1–19. <https://doi.org/10.3390/APP10175729>
- Kılıçarslan, S., Adem, K., & Çelik, M. (2021). An overview of the activation functions used in deep learning algorithms. *Journal of New Results in Science*, 10(3), 75–88. <https://doi.org/10.54187/jnrs.1011739>
- Kumar, T., Mileo, A., Brennan, R., & Bendechache, M. (2024). Image data augmentation approaches: a comprehensive survey and future directions. *IEEE Access*, 12. <https://doi.org/10.1109/ACCESS.2024.3470122>
- Laghmati, S., Hicham, K., Cherradi, B., Hamida, S., & Tmiri, A. (2023). Segmentation of breast cancer on ultrasound images using attention U-Net model. *International Journal of Advanced Computer Science and Applications*, 14(8), 770–778. <https://doi.org/10.14569/IJACSA.2023.0140885>
- Lai, Z., Chen, R., Jia, J., & Qian, Y. (2023). Real-time micro-expression recognition based on ResNet and atrous convolutions. *Journal of Ambient Intelligence and Humanized Computing*, 14(11), 15215–15226. <https://doi.org/10.1007/s12652-020-01779-5>
- Li, C., Tan, Y., Chen, W., Luo, X., Gao, Y., Jia, X., & Wang, Z. (2020). Attention UNet++ : A Nested Attention-Aware U-Net for liver CT image segmentation. *IEEE International Conference on Image Processing (ICIP)*, 345–349. <https://doi.org/10.1109/icip40778.2020.9190>
- Li, G. (2021). A novel computer-aided cloud type classification method based on convolutional neural network with squeeze-and- excitation. *IOP Conference*

- Series: Earth and Environmental Science, 1802(3), 1–8.*
<https://doi.org/10.1088/1742-6596/1802/3/032051>
- Li, Q., Xu, Y., Chen, Z., Liu, D., Feng, S.-T., Law, M., Ye, Y., & Huang, B. (2018). Tumor segmentation in contrast-enhanced magnetic resonance imaging for nasopharyngeal carcinoma: deep learning with convolutional neural network. *BioMed Research International*, 18(20), 1–8. <https://doi.org/https://doi.org/10.1155/2018/9128527>
- Li, X., Shen, X., Zhou, Y., Wang, X., & Li, T. Q. (2020). Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PLoS ONE*, 15(5), 1–13. <https://doi.org/10.1371/journal.pone.0232127>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Lin, M., Chen, Q., & Yan, S. (2014). Network In Network. *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings*, 1–10. <https://arxiv.org/pdf/1312.4400.pdf>
- Liu, Y., Gross, L., Li, Z., Li, X., Fan, X., & Qi, W. (2019). Automatic building extraction on high-resolution remote sensing imagery using deep convolutional encoder-decoder with spatial pyramid pooling. *IEEE Access*, 7, 128774–128786. <https://doi.org/10.1109/ACCESS.2019.2940527>
- Lukong, K. E. (2017). Understanding breast cancer – The long and winding road. *BBA Clinical*, 7, 64–77. <https://doi.org/10.1016/j.bbaci.2017.01.001>
- Lv, Y., Ma, H., Li, J., & Liu, S. (2020). Attention guided U-Net with atrous convolution for accurate retinal vessels segmentation. *IEEE Access*, 8, 32826–32839. <https://doi.org/10.1109/ACCESS.2020.2974027>
- Mapayi, T., Viriri, S., & Tapamo, J. R. (2015). Comparative study of retinal vessel segmentation based on global thresholding techniques. *Computational and Mathematical Methods in Medicine*, 2015(1), 895267. <https://doi.org/10.1155/2015/895267>
- Mehta, M., & Shao, C. (2022). Federated learning-based semantic segmentation for pixel-wise defect detection in additive manufacturing. *Journal of Manufacturing Systems*, 64, 197–210. <https://doi.org/10.1016/j.jmsy.2022.06.010>
- Michael, E., Ma, H., Li, H., Kulwa, F., & Li, J. (2021). Breast cancer segmentation methods: current status and future potentials. *BioMed Research International*, 2021(1), 9962109. <https://doi.org/10.1155/2021/9962109>
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803, 728–741. <https://doi.org/10.1117/12.2217959>

- Mungoli, N. (2023). Adaptive ensemble learning: boosting model performance through intelligent feature fusion in deep neural networks. <https://doi.org/https://doi.org/10.48550/arXiv.2304.02653>
- Nastase, I. N. A., Moldovanu, S., & Moraru, L. (2024). Deep learning-based segmentation of breast masses using convolutional neural networks. *Journal of Physics: Conference Series*, 2701(1), 012005. <https://doi.org/10.1088/1742-6596/2701/1/012005>
- Nguyen, K. T. (2024). Breast ultrasound images segmentation using deep neural networks. <https://hdl.handle.net/1828/16535>
- 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. <http://arxiv.org/abs/1804.03999>
- Rabut, C., Yoo, S., Hurt, R. C., Jin, Z., Li, H., Guo, H., Ling, B., & Shapiro, M. G. (2020). Ultrasound technologies for imaging and modulating neural activity. *Neuron*, 108(1), 93–110. <https://doi.org/10.1016/j.neuron.2020.09.003>
- Ruby, A. U., Theerthagiri, P., Jacob, I. J., & Vamsidhar, Y. (2020). Binary cross entropy with deep learning technique for Image classification. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(4), 5393–5397. <https://doi.org/10.30534/ijatcse/2020/175942020>
- Sandru, A., Georgescu, M. I., & Ionescu, R. T. (2023). Feature-level augmentation to improve robustness of deep neural networks to affine transformations. *Lecture Notes in Computer Science*, 13801, 332–341. https://doi.org/10.1007/978-3-031-25056-9_22
- Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. (2018). How does batch normalization help optimization? *Advances in Neural Information Processing Systems*, 2483–2493. <https://doi.org/https://doi.org/10.48550/arXiv.1805.11604>
- Sathyaranarayanan, S., & Tantri, B. R. (2024). Confusion matrix-based performance evaluation metrics. *African Journal Biomedical Research*, 27(4), 4023–4032. <https://doi.org/10.53555/AJBR.v27i4S.4345>
- Shantal, M., Othman, Z., & Bakar, A. A. (2023). A novel approach for data feature weighting using correlation coefficients and min–max normalization. *Symmetry*, 15(12), 2185. <https://doi.org/10.3390/sym15122185>
- Silva, C., Mafalda, S., Bezerra, E., Oliveira de Castro, G., Santos Júnior, P., & Alvarez, A. (2024). Comparision through architectures of semantic segmentation in breast ultrasound images across differents input data dimensions. *BIOSTEC*, 2, 354–361. <https://doi.org/10.5220/0012322500003657>
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep learning models for retinal blood vessels segmentation: a review. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>

- Sulaiman, A., Anand, V., Gupta, S., Rajab, A., Alshahrani, H., Al Reshan, M. S., Shaikh, A., & Hamdi, M. (2024). Attention based UNet model for breast cancer segmentation using BUSI dataset. *Scientific Reports*, 14(1), 22422. <https://doi.org/10.1038/s41598-024-72712-5>
- Tan, Y. S., Lim, K. M., Tee, C., Lee, C. P., & Low, C. Y. (2021). Convolutional neural network with spatial pyramid pooling for hand gesture recognition. *Neural Computing and Applications*, 33(10), 5339–5351. <https://doi.org/10.1007/s00521-020-05337-0>
- Yang, C., An, Z., Zhu, H., Hu, X., Zhang, K., Xu, K., Li, C., & Xu, Y. (2020). Gated convolutional networks with hybrid connectivity for image classification. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(7), 12581–12588. <https://doi.org/https://doi.org/10.1609/aaai.v34i07.6948>
- You, G., Yang, X., Lee, X., & Zhu, K. (2024). EfficientUNet: an efficient solution for breast tumour segmentation in ultrasound images. *IET Image Processing*, 18(2), 523–534. <https://doi.org/10.1049/ipr2.12966>
- Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alrubaan, A., Dutta, A. K., & Almotairi, S. (2022). A comparison of pooling methods for convolutional neural networks. *Applied Sciences*, 12(17), 1–21. <https://doi.org/10.3390/app12178643>
- Zhang, C., Benz, P., Argaw, D. M., Lee, S., Kim, J., Rameau, F., Bazin, J. C., & Kweon, I. S. (2021). ResNet or DenseNet? introducing dense shortcuts to ResNet. *Proceedings - 2021 IEEE Winter Conference on Applications of Computer Vision, WACV 2021*, 3549–3558. <https://doi.org/10.1109/WACV48630.2021.00359>
- Zhang, J., Jiang, Z., Dong, J., Hou, Y., & Liu, B. (2020). Attention gate ResU-Net for automatic MRI brain tumor segmentation. *IEEE Access*, 8, 58533–58545. <https://doi.org/10.1109/ACCESS.2020.2983075>
- Zhang, S., Liao, M., Wang, J., Zhu, Y., Zhang, Y., Zhang, J., Zheng, R., Lv, L., Zhu, D., Chen, H., & Wang, W. (2023). Fully automatic tumor segmentation of breast ultrasound images with deep learning. *Journal of Applied Clinical Medical Physics*, 24(1), 1–13. <https://doi.org/10.1002/acm2.13863>
- Zhang, W., Niu, L., Zhang, D., Wang, G., Farrukh, F. U. D., & Zhang, C. (2023). HW-ADAM: FPGA-based accelerator for adaptive moment estimation. *Electronics*, 12(2), 263. <https://doi.org/10.3390/electronics12020263>
- Zhuang, Z., Li, N., Raj, A. N. J., Mahesh, V. G. V., & Qiu, S. (2019). An RDAU-NET model for lesion segmentation in breast ultrasound images. *PLoS ONE*, 14(8), 1–23. <https://doi.org/10.1371/journal.pone.0221535>