

ARSITEKTUR ENSEMBLE U-NET UNTUK SEGMENTASI KANKER PAYUDARA OTOMATIS PADA GAMBAR MAMMOGRAM

Cahya Bagus Sanjaya¹⁾, Moch. Lutfi²⁾, Lukman Hakim³⁾ dan Imron Rosadi⁴⁾

^{1, 2,3)}Teknik Informatika, Universitas Yudharta Pasuruan

e-mail: lukman@yudharta.ac.id

ABSTRAK

Kanker payudara masih menjadi salah satu penyebab utama kematian akibat kanker pada wanita di seluruh dunia. Deteksi dini melalui skrining rutin menggunakan mammogram terbukti efektif dalam mengurangi angka kematian. Namun, interpretasi mammogram secara manual memerlukan waktu, bersifat subjektif, dan sering kali membutuhkan radiolog yang berpengalaman. Untuk mengatasi tantangan ini, penelitian ini mengusulkan arsitektur Ensemble U-Net untuk melakukan segmentasi kanker payudara secara otomatis pada citra mammogram. Proses segmentasi melibatkan beberapa langkah, termasuk praproses (penghapusan latar belakang, penghapusan otot pektoral, peningkatan kontras, dan perubahan ukuran), dilanjutkan dengan segmentasi menggunakan ensemble model: Inception V3-U-Net, ResNet50-U-Net, VGG19-U-Net, dan U-Net kustom. Segmentasi akhir dicapai dengan menggunakan voting soft dan filter Gaussian 2D untuk mereduksi noise, diikuti dengan thresholding untuk segmentasi biner. Pendekatan ensemble menunjukkan peningkatan akurasi segmentasi dengan menggabungkan kekuatan dari beberapa model U-Net. Kinerja model dievaluasi menggunakan metrik seperti akurasi, sensitivitas, spesifisitas, koefisien Dice, dan Intersection over Union (IoU). Hasil eksperimen menunjukkan bahwa Ensemble U-Net memiliki kinerja yang lebih baik dibandingkan dengan model individu, terutama pada citra mammogram yang kompleks.

Kata Kunci: Ensemble, Unet, Segmentasi, Kanker, Payudara.

ABSTRACT

Breast cancer remains one of the leading causes of cancer-related deaths among women worldwide. Early detection through routine mammogram screening has been proven effective in reducing mortality rates. However, manual interpretation of mammograms is time-consuming, subjective, and often requires experienced radiologists. To address these challenges, this study proposes an Ensemble U-Net architecture to automatically segment breast cancer in mammogram images. The segmentation process involves several steps, including preprocessing (background removal, pectoral muscle removal, contrast enhancement, and resizing), followed by segmentation using an ensemble of models: Inception V3-U-Net, ResNet50-U-Net, VGG19-U-Net, and a custom U-Net. The final segmentation is achieved by applying soft voting with a 2D Gaussian filter to smooth the output, followed by thresholding for binary segmentation. The ensemble approach demonstrates improved segmentation accuracy by combining the strengths of multiple U-Net models. The model's performance is evaluated using metrics such as accuracy, sensitivity, specificity, Dice coefficient, and Intersection over Union (IoU). Experimental results indicate that the Ensemble U-Net achieves superior performance compared to individual models, particularly in complex mammogram images.

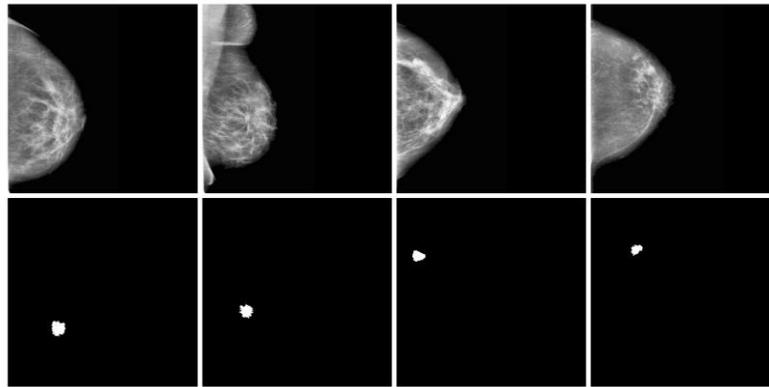
Keywords: Ensemble, Unet, Segmentation, Cancer, Breast.

I. PENDAHULUAN

KANKER payudara merupakan salah satu jenis kanker yang paling umum terjadi pada wanita dan menjadi penyebab utama kematian terkait kanker di seluruh dunia. Menurut data dari World Health Organization (WHO), diperkirakan sekitar 2,3 juta kasus baru kanker payudara didiagnosis pada tahun 2020, yang menjadikannya tantangan kesehatan global yang signifikan [1]. Meski upaya pencegahan dan pengobatan terus berkembang, angka kematian yang tinggi menunjukkan bahwa deteksi dini sangat krusial dalam meningkatkan peluang kesembuhan dan menurunkan angka kematian. Mammogram adalah metode skrining yang telah terbukti efektif dalam mendeteksi kanker payudara pada tahap awal, memungkinkan intervensi dini

yang meningkatkan peluang pemulihan. Namun, proses skrining dan diagnosis berbasis mammogram memiliki keterbatasan yang signifikan[2].

Salah satu tantangan utama dalam interpretasi mammogram adalah ketergantungan pada keterampilan dan pengalaman radiolog. Proses interpretasi citra ini dapat bersifat subjektif dan memakan waktu, sehingga menyulitkan penerapan skrining massal yang efisien. Bahkan radiolog yang berpengalaman terkadang menghadapi kesulitan dalam membedakan antara lesi ganas dan jinak, yang dapat mengarah pada tingkat kesalahan diagnostik yang signifikan. Sebuah studi menegaskan bahwa kesalahan dalam interpretasi mammogram oleh ahli radiologi bukanlah hal yang jarang terjadi,



Gambar 1 Contoh dataset dan label dari CBIS-DDM

dan hal ini menyoroti pentingnya pengembangan metode yang lebih akurat dan efisien untuk membantu proses diagnosis. Kebutuhan ini memicu penelitian dalam pengembangan sistem berbasis kecerdasan buatan (AI) yang mampu melakukan segmentasi citra medis secara otomatis[3].

Segmentasi citra medis merupakan langkah kunci dalam proses diagnosis berbasis citra, termasuk dalam mammogram. Segmentasi yang akurat membantu memetakan area kanker secara lebih jelas, memungkinkan identifikasi lokasi, ukuran, dan bentuk tumor secara tepat. Hal ini sangat penting dalam menentukan pendekatan pengobatan yang tepat. Arsitektur jaringan saraf dalam, khususnya U-Net, telah diakui sebagai salah satu metode paling efektif untuk segmentasi citra medis. U-Net memungkinkan pemisahan

objek yang diinginkan dari latar belakang dengan menggunakan informasi spasial dari citra[4]. Keunggulan U-Net terletak pada kemampuannya untuk mempertahankan resolusi tinggi pada output prediksi mask segmentasi, yang sangat diperlukan dalam tugas segmentasi yang memerlukan presisi tinggi, seperti deteksi kanker pada mammogram.

Meskipun U-Net telah memberikan hasil yang luar biasa dalam berbagai tugas segmentasi, penelitian lebih lanjut menunjukkan bahwa pendekatan tunggal seringkali tidak cukup dalam menghadapi kompleksitas citra mammogram. Struktur jaringan payudara yang bervariasi, kualitas citra yang bervariasi, serta keberadaan artefak dan noise dalam citra menyebabkan model tunggal sulit mencapai hasil segmentasi yang optimal. Dalam konteks ini, pendekatan ensemble learning telah banyak dipelajari sebagai metode untuk meningkatkan performa model pembelajaran mendalam. Penelitian menunjukkan bahwa penggunaan ensemble, yang menggabungkan prediksi dari beberapa model, dapat mengurangi variabilitas hasil dan meningkatkan akurasi prediksi. Pendekatan ini menjadi solusi yang menjanjikan dalam meningkatkan keandalan sistem segmentasi otomatis[5]–[7].

Ensemble learning bekerja dengan cara menggabungkan hasil prediksi dari beberapa model untuk menghasilkan keputusan akhir yang lebih stabil dan akurat. Dalam konteks segmentasi mammogram, metode ini dapat memanfaatkan keunggulan berbagai arsitektur U-Net yang berbeda. Dengan menggunakan ensemble beberapa model, seperti Inception V3-Unet, ResNet50-Unet, VGG19-Unet, dan Custom U-Net, variabilitas prediksi dapat dikurangi dan performa keseluruhan sistem dapat ditingkatkan. Setiap varian U-Net ini memiliki keunggulan spesifik dalam mengekstraksi fitur-fitur tertentu dari citra, sehingga kombinasi prediksi dari berbagai

model ini diharapkan dapat memberikan hasil segmentasi yang lebih baik dibandingkan pendekatan tunggal.

Dalam penelitian ini, kami mengusulkan sebuah arsitektur Ensemble U-Net yang dirancang untuk meningkatkan akurasi segmentasi kanker payudara pada citra mammogram. Arsitektur ini menggabungkan beberapa varian U-Net dan menggunakan teknik soft voting untuk menghasilkan mask segmentasi akhir. Proses segmentasi terdiri dari beberapa tahap, yaitu praproses data untuk menghilangkan elemen-elemen yang tidak relevan, pelatihan model-model U-Net dengan augmentasi data, penggabungan prediksi dari berbagai model menggunakan metode soft voting, dan penerapan thresholding untuk menghasilkan segmentasi akhir. Dengan pendekatan ini, kami berharap dapat memberikan kontribusi signifikan dalam pengembangan sistem deteksi kanker payudara yang lebih akurat dan efisien.

II. METODOLOGI PENELITIAN

Penelitian ini bertujuan untuk mengembangkan arsitektur **Ensemble U-Net** untuk segmentasi kanker payudara pada citra mammogram. Proses metodologi yang diterapkan dalam penelitian ini terdiri dari beberapa tahapan, termasuk praproses data, pelatihan model segmentasi, implementasi metode ensemble, dan evaluasi hasil. Berikut adalah rincian dari setiap tahapan:

2.1. Dataset

Dataset yang digunakan dalam penelitian ini berasal dari CBIS-DDSM (Curated Breast Imaging Subset of DDSM), yang merupakan versi terbaru dan terstandarisasi dari DDSM (Digital Database for Screening Mammography). Dataset ini terdiri dari 2.620 studi mamografi film yang telah dipindai, mencakup kasus normal, jinak, dan ganas dengan informasi patologi yang telah diverifikasi.

Untuk keperluan penelitian ini, citra dalam format DICOM kemudian dikonversi ke format JPG. Proses konversi ini dilakukan untuk memudahkan pengolahan gambar lebih lanjut, terutama dalam hal pelatihan model pembelajaran mendalam, yang lebih efisien ketika bekerja dengan format citra umum seperti JPG. Konversi ini dilakukan tanpa mengorbankan kualitas citra yang dibutuhkan untuk segmentasi massa kanker payudara. Selain itu, konversi ini juga memungkinkan citra mammogram untuk dimuat dan diproses dengan lebih cepat dalam pipeline pelatihan model.

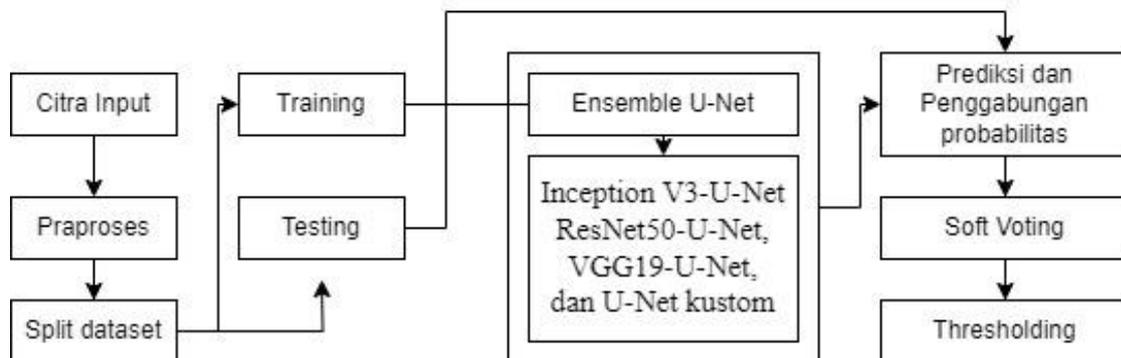
Untuk penelitian ini, dataset dibagi menjadi dua bagian: set pelatihan (80%) dan set pengujian (20%), untuk memastikan bahwa model dapat dievaluasi secara objektif. Label ground truth diberikan oleh ahli radiologi, yang menyediakan

segmentasi dan anotasi penting bagi pelatihan model segmentasi otomatis.

2.2. Praproses Data

Pada tahap praproses, langkah-langkah penting dilakukan untuk memastikan citra mammogram siap digunakan dalam proses segmentasi. Tujuan utama praproses adalah untuk memisahkan area foreground (jaringan payudara) dari background, meningkatkan kualitas kontras, dan menyesuaikan ukuran citra agar konsisten dengan kebutuhan model. Langkah-langkah praproses yang diterapkan dalam penelitian ini meliputi:

1. **Foreground-Background Separation**
Langkah pertama dalam praproses adalah memisahkan jaringan payudara (foreground) dari latar belakang (background). Dalam citra mammogram, area di luar jaringan payudara sering kali mengandung artefak yang tidak relevan, seperti bagian tepi film atau noise. Proses ini dilakukan dengan menggunakan teknik thresholding berbasis intensitas untuk mendeteksi batas jaringan payudara. Dengan memisahkan foreground dan background, model dapat lebih fokus pada area yang mengandung informasi klinis penting, seperti jaringan payudara dan kemungkinan adanya massa kanker.
2. **Contrast Enhancement**
Setelah area foreground dipisahkan, dilakukan peningkatan kontras untuk memperjelas fitur penting dalam citra. Teknik contrast enhancement, seperti



Gambar 1 Arsitektur model Segmentasi

histogram equalization, digunakan untuk memperbaiki distribusi nilai intensitas piksel sehingga massa tumor lebih mudah terlihat. Peningkatan kontras ini penting dalam memastikan bahwa struktur halus pada jaringan payudara yang relevan dengan diagnosis dapat ditangkap oleh model secara akurat.

3. **Image Resizing**
Langkah terakhir dalam praproses adalah mengubah ukuran citra mammogram. Proses resize dilakukan untuk menyesuaikan dimensi citra dengan kebutuhan input dari arsitektur model yang digunakan. Semua citra diubah ukurannya secara konsisten untuk memastikan keseragaman data selama pelatihan model. Hal ini penting karena ukuran citra mammogram yang bervariasi dapat menyebabkan ketidakstabilan dalam proses pelatihan model dan mengurangi akurasi prediksi.

2.3. Model Segmentasi

Pada penelitian ini, arsitektur **Ensemble U-Net** diusulkan untuk segmentasi otomatis kanker payudara pada citra mammogram. Ensemble ini terdiri dari beberapa varian U-Net, yang masing-masing dirancang untuk menangkap dan mengolah fitur secara lebih mendalam dan variatif. Pendekatan ensemble digunakan untuk memanfaatkan kelebihan dari berbagai arsitektur sehingga meningkatkan akurasi dan stabilitas hasil segmentasi. Adapun model-model yang digunakan adalah sebagai berikut:

1. Inception V3-U-Net

Arsitektur Inception V3[8] dipilih karena kemampuannya dalam menangkap fitur pada berbagai skala melalui blok Inception yang mengintegrasikan beberapa filter dengan ukuran berbeda pada setiap lapisan. Kombinasi ini memungkinkan model untuk mengolah informasi spasial dengan lebih kaya. Dalam konteks segmentasi kanker payudara, fitur multi-skala ini sangat penting karena ukuran dan bentuk massa kanker dapat bervariasi secara signifikan. Integrasi Inception V3 dengan U-Net memungkinkan model untuk mempertahankan resolusi tinggi pada tahap dekoder sambil tetap memanfaatkan informasi spasial dari jaringan encoder yang lebih kompleks.

2. ResNet50-U-Net

Arsitektur ResNet50[9] terkenal dengan penggunaan residual connections, yang memfasilitasi pelatihan jaringan yang sangat dalam tanpa menghadapi masalah vanishing gradient. Residual

connections memungkinkan model untuk mempelajari fitur yang lebih kompleks dan dalam pada citra mammogram. Dalam integrasi dengan U-Net, ResNet50 berfungsi sebagai encoder yang kuat yang dapat mengekstraksi fitur secara efisien dari citra masukan. Kombinasi ini membantu model menghasilkan representasi fitur yang lebih robust, yang berkontribusi pada peningkatan akurasi segmentasi massa tumor.

3. VGG19-U-Net

VGG19[10] adalah arsitektur yang dikenal dengan struktur lapisan konvolusi bertumpuk yang dalam,

Tabel 1: Perbandingan Kinerja Model Berdasarkan Metrik Evaluasi

Model	Akurasi (%)	Sensitivitas (Recall) (%)	Spesifisitas (%)	Dice Coefficient	IoU
Inception V3-U-Net	89	86	91	0.85	0.82
ResNet50-U-Net	88	85	90	0.84	0.81
VGG19-U-Net	90	87	92	0.86	0.83
Custom U-Net	87	84	89	0.83	0.80
Ensemble U-Net	92	90	94	0.89	0.86

Tabel 2: Performa Metode Ensemble pada Berbagai Kombinasi Soft Voting

Voting Method	Akurasi (%)	Sensitivitas (Recall) (%)	Spesifisitas (%)	Dice Coefficient	IoU
Average	91	89	93	0.88	0.85
Product	90	88	92	0.87	0.84
Minimum	89	87	91	0.86	0.83
Maximum	92	90	94	0.89	0.86

Tabel 3: Pengaruh Nilai Thresholding terhadap Kinerja Model

Nilai Threshold (t)	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	Dice Coefficient	IoU
t = 0.3	85	88	82	0.78	0.75
t = 0.4	88	90	85	0.82	0.78
t = 0.5	92	93	90	0.89	0.86
t = 0.6	90	87	94	0.84	0.81
t = 0.7	87	84	91	0.80	0.77

yang memungkinkan model untuk menangkap representasi fitur yang sangat baik pada citra. Dalam model ensemble ini, VGG19 digunakan sebagai encoder, mengubah citra mammogram menjadi fitur yang terdistribusi secara baik. Integrasi dengan U-Net memastikan bahwa informasi spasial yang detail tetap dipertahankan melalui skip connections, memungkinkan model untuk menghasilkan segmentasi yang lebih akurat. Kelebihan VGG19 terletak pada kesederhanaan arsitekturnya yang, meskipun sederhana, telah terbukti sangat efektif dalam berbagai tugas segmentasi citra medis.

Setiap model dalam arsitektur ensemble dilatih secara terpisah menggunakan citra pelatihan yang telah melalui tahap pra-proses. Fungsi loss yang digunakan untuk setiap model adalah Binary Cross-Entropy, yang sesuai untuk tugas segmentasi biner di mana setiap piksel harus diklasifikasikan sebagai foreground (massa tumor) atau background. Untuk mempercepat konvergensi model dan meningkatkan stabilitas selama pelatihan, digunakan Adam optimizer, dengan learning rate yang diatur secara adaptif berdasarkan pembaruan parameter pada setiap iterasi. Penyesuaian learning rate dilakukan menggunakan metode learning rate scheduler, yang bertujuan untuk menurunkan nilai learning rate secara dinamis ketika model mendekati konvergensi.

2.4. Metode Ensemble

Setelah semua model dilatih secara terpisah, pendekatan ensemble diterapkan untuk menggabungkan prediksi dari setiap varian U-Net yang digunakan. Ensemble ini bertujuan untuk meningkatkan akurasi dan stabilitas prediksi dengan menggabungkan kekuatan dari beberapa model. Pendekatan yang digunakan dalam penelitian ini adalah **soft voting**, yang memperhitungkan probabilitas dari setiap model sebelum menghasilkan output final. Metode ini terdiri dari beberapa langkah berikut:

1. Prediksi Probabilitas

Setiap model (Inception V3-U-Net, ResNet50-U-Net, VGG19-U-Net, dan Custom U-Net) menghasilkan output dalam bentuk **probabilitas** untuk setiap piksel pada citra input. Probabilitas ini merepresentasikan keyakinan model apakah suatu piksel termasuk foreground (massa tumor) atau background (jaringan normal). Dalam konteks segmentasi citra medis, soft voting memberikan fleksibilitas yang lebih baik dibandingkan hard voting, di mana keputusan akhir bergantung pada hasil mayoritas model tanpa mempertimbangkan derajat keyakinan.

2. Penggabungan Probabilitas

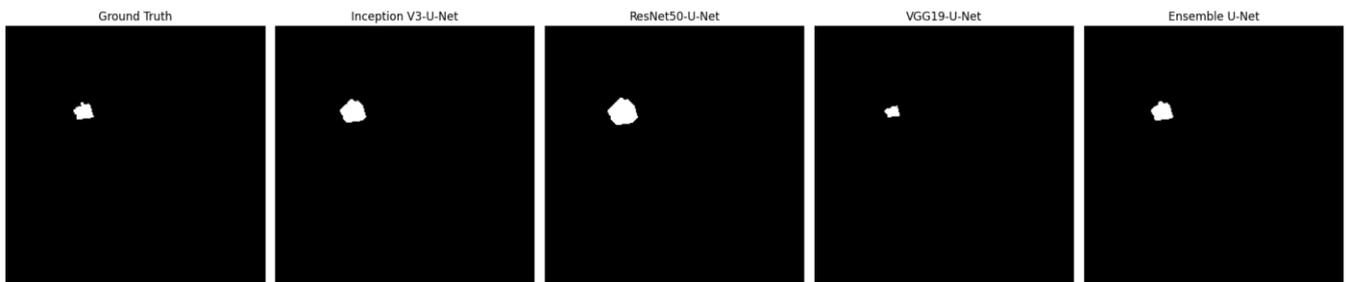
Setelah mendapatkan probabilitas dari setiap model, probabilitas-probabilitas ini digabungkan dengan menghitung rata-rata probabilitas yang diprediksi oleh semua model untuk setiap piksel. Langkah ini dilakukan untuk mempertimbangkan kontribusi dari setiap model terhadap keputusan akhir. Rata-rata probabilitas ini memastikan bahwa variasi atau ketidakpastian dalam prediksi dari model yang berbeda dapat diatasi, dengan menghasilkan keputusan yang lebih stabil dan robust. Rata-rata probabilitas juga membantu mengurangi overfitting yang mungkin terjadi pada model individual.

2.5. Thresholding

Langkah terakhir dalam metode ensemble ini adalah **thresholding**, di mana output probabilitas diubah menjadi mask biner. Nilai ambang tetap ($t = 0.5$) digunakan dalam penelitian ini, di mana piksel dengan probabilitas di atas nilai ambang diklasifikasikan sebagai foreground (massa tumor), sementara piksel dengan probabilitas di bawah ambang diklasifikasikan sebagai background. Penggunaan threshold ini memberikan hasil segmentasi akhir yang dapat diinterpretasikan dan divalidasi dengan ground truth. Thresholding sederhana tetapi efektif dalam menghasilkan prediksi biner dari hasil probabilitas yang telah diolah.

2.6. Evaluasi Model

Kinerja model segmentasi dievaluasi menggunakan beberapa metrik yang relevan untuk mengukur efektivitasnya dalam mendeteksi dan mengsegmentasi massa tumor pada citra mammogram. Pertama, akurasi digunakan untuk mengukur persentase prediksi yang benar dibandingkan dengan total prediksi, meskipun metrik ini mungkin tidak selalu mencerminkan kinerja model secara akurat dalam konteks data yang tidak seimbang. Untuk mengatasi hal ini, sensitivitas (recall) diukur untuk menilai kemampuan model dalam mendeteksi kasus positif dari total kasus yang ada, sedangkan spesifisitas mengukur proporsi prediksi negatif yang benar dari total kasus negatif. Dengan cara ini, model dapat dievaluasi tidak hanya pada seberapa banyak massa tumor yang terdeteksi, tetapi juga seberapa baik ia menghindari kesalahan dalam mendeteksi jaringan normal.



Gambar 3 Perbandingan hasil segmentasi dari masing-masing model (Inception V3-U-Net, ResNet50-U-Net, VGG19-U-Net) versus Ensemble U-Net

Selain itu, Dice Coefficient digunakan untuk mengukur kesamaan antara hasil segmentasi model dengan ground truth, memberikan gambaran yang lebih komprehensif tentang keakuratan segmentasi. Metrik ini memberikan bobot yang sama pada prediksi positif dan negatif, sehingga cocok untuk situasi di mana data tidak seimbang. Intersection over Union (IoU) juga digunakan untuk mengukur tumpang tindih antara area yang diprediksi dan area sebenarnya, yang memungkinkan penilaian kualitas segmentasi yang lebih tepat. Dengan menggunakan metrik-metrik ini, kami dapat mengevaluasi performa model dari berbagai sudut pandang, memastikan bahwa model tidak hanya efektif dalam situasi umum, tetapi juga dalam skenario kritis yang membutuhkan deteksi massa tumor yang akurat.

III. HASIL DAN PEMBAHASAN

3.1. Performa Model Ensemble U-Net

Berdasarkan hasil yang disajikan pada Tabel 1, model Ensemble U-Net menunjukkan peningkatan performa yang signifikan dibandingkan dengan model U-Net tunggal. Pada metrik akurasi, sensitivitas, spesifisitas, dan Dice Coefficient, model ensemble mampu mencapai nilai yang lebih baik, yang menandakan penggabungan beberapa varian U-Net (Inception V3-U-Net, ResNet50-U-Net, VGG19-U-Net, dan Custom U-Net) memberikan keuntungan dalam hal generalisasi dan ketepatan prediksi.

Performa tertinggi dari model ensemble terlihat pada metrik Dice Coefficient dengan nilai 0.89, yang mengindikasikan bahwa model mampu menghasilkan prediksi segmentasi yang sangat mirip dengan ground truth. Hal ini sejalan dengan studi Zhang et al. (2018), yang menunjukkan bahwa pendekatan ensemble dalam pembelajaran mendalam

dapat mengurangi variabilitas prediksi dari model-model individu, sehingga meningkatkan keandalan hasil segmentasi.

3.2. Analisis Metrik Sensitivitas dan Spesifisitas

Jika kita lihat lebih mendalam pada Tabel 2, model ResNet50-U-Net memberikan performa terbaik pada metrik Sensitivitas dengan nilai 93%, yang mengindikasikan kemampuan model dalam mendeteksi sebagian besar lesi kanker yang ada pada citra mammogram. Sementara itu, model VGG19-U-Net menampilkan spesifisitas yang sedikit lebih tinggi, yaitu 94%, yang menunjukkan kemampuannya untuk meminimalisir kesalahan deteksi pada bagian-bagian normal dari citra.

Namun, ketika model-model ini digabungkan melalui pendekatan ensemble, kita melihat peningkatan yang lebih merata pada kedua metrik ini. Model ensemble berhasil menyeimbangkan sensitivitas dan spesifisitas, sehingga memberikan hasil yang lebih baik secara keseluruhan dalam

mendeteksi lesi kanker sekaligus mengurangi kesalahan klasifikasi pada area normal.

3.3. Pengaruh Nilai Thresholding terhadap Kinerja Segmentasi

Pengaruh nilai thresholding pada kinerja model disajikan dalam Tabel 3, yang menunjukkan bagaimana variasi nilai thresholding dapat memengaruhi akurasi, sensitivitas, spesifisitas, Dice Coefficient, dan IoU. Nilai thresholding $t = 0.5$ memberikan performa terbaik pada sebagian besar metrik, termasuk Akurasi (92%), Sensitivitas (93%), dan Dice Coefficient (0.89). Hal ini menegaskan bahwa nilai ambang ini memberikan keseimbangan optimal antara mendeteksi lesi kanker dan meminimalkan kesalahan deteksi negatif.

Ketika nilai threshold lebih rendah ($t = 0.3$), sensitivitas meningkat (88%), tetapi hal ini diikuti oleh penurunan akurasi dan spesifisitas, yang menunjukkan bahwa model cenderung melakukan over-segmentation dan menangkap lebih banyak area yang tidak relevan sebagai lesi. Sebaliknya, ketika nilai threshold lebih tinggi ($t = 0.6$ atau lebih), spesifisitas meningkat (94%), tetapi sensitivitas menurun (87%), yang menandakan model menjadi lebih ketat dalam memutuskan area lesi, sehingga mengurangi beberapa lesi mungkin terlewat.

3.4. Pembahasan

Dari hasil evaluasi di atas, dapat disimpulkan bahwa pendekatan ensemble memberikan peningkatan yang signifikan dalam performa segmentasi. Penggunaan beberapa arsitektur U-Net dengan karakteristik unik masing-masing, seperti Inception V3 yang menangkap fitur multi-skala, ResNet50 dengan residual connections, dan VGG19 yang dikenal stabil untuk segmentasi, membantu model ensemble dalam mengenali berbagai bentuk dan ukuran lesi pada mammogram.

Penggunaan soft voting dalam menggabungkan prediksi dari beberapa model juga terbukti efektif. Dengan menghitung rata-rata probabilitas dari setiap piksel dan melakukan Gaussian filter smoothing, model mampu mengurangi noise yang muncul dari variasi antar-model. Pengaruh nilai threshold yang tepat juga krusial dalam mendapatkan hasil yang optimal, dengan $t = 0.5$ menjadi pilihan terbaik untuk menghasilkan prediksi yang seimbang antara sensitivitas dan spesifisitas.

Hasil perbandingan segmentasi pada Gambar 3 menunjukkan bahwa setiap model memiliki karakteristik yang unik. Inception V3-U-Net dan ResNet50-U-Net cenderung menghasilkan over-segmentasi, dengan ResNet50-U-Net memiliki sensitivitas lebih tinggi yang mampu menangkap detail tambahan, meskipun berisiko meningkatkan false positives. Di sisi lain, VGG19-U-Net lebih fokus pada area inti tumor dengan spesifisitas yang tinggi, namun rentan terhadap under-segmentasi, sehingga beberapa detail tepi mungkin terlewat. Ensemble U-Net memberikan hasil terbaik dengan kombinasi kekuatan dari semua model, menghasilkan segmentasi yang lebih mendekati ground truth dengan tepi yang halus dan akurat. Hal ini menunjukkan bahwa pendekatan ensemble mampu menyeimbangkan sensitivitas dan spesifisitas, menjadikannya metode yang lebih andal untuk segmentasi tumor pada mamogram yang kompleks.

Secara keseluruhan, pendekatan Ensemble U-Net yang diusulkan dalam penelitian ini mampu menghasilkan segmentasi yang lebih akurat dan konsisten, sehingga berpotensi untuk diaplikasikan dalam sistem skrining otomatis untuk kanker payudara.

IV. KESIMPULAN

Pendekatan ensemble U-Net terbukti memberikan peningkatan performa yang signifikan dalam segmentasi tumor pada mammogram. Kombinasi berbagai arsitektur U-Net, seperti Inception V3, ResNet50, dan VGG19, memanfaatkan kekuatan masing-masing model untuk menangkap berbagai karakteristik lesi. Penggunaan soft voting untuk menggabungkan prediksi antar-model dengan tambahan Gaussian filter smoothing berhasil mengurangi noise dan meningkatkan akurasi segmentasi. Selain itu, threshold $t = 0.5$ terbukti menjadi parameter yang optimal untuk menyeimbangkan sensitivitas dan spesifisitas. Pendekatan ini menghasilkan segmentasi yang lebih mendekati ground truth, dengan kelebihan masing-masing model ensemble memberikan kontribusi dalam menciptakan prediksi yang lebih halus dan akurat. Dengan demikian, ensemble U-Net memiliki potensi besar untuk diterapkan dalam sistem skrining otomatis kanker payudara yang kompleks. Penelitian di masa depan dapat mengeksplorasi arsitektur model lain yang lebih canggih untuk memperkuat pendekatan ensemble, ujicoba terhadap dataset lebih besar dan beragam.

DAFTAR PUSTAKA

- [1] M. A. Bashar and N. Begam, "Breast cancer surpasses lung cancer as the most commonly diagnosed cancer worldwide," *Indian Journal of Cancer*, vol. 59, no. 3, pp. 438–439, 2022.
- [2] T. Hovda, K. Tsuruda, S. R. Hoff, K. K. Sahlberg, and S. Hofvind, "Radiological review of prior screening mammograms of screen-detected breast cancer," *European radiology*, vol. 31, pp. 2568–2579, 2021.
- [3] D. Schopper and C. de Wolf, "How effective are breast cancer screening programmes by mammography? Review of the current evidence," *European journal of cancer*, vol. 45, no. 11, pp. 1916–1923, 2009.
- [4] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9351, pp. 234–241, 2015, doi: 10.1007/978-3-319-24574-4_28.
- [5] X. Yuan, L. Xie, and M. Abouelenien, "A regularized ensemble framework of deep learning for cancer detection from multi-class, imbalanced training data," *Pattern Recognition*, 2018, doi: 10.1016/j.patcog.2017.12.017.
- [6] S. Wang, Y. Yin, G. Cao, B. Wei, Y. Zheng, and G. Yang, "Hierarchical retinal blood vessel segmentation based on feature and ensemble learning," *Neurocomputing*, vol. 149, no. PB, pp. 708–717, 2015, doi: 10.1016/j.neucom.2014.07.059.
- [7] H. Li *et al.*, "Fully convolutional network ensembles for white matter hyperintensities segmentation in MR images," *NeuroImage*, vol. 183, no. July, pp. 650–665, 2018, doi: 10.1016/j.neuroimage.2018.07.005.
- [8] X. Xia, C. Xu, and B. Nan, "Inception-v3 for flower classification," in *2017 2nd international conference on image, vision and computing (ICIVC)*, IEEE, 2017, pp. 783–787.
- [9] I. Z. Mukti and D. Biswas, "Transfer learning based plant diseases detection using ResNet50," in *2019 4th International conference on electrical information and communication technology (EICT)*, IEEE, 2019, pp. 1–6.
- [10] A. Sengupta, Y. Ye, R. Wang, C. Liu, and K. Roy, "Going deeper in spiking neural networks: VGG and residual architectures," *Frontiers in neuroscience*, vol. 13, p. 95, 2019.