

# PENERAPAN METODE U-NET DALAM SEGMENTASI CITRA ULTRASONOGRAFI UNTUK VISUALISASI TUMOR PAYUDARA

Agung Kridoyono<sup>1)</sup>, Elvianto Dwi Hartono<sup>\*2)</sup>, Bagus Winarno<sup>3)</sup>

1. Teknik Informatika, Fakultas Teknik, Universitas 17 Agustus 1945 Surabaya, Indonesia
2. Teknik Robotika dan Kecerdasan Buatan, Fakultas Teknik, Universitas 17 Agustus 1945 Surabaya, Indonesia
3. Magister Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Maulana Malik Ibrahim Malang, Indonesia

**Kata kunci:** Segmentasi citra; Citra Ultrasound (USG); Tumor Payudara; Arsitektur U-Net; Image Preprocessing.

**Keywords:** Image Segmentation; Ultrasound Images (USG); Breast Tumor; U-Net Architecture; Image Preprocessing

## Article history:

Received 20 April 2025  
Revised 5 May 2025  
Accepted 19 May 2025  
Available online 20 May 2025

## DOI :

<https://doi.org/10.29100/jipi.v10i2.7775>

\* Corresponding author.

Corresponding Author

E-mail address:

[elvianto.evvh@untag-sby.ac.id](mailto:elvianto.evvh@untag-sby.ac.id)

## ABSTRAK

Tumor payudara merupakan benjolan dipayudara. Timbulnya benjolan pada payudara dapat merupakan indikasi adanya jenis tumor atau kanker payudara. Namun, untuk memastikan perlu dilakukan pemeriksaan patologis. Tumor payudara adalah kondisi yang disebabkan oleh pertumbuhan sel yang tidak normal pada kelenjar, jaringan ikat, maupun saluran ASI di payudara. Tumor payudara dapat bersifat jinak ataupun ganas (Kanker). Penggunaan citra digital telah dimanfaatkan dalam berbagai bidang, termasuk dalam bidang medis. Salah satu contohnya adalah penggunaan citra digital untuk mendeteksi lokasi organ vital dalam tubuh manusia. Tujuan dari penelitian ini adalah untuk menghasilkan bentuk potongan area payudara dengan menerapkan metode segmentasi deep learning dan memvisualisasikan hasilnya. Tahapan penelitian ini dilakukan dengan akuisisi citra USG, diikuti oleh proses image preprocessing untuk meningkatkan kualitas citra agar hasil proses segmentasi menjadi lebih baik, dilanjutkan dengan menerapkan metode segmentasi. Penelitian ini berfokus pada penggunaan metode U-Net untuk segmentasi tumor payudara pada citra ultrasound (USG) dan memvisualisasikannya. Dengan menggunakan arsitektur U-Net dalam penelitian mendalam untuk segmentasi tumor payudara pada citra ultrasound (USG), penelitian ini diharapkan dapat memberikan visualisasi yang lebih presisi. Segmentasi tumor payudara pada citra ultrasound (USG) dapat digunakan sebagai referensi bagi dokter spesialis kesehatan dan profesional lainnya untuk melakukan penelitian lebih lanjut. Dari hasil implementasi, dilakukan training terhadap dataset tumor payudara dan menghasilkan akurasi training sebesar 88.79%. Berdasarkan hasil yang didapatkan, metode U-Net dapat digunakan pada segmentasi tumor payudara pada citra ultrasound (USG).

## ABSTRACT

Breast tumors are lumps that appear in the breast. The presence of a lump in the breast can be an indication of a type of tumor or breast cancer. However, to confirm this, a pathological examination is necessary. Breast tumors are conditions caused by the abnormal growth of cells in the glands, connective tissues, or milk ducts of the breast. Breast tumors can be either benign or malignant (cancerous). Digital imaging has been utilized in various fields, including the medical field. One example is the use of digital images to detect the location of vital organs in the human body. The purpose of this study is to generate a segmented area of the breast by applying deep learning segmentation methods and visualizing the results. The research stages include ultrasound (USG) image acquisition, followed by image preprocessing to enhance image quality for better segmentation results, and then the application of the segmentation method. This study focuses on using the U-Net method for segmenting breast tumors in ultrasound (USG) images and visualizing them. By using the U-Net architecture in deep learning for segmenting breast tumors in ultrasound images, this research is expected to provide more precise visualizations. Breast tumor segmentation in ultrasound (USG) images can serve as a reference for medical specialists and other professionals for further research. From the implementation results, training was conducted on a breast tumor dataset and produced a training

accuracy of 88.79%. Based on these results, the U-Net method can be used for breast tumor segmentation in ultrasound (USG) images.

## I. PENDAHULUAN

Tumor payudara merupakan benjolan di payudara. Timbulnya benjolan pada payudara dapat merupakan indikasi adanya jenis tumor/kanker payudara. Namun, untuk memastikannya perlu dilakukan pemeriksaan patologis. Kanker payudara adalah keganasan yang berasal dari sel kelenjar, saluran kelenjar dan jaringan penunjang payudara yang ditandai dengan adanya benjolan di payudara, dan pada stadium lanjut terasa sakit. Meskipun ilmu pengetahuan semakin canggih akan tetapi hingga saat ini belum diketahui secara pasti faktor penyebab utama penyakit tumor/kanker payudara, diperkirakan multifaktorial [1].

Dari beberapa studi diketahui faktor-faktor yang berhubungan dengan tumor/kanker payudara antara lain umur tua (aging), perempuan 100 kali lebih berisiko dibandingkan dengan laki-laki, adanya faktor genetik seperti riwayat keluarga menderita tumor/kanker payudara terutama ibu dan saudara perempuan, riwayat menstruasi dini, usia makin tua saat menopause, hamil pertama di usia tua, menggunakan kontrasepsi hormonal, obesitas dan asupan rendah serat, tinggi lemak khususnya lemak jenuh [2].

Citra ultrasound (USG) merupakan salah satu modalitas pencitraan medis yang banyak digunakan dalam deteksi dan diagnosis tumor payudara karena sifatnya yang non-invasif, aman, dan relatif murah. Namun, citra USG memiliki sejumlah tantangan teknis, seperti adanya *speckle noise* yang tinggi, kontras yang rendah antara jaringan normal dan tumor, serta kontur lesi yang tidak jelas. Karakteristik ini menyulitkan proses segmentasi otomatis, yang merupakan tahap penting dalam analisis citra medis untuk menentukan lokasi, ukuran, dan bentuk tumor secara presisi.

Metode segmentasi tradisional seperti canny edge detection dan active contour (snake model) telah banyak digunakan pada berbagai jenis citra medis. Namun, metode ini memiliki keterbatasan yang signifikan ketika diterapkan pada citra USG payudara. Canny edge detection, misalnya, sangat bergantung pada perubahan intensitas yang tajam untuk mendeteksi tepi, sehingga sering kali gagal mengidentifikasi batas tumor yang kabur atau terdistorsi oleh noise. Sementara itu, active contour memerlukan inisialisasi manual dan rentan terhadap lokal minima, sehingga kurang andal pada citra dengan bentuk tumor yang tidak teratur atau batas yang samar.

Segmentasi tumor payudara pada citra ultrasound (USG) menghadapi tantangan signifikan akibat karakteristik intrinsik citra tersebut. Variasi morfologi tumor, batas lesi yang kabur, dan artefak akustik seperti speckle noise serta bayangan posterior membuat segmentasi manual menjadi sulit dan rawan kesalahan, bahkan bagi radiolog berpengalaman. Untuk mengatasi keterbatasan ini, berbagai arsitektur deep learning telah dikembangkan. AAU-Net, misalnya, mengintegrasikan modul perhatian adaptif untuk menangani kompleksitas citra USG dengan lebih baik. ECU-Net memperkenalkan deteksi batas multi-skala dan peningkatan fitur kontras untuk memperbaiki segmentasi pada batas lesi yang kabur. Selain itu, pendekatan seperti NU-Net dan CResU-Net menawarkan solusi yang lebih efisien dengan mempertahankan akurasi tinggi dalam segmentasi tumor payudara. Secara keseluruhan, inovasi-inovasi ini menunjukkan bahwa pendekatan berbasis U-Net dan variannya mampu mengatasi tantangan spesifik dalam segmentasi tumor payudara pada citra USG, menawarkan solusi yang lebih akurat dan efisien dibandingkan metode tradisional.

Sebagai respons terhadap keterbatasan tersebut, pendekatan berbasis deep learning, khususnya arsitektur U-Net, muncul sebagai solusi yang lebih adaptif dan efektif. U-Net dirancang khusus untuk segmentasi citra medis dan memiliki kemampuan untuk mengekstraksi fitur spasial pada berbagai level resolusi melalui encoder-decoder architecture. Komponen *skip connections* memungkinkan jaringan untuk mempertahankan informasi spasial yang penting dari input awal, sehingga hasil segmentasi menjadi lebih akurat bahkan pada citra dengan detail yang halus. Selain itu, karena bersifat *end-to-end*, U-Net tidak memerlukan langkah pra-pemrosesan atau tuning parameter yang kompleks seperti pada metode tradisional.

Lebih lanjut, kemampuan U-Net untuk belajar langsung dari data ground-truth memungkinkan model untuk beradaptasi dengan karakteristik citra USG yang kompleks dan bervariasi. Dalam konteks segmentasi tumor payudara, U-Net telah terbukti memberikan performa yang lebih konsisten dalam mengidentifikasi batas lesi dibandingkan metode konvensional. Hal ini menegaskan bahwa terdapat gap penting dalam pendekatan segmentasi tradisional yang dapat diatasi secara lebih efektif oleh metode deep learning seperti U-Net, terutama dalam aplikasi klinis yang membutuhkan kecepatan dan akurasi tinggi.

Sebelumnya, penelitian untuk mengidentifikasi telah berhasil dilakukan, dengan memanfaatkan deteksi tepi menggunakan metode canny dan membandingkannya dengan metode lainnya penelitian yang sama juga dilakukan dengan memanfaatkan segmentasi citra untuk mengidentifikasi objek tumor menggunakan metode active contour yang mampu melakukan segmentasi citra pada objek multi region dan objek yang saling

berdekatan namun sensitif terhadap derau, sedangkan penelitian untuk mengidentifikasi tumor jinak pada payudara menggunakan citra medis hasil USG masih jarang ditemukan. Penelitian pemrosesan citra medis hasil USG dengan menggunakan metode sobel untuk membantu dokter atau radiologis dalam mengidentifikasi tumor payudara [3].

Metode segmentasi tradisional seperti Canny edge detection dan active contour memiliki keterbatasan signifikan dalam menangani karakteristik unik citra USG payudara. Citra USG sering kali memiliki kualitas rendah, dengan batas lesi yang kabur, artefak speckle, dan kontras yang rendah. Metode seperti Canny edge detection bergantung pada deteksi tepi berbasis gradien, yang rentan terhadap noise dan dapat menghasilkan deteksi tepi yang tidak akurat. Active contour, meskipun lebih adaptif, memerlukan inisialisasi yang tepat dan dapat terjebak pada minimum lokal, terutama pada citra dengan batas lesi yang tidak jelas.

Arsitektur U-Net telah menjadi standar dalam segmentasi medis karena kemampuannya dalam menangkap informasi kontekstual dan spasial melalui struktur encoder-decoder dengan skip connections. Variasi dari U-Net telah dikembangkan untuk mengatasi keterbatasan U-Net standar dan meningkatkan performa segmentasi pada citra USG payudara.

Dalam lima tahun terakhir, berbagai varian U-Net telah dikembangkan untuk meningkatkan performa segmentasi citra medis, khususnya pada citra ultrasonografi (USG). Salah satu varian tersebut adalah AAU-Net, yang memanfaatkan modul perhatian adaptif hibrid (channel dan spatial) guna menangani kompleksitas citra USG. Model ini telah dievaluasi pada tiga dataset publik dan menunjukkan performa yang unggul dibandingkan metode *state-of-the-art* (SOTA) lainnya[10]. Selanjutnya, RCA-IUnet mengintegrasikan *residual inception*, *cross-spatial attention*, dan *hybrid pooling* untuk mengatasi variasi ukuran tumor. Dengan parameter pelatihan yang minimal[11], model ini berhasil mengungguli SOTA pada dua dataset publik. Model Sharp Attention U-Net menambahkan filter penajam dan modul *attention gate* untuk meningkatkan sensitivitas dan nilai *dice coefficient*, dengan peningkatan sensitivitas lebih dari 5% dibandingkan model terbaik kedua pada dataset BUSI[12]. Sementara itu, GDUNet menggunakan kombinasi *attention gate*, *dilated convolution*, dan *tokenized MLP* guna mengekstraksi informasi multiskala, menghasilkan segmentasi yang lebih baik dengan jumlah parameter yang lebih sedikit serta kecepatan inferensi yang lebih tinggi[13]. Terakhir, UCaps-Net merupakan integrasi antara U-Net dan *Capsule Network*, yang dirancang untuk tugas klasifikasi. Penggunaan BUSI Dataset memberikan dasar yang kuat dalam melatih dan menguji performa UCaps-Net dalam mendeteksi objek atau area yang relevan dalam citra USG[14].

Integrasi output segmentasi tumor payudara berbasis deep learning, seperti U-Net dan variannya, ke dalam alur kerja klinis radiologi dapat meningkatkan efisiensi dan akurasi diagnosis. Model-model ini dapat diintegrasikan ke dalam sistem PACS (Picture Archiving and Communication System), memungkinkan hasil segmentasi ditampilkan secara otomatis pada workstation radiolog. Dengan demikian, radiolog dapat melihat delineasi lesi secara langsung, yang membantu dalam penilaian BI-RADS, perencanaan biopsi, dan pemantauan respons terapi. Studi menunjukkan bahwa integrasi ini dapat mengurangi waktu interpretasi dan meningkatkan konsistensi diagnosis antar-radiolog. Namun, untuk implementasi yang efektif, diperlukan validasi klinis yang ketat dan pelatihan pengguna agar radiolog memahami dan mempercayai output model. Selain itu, integrasi yang mulus dengan sistem informasi rumah sakit dan kepatuhan terhadap regulasi privasi data juga menjadi pertimbangan penting dalam adopsi teknologi ini dalam praktik klinis sehari-hari.

## II. METODE PENELITIAN

### A. Intensitas Ultrasound

Saat melewati medium, gelombang membawa energi yang terfokus ke area tertentu / luasan tertentu yang didefinisikan sebagai intensitas gelombang. Intensitas biasanya digambarkan relatif terhadap intensitas referensi, sebagai contoh intensitas gelombang ultrasound yang dipantulkan Kembali kepermukaan tubuh. Gelombang yang dipantulkan ke permukaan mencapai seperseratus atau lebih dari intensitas gelombang yang ditransmisikan.

### B. Prinsip Kerja Ultrasonografi

Gelombang ultrasonik pada peralatan ultrasonography (USG) ditransmisikan melalui transduser ke jaringan tubuh pasien dan mengenai batas-batas antar jaringan seperti cairan, otot, dan tulang. Sebagian gelombang lalu dipantulkan Kembali ke transduser, Sebagian lain harus menembus bagian tubuh lainnya hingga dipantulkan Kembali. Gelombang yang dipantulkan Kembali ditangkap oleh transduser dan diteruskan ke mesin ultrasonik. Mesin ultrasonik akan menampilkan hasil dari pantulan gelombang kedalam layar dala, bentuk sinyanya. Hasil pantulan (echo) dari gelombang tersebut kemudian terdeteksi dengan transduser yang kemudian merubah gelombang ultrasonik. Ke sinyal elektronik untuk ditampilkan dalam bentuk citra [4].

### C. Tumor Payudara

Tumor payudara dapat di artikan sebagai benjolan atau pembengkakan di payudara yang disebabkan pertumbuhan sel abnormal dalam tubuh. Pertumbuhan tumor dapat bersifat ganas (malignan) atau jinak (benign) .

Tumor Jinak biasanya terdiri dari gumpalan lemak yang terbungkus dalam suatu wadah yang menyerupai kantong dan tidak menyebar kebagian lain pada tubuh [5].

#### D. Pengolahan Citra Digital

Teknik pengambilan citra payudara untuk deteksi kanker dapat dilakukan dengan banyak cara dan metode [6]. mengulas beberapa metode pengambilan citra payudara, di antaranya; mamografi, mamografi dengan kontras citra yang ditingkatkan, tomosintesis digital, sonografi, sonoelastografi, pencitraan resonansi magnetik, elastografi magnetik, pencitraan berbobot difusi, spektroskopi magnetik, kedokteran nuklir, pencitraan optik, dan pencitraan gelombang mikro.

Pemilihan metode terbaik dalam Teknik pencitraan payudara bergantung pada keadaan dan stadium pasien, usia pasien, dan kepadatan jaringan payudara. Pengolahan citra digital merupakan pemrosesan citra khususnya menggunakan komputer untuk menjadikan citra dengan kualitas yang lebih baik.

#### E. Segmentasi

Image segmentation (segmentasi citra) adalah salah satu langkah penting dalam analisis sebuah citra [7]. Segmentasi citra diterapkan untuk memisahkan bagian yang penting atau berbeda dari citra. Proses segmentasi citra ialah membagi citra menjadi beberapa wilayah yang berbeda berdasarkan karakteristik piksel. Segmentasi citra adalah proses membagi atau mengelompokkan piksel dalam suatu gambar ke dalam segmen atau wilayah yang memiliki karakteristik visual atau atribut yang serupa. Tujuan utamanya adalah untuk memudahkan analisis dan pemahaman struktur atau objek dalam gambar dengan memecahnya menjadi segmen-segmen kecil. Setiap segmen dapat diolah atau dianalisis secara terpisah, memberikan informasi yang lebih rinci.

Metode segmentasi citra dapat melibatkan pemisahan objek dari latar belakang, pemberian label pada area dengan warna atau tekstur serupa, atau pengelompokan piksel berdasarkan tingkat kecerahan atau warna. Segmentasi citra memiliki berbagai aplikasi, seperti dalam pengolahan citra medis, pengenalan pola, dan visi komputer. Proses segmentasi citra memungkinkan pemrosesan dan analisis lanjutan dengan lebih efisien, membuka potensi aplikasi yang lebih canggih di berbagai bidang.

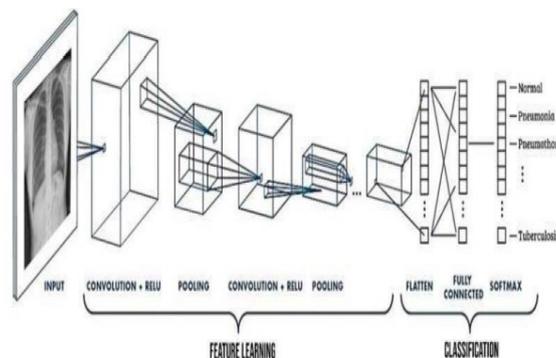


Fig 1. Struktur CNN [1]

#### F. Deep Learning

Deep learning adalah cabang dari pembelajaran mesin yang berusaha untuk memodelkan abstraksi tingkat tinggi dari data menggunakan multiple layer dari neuron yang terdiri dari struktur kompleks atau transformasi non-linear. Dengan meningkatnya jumlah data dan kekuatan komputasi, jaringan saraf dengan struktur yang lebih kompleks telah menarik perhatian luas dan telah diterapkan pada berbagai bidang. Salah satunya di bidang medis, dalam hal ini contohnya yaitu citra USG. Dalam citra USG, penggunaan deep learning telah memberikan dampak yang signifikan [8].

Melalui deep learning, peneliti dan praktisi di bidang citra USG telah berhasil mengembangkan algoritma dan model yang mampu mengidentifikasi struktur anatomi, mendeteksi kelainan atau patologi, serta melakukan segmentasi untuk memisahkan organ atau jaringan tertentu dalam citra USG. Penggunaan deep learning dalam citra USG juga telah membantu dalam meningkatkan kualitas citra, mengurangi noise, dan mengatasi masalah artefak.

#### G. Autoencoder

Autoencoder adalah Neural Network yang mampu merekonstruksi input (Fiorina, no date).

#### H. U-Net

U-Net adalah mapping fitur dari gambar (segmentasi), neural network ini dikhususkan untuk masalah klasifikasi untuk setiap pixel karena vector label untuk setiap pixelnya sudah disediakan oleh radiologist, dimana setiap file CT Scan bisa memiliki lebih dari 1 nodule, label dalam kasus ini adalah area nodule dengan nilai Id Finding yang dapat dilihat pada file csv. Target dari neural network adalah menghasilkan vector label. Unet memiliki encoder (down sampling) dan decoder (up sampling) yang sama seperti Autoencoder.

Tiap layer encoder yang ada akan mengecilkan dimensi input layer tersebut, sehingga hal ini disebut down sampling. Tiap layer decoder yang ada akan membesarkan dimensi input layer tersebut, sehingga hal ini disebut up sampling. Hal yang membedakan kedua jenis adalah adanya layer penghubung encoder menuju decoder (layer concatenate). Unet biasanya menggunakan layer convolutional untuk bagian encoder dan decodernya ketimbang menggunakan layer dense [9].

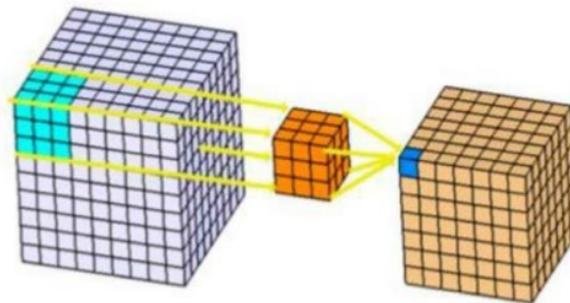


Fig 2. Layer Convolutional 3 Dimensi [1]

U-Net dapat menerima input gambar 3 dimensi maupun 2 dimensi, dengan bantuan layer convolutional, hal ini menjadi mudah. Karena layer convolutional berupa 3 dimensi, maka weight juga berupa 3 dimensi. Proses perkalian input (Bukan Dot matrix) dengan weight akan menghasilkan output 3 dimensi juga. Dimensi output dapat diatur menggunakan stride dan padding, dimensi output dapat sama dengan dimensi input dengan bantuan padding dan tipe same. Hal yang membedakan U-Net dari Autoencoder adalah adanya layer skip connection yang menghubungkan hasil feature map sebagai input tambahan untuk layer decoder pada level yang sama dengan menggunakan bantuan layer concatenate, sehingga dimensi input akan bertambah, bukannya nilai dari input decoder yang bertambah. Dengan Xu et al. Menyelidiki kegunaan jaringan konvolusional penuh dan U-Net untuk massa payudara segmentasi [10].

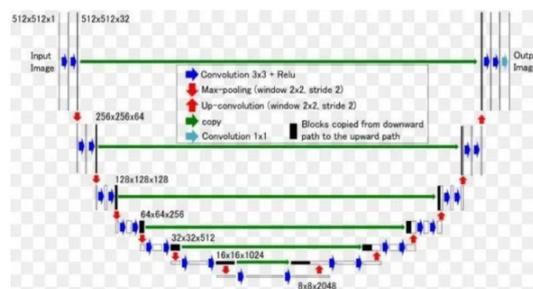


Fig 3. Struktur U-Net [6]

Garis hijau adalah layer concatenate yang menghubungkan encoder ke decoder. Garis merah kebawah adalah layer downsampling yang biasanya menggunakan layer max pooling ataupun dapat memanfaatkan atribut stride pada layer convolutional. Garis merah keatas adalah layer transpose. Transpose Layer adalah Teknik lain sekain up sampling biasa. Transpose layer lebih dikenal sebagai layer deconvolutional, padahal kedua layer adalah jenis yang berbeda. Layer deconvolutional memutar balikkan operasi dari layer convolutional biasa. Sedangkan layer transposed meningkatkan spatial dimensi dari input dengan bantuan stride dan padding. Selain itu, layer transposed memiliki weight yang dapat dipelajari, cara mempelajari weight sama sama dengan layer convolutional pada umumnya, sehingga layer ini mempunyai ukuran filter dan jumlah channel. Hal ini lah yang membedakan dari layer up sampling biasa. Hasil output dari layer deconvolutional dan layer transpose memiliki spatial dimension yang sama, sehingga hal ini yang membuat pemahaman kebanyakan orang salah.

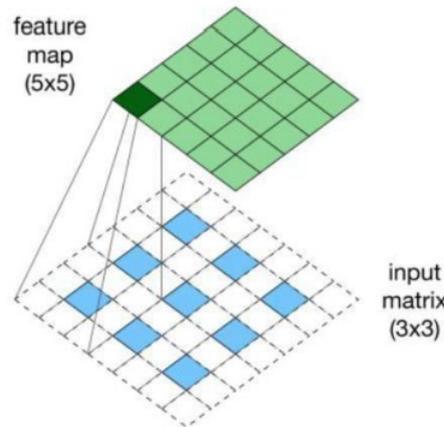


Fig 4. Visualisasi Layer Transpose [6]

Input matrix awalnya adalah 3x3, Karena terdapat padding 1 dan stride 2 maka akan keluar hasil seperti pada gambar. Kotak berwarna biru adalah kotak dengan nilai input awal matrix, sedangkan kotak tidak berwarna bernilai 0. Langkah selanjutnya adalah melakukan perkalian dengan weight seperti layer convosional. Jika stride adalah 3 dan padding bertipe same, maka dimensi input awal akan dikalikan dengan 3.

Metode U-Net (Universal Neural Network) adalah arsitektur jaringan saraf tiruan yang populer untuk tugas segmentasi gambar, khususnya tugas segmentasi semantik. Arsitektur U-Net awalnya dikembangkan untuk aplikasi segmentasi medis, tetapi sejak itu digunakan dalam berbagai bidang, termasuk pengolahan citra dan penglihatan komputer. U-Net memiliki struktur jaringan yang simetris dan terdiri dari dua bagian utama: encoder (pemampat) dan decoder (dekompresor). Bagian encoder digunakan untuk mengekstraksi fitur dari gambar input, sedangkan bagian decoder bertanggung jawab untuk menghasilkan segmentasi piksel demi piksel.

#### A. Tahapan Penelitian

Sistem klasifikasi tumor payudara dilakukan dengan memasukkan citra input berupa citra ultrasound payudara dengan output berupa hasil klasifikasi. Diagram pada Gambar 3.2 merupakan diagram proses yang menunjukkan langkah-langkah segmentasi. Pertama citra input akan dipreproses, kemudian diekstraksi fitur, dan baru akan dilakukan Akurasi hasil.

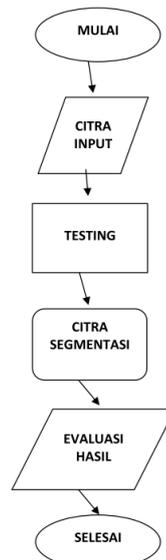


Fig 5. Diagram Proses Segmentasi Citra Tumor Payudara

Dalam penelitian ini akan dilakukan delapan kali percobaan dengan kombinasi dua variabel. Variabel tersebut antara lain metode image preprocessing, metode distribusi kelas. Adapun alur yang akan dilakukan dalam penelitian ini dapat dilihat pada Gambar 3.3.

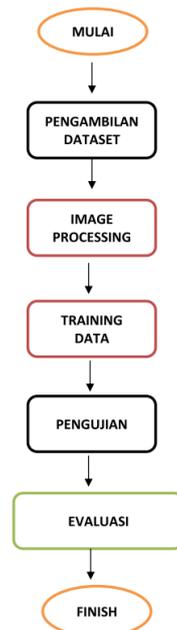


Fig 6. Flowchart Alur Penelitian Klasifikasi Tumor Payudara

#### IV. HASIL DAN PEMBAHASAN

##### A . Hasil Uji Unit Akuisisi dan Gambar

##### A.1. Tahap Pengambilan Dataset

Data citra gambar yang digunakan berjumlah 192 data citra gambar untuk diuji dalam dalam penelitian kali ini, untuk citra gambar yang digunakan total keseluruhan memiliki jumlah piksel yang sama yaitu 222 piksel, data tersebut bertipe JPG.

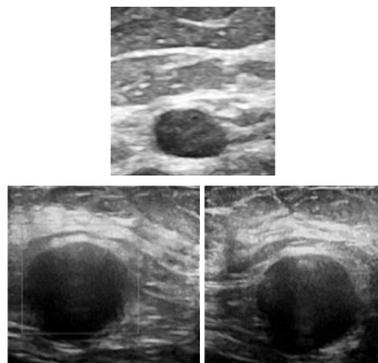


Fig 7. Citra Ultrasound Tumor Payudara

Pada dataset juga belum disajikan ( Ground truth ) yang menunjukkan letak objek tumor. Namun dalam penelitian ini akan mencari letak tumor yang terletak pada citra gambar yang disajikan . Preproses citra yang akan dilakukan yaitu mengubah ukuran gambar menjadi 256 x 256 piksel.

##### B. Tahap Preprocessing Citra

Preprocessing citra dilakukan dengan menggunakan metode hybrid untuk mengurangi noise bintang pada citra ultrasound. Metode ini diusulkan oleh (Fajar Astuti Hermawati, 2022). Metode ini menggunakan metode U-Net. Pada tahap ini dataset dalam satu folder akan diambil dalam bentuk image data store. Kemudian dilakukan iterasi sebanyak jumlah dataset. Citra input diubah menjadi bentuk grayscale sebagai syarat input Preprocessing. Hasil Preprocessing kemudian dirubah kembali kebentuk Grayscale. Terakhir, Hasil final Preprocessing disimpan kembali kedalam folder baru. Pada preproses citra menggunakan metode U-Net.

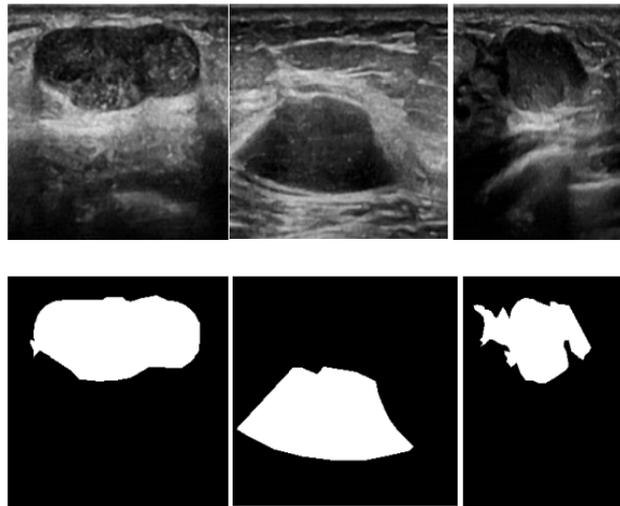
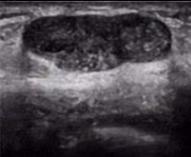
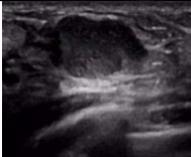
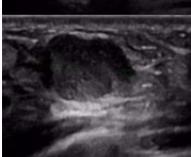
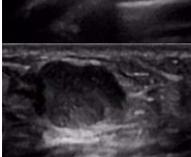


Fig 8. Resized dan Cropping Data

Sebelum memulai proses pelatihan data, langkah awal pra-pemrosesan citra melibatkan dua tahap utama dapat dilihat pada Gambar 4.2 Resized dan Cropping Data Image Preprocessing. Tahap pertama adalah penyesuaian ukuran citra melalui resize, dimana dimensi citra dirubah sesuai dengan format yang diinginkan , sementara itu untuk langkah kedua yaitu pemotongan citra ( cropping ), dilakukan untuk menghilangkan bagian tertentu dari citra yang mungkin tidak diperlukan atau untuk mengatasi masalah komposisi gambar. Proses resize diarahkan untuk menjamin konsistensi ukuran citra, sementara pemotongan bertujuan untuk memusatkan pada area yang paling relevan dan mengurangi elemen yang kurang signifikan. Kedua tahan ini merupakan bagian yang tak terpisahkan dari pra-pemrosesan citra, dengan tujuan mempersiapkan data sesuai dengan kebutuhan model yang dijalankan.

TABEL I.  
 SEBAGIAN HASIL RESIZE & CROPPING IMAGE

No.	Image	Label
1.		
2.		
3.		
4.		



Pada Tabel diatas memperlihatkan contoh sebagian dari output proses resize dan juga cropping image. Tabel ini menampilkan sebagian representatif dari gambar yang telah mengalami penyesuaian ukuran dan pemotongan. Presentasi hasil dalam tabel tersebut memberikan gambaran visual mengenai perubahan yang telah diterapkan pada gambar.

### C. Training Data

Dalam penelitian segmentasi tumor payudara pada citra ultrasound menggunakan metode U-Net, validasi model dilakukan dengan pendekatan *train-test split* yang umum digunakan dalam praktik machine learning. Pendekatan ini membagi dataset menjadi dua subset: satu untuk pelatihan model (*training set*) dan satu lagi untuk evaluasi kinerja model (*test set*). Pembagian ini bertujuan untuk memastikan bahwa model dapat belajar dari data yang ada dan diuji pada data yang belum pernah dilihat sebelumnya, sehingga dapat mengukur kemampuannya dalam menggeneralisasi ke data baru.

Pemilihan rasio pembagian dataset antara *training* dan *test* set sangat penting untuk menghindari bias dalam evaluasi model. Rasio yang umum digunakan adalah 70:30 atau 80:20, yang memberikan keseimbangan antara jumlah data untuk pelatihan dan evaluasi. Namun, dalam kasus dataset kecil, seperti pada citra medis, rasio 80:20 sering dianggap optimal karena menyediakan cukup data untuk pelatihan tanpa mengurangi jumlah data untuk evaluasi yang representatif.

Selain itu, penting untuk melakukan *stratified sampling* saat membagi dataset, terutama jika terdapat ketidakseimbangan kelas dalam data. Metode ini memastikan bahwa proporsi kelas dalam *training* dan *test* set tetap konsisten dengan proporsi kelas dalam dataset asli, sehingga model tidak cenderung bias terhadap kelas yang lebih dominan.

Tahapan awal sebelum melanjutkan proses pelatihan data adalah menyiapkan data-data yang dibutuhkan. Semua data ini ditempatkan dalam sebuah folder khusus yang akan digunakan untuk melatih model. Di dalam folder ini, kita perlu membuat dua subfolder terpisah.

Berdasarkan hasil pelatihan, ditemukan bahwa tingkat akurasi tertinggi mencapai 88,79%, dan pencapaian ini terjadi pada dan ke-50. Dengan kata lain, nilai akurasi yang paling optimal tercapai pada tahap terakhir dari pelatihan model menunjukkan hasil Accuracy dan Loss yang tingkat Validation Accuracy mencapai 88.79%, dataset melewati keseluruhan sebanyak 50 kali Epoch. Dataset dipecah menjadi 17 batch per Epoch, menghasilkan total 850 iterasi untuk pelatihan, hasil loss dan accuracy mengevaluasi apakah model sudah cukup dilatih atau perlu penyesuaian lebih lanjut.

- EPOCH

Satu epoch adalah ketika model telah memproses seluruh dataset pelatihan sekali, melalui forward pass (prediksi) dan backward pass (pembaruan bobot).

- ITERATION

Satu Iteration adalah ketika model memproses sejumlah batch dari dataset, total iteration (850) dihitung dari :

Total Iteration = Epoch X Iteration per Epoch Dalam kasus ini : 850 X 17

17 Iteration per Epoch berarti dataset dibagi menjadi 17 batch pada setiap epoch.

- Maximum Iterations

Menampilkan batas maksimum iterasi yang direncanakan untuk pelatihan, biasanya dihitung dari :

Maximum Iteration = Epoch X Iteration per Epoch

Nilai 850 tersebut sesuai dengan 50 Epoch dikalikan dengan 17 iterasi per Epoch.

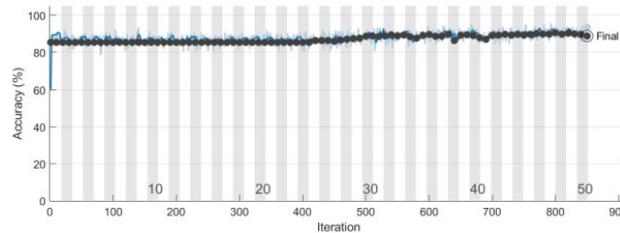


Fig 9. Traffic Accuracy

Pada gambar diatas Traffic Accuracy menampilkan hasil Akurasi dari Training U-Net yang telah dilakukan. Training dalam konteks segmentasi Tumor, dapat didefinisikan berdasarkan metrik seperti Intersection over Union ( IoU ), Dice Coefficient, atau piksel-wise accuracy. Akurasi pada data pelatihan menunjukkan seberapa baik model menyesuaikan diri dengan data yang dilihat selama pelatihan. Validation akurasi pada data validasi menggambarkan kemampuan model untuk memprediksi data baru, akurasi yang meningkat pada training dan validation set menandakan model semakin baik. Jika akurasi pada validation stagnan atau menurun, itu mungkin menunjukkan overfitting.

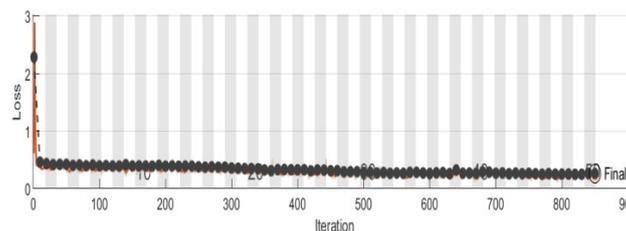


Fig 10. Traffic Loss

Pada gambar Traffic Loss mengukur seberapa jauh prediksi model dari label sebenarnya ( Ground Truth ). Nilai Loss yang rendah menunjukkan bahwa model lebih baik dalam memprediksi output yang benar. Analisis hasil Loss pelatihan Loss menunjukkan seberapa baik model mempelajari pola dari data pelatihan. Validation Loss menunjukkan performa model pada data yang tidak dilihat selama pelatihan ( validasi ). Jika validasi Loss lebih tinggi dibandingkan training loss, itu dapat mengindikasikan overfitting. Graffik Loss yang stabil pada pelatihan dan validasi dataset menandakan model belajar dengan baik, jika loss stagnan atau meningkat itu menunjukkan model kesulitan belajar atau terlalu overfit.

Dalam penelitian segmentasi tumor payudara pada citra ultrasound menggunakan metode U-Net, diperoleh akurasi tertinggi sebesar 88,79% setelah 50 epoch pelatihan. Hasil ini menunjukkan bahwa model U-Net dapat memberikan segmentasi yang cukup akurat meskipun dengan dataset yang terbatas. Namun, untuk memberikan konteks lebih lanjut dan menilai kontribusi penelitian ini, penting untuk membandingkan hasil tersebut dengan penelitian-penelitian terkait yang telah dilakukan sebelumnya.

Salah satu penelitian yang relevan [15] mengusulkan model DAU-Net (Dual Attention U-Net) untuk segmentasi tumor payudara pada citra ultrasound. Model ini mengintegrasikan dua mekanisme perhatian, yaitu Positional Convolutional Block Attention Module (PCBAM) dan Shifted Window Attention (SWA), dalam arsitektur Residual U-Net. Hasil evaluasi pada dua dataset umum menunjukkan bahwa DAU-Net mencapai skor Dice sebesar 74,23% dan 78,58% pada dataset BUSI dan UDIAT, masing-masing. Meskipun skor Dice ini lebih rendah dibandingkan dengan model U-Net dalam penelitian ini, DAU-Net menunjukkan kemampuan yang baik dalam menangani variasi bentuk dan batas tumor yang kabur, yang merupakan tantangan utama dalam segmentasi citra ultrasound payudara. Selain itu, DAU-Net menggunakan 10-fold cross-validation, yang memberikan estimasi kinerja model yang lebih robust dan mengurangi kemungkinan bias dalam evaluasi

Perbandingan ini menunjukkan bahwa meskipun model U-Net dalam penelitian ini mencapai akurasi yang tinggi, pendekatan yang lebih kompleks seperti DAU-Net dapat menawarkan keunggulan dalam menangani tantangan spesifik dalam segmentasi tumor payudara pada citra ultrasound. Oleh karena itu, penelitian ini memberikan kontribusi penting dengan menunjukkan efektivitas model U-Net dalam konteks dataset yang terbatas dan membuka peluang untuk pengembangan lebih lanjut dengan mengintegrasikan mekanisme perhatian untuk meningkatkan akurasi segmentasi.

## V. KESIMPULAN

Berdasarkan hasil penelitian ini, dapat disimpulkan bahwa metode U-Net membuktikan ke efektifannya dalam melakukan segmentasi tumor payudara pada citra ultrasound ( USG ), menghasilkan keluaran yang lebih presisi.

Temuan ini memiliki dampak positif terutama dalam konteks praktik medis, di mana dokter spesialis tumor dan profesional medis lainnya dapat mengandalkan referensi yang lebih akurat untuk mendiagnosis dan memahami perkembangan penyakit tumor. Keakuratan segmentasi yang diberikan oleh U-Net memberikan nilai tambah dalam memahami struktur dan konteks visual dari citra USG, memungkinkan para profesional medis untuk membuat keputusan yang lebih informasional dan tepat. Keseluruhan, penelitian ini menggambarkan potensi besar U-Net dalam meningkatkan pemahaman dan implementasi teknologi di bidang medis, membawa manfaat signifikan dalam perawatan dan pemantauan kehamilan serta memberikan kontribusi positif terhadap pengembangan ilmu kedokteran. Sebagai rekomendasi untuk penelitian mendatang, disarankan untuk mengimplementasikan upaya-upaya yang bertujuan meningkatkan akurasi segmentasi. Hal ini dapat dicapai dengan melibatkan dataset yang lebih besar, memastikan representativitas yang lebih baik dari variasi kondisi dan karakteristik citra. Selain itu, eksplorasi terhadap metode-metode terbaru dalam pengembangan visualisasi citra medis dapat menjadi langkah yang bermanfaat. Penggunaan teknologi terkini dan pendekatan inovatif dalam pengolahan citra dapat membuka peluang untuk meningkatkan ketelitian dan ketepatan hasil segmentasi. Selanjutnya, penelitian dapat fokus pada integrasi teknik-teknik machine learning atau deep learning yang baru dan telah terbukti efektif dalam meningkatkan performa segmentasi pada konteks citra medis. Dengan demikian, hasil penelitian selanjutnya diharapkan dapat memberikan kontribusi signifikan dalam mengatasi tantangan dan memajukan bidang segmentasi citra medis.

#### DAFTAR PUSTAKA

- [1] Agung and Adisusilo, A.K. (2020) 'Pemanfaatan 3D U-Net untuk Segmentasi 3 Dimensi Gelembung Penyebab Kanker Paru-paru (Nodule) pada Lapisan Citra CT Scan', Journal of Intelligent System and Computation, 2(2), pp. 74–85. Available at: <https://doi.org/10.52985/insyst.v2i2.159>
- [2] Al-Dhabyani, W. et al. (2020) 'Dataset of breast ultrasound images', Data in Brief, 28, p104863. Available at: <https://doi.org/10.1016/j.dib.2019.104863>
- [3] Alfari, H.M. (2020) 'Mengenal Perbedaan Artificial Intelligence, Machine Learning, Neural Network & Deep Learning (Part II)', 21 March 2020, pp. 1–1. Available at: [http://sistem-komputer.s1.stekom.ac.id/informasi/baca/Mengenal-Perbedaan-Artificial-Intelligence-Machine-Learning-Neural-Network-Deep-Learning-Seri-3/a115e35a62282ce8927b9bf6b0d4261fda07051c%0Ahttps://medium.com/@hai\\_qalmuhamadalfari/mengenal-perbedaan-a](http://sistem-komputer.s1.stekom.ac.id/informasi/baca/Mengenal-Perbedaan-Artificial-Intelligence-Machine-Learning-Neural-Network-Deep-Learning-Seri-3/a115e35a62282ce8927b9bf6b0d4261fda07051c%0Ahttps://medium.com/@hai_qalmuhamadalfari/mengenal-perbedaan-a)
- [4] Ayana, G., Dese, K. and Choe, S. (2021) 'Transfer Learning in Breast Cancer Diagnoses via', Transfer Learning in Breast Cancer Diagnoses via Ultrasound Imaging, pp. 1–15
- [5] Badawy, S.M. et al. (2021) 'Automatic semantic segmentation of breast tumors in ultrasound images based on combining fuzzy logic and deep learning — A feasibility study'. Available at: <https://doi.org/10.1371/journal.pone.0251899>.
- [6] Byra, M. et al. (2020) 'Breast mass segmentation in ultrasound with selective kernel U-Net convolutional neural network', Biomedical Signal Processing and Control, 61. Available at: <https://doi.org/10.1016/j.bspc.2020.102027>.
- [7] Darenoh, N.V. et al. (2014) 'Segmentasi Semantik Citra Dengan Convolutional Neural Network Menggunakan Arsitektur U-Net', Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK), x, No. x(30), p. 2. Available at: <https://doi.org/10.25126/jtiik>.
- [8] Diah Irawati, P.A. and Hermawati, F.A. (2022) 'Klasifikasi Kanker Payudara Berbasis Citra Ultrasound Menggunakan Metode Transfer Learning Canny'
- [9] Fadlur Rochman and Junaedi, H. (2020) 'Implementasi Transfer learning Untuk Identifikasi Ordo Tumbuhan Melalui Daun', jurnal Health Sains, 1(6), pp. 672– 679. Available at: <https://doi.org/10.46799/jsa.v1i6.103>.
- [10] Gongping Chen, Lei Li, Yu Dai, Jianxun Zhang, and Moi Hoon Yap (2022) AAU-net: An Adaptive Attention U-net for Breast Lesions Segmentation in Ultrasound Images, IEEE transactions on medical imaging.
- [11] Narinder Singh Punn\*, Sonali Agarwal (2022) RCA-IUnet: A residual cross-spatial attention guided inception U-Net model for tumor segmentation in breast ultrasound imaging
- [12] Donya Khaledeyan\*, Thomas J. Marini, Timothy M. Baran, Avicé O'Connell, Kevin Parker (2023) Enhancing breast ultrasound segmentation through fine-tuning and optimization techniques: Sharp attention UNet
- [13] Jiadong Chen, Xiaoyan Shen, Yu Zhao, Wei Qian, He Ma, Liang Sang (2024) Attention gate and dilation U-shaped network (GDUNet): an efficient breast ultrasound image segmentation network with multiscale information extraction
- [14] Golla Madhu, Avinash Meher Bonasi, Sandeep Kautish, Abdulaziz S. Almazyad, Ali Wagdy Mohamed, Frank Werner, Mehdi Hosseinzadeh and Mohammad Shokouhifar (2024) UCapsNet: A Two-Stage Deep Learning Model Using U-Net and Capsule Network for Breast Cancer Segmentation and Classification in Ultrasound Imaging
- [15] Payel Pramanik, Ayush Roy, Erik Cuevas, Marco Perez-Cisneros, Ram Sarkar (2024) DAU-Net: Dual attention-aided U-Net for segmenting tumor in breast ultrasound images
- [16] Bray F, Ferlay J, Soerjomataram I, Siegel RL, Torre LA, Jemal A. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. CA: a cancer journal for clinicians. 2018; 68(6):394–424
- [17] Pramanik P, Mukhopadhyay S, Kaplun D, Sarkar R. A deep feature selection method for tumor classification in breast ultrasound images. In: International conference on mathematics and its applications in new computer systems. Springer; 2021. p. 241–252.
- [18] Muhammad M, Zeebaree D, Brifcani AMA, Saeed J, Zebari DA. Region of interest segmentation based on clustering techniques for breast cancer ultrasound images: A review. Journal of Applied Science and Technology Trends. 2020; 1(3):78–91. <https://doi.org/10.38094/jastt20201328>
- [19] Huang Q, Luo Y, Zhang Q. Breast ultrasound image segmentation: a survey. International journal of computer assisted radiology and surgery. 2017; 12:493–507. <https://doi.org/10.1007/s11548-016-1513-1>
- [20] Oktay O, Schlemper J, Folgoc LL, Lee M, Heinrich M, Misawa K, et al. Attention u-net: Learning where to look for the pancreas. arXiv preprint arXiv:180403999. 2018;