

BAB II TINJAUAN PUSTAKA

Penulis mencari literatur untuk penelitian yang relevan dan menggunakan temuan tersebut sebagai panduan untuk penyelidikan mereka sendiri. Tema penulis yaitu Analisis Kinerja Segmentasi Tumor Hati Menggunakan Citra *CT-Scan* dengan Metode *Attention U-Net* dan *Active Contour*, didukung oleh sejumlah sumber baik berupa artikel maupun tesis. Berikut adalah beberapa sumber yang dapat digunakan ketika melakukan penelitian:

2.1 Penelitian Yang Relevan

Berikut beberapa penelitian terdahulu dengan teori yang relevan sebagai pembanding serta pedoman dalam memahami dan merancang metode penelitian yang akan digunakan.

Penelitian pertama yang berjudul “***Breast Tumor Detection Via Active Contour Technique***” oleh (Radhi & Kamil, 2021). The mammography tumor segmentation technique is very difficult because of the irregularities in the tumor-payudara contrast between the surrounding payudara jaringan and the tumor, especially when the little tumor is present and not clearly visible at the jaringan's edge. Algorithm segmentation frequently fails to identify the tumor's location during an attempt to determine its location. To segment as a tingkat tinggi technology for batas penetration, kontur aktif digunakan secara luas. The ultimate goal is to provide a clear contrast between the normal and tumorous regions. In this study, two approaches to active contour are presented: graphical and set level. The method is applied to all abnormal mammography images that are extracted from the mini-MIAS database. The first segmentation method indicates the degree of overlap in this type of image, whereas subsequent segmentation methods are able to segment every mammography tumor. The most common method is the Chan-Vese method.

Penelitian kedua yang berjudul “***COVID-19 Lesion Segmentation Using Lung CT Scan Images: Comparative Study Based on Active Contour Models***” oleh (Akbari et al., 2021). Pneumonia is a respiratory infection that affects every member of the human body. In this case study, we used a CT scan as one of the successful methods for gambar segmentation in order to assess the effectiveness of the ACM model for pneumonia caused by the Corona virus (COVID-19). Comparisons have been made between the work

methods and the final methods that are carried out using data from paru-paru CT scan images. This guide helps readers identify the starting point for analysis in the COVID-19 model's dynamic contraction, which is a top priority for researchers and practitioners. Finally, the experiment's results show that the active contour method achieves the desired results when there are not enough images to use the method based on direct instruction as one of the most effective tools for image segmentation.

Penelitian ketiga yang berjudul “ ***Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture***” oleh (Djohar, Desiani, Dwi Putri, et al., 2022). Liver segmentation is usually done manually using a sinar-x. This manual detection method takes a long time to yield analysis results. Segmentation is a technique used in the picture enlargement process that transfers images to the object and border regions. Deep learning applications can be used to assist with medical segmentation. One popular deep learning method used for segmentation is called U-Net CNN. U-Net CNN has two parts, an encoder and a decoder, which are used to perform citra segmentation. This study uses U-Net CNN to do segmentation on the heart data. The work output of the U-Net CNN on the cornea is quite good, with a 99% accuracy and 99% sensitivity achieved. Specialization score of 99%, F1 score of 98%, Jacard coefficient of 96.46%, and DSC percentage of 98%. Performance that results from observation.

Penelitian keempat yang berjudul “ ***A Comprehensive Review Of The Methods Of Diagnosing And Predicting Liver Diseases Using Smart Methods***” oleh (Farahi & Derakhshanfard, 2025). Abstract Liver diseases are among the most significant health problems for humanity, and quick and accurate diagnosis is essential for effective treatment. Nowadays, machine learning and artificial intelligence algorithms play an important role in enhancing the accuracy of diagnosing and predicting these diseases. The aim of this study is to systematically review the intelligent methods used in the diagnosis and prediction of liver diseases. First, the types of liver diseases and the importance of their early diagnosis are introduced, followed by a review of algorithms and the categorization of machine learning and artificial intelligence methods in this field. The application of medical data and liver images for training and evaluating these algorithms is also examined in detail, and the criteria for selecting the optimal diagnostic method are explained. In the end, the results and effectiveness of various approaches are compared, and suggestions for enhancing future research are provided. This article can serve as a

comprehensive and practical reference for researchers in the field of intelligent diagnosis of liver diseases.

Penelitian kelima yang berjudul “*Automated left atrial time-resolved segmentation in MRI long-axis cine images using active contours*” oleh (Gonzales et al., 2021). In order to evaluate atrial size and function—which are crucial imaging biomarkers for a number of cardiovascular disorders, such as atrial fibrillation, stroke, and diastolic dysfunction—the left atrium (LA) must be segmented. At the moment, LA segmentation is done manually, which takes time and depends on the observer. This work provides an automated image processing approach that uses active contours to perform time-resolved LA segmentation in long-axis cine cardiac magnetic resonance imaging (MRI) images of the 2-chamber (2ch) and 4-chamber (4ch) perspectives. Mitral valve tracking, automatic threshold calculation, edge detection on a radially resampled image, edge tracking based on Dijkstra's method, and post-processing involving interpolation and smoothing are all combined in the suggested algorithm. Thirty-seven individuals, mostly diagnosed with paroxysmal atrial fibrillation, underwent algorithm evaluation. Dice similarity coefficient (DSC) and Hausdorff distance (HD) were used to measure the accuracy of the segmentation, with manual segmentations in all time frames serving as the benchmark. A second observer manually segmented each subject's end-diastole and end-systole for the purpose of conducting an inter-observer variability study. High performance in LA segmentation in long-axis cine sequences was attained by the automated technique that was suggested; the DSC for 2-ch and 4-ch was 0.96, while the HD for 2-ch and 4-ch was 6.4 mm. The mean DSC and mean HD of the manual inter-observer variability study were 0.95 and 4.9 mm, respectively. In summary, the automated approach that was suggested was able to perform on par with human specialists who analysed MRI pictures to determine the size and function of the atrium.

Penelitian keenam yang berjudul “*Medical Image Segmentation with active contour and optimization Techniques*” oleh (Hussein & Mosa, 2022). The principal aim is to improve medical diagnosis through segmented images. Thus, medical image segmentation become one of the key technologies in computer-aided diagnosis. Active contours, or snakes, have been widely used for image segmentation purposes. However, high noise sensitivity and poor performance over weak edges are the most acute issues that hinder the segmentation accuracy of these curves, particularly in medical images. To

overcome these issues, a novel external force that integrates gradient vector flow (GVF) field forces and the traditional snake function is proposed in this research. In addition, a novel technique is applied to limit the boundary of the initial contour by set four initial points around the medical issue and then connecting them by polynomial curves. Moreover, the positive effect of Particle Swarm Optimization (PSO) on calculating the final active contour area and its percentage to the entire image area is proved in this work.

Penelitian ketujuh yang berjudul ***“Optimizing Liver Cancer Detection: Leveraging Gabor Features and Machine Learning for Enhanced Abdominal CT Image Segmentation”*** oleh (Faheem et al., 2025). This study proposes an advanced approach that integrates Gabor Features (GF) with three distinct machine learning algorithms—Random Forest (RF), Support Vector Machine (SVM), and Deep Neural Networks (DNN)—for more efficient liver and tumour segmentation. The GF-based texture data is designed to maintain consistency and homogeneity across different slices of the liver, improving the accuracy of segmentation. In the first phase, pixel-level features are extracted using a series of Gabor filters, capturing the intricate texture of the liver. Subsequently, three classifiers (RF, SVM, and DNN) are employed on the GF data to segment the liver from the CT image. In the final phase, tumour segmentation is performed on the liver region using the same features and classifiers. The Gabor filter's analogy to the human visual system enhances the method's robustness and performance, ensuring accurate pixel-wise segmentation. The proposed model demonstrates superior potential for liver cancer detection, offering a promising tool for clinical diagnosis and decision- making.

Penelitian kedelapan yang berjudul ***“Segmentasi Dengan Metode Active Contour Untuk Peningkatan Akurasi Klasifikasi Citra Usg Kanker Payudara Menggunakan K-Nearest Neighbor (Knn)”*** oleh (Menggunakan & Knn, 2025). Dalam penelitian ini, metode Grayscale, Median Filtering, dan Aktif Kontur diadopsi untuk mengidentifikasi morfologi kanker dalam citra, sementara proses klasifikasi menggunakan metode K-Nearest Neighbor dengan ekstraksi fitur melalui Gray Level Co-Occurrence Matrix untuk menganalisis tekstur kanker. Temuan dari penelitian ini menegaskan bahwa proses aktif kontur digunakan untuk melihat morfologi kanker, diikuti dengan pemotongan citra asli sesuai dengan kontur yang dihasilkan. Selain itu, hasil pengujian K-Nearest Neighbor pada K=18 dengan pembagian data 90% untuk Data Training dan 10% untuk Data Uji

menggunakan K-Fold Cross Validation, menunjukkan akurasi algoritma sebesar 68% yang diperoleh melalui Confusion Matrix.

Penelitian kesembilan yang berjudul “**Arsitektur *U-Net* pada Segmentasi Citra Hati sebagai Deteksi Dini Kanker *Liver***” oleh (Naraloka et al., 2022) Hati adalah organ yang paling vital dalam tubuh manusia. Sebelum darah disalurkan ke area lain di dalam tubuh, hati menyaring darah dari saluran pencernaan dan memecah, menyerap, dan memproses makanan. Kanker hati adalah salah satu dari sekian banyak kondisi yang membuat hati rentan. Untuk itu, diperlukan identifikasi atau deteksi dini penyakit hati. Segmentasi hati yang dilakukan pada penelitian ini menggunakan pendekatan *Convolutional Neural Network (CNN)* dengan arsitektur *U-Net* pada citra hati. Penelitian ini diawali dengan penggunaan teknik green channel, contrast limited adaptive histogram equalization (*CLAHE*), dan histogram equalization (*HE*). Proses segmentasi kemudian dilakukan dengan cara yang direkomendasikan. Kumpulan data hati yang dikumpulkan melalui situs web Kaggle digunakan dalam investigasi ini. Hasilnya menunjukkan tingkat akurasi 97,62%, sensitivitas 89,84%, spesifisitas 98,37%, koefisien jaccard 76,99%, dan koefisien kesamaan dadu (*DSC*) 87% dari metode *CNN* arsitektur *U-Net*. Temuan ini menunjukkan segmentasi dataset hati yang unggul yang dapat dicapai dengan pendekatan yang direkomendasikan.

Penelitian kesepuluh yang berjudul “**Pendekatan Berbasis *U-Net* Untuk Segmentasi *Hard Exudate* Dalam Citra Fundus Retina**” (Antara, 2023) Menurut perkiraan WHO (*World Health Organization*), 422 juta orang di atas usia 18 tahun di seluruh dunia menderita diabetes pada tahun 2014. World Diabetes Foundation memproyeksikan bahwa pada tahun 2030, akan ada lebih dari 439 juta orang di seluruh dunia yang mengidap diabetes, yang memperkuat statistik ini. Salah satu kondisi yang disebabkan oleh diabetes adalah retinopati diabetik, yang dapat mengakibatkan gangguan penglihatan hingga kebutaan. Eksudat adalah bercak darah berwarna kekuningan yang terbentuk secara tidak normal dan mengandung lemak; ini merupakan tanda adanya cedera pada pembuluh darah dan serabut saraf di mata. Pada gambar fundus retina, dokter mata masih harus mencari dan memeriksa eksudat keras secara manual. Penelitian ini memajukan segmentasi eksudat keras menggunakan pendekatan *U-Net* dengan mengevaluasi nilai metrik untuk akurasi, sensitivitas, dan spesifisitas. Penelitian ini menggunakan dataset gambar diabetes retina India (*IDRiD*), yang terdiri dari 81 foto: 54

gambar pelatihan dan 27 gambar pengujian. Ada dua bagian dalam perjalanan penelitian ini. Penilaian Model dan Pelatihan: Berbagai dataset foto digunakan dalam pelatihan model untuk membuat model yang terlatih, dan prosesnya juga melibatkan validasi untuk menilai kebenaran model. Dengan menggunakan dataset foto yang tidak digunakan untuk pelatihan, model yang telah dilatih juga diuji sebagai bagian dari proses pelatihan model. Nilai metrik *U-Net* untuk hasil segmentasi eksudat keras adalah 0,993, 0,454, dan 0,997, dengan urutan tersebut.

Penelitian kesebelas yang berjudul “**Arsitektur *U-Net* Pada Segmentasi Citra Paru Untuk Mendeteksi Nodul Paru**” oleh (Ningsih, 2025). Arsitektur *U-Net* dirancang untuk mengatasi kendala jumlah data yang terbatas, terutama dalam bidang medis. Dengan struktur encoder-decoder yang simetris, *U-Net* mampu mengekstraksi fitur penting dari citra input melalui encoder dan merekonstruksi citra sambil mempertahankan detail spasial melalui koneksi skip. Dalam segmentasi citra paru, *U-Net* digunakan untuk mendeteksi dan memetakan nodul paru secara otomatis dari CT scan. Penerapan *U-Net* diharapkan dapat mengurangi beban kerja ahli radiologi, meningkatkan konsistensi diagnosis, dan mempercepat proses deteksi nodul. Pada penelitian ini, *U-Net* mencapai akurasi sebesar 94% dalam segmentasi nodul paru.

Penelitian kedua belas yang berjudul “***Enhancing U-Net With Spatial-Channel Attention Gate For Abnormal Tissue Segmentation In Medical Imaging***” (Khanh et al., 2020) Penelitian ini memperkenalkan gerbang perhatian saluran spasial unik yang didesain untuk mengatasi kelemahan koneksi lompatan sederhana. Hal ini dapat dengan cepat dan mudah dimasukkan ke dalam jaringan encoder-decoder untuk meningkatkan kinerja tugas segmentasi gambar. Hasil yang komprehensif menunjukkan bahwa hanya dengan sedikit tambahan overhead komputasi, gerbang perhatian saluran spasial secara signifikan meningkatkan kemampuan segmentasi arsitektur *U-Net*. Menurut data eksperimen, pendekatan yang disarankan berkinerja lebih baik daripada jaringan dalam tradisional dalam hal skor Dice, mencapai 71,72%.

Penelitian ketiga belas yang berjudul “**Penerapan *Hyperparameter Convolutional Neural Network (CNN)* Dalam Membangun Model Segmentasi Gambar Menggunakan Arsitektur *U-Net* Dengan *Tensorflow***” (Sulistiyorini et al., 2023) Saat ini, teknologi mutakhir bergantung pada kemampuan atau hasil yang luar biasa, terutama

ketika menggunakan teknik pembelajaran mesin. Artificial Neural Networks (ANN), di mana Convolutional Neural Networks (CNN) sekarang menjadi salah satu arsitektur terbaik, merupakan hasil dari kemajuan di bidang pembelajaran mesin. Tujuan dari proyek ini adalah untuk menggunakan CNN-khususnya, U-Net di TensorFlow-untuk menyegmentasi gambar menggunakan pembelajaran mendalam. Studi ini menilai prediksi yang dibuat oleh arsitektur U-Net menggunakan Oxford-IIIT Pet Dataset, dengan fokus pada identifikasi kelas kucing dengan nilai Intersection over Union (IOU) sebesar 0,933. CNN, pembelajaran mesin, dan arsitektur U-Net-yang pada awalnya dibuat untuk segmentasi gambar biologis-semuanya dimasukkan ke dalam metodologi penelitian. Perbandingan skor IOU antara True Mask dan Predicted Mask pada kelas kucing memenuhi kriteria minimum 0,5 dalam IOU, yang menunjukkan kinerja yang kuat dalam prediksi.

Penelitian keempat belas yang berjudul *“Liver Segmentation Using Convolutional Neural Network Method with U-NetArchitecture”* (Djohar, Desiani, Putri, et al., 2022) Kanker hati adalah salah satu gangguan pada hati yang dapat diidentifikasi melalui kelainan hati. Segmentasi diperlukan untuk membuang jaringan hati yang terkena dampak untuk mendeteksi kelainan pada hati. Segmentasi hati sering kali dilakukan dengan tangan menggunakan sinar-x, dan prosesnya memakan waktu. Segmentasi adalah teknik yang digunakan dalam pemrosesan gambar yang memisahkan gambar menjadi objek dan latar belakang. U-Net CNN adalah teknik pembelajaran mendalam yang populer untuk segmentasi gambar medis. Encoder dan decoder, yang membentuk U-Net CNN, adalah komponen yang digunakan untuk segmentasi gambar. U-Net CNN digunakan dalam penelitian ini untuk mensegmentasi gambar data hati. Nilai kinerja yang dicapai meliputi akurasi 99%, sensitivitas 99%, dan spesifisitas 99%. F1-Score sebesar 98%, Jaccard Coefficient sebesar 96,46%, dan DSC sebesar 98%. Secara keseluruhan, program U-Net CNN mampu mengelompokkan kelainan hati dengan kapasitas yang sangat baik dan kuat, dengan kinerja rata-rata di atas 95%. Namun, klasifikasi berbagai penyakit yang dapat mempengaruhi hati tidak dipertimbangkan dalam penelitian ini, melainkan hanya berkonsentrasi pada segmentasi gambar hati. Hasilnya, hasil segmentasi dari program U-Net CNN dapat digunakan dalam penelitian di masa depan untuk mengkategorikan berbagai penyakit hati.

Penelitian kelima belas yang berjudul “**U-Net combined with multi-scale attention mechanism for liver segmentation in CT images**” oleh (Wu et al., 2021). Untuk mendukung segmentasi hati otomatis dalam konteks klinis, makalah ini mengusulkan jaringan berbentuk U dengan mekanisme attention multi-skala untuk segmentasi organ hati pada citra CT, yang disebut MSA-UNet. Metode kami menghadirkan desain baru untuk komponen encoder, decoder, skip connection, dan struktur transisi konteks pada arsitektur U-Net. Struktur-struktur ini secara signifikan meningkatkan kemampuan ekstraksi fitur pada encoder serta efisiensi decoder dalam memulihkan informasi lokasi spasial. Kami telah merancang berbagai eksperimen menggunakan dataset yang tersedia untuk umum guna menunjukkan efektivitas MSA-UNet. Dibandingkan dengan beberapa metode segmentasi canggih lainnya, MSA-UNet pada akhirnya mencapai hasil segmentasi terbaik, dengan nilai Dice Similarity Coefficient (DSC) sebesar 98,00% dan *Intersection over Union* (IoU) sebesar 96,08%.

2.1.1 Matriks Penelitian

Tabel 2. 1 Matriks Penelitian

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
1.	(Radhi & Kamil, 2021)	Breast Tumor Detection Via Active Contour Technique	Citra Mammogram	Database mini-MIAS	Active Contour	Namun, untuk mengidentifikasi kanker hati dengan menggunakan citra imaging, terutama pada teknik CT-Scan, menghasilkan data citra hati yang juga menampilkan organ lain seperti pankreas, empedu, dan ginjal, sehingga dapat mempersulit diagnosis kanker hati. Penelitian ini bertujuan mengembangkan metode segmentasi tumor payudara pada

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						citra mammogram menggunakan teknik active contour. Dua mengembangkan metode segmentasi tumor payudara pada citra mammogram menggunakan teknik active contour. Dua pendekatan active contour yang digunakan adalah snakes dan level sets. Metode yang diusulkan diterapkan pada citra mammogram abnormal dari database mini-MIAS. Evaluasi statistik menunjukkan bahwa metode Chan-Vese batas dan lokasi tumor pada citra mamografi
2.	(Akbari et al., 2021)	COVID-19 Lesion Segmentation Using Lung CT Scan Images: Comparative Study Based on Active Contour Models	Ct Scan	The research uses lung CT scan images to investigate the effectiveness of active contour models (ACMs) for segmentation of pneumonia caused by	Clustering-based methods, Graph-cut-based methods, Neural network-based (deep learning) methods, dan Active contour	Penelitian ini membandingkan kinerja beberapa metode segmentasi berbasis active contour models (ACMs) untuk mendeteksi lesi akibat infeksi COVID-19 pada citra CT scan paru-paru. Hasil eksperimen menunjukkan metode berbasis ACMs mencapai hasil yang menjanjikan, terutama ketika data citra tidak cukup untuk menggunakan metode deep learning. Hal ini penting

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
				COVID-19.	model (ACM) methods.	karena diagnosis COVID-19 menghadapi tantangan di mana tes RT-PCR memiliki sensitivitas lebih rendah daripada tes CT scan, tetapi analisis hasil CT scan oleh radiolog masih memakan waktu lama.
3.	(Djohar, Desiani, Dwi Putri, et al., 2022)	Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture	Citra Rontgen	Global Cancer Statistic	U-Net Convolutional Neural Network (U-Net CNN)	Penelitian ini menggunakan metode U-Net CNN untuk segmentasi citra hati. U-Net CNN terbukti sangat efektif dalam segmentasi kelainan hati, dengan kinerja rata-rata di atas 95%, akurasi 99%, sensitivitas 99%, spesifisitas 99%, F1-Score 98%, koefisien Jaccard 96,46%, dan DSC 98%.
4.	(Farahi & Derakhshanfard, 2025)	A comprehensive review of the methods of diagnosing and predicting liver diseases using smart methods	Ct Scan	Global Cancer Statistic	(Neural network-based (deep learning) methods, dan Active contour)	This study presents a systematic overview of the application of machine learning and artificial intelligence methods for the diagnosis and prediction of liver disease. Various algorithms, medical data, and liver images are compared to evaluate their effectiveness in enhancing diagnostic accuracy. The findings demonstrate that artificial intelligence

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						technology holds significant potential for supporting faster and more accurate liver disease diagnosis and offer recommendations for future research.
5.	(Gonzales et al., 2021)	Automated left atrial time-resolved segmentation in MRI long-axis cine images using active contours	citra MRI (magnetic resonance imaging)	37 pasien yang sebagian besar didiagnosis dengan fibrilasi atrium paroksismal.	Active Contour	Studi ini menyajikan metode segmentasi otomatis untuk segmentasi LA yang tergantung waktu pada citra MRI jangka panjang tampilan 2ch dan 4ch menggunakan active contours. Metode ini mencapai kinerja sebanding dengan ahli dalam menganalisis citra MRI untuk evaluasi ukuran dan fungsi atrium. Metode ini membantu mengatasi keterbatasan segmentasi manual yang memakan waktu dan bergantung pada pengamat, sehingga mempercepat evaluasi ukuran dan fungsi atrium kiri pada pasien dengan berbagai kondisi kardiovaskular
6.	(Hussein & Mosa, 2022)	Medical Image Segmentation with active contour	Citra MRI (Magnetic Resonance Imaging) dan CT (Computed Tomography).	Ct Kidney Dataset	Active contour	Jurnal ini menyimpulkan bahwa pendekatan yang diusulkan, menggunakan active contour yang diperbaharui dengan gaya vektor gradient (GVF) dan fungsi

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
		and optimizati on Technique s				snake tradisional, serta teknik baru untuk membatasi kontur awal, meningkatkan akurasi segmentasi citra medis. Selain itu, penerapan PSO untuk menghitung luas area active contour memberikan efek positif. Hasil ini menunjukkan potensi metode ini dalam meningkatkan diagnosis medis melalui citra medis yang tersegmentasi.
7.	(Faheem et al., 2025)	Optimizing Liver Cancer Detection: Leveraging Gabor Features and Machine Learning for Enhanced Abdominal CT Image Segmentation	CT scan	Data citra medis	Active Contour	Jurnal menyimpulkan bahwa Penelitian ini mengusulkan metode segmentasi otomatis untuk mendeteksi kanker hati pada citra CT scan dengan menggabungkan fitur Gabor (Gabor Features) dan tiga algoritma machine learning, yaitu Random Forest (RF), Support Vector Machine (SVM), dan Deep Neural Network (DNN). Fitur Gabor digunakan untuk mengekstraksi tekstur hati sehingga meningkatkan konsistensi dan akurasi segmentasi. Hasil penelitian menunjukkan variasi bentuk dan ukuran tumor serta kualitas citra yang buruk.

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						Evaluasi pada database LIDC menunjukkan nilai Dice similarity sebesar 84,88%, lebih baik dibandingkan metode state-of-the-art lainnya.
8.	(Menggunakan & Knn, 2025)	Segmentasi Dengan Metode Active Contour Untuk Peningkatan Kanker Payudara Menggunakan K-Nearest Neighbor (Knn)	CT Scan, MRI, USG	Data citra medis	Gray Level Co-Occurrence Matrix (GLCM) K-Nearest	Penelitian menggunakan metode Grayscale, Median Filtering, dan Active Contour untuk memperoleh morfologi kanker melalui proses segmentasi. Setelah area kanker diperoleh, citra dipotong berdasarkan kontur hasil segmentasi dan dilakukan ekstraksi fitur menggunakan GLCM. Selanjutnya klasifikasi dilakukan dengan K-Nearest Neighbor (KNN). Hasil terbaik diperoleh pada K = 18 dengan pembagian
9.	(Naraloka et al., 2022)	Arsitektur <i>U-Net</i> pada Segmentasi Citra Hati sebagai Deteksi Dini Kanker Liver	CT-Scan	Kaggle	U-Net	Arsitektur U-Net telah menunjukkan hasil yang baik untuk segmentasi gambar hati, dengan parameter evaluasi kinerja untuk akurasi dan spesifisitas di atas 95%, sensitivitas dan nilai DSC di atas 85%, dan nilai koefisien Jaccard yang tersisa di sekitar 80%. Temuan ini menunjukkan seberapa baik arsitektur U-Net dapat mengantisipasi hasil dari objek hitam

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						(latar belakang) dan objek putih (hati) dalam segmentasi gambar hati.
10.	(Putra et al., 2023)	PENDEKATAN BERBASIS U-NET UNTUK SEGMENTASI HARD EXUDATE DALAM CITRA FUNDUS RETINA	citra fundus diabetic retinopathy	Dataset citra retina yang digunakan berasal dari himpunan data yang sudah tersedia di Indian Diabetic Retinopathy Image Dataset (IDRiD)	U-Net	Sebanyak 81 foto fundus retina RGB digunakan dalam metode yang kami sarankan: 54 digunakan dalam set pelatihan, 14 digunakan dalam set validasi, dan 13 digunakan dalam set pengujian. Ketika tidak ada lagi peningkatan kehilangan validasi selama fase pelatihan, proses pelatihan secara otomatis berakhir pada epoch ke-55. Hasil pelatihan menunjukkan bahwa akurasi adalah 0.997, loss 0.307, akurasi validasi 0.989, dan loss validasi 0.554. Mengikuti prosedur pelatihan dan akuisisi model pelatihan, hasil segmentasi dari model pelatihan dinilai untuk akurasi (0.993), sensitivitas (0.454), dan spesifisitas (0.997) dengan membandingkannya dengan groundtruth. Hasil ini menunjukkan bahwa, jika dievaluasi dari nilai akurasi dan spesifisitas, yang mendapatkan nilai tinggi, metode yang disarankan cukup memadai dalam mensegmentasi eksudat keras. Namun, beberapa foto mendapatkan nilai sensitivitas yang rendah karena foto-foto tersebut kurang baik

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						dalam membedakan antara eksudat keras dan petunjuk visual lainnya.
11.	(Ningsih, 2025)	Arsitektur U-Net Pada Segmentasi Citra Paru Untuk Mendeteksi Nodul Paru	Ct-Scan	Kaggle	U-Net	Metode U-Net efektif untuk melakukan segmentasi nodul paru pada citra CT Scan. Arsitektur encoder-decoder dengan skip connection mampu mempertahankan detail spasial sehingga menghasilkan segmentasi yang baik. Penerapan U-Net dapat membantu radiolog dalam mendeteksi nodul paru secara otomatis, meningkatkan konsistensi diagnosis, mempercepat proses analisis, serta memperoleh akurasi segmentasi sebesar 94%.
12.	(Khanh et al., 2020)	Enhancing U-Net with Spatial-Channel Attention Gate for Abnormal Tissue Segmentation in Medical Imaging	CT-Scan dan MRI	CVC-ClinicDB dataset	U-Net	Hasil yang komprehensif menunjukkan bahwa gerbang perhatian saluran spasial kami secara signifikan meningkatkan kapasitas segmentasi arsitektur U-Net dengan hanya sedikit beban komputasi tambahan. Hasil eksperimen menunjukkan bahwa metode yang kami usulkan mengungguli jaringan dalam konvensional
13.	(Sulistyorini et al., 2023)	Penerapan Hyperparameter Convolutional Neural Network (Cnn)	Ct-Scan dan MRI	The Oxford-IIIT Pet Dataset	U-Net	Berdasarkan temuan penelitian Berdasarkan temuan penelitian, dapat ditarik kesimpulan bahwa hasil prediksi arsitektur U-Net, ketika

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
		Dalam Membangun Model Segmentasi Gambar Menggunakan Arsitektur U-Net Dengan Tensorflow				membandingkan topeng yang diprediksi dengan topeng yang sebenarnya pada kelas kucing, menghasilkan skor IOU 0,933 pada skala batas bawah 0,5.
14.	(Djohar, Desiani, Amran, et al., 2022)	Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture	CT-Scan	Kaggle	U-Net	Akurasi 99% dan sensitivitas 99% dicapai dalam kinerja. Skor F1 adalah 98%, Spesifisitas 99%. DSC adalah 98% dan koefisien Jacard 96,46%. Karena kinerja aplikasi U-Net CNN rata-rata lebih dari 95%, dapat dikatakan bahwa aplikasi U-Net CNN sangat efektif dan kuat dalam mensegmentasi masalah hati.
15.	(Wu et al., 2021)	U-Net combined with multi-scale attention mechanism for liver segmentation in CT images	Ct-Scan	3D-IRCADb,	MSA-UNet (Multi-Scale Attention U-Net)	MSA-UNet berhasil meningkatkan kemampuan segmentasi organ hati pada citra CT Scan melalui penerapan multi-scale attention mechanism, encoder dan decoder yang telah dimodifikasi, serta skip connection yang lebih efektif. Hasil eksperimen menunjukkan bahwa metode ini mengungguli beberapa metode segmentasi lainnya dengan memperoleh Dice Similarity Coefficient (DSC) sebesar 98,00% dan Intersection over Union (IoU) sebesar 96,08%, sehingga

NO.	Nama Peneliti	Judul Penelitian	Jenis Citra	Sumber Data	Ekstrak Fitur	Kesimpulan
						sangat efektif untuk segmentasi hati secara otomatis dan berpotensi membantu proses diagnosis klinis.

Dari 15 penelitian yang ada di atas, terdapat perbedaan dan perbandingan antara penelitian sebelumnya dengan yang penulis buat. Berikut perbedaan dan perbandingan yang di maksud :

1. Penelitian sebelumnya membahas tentang Segmentasi Citra Paru-Paru Menggunakan Metode Kontur Aktif Dengan Validasi Roc.
2. Penelitian sebelumnya membahas tentang Segmentasi Hati Pada Gambar Ct Menggunakan Jaringan Konvolusional Penuh Tiga Dimensi Hingga Dua Dimensi.
3. Penelitian sebelumnya membahas tentang Segmentasi Lesi COVID-19 Menggunakan Gambar CT Scan Paru Studi Banding Berdasarkan Model Kontur Aktif.
4. Penelitian ini berfokus pada proses segmentasi citra CT-Scan kanker hati.
5. Penelitian ini menggunakan ROC (Receiver Operating Characteristic) sebagai pengujian.

2.1 Landasan Teori

Landasan teori akan membahas teori-teori dari studi kepustakaan yang disusun secara sistematis sesuai dengan penelitian ini, termasuk definisi dan penjelasan lengkap secara mendalam. Landasan teori ini diharapkan dapat membuat penelitian menjadi lebih jelas dan terarah.

2.2.1 Kanker Hati

Kanker hati adalah salah satu dari enam kanker yang paling sering didiagnosis dan penyebab kematian akibat kanker kedua yang paling umum di seluruh dunia, yang menyebabkan kematian 758.000 orang pada tahun 2022 (GLOBOCAN, 2022).



Gambar 2. 1 Organ Hati Yang Healty Dan *Cancer* (Endrini et al., 2009)

Kanker hati terjadi karena adanya mutasi (perubahan) pada DNA sel hati dapat mengakibatkan kanker hati. DNA yang ditemukan dalam sel hati mengontrol reaksi dan proses kimia yang terjadi di dalam sel. Mutasi pada DNA sel dapat menyebabkan pertumbuhan dan pembentukan massa yang terlalu cepat. Infeksi hepatitis kronis adalah penyebab utama kanker hati. Seperti infeksi hepatitis B dan hepatitis C adalah jenis kanker hati yang paling umum. (Karim et al., 2024).

A. Faktor Resiko Terjadinya Kanker Hati

Terdapat beberapa faktor risiko terjadinya kanker hati, yaitu:

1. Infeksi kronis hepatitis B atau hepatitis C
2. Sirosis hati (kondisi progresif dan irreversible yang menyebabkan jaringan pada hati berubah menjadi jaringan parut)
3. Beberapa penyakit hati yang diturunkan secara genetik, seperti hemokromatosis dan Wilson's disease
4. Diabetes
5. Perlemakan hati non alkoholik
6. Mengonsumsi alkohol terlalu banyak
7. Paparan aflatoksin (merupakan senyawa beracun yang dihasilkan oleh jenis jamur kapang)

B. Gejala

Kebanyakan orang tidak menyadari gejala awal dari kanker hati. Berikut beberapa gejala yang dapat muncul, yaitu:

1. Penurunan berat badan tanpa penyebab
2. Hilang nafsu makan
3. Nyeri pada perut kanan atas

4. Mual dan muntah
5. Merasa cepat lelah dan lemah
6. Perut membengkak
7. Kulit dan bagian putih mata terlihat kuning (jaundice)
8. BAB atau kotoran berwarna pucat seperti dempul

2.2.2 *Ct-Scan*

Teknologi sinar-X dan pencitraan komputer yang digunakan untuk menghasilkan gambar penampang tubuh disebut gambar *Ct-Scan* (*Computed Tomography scan*). Untuk menghasilkan gambar detail organ, tulang, pembuluh darah, dan jaringan lain di dalam tubuh, rangkaian gambar sinar-X yang diambil dari berbagai sudut di sekitar tubuh digabungkan menggunakan algoritma komputer. Dengan penggunaan *Ct-Scan*, profesional medis dapat mengidentifikasi berbagai macam penyakit, termasuk kanker, patah tulang, infeksi, dan gangguan kardiovaskular, serta mengamati struktur bagian dalam dengan lebih tepat. Dibandingkan dengan sinar-X tradisional, *Ct-Scan* menghasilkan gambar yang lebih detail, yang menawarkan informasi unggul untuk diagnosis dan perencanaan pengobatan. (Fadillah & Rizka Gunawan, 2019).




Gambar 2. 2 Citra *Ct-Scan* (Kuswardani et al., 2011)

2.2.3 Citra Digital

Citra adalah gambar pada bidang dua dimensi dalam tinjauan matematis. Citra digital merupakan Teknik mengolah citra yang bertujuan memperbaiki kualitas citra agar mudah di interpretasi oleh manusia atau mesin komputer yang dapat berupa

foto. Tujuan pemrosesan citra digital adalah untuk meningkatkan kualitas gambar sehingga manusia atau sistem komputer dapat menafsirkannya dengan lebih mudah. Subbidang kecerdasan buatan yang disebut pemrosesan gambar menggunakan representasi digital dari gambar objek untuk memecahkan masalah. Teknik dalam gambar dapat diterapkan secara geometris atau matematis untuk menghitung objek dalam piksel. Setiap item gambar mempunyai nilai perbedaan yang dapat dihitung secara ilmiah yang menggambarkan banyaknya atribut objek dalam kaitannya satu sama lain. Anda dapat mengetahui perbedaan suatu benda dengan benda lain berdasarkan warna, tekstur, atau bentuknya. Pada bidang dua dimensi, suatu bayangan merupakan fungsi kontinu dari intensitas cahaya. (Aplikasi, n.d.).



Gambar 2. 3 Citra Digital Dan Piksel penyusunnya (Rinaldi Munir, 2004)

1. Citra Berwarna

Citra berwarna adalah representasi visual dari gambar yang mengandung informasi tentang warna pada setiap titik atau pikselnya. Gambar berwarna yang sering disebut dengan gambar RGB adalah jenis gambar yang terdiri dari komponen warna merah (*red*), hijau (*green*), dan biru (*blue*), yang dikenal sebagai model warna RGB. Dengan mengkombinasikan berbagai intensitas ketiga warna ini, citra berwarna dapat menampilkan berbagai macam warna yang menyerupai warna asli yang dilihat oleh mata manusia. Citra berwarna digunakan dalam berbagai aplikasi, termasuk fotografi digital, televisi, grafik komputer, dan pengolahan citra digital (Harefa et al., 2024).



Gambar 2. 4 Citra Model Warna RGB (Rinaldi Munir, 2004)

2. Citra Biner

Citra biner adalah citra digital yang hanya memiliki dua nilai piksel, yaitu hitam dan putih. Gambar biner juga dikenal sebagai gambar hitam putih atau gambar monokrom. Citra biner merupakan jenis citra digital yang hanya memiliki dua nilai piksel: 0 dan 1. Nilai-nilai ini biasanya mewakili warna hitam dan putih, di mana 0 biasanya digunakan untuk hitam dan 1 untuk putih. Citra biner digunakan untuk merepresentasikan gambar yang memiliki kontras tinggi dan tidak memerlukan informasi warna atau gradasi abu-abu. Contoh penggunaan citra biner termasuk pemrosesan teks, pengenalan bentuk, dan analisis objek dalam citra digital, seperti dalam aplikasi pemindaian dokumen dan pengenalan karakter optik (OCR) (Febrian et al., 2024).



Gambar 2. 5 Citra Biner (Rinaldi Munir, 2004)

3. Citra *Grayscale*

Citra berskala keabuan (*grayscale*) merupakan citra digital yang hanya memiliki satu nilai pada setiap pikselnya. Nilai komponen merah, hijau, biru, dapat digunakan untuk mendeskripsikan gambar skala abu-abu. Tingkat intensitas ditunjukkan dengan nilai. Warnanya putih, abu-abu, dan hitam. Spektrum warna

abu yang berkisar dari hitam hingga hampir putih disebut tingkat keabuan. Karena gambar skala abu-abu tidak sekompleks gambar berwarna namun menawarkan informasi visual yang cukup untuk berbagai aplikasi, termasuk identifikasi pola, pemrosesan gambar, dan analisis gambar medis, gambar tersebut sering digunakan dalam pemrosesan gambar. (Febrian et al., 2024).



Gambar 2. 6 Citra *Grayscale* (Rinaldi Munir, 2004)

2.2.4 Inverse

Inverse citra adalah proses penerapan efek negatif pada suatu gambar, di mana setiap nilai intensitas piksel dibalik atau diinvers menggunakan ambang batas yang ditentukan. Proses ini sering digunakan pada gambar medis seperti *Ct-Scan* dan *USG* (Rosalina & Agustin, 2019).

Proses *inverse* citra didefinisikan dengan :

$$X_n = 255 - x \dots\dots\dots(2.1)$$

Keterangan ;

X = nilai derajat keabuan

X_n = nilai hasil *inverse* citra



Gambar 2. 7 (a) citra asli, (b) Citra setelah proses Inverse (Rinaldi Munir, 2004)

2.2.5 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) adalah teknik pemrosesan gambar yang digunakan untuk meningkatkan kontras lokal dalam sebuah citra digital. Berbeda dengan pendekatan penyetaraan histogram standar, yang memproses gambar secara keseluruhan, CLAHE mempartisi gambar menjadi bagian atau bagian yang lebih kecil yang disebut ubin. CLAHE menghitung tinggi maksimum histogram menggunakan batasan klip. (Hana & Maulida, 2021). Cara menghitung clip limit histogram citra digital dapat didefinisikan dengan persamaan:

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (S_{max} - 1) \right) \dots\dots\dots (2.2)$$

Variabel M menyatakan ukuran luas region, N menyatakan nilai keabuan citra dan α menyatakan clip faktor yang merupakan batas limit histogram. Histogram yang bernilai diatas clip limit akan dianggap kelebihan (excess) piksel yang akan didistribusikan ke area sekitar dibawah clip limit, sehingga histogram menjadi rata (Momeni Pour et al., 2020).

2.2.6 Perenggangan Kontras

Metode pemrosesan gambar yang disebut pereganggan kontras digunakan untuk meningkatkan kontras gambar. Tujuannya adalah untuk memperluas rentang nilai intensitas piksel, sehingga detail dalam citra menjadi lebih terlihat. Teknik ini sangat berguna terutama untuk citra dengan rentang nilai intensitas yang sempit, seperti gambar yang tampak kusam atau terlalu gelap. Kontras menunjukkan distribusi

terang dan gelap dalam sebuah gambar. Tiga kategori kontras dapat diterapkan pada gambar seperti kontras rendah, kontras baik (atau normal), dan kontras tinggi. Seringkali, ketiga kelompok ini dapat dibedakan secara intuitif. (Hatta et al., 2024).

$$Y(n1, n2) = 255 \cdot \frac{X(n1, n2) - X_{min}}{X_{max} - X_{min}} \dots\dots\dots (2.3)$$

Dimana (n1, n2) merupakan posisi koordinat matriks pada citra, simbol X menunjukkan nilai awal dan Y adalah nilai baru. Xmin adalah nilai intensitas warna terendah pada citra asli, sedangkan Xmax adalah nilai intensitas warna tertinggi pada citra asli.

2.2.7 Segmentasi Citra

Segmentasi adalah proses yang memisahkan atau membagi satu objek dari objek lainnya dalam sebuah gambar. Dengan segmentasi, pengguna dapat mengidentifikasi bagian-bagian yang baik dan buruk dari suatu objek pada gambar. Ini merupakan langkah awal dalam analisis citra sebelum melanjutkan ke tahap pengenalan citra dari input tertentu. Seperti yang telah dijelaskan sebelumnya, tujuan segmentasi citra adalah untuk membagi citra menjadi beberapa wilayah berdasarkan kesamaan tekstur, warna, bentuk, dan berbagai atribut lainnya (Fadillah & Rizka Gunawan, 2019).

Teknik segmentasi ini menggunakan diskontinuitas dan kesamaan sebagai tingkat kecerahan gambar. Dalam diskontinuitas, tepi, garis, area, dan sisi gambar sering kali dideteksi dengan mengelompokkan gambar berdasarkan variasi kecerahan yang terlihat. Segmentasi kesamaan biasanya diterapkan pada gambar statis dan dinamis, dan didasarkan pada perbatasan, pertumbuhan wilayah, dan penyebaran wilayah. (Orisa & Hidayat, 2019).




Gambar 2. 8 (a) Citra asli, (b) Citra hasil segmentasi (Rinaldi Munir, 2004)

2.2.8 *U-Net*

U-Net adalah variasi arsitektur CNN yang sering digunakan dalam industri medis untuk segmentasi dalam domain kedokteran. Dua komponen utama dari *U-Net* adalah jalur perluasan, yang mengambil fitur yang dikodekan dan menemukan kecocokan terbaik dengan input utama atau output yang direncanakan, dan jalur kontraksi, yang menggunakan fitur input untuk menghasilkan dimensi yang lebih kecil dari input (Djohar, Desiani, Putri, et al., 2022).

2.2.9




Gambar 2. 9 Arsitektur *U-Net* (Djohar, Desiani, Amran, et al., 2022).

Data input akan melalui jalur encode *U-Net*, yang terdiri dari empat blok konvolusi, berdasarkan Gambar 2.11. Blok konvolusi pertama adalah Max Pooling 2X2, dilanjutkan dengan aktivasi ReLU, kemudian dilanjutkan dengan proses konvolusi 3X3 pada convolutional layer.

Blok konvolusi pertama, yang dimulai dengan Max Pooling 2X2, dilanjutkan dengan aktivasi ReLU, dan menggunakan Persamaan (1) untuk melakukan proses konvolusi 3X3 pada convolutional layer. Selanjutnya, tiga iterasi konvolusi 3X3 dan ReLU dilakukan. Terakhir adalah jalur decode, yang terdiri dari empat blok upsampling konvolusi: konvolusi 2X2 yang ditransposisikan, penggabungan, konvolusi 3X3, dan ReLU. Terakhir, fungsi aktivasi sigmoid diterapkan di seluruh proses decode (Djohar, Desiani, Amran, et al., 2022).

2.2.10 Attention U-Net

Attention *U-Net* merupakan arsitektur yang dikembangkan dari *U-Net* dengan menambahkan mekanisme perhatian (attention mechanism) pada proses segmentasi citra medis. Penambahan mekanisme ini bertujuan agar model dapat lebih memusatkan proses pembelajaran pada bagian citra yang memiliki informasi penting, seperti organ maupun jaringan tumor, sekaligus mengurangi pengaruh dari area yang kurang relevan. Pada *U-Net* konvensional, fitur yang berasal dari bagian *encoder* diteruskan secara langsung menuju *decoder* melalui *skip connection*. Sementara itu, pada *Attention U-Net* terdapat komponen tambahan berupa *Attention Gate* yang berfungsi menyaring dan memberikan bobot terhadap fitur sebelum diteruskan ke bagian *decoder*. Melalui proses tersebut, model dapat lebih efektif mengenali area target sehingga mampu mendukung hasil segmentasi yang lebih baik, terutama pada objek berukuran kecil, memiliki batas yang kurang tegas, atau menunjukkan perbedaan kontras yang rendah terhadap jaringan di sekitarnya. Secara umum, mekanisme *Attention U-Net* dalam proses segmentasi terdiri atas beberapa tahapan utama sebagai berikut (Chen et al., 2026).



Gambar 2. 10 Komponen Attention Mechanism (Chen et al., 2026).

1. Input Citra

Tahapan pertama dilakukan dengan memasukkan citra CT Scan ke dalam jaringan sebagai data masukan. Citra tersebut selanjutnya diproses oleh model untuk memperoleh berbagai informasi visual yang berkaitan dengan karakteristik jaringan hati serta keberadaan area tumor.

2. Convolution dan Aktivasi ReLU

Citra yang telah dimasukkan kemudian melewati sejumlah lapisan konvolusi yang dikombinasikan dengan fungsi aktivasi ReLU. Tahapan ini digunakan untuk mengenali dan mengekstraksi berbagai karakteristik pada citra, seperti tepi (*edges*), tekstur, bentuk, maupun pola tertentu yang dapat membantu model membedakan jaringan normal dan area yang menjadi target segmentasi.

3. **Max Pooling**
Fitur yang diperoleh dari proses konvolusi kemudian melalui tahapan *max pooling*. Proses ini digunakan untuk memperkecil ukuran spasial dari *feature map* dengan tetap mempertahankan informasi yang dianggap dominan. Pengurangan dimensi tersebut juga membantu menekan beban komputasi sehingga proses pembelajaran jaringan menjadi lebih efisien.
4. **Ekstraksi Fitur Bertingkat**
Pada setiap tingkat jaringan, model menghasilkan fitur dengan tingkat kompleksitas yang berbeda. Semakin dalam lapisan jaringan, jumlah *feature map* dapat meningkat, misalnya dari 8, 16, 32 hingga 64 kanal. Lapisan awal cenderung menangkap karakteristik sederhana, sedangkan lapisan yang lebih dalam mampu merepresentasikan pola dan struktur objek yang lebih kompleks.
5. *Attention Gate sebagai Komponen Utama*
Attention Gate merupakan bagian penting pada Attention U-Net yang berfungsi melakukan seleksi terhadap fitur yang diperoleh dari jaringan. Mekanisme ini memberikan bobot perhatian yang lebih tinggi terhadap bagian citra yang dianggap relevan dengan objek target dan mengurangi kontribusi fitur yang berasal dari area yang tidak diperlukan. Dari proses tersebut dihasilkan *attention map* yang menunjukkan tingkat kepentingan setiap bagian citra. Dengan demikian, area seperti tumor dapat memperoleh perhatian yang lebih besar selama proses segmentasi.
6. *Global Weighted Average Pooling*
Fitur yang telah memperoleh pembobotan melalui mekanisme *attention* kemudian dirangkum menggunakan *Global Weighted Average Pooling*. Tahapan ini digunakan untuk menggabungkan informasi penting dari masing-masing fitur berdasarkan bobot yang telah diperoleh, sehingga informasi yang dianggap lebih relevan memiliki kontribusi yang lebih besar. Selain itu, proses tersebut dapat membantu mengurangi dimensi data sebelum diteruskan ke tahapan berikutnya.
7. *Aggregation dan Prediction*
Pada tahap akhir, fitur-fitur yang telah diperoleh dari berbagai tingkat jaringan digabungkan melalui proses *aggregation*. Penggabungan tersebut menghasilkan representasi fitur yang lebih lengkap karena mencakup informasi dari berbagai skala. Representasi tersebut kemudian digunakan oleh jaringan untuk menghasilkan prediksi akhir berupa *mask segmentasi*, yang menunjukkan lokasi serta bentuk area tumor pada citra CT Scan.

2.2.11 Dice Coefficient dan IoU

Dalam penelitian segmentasi citra medis, proses evaluasi dilakukan untuk mengetahui seberapa baik hasil segmentasi yang dihasilkan oleh model dibandingkan dengan *ground truth* sebagai data acuan. Kinerja model dapat dinilai menggunakan berbagai jenis metrik evaluasi. Di antara metrik tersebut, *Dice Similarity Coefficient* (*Dice Score*) dan *Intersection over Union* (*IoU*) termasuk metrik yang paling umum digunakan dalam evaluasi segmentasi. Kedua metrik ini menilai tingkat kesamaan berdasarkan luas area yang saling bertumpang tindih (*overlap*) antara hasil prediksi model dan area referensi. Semakin besar tingkat tumpang tindih yang diperoleh, semakin baik pula kemampuan model dalam menghasilkan segmentasi yang sesuai dengan objek sebenarnya (Rainio & Klén, 2026).

1. Dice Similarity Coefficient (Dice Score)

merupakan metrik evaluasi yang digunakan untuk mengukur tingkat kesamaan antara hasil segmentasi yang dihasilkan oleh model dengan *ground truth*, khususnya dalam tugas segmentasi citra medis seperti deteksi tumor. Dice Score menghitung tingkat tumpang tindih (*overlap*) antara dua area, yaitu hasil prediksi dan *ground truth*. yaitu hasil prediksi dan *ground truth*, yang dirumuskan sebagai berikut:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \dots\dots\dots (2.4)$$

di mana A merupakan area hasil prediksi, B merupakan area *ground truth*, dan $A \cap B$ adalah area irisan antara keduanya. Nilai Dice Score berada pada rentang 0 hingga 1, di mana nilai 0 menunjukkan tidak adanya kesamaan, sedangkan nilai 1 menunjukkan kesamaan sempurna antara hasil prediksi dan *ground truth*. Metrik ini sangat sesuai digunakan dalam segmentasi citra medis karena mampu memberikan evaluasi yang lebih representatif pada kondisi data yang tidak seimbang, di mana jumlah piksel objek seperti tumor jauh lebih sedikit dibandingkan latar belakang. Selain itu, Dice Score memberikan penalti yang seimbang terhadap kesalahan prediksi berupa *false positive* dan *false negative*, sehingga mampu menggambarkan performa model secara lebih akurat dalam mendeteksi dan memisahkan area tumor dari jaringan normal.

2. Intersection over Union (IoU)

Intersection over Union (*IoU*), yang juga dikenal sebagai Jaccard Index, merupakan metrik evaluasi yang digunakan untuk mengukur tingkat kesamaan antara hasil segmentasi model dengan *ground truth* berdasarkan perbandingan antara area irisan dan area gabungan dari keduanya. *IoU* dirumuskan sebagai berikut:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \dots\dots\dots (2.5)$$

2.2.12 Active Contour

Active Contour adalah metode segmentasi yang dapat bergerak melebar ataupun menyempit dengan menggunakan model kurva tertutup. *Active Contour* dapat mendeteksi fitur tertentu dalam citra menggunakan prinsip meminimumkan energi citra. *Active Contour* merupakan kurva yang dapat bergerak secara dinamis ke arah garis atau tepi yang diinginkan atau objek di dalam gambar (mampu digunakan sebagai segmentasi objek otomatis). Metode *Active Contour* merupakan teknik segmentasi yang digunakan untuk mendeteksi objek dalam citra digital dengan memodelkan batas atau kontur objek. Dalam konteks segmentasi penyakit kanker hati, metode *Active Contour* membantu dalam memisahkan area kanker dari jaringan hati yang sehat dengan akurat. Metode ini bekerja dengan menginisiasi sebuah kurva atau kontur di sekitar area yang diinginkan, yang kemudian secara iteratif bergerak menuju tepi objek berdasarkan informasi gradien dan energi gambar. Kurva ini menyesuaikan bentuknya agar meminimalkan energi total, yang merupakan kombinasi dari energi internal (berhubungan dengan kelenturan kurva) dan energi eksternal (berhubungan dengan fitur citra seperti tepi dan garis). Penggunaan *Active Contour* dalam segmentasi kanker hati sangat berguna karena mampu menangani variasi bentuk dan ukuran tumor, serta dapat memperhitungkan ketidakseragaman dalam intensitas citra yang sering terjadi pada gambar medis. Oleh karena itu, pendekatan ini dapat menghasilkan temuan segmentasi yang lebih akurat, yang sangat penting untuk diagnosis dan perencanaan pengobatan yang akurat. (Radhi & Kamil, 2021). *Active contour* berupa energi minimum yang memenuhi properti dari kurva active contour dan properti dari gambar digital. dengan rumus sebagai berikut:

$$E_{snake} = \int_{s=0}^1 E_{int}(v(s)) + E_{img} + E_{con}(v(s))ds \dots\dots\dots (2.6)$$

Keterangan ;

E_{snake} = Merupakan fungsi energi dari *Active Contour*, dari fungsi tersebut akan dicari

objek yang memenuhi fungsi energi tersebut.

$v(s)$ = Merupakan kumpulan dari x dan y koordinat dari kurva *Active contour*.

E_{int} = Merupakan energi internal dari *Active Contour*, energi ini mempengaruhi pergerakan dari kurva *Active Contour*.

E_{img} = Merupakan energi dari gambar digital yang menjadi inputan
(*low level features*).

E_{con} = *High level* information yang mempengaruhi pergerakan dari kurva *Active Contour*.

Proses dimulai dengan menggunakan masking awal yang direpresentasikan sebagai kurva tertutup. Selanjutnya, secara iteratif, masking tersebut dimodifikasi sehingga mengalami ekspansi atau kontraksi hingga mencapai bentuk objek yang diinginkan. Metode *Active Contour* bertujuan untuk meminimalkan energi. Dengan demikian, setiap kumpulan koordinat x dan y dari kurva pada iterasi berikutnya memiliki energi yang lebih rendah daripada iterasi sebelumnya, sambil memenuhi tiga jenis energi: E_{int} (energi internal), E_{img} (energi gambar), dan E_{con} (energi konteks). Karena bertujuan untuk mencari energi minimal, persamaan di atas digunakan untuk menemukan kumpulan koordinat x dan y dari kurva *Active Contour* yang memenuhi kondisi tersebut.

$$\frac{dE_{snake}}{dv} = 0 \dots\dots\dots (2.7)$$

E_{int} merupakan energi internal dari kurva *Active Contour* yang mempengaruhi pergerakan dari kurva itu sendiri. E_{int} dapat di jelaskan dengan rumus sebagai berikut;

$$E_{int} = a(s) \left| \frac{dv(s)}{ds} \right|^2 + \beta(s) \left| \frac{d^2v(s)}{ds} \right|^2 \dots\dots\dots (2.8)$$

Keterangan;

$dv(s) ds$ = Turunan pertama untuk menghitung energi yang mengatur elastisitas dari kurva *Active Contour*.

$a(s)$ = Parameter yang mengatur elastisitas dari kurva (jarak antar titik dari kurva).

$d^2v(s)$ = Turunan kedua untuk menghitung energi yang mengatur kelengkungan dari kurva.

$\beta(s)$ = Parameter yang mengatur kelengkungan dari kurva.

Nilai a (α) memiliki efek sebagai berikut: nilai a yang kecil akan menghasilkan jarak yang tidak beraturan antara titik-titik pada kurva, sedangkan nilai a yang besar akan mempertahankan jarak yang konstan antara titik-titik tersebut. Nilai β yang kecil akan menghasilkan kurva yang tidak mulus dengan kemungkinan adanya sudut atau lekukan yang tajam, sedangkan nilai β yang besar akan menghasilkan kurva yang mulus dengan lekukan yang lebih halus dan lebih sedikit. Sebaliknya, nilai β yang besar (β eta) memiliki dampak sebagai berikut: sifat tingkat rendah seperti kecerahan dan tepi terdapat pada E_{img} . Tiga komponen rumus Kass (1988) untuk E_{img} adalah terminasi, tepi, dan garis. Rumus E_{img} adalah sebagai berikut:

$$E_{img} = W_{line} E_{line} + W_{edge} E_{edge} + W_{term} E_{term} \dots\dots\dots(2.9)$$

Keterangan;

E_{line} = energi dari *lines*.

E_{edge} = energi dari *edges*.

E_{term} = energi dari terminations.

W_{line} = parameter yang mengatur energi dari *lines*.

W_{edge} = parameter yang mengatur energi dari *edges*.

W_{term} = parameter yang mengatur energi dari terminations.

parameter yang mengontrol energi penghentian. *Active contour* akan bergerak maju ke dalam bayangan. Di sisi lain kurva *Active contour* akan bergerak ke arah area yang lebih terang jika warna pada titik tersebut lebih terang (nilai intensitas yang lebih besar). Hal ini memungkinkan untuk menghasilkan *Edge* menggunakan operator deteksi tepi, seperti *Prewitt*, *Sobel*, atau operator lainnya. Berdasarkan tingkat gambar total, E_{term} digunakan untuk memodifikasi pergerakan kurva *Active Contour*. Dengan menggunakan metode *Active Contour*, segmentasi dimulai dengan inisialisasi mask awal, yang kemudian direpresentasikan sebagai kurva tertutup (Hussein & Mosa, 2022).

2.2.13 Receiver Operating Characteristic (ROC)

Receiver Operating Characteristic (ROC) adalah kurva yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan menampilkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai *threshold* klasifikasi. Persentase kasus positif yang benar-benar terdeteksi oleh model disebut *True Positive Rate*, terkadang disebut juga sensitivitas atau *recall*. Persentase kasus negatif yang secara keliru diklasifikasikan oleh model sebagai kasus positif dikenal sebagai tingkat positif palsu (Gneiting & Vogel, 2022). Pada ROC ada empat kemungkinan yang akan terjadi, yaitu:

1. Jika terdapat nilai yang sebenarnya positif dan pada hasil model juga positif, maka dimasukkan ke dalam nilai *True Positive* (TP).
2. Jika terdapat nilai yang sebenarnya negatif dan pada hasil model juga negatif, maka dimasukkan ke dalam nilai *True Negative* (TN).
3. Jika terdapat nilai yang sebenarnya positif, tetapi pada hasil model bernilai negatif, maka dimasukkan ke dalam nilai *False Negative* (FN).
4. Jika terdapat nilai yang sebenarnya negatif, tetapi pada hasil model bernilai positif, maka dimasukkan ke dalam nilai *False Positive* (FP).


Dari keempat nilai diatas dapat dihitung akurasi, sensitifitas dan spesifisitas. Rumusnya sebagai berikut:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(2.10)$$

$$\text{Sensitifitas} = \frac{TP}{TP+FN} \dots\dots\dots(2.11)$$

$$\text{Spesifisitas} = \frac{TN}{TN+FP} \dots\dots\dots(2.12)$$

Dimana daerah yang menggambarkan bagian TP, TN, FP dan FN diperlihatkan pada gambar dibawah ini:



Gambar 2. 11 Perbedaan Citra Segmentasi Manual dengan Hasil Citra Segmentasi Program (Rinaldi Munir, 2004).

2.2.14 Matlab

MATLAB, singkatan dari "*Matrix Laboratory*," dirancang khusus untuk memudahkan pemrosesan matriks, komputasi numerik, analisis data, visualisasi, dan pengembangan algoritma. MATLAB sangat populer dalam berbagai bidang teknik, sains, ekonomi, dan matematika karena kemampuannya dalam menangani perhitungan yang kompleks dengan efisiensi tinggi (Salgotra et al., 2024).

Penggunaan Matlab meliputi bidang–bidang:

- A. Matematika dan Komputasi
- B. Pengembangan dan Algorithma
- C. Akusisi Data
- D. Pemodelan, simulasi, dan pembuatan prototipe
- E. Analisa data, explorasi, dan visualisasi
- F. Grafik Keilmuan dan bidang Rekayasa


Standar industri untuk membuat dan memperkenalkan presentasi ilmiah, teknis, dan matematika adalah matlab. Matlab adalah alat pilihan di industri untuk penelitian, pengembangan, dan analisis yang sangat produktif.

2.2.15 Google Collaboration

Google Collaboratory, juga dikenal sebagai *Google Colab*, adalah platform berbasis *cloud* yang dimaksudkan untuk *analyst*, pengembang, peneliti, dan pendidik yang bekerja di bidang *data science* dan *machine learning* untuk menulis, menjalankan, dan berbagi kode *Python* melalui *web browser*. Platform ini menawarkan lingkungan komputasi yang fleksibel dan mudah diakses tanpa biaya. *Google Colab* juga menawarkan kemampuan untuk menjalankan *Jupyter Notebook*, sebuah web aplikasi *open-source* yang memungkinkan visualisasi data, kombinasi kode, dan teks terformat, langsung dari *web browser* tanpa perlu melakukan konfigurasi khusus (Febrywinata, 2024).

2.2.16 CRISP-DM

Pada penelitian ini menggunakan pendekatan methodology *CRISP-DM*. Cross-Industry Standard Process for Data Mining (*CRISP-DM*) merupakan salah satu metodologi yang banyak digunakan sebagai pedoman dalam pelaksanaan proyek data mining dan analisis data. Metode ini menyediakan kerangka kerja yang terstruktur dan sistematis untuk membantu setiap tahapan proyek berjalan secara efektif serta menghasilkan solusi yang sesuai dengan tujuan yang telah ditetapkan. Menurut (Schröer et al., 2021), *CRISP-DM* terdiri atas enam tahapan utama yang saling berkaitan, sehingga proses pengembangan model dapat dilakukan secara terarah dan menghasilkan keluaran yang bernilai.



Gambar 2. 12 Model *CRISP-DM* (Schröer et al., 2021)

Model *CRISP-DM* memiliki 6 tahapan, yaitu:

1. *Business Understanding*

Tahap awal yang berfokus pada identifikasi dan pemahaman terhadap tujuan bisnis, kebutuhan pengguna, serta permasalahan yang akan diselesaikan melalui analisis data.

2. *Data Understanding*

Tahap pengumpulan, eksplorasi, dan analisis data untuk memahami karakteristik, kualitas, serta kesesuaian data yang akan digunakan dalam penelitian.

3. *Data Preparation*

Tahap mempersiapkan data sebelum proses pemodelan, meliputi pembersihan data, transformasi, integrasi, dan pemilihan data agar siap digunakan oleh model.

4. *Modeling*

Tahap pembangunan model dengan menerapkan algoritma atau metode yang dipilih untuk menghasilkan model prediksi, klasifikasi, atau segmentasi sesuai tujuan penelitian.

5. *Evaluation*

Tahap penilaian terhadap performa model untuk memastikan bahwa hasil yang diperoleh telah memenuhi tujuan penelitian dan dapat memberikan solusi terhadap permasalahan yang diidentifikasi.

6. *Deployment*





Tahap implementasi model yang telah memenuhi kriteria evaluasi ke dalam lingkungan operasional atau aplikasi sehingga dapat dimanfaatkan oleh pengguna dalam mendukung pengambilan keputusan.

2.2.1 Flowchart


Flowchart adalah representasi grafis yang menunjukkan urutan langkah-langkah atau proses secara sistematis untuk menjalankan suatu program. *Flowchart* merupakan gambaran yang membantu dalam analisis, perancangan, dan pengkodean, sehingga memudahkan pemecahan masalah secara lebih rinci dalam operasi suatu kegiatan. Umumnya, *flowchart* digunakan untuk menyederhanakan penyelesaian masalah saat dilakukan evaluasi lebih lanjut. Secara sederhana, *flowchart* adalah diagram yang menggunakan simbol-simbol grafis untuk menggambarkan alur suatu

proses. Diagram ini menunjukkan langkah-langkah atau tindakan yang diwakili oleh simbol-simbol tersebut. *Flowchart* berfungsi penting dalam memberikan gambaran tentang proses produksi, membuatnya lebih mudah dipahami dan diikuti, terutama dengan menunjukkan urutan langkah dari satu proses ke proses berikutnya (Kus Indrani Listyoningrum et al., 2023).

Tabel 2. 2 *Flowchart*

No	Simbol	Nama	Keterangan
1.		Terminal	Simbol yang mengartikan awal dan akhir nya sebuah program
2.		<i>Input</i> atau <i>Output</i>	Simbol yang menunjukkan proses input atau <i>output</i>
3.		Proses	Simbol yang mengartikan proses yang berjalan di dalam sebuah komputer
4.		<i>Decision</i>	Simbol yang menghasilkan kemungkinan dua jawaban yaitu YA/TIDAK pada kondisi tertentu
5.		<i>Display</i>	Simbol yang membantu keluaran pada sebuah <i>layer</i> monitor
6.		Alur Proses	Simbol yang menunjukkan alur proses objek
7.		<i>Connector</i>	Simbol untuk membrikan hubungan antar objek dengan yang lain pada halaman yang sama
8.		<i>Offline Connector</i>	Simbol untuk membrikan hubungan antar objek dengan yang lain pada halaman yang berbeda
9.		<i>Document</i>	Simbol mencetak dokumen
10.		<i>Disk Storage</i>	Simbol untuk memberikan <i>input</i> atau <i>output</i> yang di simpan ke dalam sebuah <i>disk</i>

2.2 Diagram Fishbone Kinerja Segmentasi Tumor Hati



Gambar 2. 13 Diagram *Fishbone*

Diagram *fishbone* tersebut dapat dijelaskan sebagai hubungan antara beberapa komponen utama penelitian yang bersama-sama memengaruhi hasil analisis kinerja segmentasi tumor hati. Berbeda dengan diagram alir yang menunjukkan urutan proses secara linear, diagram fishbone digunakan untuk memperlihatkan faktor atau aspek yang berkontribusi terhadap hasil akhir penelitian.

1. Data *Ct-Scan*

Data *CT-Scan* merupakan sumber utama yang digunakan dalam penelitian untuk melakukan segmentasi tumor hati. Karakteristik citra dapat memengaruhi kemampuan metode dalam mengenali area tumor. Beberapa aspek yang diperhatikan meliputi kualitas kontras citra serta variasi ukuran dan bentuk tumor. Tumor dengan ukuran kecil, bentuk tidak beraturan, atau memiliki kontras yang rendah terhadap jaringan hati di sekitarnya dapat meningkatkan tingkat kesulitan proses segmentasi.

2. *Preprocessing*

Tahap *preprocessing* bertujuan untuk mempersiapkan citra *CT-Scan* agar memiliki karakteristik yang sesuai sebelum dimasukkan ke dalam metode segmentasi. Proses ini dapat meliputi normalisasi, resizing, dan pengurangan *noise*. Normalisasi digunakan untuk menyeragamkan nilai intensitas citra, *resizing* digunakan untuk menyesuaikan ukuran citra dengan kebutuhan model, sedangkan pengurangan *noise* dilakukan untuk mengurangi gangguan yang dapat memengaruhi proses pengenalan objek. Dengan proses tersebut, citra diharapkan memiliki kualitas yang lebih konsisten untuk proses segmentasi.

3. *Attention U-Net*

Attention U-Net merupakan salah satu metode utama yang dianalisis dalam penelitian. Metode ini melakukan ekstraksi fitur terhadap citra *CT-Scan* dan menggunakan mekanisme *Attention Gate* untuk memberikan perhatian lebih besar pada fitur yang berkaitan dengan area tumor. Mekanisme tersebut membantu model mengurangi kontribusi fitur dari bagian citra yang kurang relevan. Hasil akhirnya berupa mask prediksi yang menunjukkan area tumor yang berhasil diidentifikasi oleh *Attention U-Net*.

4. *Active Contour*

Active Contour digunakan sebagai metode segmentasi lain yang kinerjanya dibandingkan dengan *Attention U-Net*. Metode ini bekerja dengan menentukan kontur awal, kemudian kontur tersebut bergerak dan menyesuaikan bentuknya secara iteratif berdasarkan karakteristik citra hingga mendekati batas objek. Dalam penelitian ini, proses tersebut digunakan untuk memperoleh batas tumor hati sehingga menghasilkan mask segmentasi tumor dari metode *Active Contour*.

5. *Ground Truth* dan Evaluasi

Hasil segmentasi dari kedua metode tidak dapat langsung dinyatakan baik atau buruk tanpa adanya data acuan. Oleh karena itu, hasil segmentasi dibandingkan dengan ground truth, yaitu anotasi referensi yang menunjukkan area tumor sebenarnya. Tingkat kesesuaian antara hasil prediksi dan ground truth kemudian dihitung menggunakan metrik evaluasi seperti *Dice Similarity Coefficient (Dice Score)* dan *Intersection over Union (IoU)*. Semakin tinggi nilai kedua metrik tersebut, semakin besar tingkat kesesuaian area segmentasi yang dihasilkan metode terhadap ground truth.

6. Analisis Perbandingan

Nilai evaluasi yang diperoleh selanjutnya digunakan untuk melakukan perbandingan kinerja *Attention U-Net* dan *Active Contour*. Perbandingan tidak hanya melihat nilai *Dice Score* dan *IoU*, tetapi juga dapat memperhatikan kemampuan masing-masing metode dalam menentukan lokasi, luas, bentuk, dan batas tumor. Dari tahap ini dapat diketahui kelebihan serta keterbatasan masing-masing metode pada karakteristik tumor yang berbeda.


7. Analisis Kinerja Segmentasi Tumor Hati

Bagian kepala diagram fishbone menunjukkan hasil utama yang ingin dicapai dalam penelitian, yaitu analisis kinerja segmentasi tumor hati pada citra *CT-Scan*. Seluruh komponen sebelumnya berkontribusi terhadap hasil tersebut. Melalui evaluasi dan perbandingan yang dilakukan, penelitian dapat menentukan metode mana yang memberikan hasil segmentasi lebih baik berdasarkan parameter evaluasi yang telah ditetapkan.

2.3 Kerangka Pemikiran

Menurut Widayat dan Amirullah (2002), kerangka berpikir atau kerangka konseptual merupakan suatu model yang menjelaskan hubungan antara teori dengan berbagai faktor yang telah diidentifikasi sebagai permasalahan utama dalam penelitian. Kerangka berpikir berperan sebagai dasar dalam memberikan gambaran atau penjelasan sementara mengenai fenomena yang menjadi fokus penelitian.

Penyusunan kerangka berpikir didasarkan pada teori-teori yang relevan serta didukung oleh pengalaman empiris yang berkaitan dengan topik penelitian. Kombinasi kedua aspek tersebut membentuk alur pemikiran yang sistematis, logis, dan terarah sehingga dapat menjadi landasan dalam merumuskan hipotesis maupun arah pelaksanaan penelitian.



Gambar 2. 14 Kerangka Pemikiran Metode Active Contour

Gambar di atas merupakan kerangka pemikiran yang menggambarkan proses awal hingga selesai dari penelitian ini. Penjelasan dari kerangka pemikiran di atas akan dijabarkan sebagai berikut:

1. Karakteristik Data CT-Scan

Tahap awal penelitian dimulai dengan memahami karakteristik data citra CT-Scan yang digunakan. Analisis ini mencakup jenis data, ukuran atau resolusi citra, kualitas citra, tingkat kontras, serta karakteristik visual jaringan hati dan tumor. Tahap ini penting karena tumor hati pada citra CT-Scan dapat memiliki ukuran, bentuk, lokasi, serta tingkat kontras yang berbeda-beda terhadap jaringan di sekitarnya. Karakteristik tersebut dapat memengaruhi kemampuan metode segmentasi dalam mengenali dan menentukan batas tumor secara tepat.

2. Preprocessing Citra

Setelah karakteristik data diketahui, citra memasuki tahap *preprocessing*. Tahap ini bertujuan untuk menyiapkan citra agar memiliki format dan kualitas yang sesuai sebelum dilakukan proses segmentasi. *Preprocessing* dapat mencakup perubahan ukuran citra (*resizing*), normalisasi nilai intensitas, pengurangan *noise*, serta penyesuaian data sesuai kebutuhan model. Proses ini dilakukan agar variasi data dapat dikurangi dan informasi penting yang berkaitan dengan jaringan hati maupun tumor dapat dipertahankan sehingga proses segmentasi menjadi lebih optimal.

3. Segmentasi dengan *Attention U-Net*

Citra hasil *preprocessing* kemudian diproses menggunakan metode *Attention U-Net*. Metode ini merupakan pengembangan dari *U-Net* dengan menambahkan mekanisme *Attention Gate* yang membantu model memberikan perhatian lebih besar terhadap bagian citra yang relevan dengan objek target. Pada proses segmentasi tumor hati, *Attention U-Net* melakukan ekstraksi fitur dari citra melalui bagian *encoder*, kemudian fitur yang dianggap penting diseleksi melalui mekanisme *attention* sebelum diteruskan menuju *decoder*. Dengan mekanisme tersebut, model diharapkan mampu mengurangi pengaruh area yang tidak relevan dan lebih fokus terhadap lokasi serta karakteristik tumor. Hasil dari tahap ini berupa mask segmentasi yang menunjukkan area tumor yang diprediksi oleh model.

4. Segmentasi dengan *Active Contour*

Selain menggunakan *Attention U-Net*, citra juga diproses menggunakan metode *Active Contour* sebagai metode segmentasi pembanding. *Active Contour* bekerja dengan membentuk suatu kurva atau kontur awal yang kemudian bergerak secara *iteratif* mengikuti karakteristik citra hingga mendekati batas objek yang akan disegmentasi. Pergerakan kontur dipengaruhi oleh informasi seperti intensitas, tepi, maupun perbedaan karakteristik antara bagian dalam dan luar objek. Dalam penelitian ini, *Active Contour* digunakan untuk menentukan batas tumor hati sehingga dihasilkan mask segmentasi berdasarkan hasil evolusi kontur tersebut.

5. *Ground Truth* dan Evaluasi

Hasil segmentasi yang diperoleh dari *Attention U-Net* dan *Active Contour* kemudian dibandingkan dengan ground truth. *Ground truth* merupakan anotasi referensi yang menunjukkan lokasi dan batas tumor yang dianggap benar dan digunakan sebagai standar dalam mengevaluasi hasil segmentasi. Perbandingan dilakukan menggunakan metrik evaluasi, seperti *Dice Similarity Coefficient* (*Dice Score*) dan *Intersection over Union* (*IoU*). Kedua metrik tersebut mengukur tingkat tumpang tindih antara area tumor hasil prediksi dengan area tumor pada ground truth. Nilai yang semakin tinggi menunjukkan bahwa hasil segmentasi semakin mendekati segmentasi referensi.

6. Analisis Perbandingan

Nilai hasil evaluasi dari kedua metode selanjutnya dianalisis dan dibandingkan untuk mengetahui perbedaan performa *Attention U-Net* dan *Active Contour* dalam melakukan segmentasi tumor hati. Analisis dapat dilakukan berdasarkan nilai *Dice Score*, *IoU*, ketepatan area segmentasi, serta kemampuan masing-masing metode dalam mengikuti bentuk dan batas tumor. Pada tahap ini juga dapat dianalisis kelebihan dan keterbatasan dari masing-masing metode, terutama ketika menghadapi tumor dengan ukuran kecil, bentuk tidak beraturan, batas yang kurang jelas, atau kontras rendah terhadap jaringan hati di sekitarnya.

7. Tujuan

Tahap akhir dari kerangka pemikiran adalah memperoleh kesimpulan mengenai kinerja masing-masing metode dalam melakukan segmentasi tumor hati pada citra *CT-Scan*. Berdasarkan hasil evaluasi dan analisis perbandingan, penelitian dapat menentukan metode yang memberikan performa segmentasi lebih baik berdasarkan parameter evaluasi yang digunakan. Dengan demikian, penelitian tidak hanya menghasilkan mask segmentasi tumor, tetapi juga memberikan bukti kuantitatif mengenai efektivitas *Attention U-Net* dan *Active Contour* dalam segmentasi tumor hati.