

Arsitektur *U-Net* pada Segmentasi Citra Hati sebagai Deteksi Dini Kanker Liver

U-Net Architecture on Liver Image Segmentation as Early Detection of Liver Cancer

Therezia Naraloka¹, Lucky Indra Kesuma², Ade Sukmawati³, Marissa Cristianti⁴
^{1,2,4}Program Studi Sistem Informasi, Universitas Sjakhyakirti, Palembang, Indonesia
³Program Studi Informatika, Universitas Sjakhyakirti, Palembang, Indonesia
E-mail: ¹therezia.naraloka@unisti.ac.id, ²luckyindra25@unisti.ac.id,
³adesukmawati@unisti.ac.id, ⁴marissacristianti999@gmail.com

Abstrak

Hati adalah salah satu organ tubuh manusia yang bertanggung jawab untuk mencerna, meyerap, dan memproses makanan serta berfungsi untuk menyaring darah dari saluran pencernaan sebelum dibawa kebagian organ tubuh lainnya. Hati sangat rentan terhadap berbagai penyakit, salah satunya yaitu kanker liver. Untuk itu perlu dilakukannya deteksi sejak dini atau diagnosa terhadap organ hati. Untuk mengatasi permasalahan tersebut, pada penelitian ini dilakukan segmentasi hati menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *U-Net* pada citra hati. Langkah awal pada penelitian ini dilakukan *pre-processing* data yang menerapkan teknik *green channel*, *histogram equalization* (HE), dan *contrast limited adaptive histogram equalization* (CLAHE). Setelah itu dilakukan proses segmentasi sesuai dengan metode yang diusulkan. Penelitian ini menggunakan dataset hati yang didapatkan dari website *Kaggle*. Hasil penelitian menggunakan metode CNN arsitektur *U-Net* pada data mendapatkan nilai akurasi sebesar 97,62%, sensitivitas sebesar 89,84%, spesifisitas sebesar 98,37%, koefisien jaccard sebesar 76,99%, dan *dice similarity coefficient* (DSC) sebesar 87%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode yang diusulkan memiliki hasil yang sangat baik dalam melakukan segmentasi terhadap citra hati.

Kata kunci: CNN, *U-Net*, Segmentasi, Hati

Abstract

Liver is one of the organs of the human body that is responsible for digesting, absorbing, and processing food and functions to filter blood from the digestive tract before it is carried to other body organs. The liver is very susceptible to various diseases, for that it is necessary to do early detection or diagnosis of the liver. To overcome these problems, in this study, liver segmentation was carried out using the Convolutional Neural Network (CNN) method with U-Net architecture on liver images. The first step in this research is preprocessing the data using the green channel technique, Histogram Equalization (HE), and Contrast Limited Adaptive Histogram Equalization (CLAHE). After that, the segmentation process is carried out according to the proposed method. This study uses a liver dataset obtained from the Kaggle website. The results of the study using the CNN U-Net architecture method on the data obtained an accuracy value of 97.62%, sensitivity of 89.84%, specificity of 98.37%, jaccard coefficient of 76.99%, and dice similarity coefficient (DSC) of 87%. Based on these results, it can be concluded that the proposed method has excellent results in segmenting the liver image.

Keywords: CNN, *U-Net*, Segmentation, Liver

1. PENDAHULUAN

Hati atau liver adalah salah satu organ tubuh manusia yang terletak di sisi sebelah kanan atas rongga perut [1]. Hati bertanggung jawab untuk mencerna, meyerap, dan memproses makanan serta berfungsi untuk menyaring darah dari saluran pencernaan sebelum dibawa

kebagian organ tubuh lainnya. Dengan fungsinya yang kompleks dan sangat penting, organ hati harus dijaga kesehatannya, karena organ tersebut rentan terhadap penyakit [2]. Salah satu penyakit yang berbahaya dan sering menyerang organ hati adalah kanker hati. Kanker hati merupakan penyakit yang disebabkan oleh pertumbuhan sel-sel ganas di hati yang tidak terkendali [3]. Pada tahun 2020, *Global Cancer Statistic* melaporkan bahwa lebih dari 900.000 orang di dunia terkena penyakit kanker hati dan lebih dari 830.000 orang meninggal dunia dikarenakan kanker hati [4]. Untuk itu diperlukan pencegahan dan deteksi sejak dini agar kondisi tersebut tidak semakin parah. Selama ini, dokter dan ahli radiologi masih melakukan deteksi penyakit pada liver secara manual menggunakan teknik *rontgen* pada bagian hati. Hasil yang didapatkan dari teknik *rontgen* ini ialah data citra hati. Namun, pada data citra hati tersebut masih terdapat bagian-bagian lain seperti ginjal, empedu, dan pankreas [1]. Bagian-bagian lain ini akan mengganggu proses deteksi penyakit pada hati. Sehingga dibutuhkanlah suatu sistem yang bisa mendapatkan bagian hati saja secara otomatis agar mempermudah dokter dan ahli radiologi dalam mendiagnosa penyakit pada hati [5].

Salah satu sistem diagnosa otomatis dalam mendeteksi penyakit pada liver adalah segmentasi citra. Segmentasi citra adalah proses membagi citra menjadi beberapa bagian, dimana proses ini digunakan untuk memisahkan objek yang berbeda dalam suatu citra [6]. Citra hati yang dimiliki terkadang memiliki kualitas yang kurang baik seperti terlalu gelap maupun terang, sehingga dapat mempengaruhi hasil segmentasi. Salah satu metode yang dilakukan untuk meningkatkan kualitas pada citra adalah *Histogram Equalization* (HE). HE bekerja dengan meningkatkan kontras citra melalui proses pemerataan histogram agar mendapatkan hasil yang seragam. Selain metode HE, terdapat juga metode lain yang mampu meningkatkan kontras citra dengan menampilkan fitur tersembunyi dari citra tersebut agar dapat terlihat dengan jelas yaitu *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE mampu meningkatkan kontras citra yang lebih baik dari citra aslinya dengan bekerja pada sebagian kecil area dari citra [7]. Beberapa penelitian tentang perbaikan kualitas citra menggunakan HE dan CLAHE diantaranya adalah Anter & Hassenian [8] dengan perbaikan citra menggunakan metode HE pada segmentasi hati menghasilkan nilai akurasi sebesar 95% dan Rela, Rao, et al. [9] menggunakan metode CLAHE untuk peningkatan kontras pada segmentasi hati menghasilkan nilai akurasi sebesar 99,58%. Kualitas suatu citra yang memiliki kontras yang baik memberikan hasil yang baik juga pada proses segmentasi.

Menurut Meng et al. [10] proses segmentasi citra hati dilakukan dengan mengambil bagian fitur hati saja, sedangkan untuk bagian fitur lain yang berada disekitarnya dijadikan sebagai *background*. Beberapa penelitian yang telah melakukan segmentasi citra hati antara lain: Penelitian oleh Anwar et al. [11] menggunakan metode *otsu thresholding* dan *spatial fuzzy c-means* menghasilkan nilai *dice similarity coefficient* (DSC) dan *jaccard* masing-masing sebesar 60% dan 58%. Selanjutnya penelitian yang dilakukan oleh Cai [12] menggunakan metode *adaptive scale-kernel fuzzy clustering* menghasilkan nilai DSC sebesar 87,02%. Kemudian penelitian lain juga dilakukan oleh R. Zhang et al. [13] menggunakan metode *improved fuzzy connectedness* menghasilkan nilai akurasi 96,4%, sensitivitas 73,7%, dan DSC 67,3%. Terlihat bahwa dari ketiga penelitian tersebut tidak menghitung nilai ukuran kinerja lainnya seperti spesifisitas dan *f-1 score*. Selain itu, pada penelitian Anwar et al. [11] dan R. Zhang et al. [13] nilai DSC, *jaccard*, dan sensitivitas masih cukup rendah, dan pada penelitian Cai [12] nilai DSC yang diperoleh cukup baik, namun masih dibawah 90%. Hal ini disebabkan karena metode segmentasi yang digunakan oleh peneliti sebelumnya merupakan metode konvensional yang belum bisa membedakan suatu objek dengan objek lainnya secara tepat dan akurat, karena metode konvensional ini hanya mempelajari representasi fitur secara dangkal [14]. Untuk mengatasi hal ini, diperlukan suatu metode yang dapat mempelajari representasi fitur secara mendalam agar dapat meningkatkan hasil kinerja suatu model yang akurat.

Salah satu metode segmentasi yang berkembang pesat saat ini adalah *Deep Learning* (DL). DL dapat mendeteksi suatu pola secara otomatis dari data yang diberikan [15]. Metode segmentasi berbasis DL yang sering digunakan untuk pengolahan data gambar adalah *Convolutional Neural Network* (CNN). Metode CNN memiliki kemampuan yang kuat jika dilatih

dengan data berdimensi besar yang berukuran $m \times n$ [6]. Salah satu arsitektur dari CNN yang banyak digunakan untuk melakukan segmentasi ialah arsitektur *U-Net*.

Arsitektur *U-Net* merupakan arsitektur CNN yang populer pada analisis citra medis karena keakuratannya dalam melakukan segmentasi dan dapat meningkatkan akurasi terhadap diagnosis penyakit yang diperiksa [16]. Arsitektur *U-Net* memiliki dua jalur yaitu jalur *encoder* dan jalur *decoder*. Proses jalur *encoder* digunakan untuk pengurangan ukuran matriks *input* sedangkan jalur *decoder* digunakan untuk mengembalikan ukuran matriks ke ukuran semula dengan meminimalkan jumlah *feature maps* sehingga gambar bisa tersegmentasi. Beberapa penelitian yang menggunakan arsitektur *U-Net* dalam segmentasi citra antara lain: Penelitian oleh Pranata et al. [17] dalam segmentasi paru-paru menghasilkan nilai akurasi 91,68%, sensitivitas 92,80%, spesifisitas 89,15%, dan *f-1 score* sebesar 93,92%. Selanjutnya penelitian yang dilakukan oleh He et al. [18] dalam segmentasi lesi kulit menghasilkan nilai akurasi 96%, DSC 93,1%. Kemudian penelitian lain yang dilakukan oleh Saeedizadeh et al. [19] dalam segmentasi ct dada untuk covid-19 menghasilkan nilai sensitivitas 80,8%, spesifisitas 96%, dan DSC 80,1%. Pada penelitian Pranata et al. [17] dalam segmentasi paru-paru nilai spesifisitas yang diperoleh cukup baik, namun masih dibawah 90%. Sedangkan pada penelitian He et al. [18] dalam segmentasi lesi kulit nilai akurasi dan DSC sudah sangat baik diatas 90%, namun tidak menghitung nilai evaluasi kinerja yang lain seperti sensitivitas, spesifisitas, *jaccard* dan *f-1 score*. Pada penelitian Saeedizadeh et al. [19] dalam segmentasi CT scan citra dada, nilai akurasi yang diperoleh sudah sangat baik, namun nilai sensitivitas dan DSC yang diperoleh masih dibawah 90%. Beberapa penelitian tersebut menunjukkan bahwa kemampuan kinerja arsitektur *U-Net* sudah cukup baik dalam melakukan segmentasi. Sehingga, pada penelitian ini akan dilakukan penggabungan proses perbaikan kualitas citra dan metode segmentasi untuk mendapatkan fitur hati pada citra hati. Pada perbaikan citra dilakukan peningkatan kontras menggunakan HE dan CLAHE. Pada segmentasi citra diterapkan model CNN menggunakan arsitektur *U-Net* dengan harapan mampu melakukan segmentasi dengan hasil evaluasi kinerja yang akurat serta dapat membantu dokter dan ahli radiologi dalam mendiagnosa penyakit pada hati sejak dini.

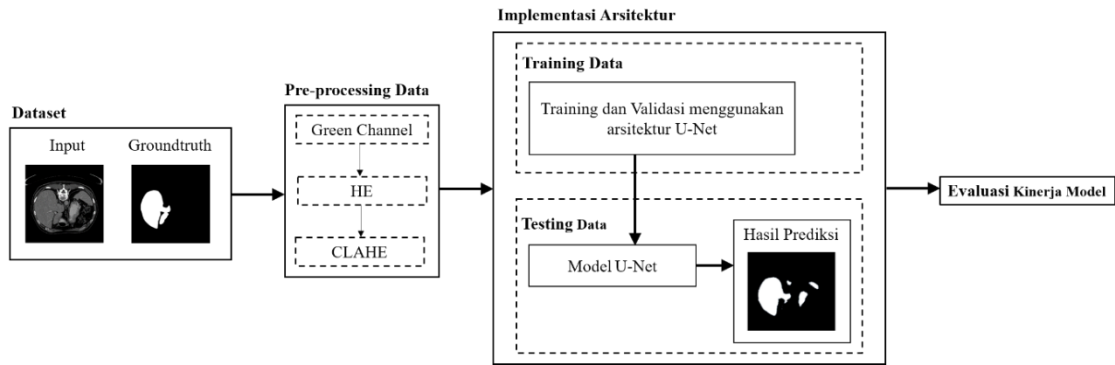
2. METODE PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *U-Net* untuk segmentasi citra hati. Langkah awal yang dilakukan adalah pengumpulan dan pendeskripsian data. Kemudian dilakukan *pre-processing* data menggunakan *green channel*, *Histogram Equalization* (HE), dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Selanjutnya hasil dari proses *pre-processing* dilakukan implementasi arsitektur *U-Net* melalui dua proses yaitu proses *training* dan proses *testing*. Proses *training* digunakan untuk melatih data dan mencoba mengenali pola-pola yang ada pada data. Sedangkan proses *testing* digunakan untuk menguji keakuratan model yang didapat dari proses *training* dalam melakukan segmentasi citra hati, sehingga hasil yang diperoleh akan termuat dalam *confusion matrix* yang digunakan untuk menghitung evaluasi kinerja model. Hasil evaluasi kinerja model tersebut diukur berdasarkan nilai akurasi, sensitivitas, spesifisitas, *koefisien jaccard*, dan *dice similarity coefficient* (DSC). Alur kerja tahapan penelitian ini disajikan dalam bentuk *flowchart* seperti pada Gambar 1.

2.2 Deskripsi Data

Dataset yang digunakan pada penelitian ini ialah data citra hasil pemeriksaan hati yang didapat dari situs *kaggle* dan dapat diakses melalui laman website <https://www.kaggle.com/markdants/liver-dataset>. Data yang digunakan berjumlah 800 citra yang terbagi menjadi 400 citra hati dan 400 *groundtruth* dengan ukuran 256×256 piksel menggunakan format (.png). Beberapa *sample* citra hati dan *groundtruth* pada dataset hati yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1.



Gambar 1 Tahapan Penelitian

2.3 Pre-processing Data

Pre-processing data merupakan proses awal dalam melakukan segmentasi citra, dimana proses ini digunakan untuk meningkatkan kualitas dari suatu citra. Beberapa *pre-processing* data yang digunakan pada penelitian ini yaitu *green channel*, *Histogram Equalization* (HE) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE).

a. *Green Channel*

Citra hati yang digunakan pada penelitian ini bertipe RGB, dimana RGB memiliki tiga komponen warna yaitu *Red* (R), *Green* (G), dan *Blue* (B). Dari ketiga komponen warna tersebut, saluran yang diambil dari citra RGB yaitu *green channel*. *Green channel* bekerja dengan mengubah nilai piksel pada citra menjadi nilai *channel* hijau atau *green*. *Green channel* dipilih karena memiliki kontras yang tidak terlalu terang maupun gelap, yang membuat fitur hati pada citra terlihat dengan jelas.

b. *Histogram Equalization* (HE)


Histogram Equalization (HE) merupakan teknik yang paling sering digunakan dalam peningkatan kontras pada suatu citra. HE bekerja dengan mengubah nilai intensitas dalam sebuah citra secara keseluruhan agar mendapatkan penyebaran histogram yang seragam sehingga setiap nilai intensitas memiliki jumlah piksel yang relatif sama.

c. *Contrast Limited Adaptive Histogram Equalization* (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan teknik perbaikan citra yang digunakan untuk mengatasi masalah ketidakseimbangan kontras agar tidak terjadi kesalahan dalam diagnosis citra hati. Berbeda dengan teknik HE, CLAHE bekerja pada sebagian kecil area dari citra yang disebut *tile* dengan memiliki nilai batas pada histogramnya. Nilai batas ini disebut dengan *clip limit* yang menyatakan tinggi maksimum dari sebuah histogram.

Tabel 1 *Sample* dataset citra hati

Nama Citra	Citra Hati	Groundtruth
001.png		
002.png		

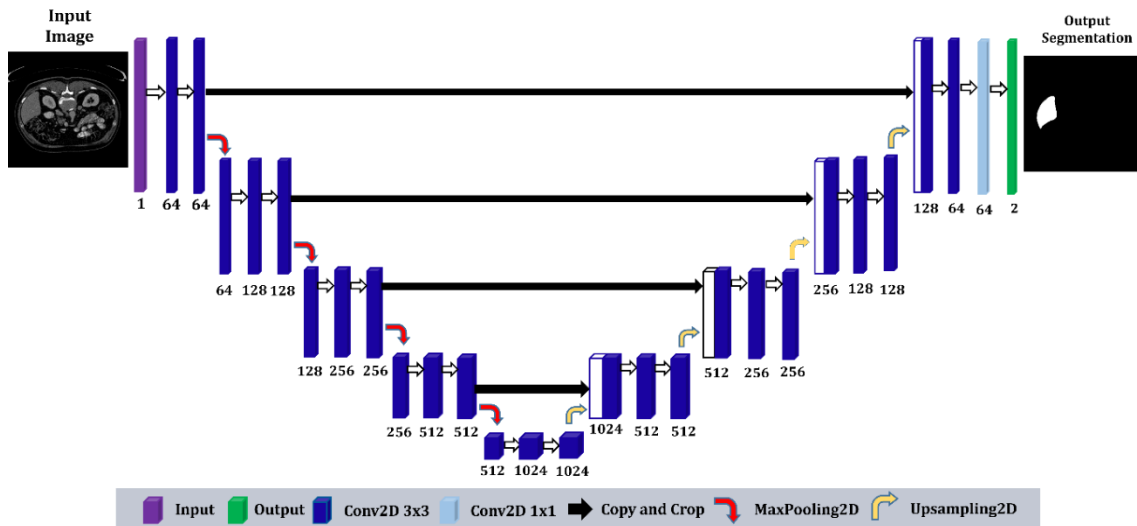


2.4 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dirancang untuk pengolahan data dua dimensi seperti data gambar. CNN termasuk ke dalam *Deep Learning*, karena memiliki kedalaman jaringan yang tinggi dan banyak diterapkan pada data citra. *Input* setiap lapisan pada CNN berukuran $m \times m \times r$ yang tersusun dalam 3 dimensi, yaitu tinggi (*height*), lebar (*width*), dan kedalaman (*depth*), dimana nilai tinggi sama dengan nilai lebarnya [20].

2.5 Arsitektur U-Net

Segmentasi citra merupakan suatu rangkaian pemrosesan citra yang dilakukan dengan memberi label pada setiap piksel citra, dimana citra tersebut dibagi menjadi beberapa bagian sehingga piksel-piksel yang terdapat dalam satu bagian memiliki karakteristik yang sama. Pada citra hati, citra dibagi menjadi dua bagian, yaitu hati dan *background* [10]. Proses segmentasi citra hati dilakukan dengan menerapkan arsitektur *U-Net*. Arsitektur *U-Net* memiliki dua jalur yaitu jalur *encoder* dan *decoder*. Jalur *encoder* digunakan untuk menangkap informasi fitur dari citra *input* dan melakukan pengurangan dimensi pada ukuran citra *input*, sedangkan jalur *decoder* digunakan untuk menangkap informasi fitur dari hasil *encoder* dan sebagai tempat keluarnya hasil segmentasi. Arsitektur *U-Net* yang diusulkan untuk segmentasi citra hati pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2 Arsitektur *U-Net* untuk segmentasi citra hati

Gambar 2 menunjukkan arsitektur *U-Net* yang terdiri dari dua jalur yaitu jalur *encoder* disisi sebelah kiri dan jalur *decoder* disisi sebelah kanan. Jalur *encoder* dimulai dengan proses *double convolution layer* 3×3 dan fungsi aktivasi ReLU, yang membuat jumlah *feature maps* menjadi 64, lalu diikuti dengan proses *maxpooling* yang berukuran 2×2 . Pada jalur *encoder*, penelitian ini menggunakan empat blok konvolusi, dimana di setiap blok konvolusi akan meningkat 2 kali lipat jumlah *feature maps* nya. Kemudian dilanjutkan dengan blok kelima yang merupakan penghubung antara jalur *encoder* dan jalur *decoder*, dimana tahapannya sama dengan blok pertama hanya saja proses *maxpooling* nya tidak perlu diikuti. Selanjutnya jalur *decoder*

dimulai dengan proses *upsampling* berukuran 2×2 , kemudian dilanjutkan dengan proses yang sama seperti blok pertama tanpa proses *maxpooling*. Pada jalur *decoder*, penelitian ini menggunakan empat blok konvolusi, dimana jumlah *feature maps* setiap blok akan berkurang 2 kali lipat sampai jumlah *feature maps* nya sama dengan jumlah *feature maps* semula, dimana tahap akhir pada jalur ini yaitu proses *convolution layer* 1×1 dan fungsi aktivasi *sigmoid* yang digunakan untuk menghasilkan gambar yang tersegmentasi.

2.6 Convolution Layer

Convolution layer merupakan komponen utama dari metode CNN yang digunakan untuk operasi konvolusi pada *output layer* sebelumnya, dimana hasil akhirnya berupa *feature maps*. Hasil dari *convolution layer* bisa dihitung menggunakan Persamaan (1) [21] berikut.

$$c_{i,j} = \left(\sum_{u=0}^{n-1} \sum_{v=0}^{n-1} a_{u+i,v+j} \times k_{i+1,j+1} \right) + b_q \quad (1)$$

dimana i merupakan baris, j adalah kolom, n adalah ukuran tinggi kernel, $c_{i,j}$ merupakan matriks *input*, $k_{i,j}$ merupakan matriks kernel, dan b_q merupakan bias untuk kernel ke- q .

2.7 Maxpooling Layer

Maxpooling layer merupakan salah satu lapisan pada *pooling layer* yang digunakan untuk mengekstraksi *patch* dari *feature maps* hasil konvolusi dengan melakukan pergeseran berdasarkan nilai terbesar dari setiap bagian tersebut [22].

2.8 Fungsi Aktivasi

Fungsi aktivasi merupakan lapisan dalam pada CNN yang digunakan untuk mengubah sinyal *input* menjadi sinyal *output*. Fungsi aktivasi sering dilakukan setelah proses *convolution layer* untuk mempercepat proses *training*. Fungsi aktivasi yang digunakan pada penelitian ini yaitu *Rectified Linear Unit* (ReLU) dan *Sigmoid*. ReLU merupakan fungsi aktivasi nonlinier yang membuat seluruh nilai piksel yang bernilai negatif pada citra menjadi 0. Fungsi aktivasi ReLU didefinisikan pada Persamaan (2) [23] berikut.

$$f(x) = \max(0, x) = \begin{cases} x & \text{jika } x \geq 0 \\ 0 & \text{jika } x < 0 \end{cases} \quad (2)$$

dimana x adalah nilai *input* citra dan $f(x)$ adalah hasil fungsi aktivasi ReLU. *Sigmoid* merupakan fungsi aktivasi yang digunakan pada lapisan akhir atau *output* pada proses segmentasi dengan nilai *output* nya terletak di interval 0 hingga 1. Fungsi aktivasi *sigmoid* dapat didefinisikan pada Persamaan (3) berikut.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

dimana $x \in (-\infty, \infty)$, $\sigma(x) \in (0,1)$.

2.9 Upsampling Layer

Upsampling layer merupakan lapisan yang digunakan untuk membuat ukuran *feature maps* ke dimensi yang lebih tinggi, dimana cara kerjanya dilakukan dengan meningkatkan lebar dan tinggi dari matriks *input* [24].

2.10 Concatenate

Concatenate digunakan untuk menggabungkan *feature maps* hasil proses konvolusi setiap blok pada jalur *encoder* dengan *feature maps* hasil proses *upsampling* pada jalur *decoder* menjadi satu buah matriks *input* baru dengan ukuran matriks yang baru [25].

2.11 Loss Function : Binary Cross Entropy

Loss function merupakan ukuran kesalahan dalam proses *training* yang digunakan untuk mengukur kesalahan antara nilai yang diprediksi dengan nilai sebenarnya. *Loss function* dibutuhkan dalam proses *training* untuk mengevaluasi hasil yang didapatkan yang secara langsung mempengaruhi keakuratan dan validitas dari model tersebut [15]. *Loss function* yang digunakan untuk segmentasi biner yang memiliki dua kelas objek adalah *binary cross entropy*. Fungsi dari *loss function binary cross entropy* didefinisikan pada Persamaan (4) [26].

$$L = -\frac{1}{m \times n} \left[\sum_{i=1}^m \sum_{j=1}^n \left((y_{i,j} \log(p_{i,j})) + ((1 - y_{i,j}) \log(1 - p_{i,j})) \right) \right] \quad (4)$$

dimana $m \times n$ merupakan ukuran matriks hasil prediksi segmentasi, p adalah nilai probabilitas yang diprediksi dan y adalah nilai sebenarnya atau *groundtruth* (0 untuk piksel *background* dan 1 untuk piksel *hati*).

2.12 Testing


Proses *testing* merupakan proses terakhir dari keseluruhan sistem penelitian. Proses *testing* dilakukan untuk menguji model yang telah dilatih pada proses *training*, dimana proses ini mengukur ketepatan segmentasi dengan menilai indeks yang dihasilkan oleh model arsitektur *U-Net* yang telah di *training*.

2.13 Evaluasi Kinerja Model

Evaluasi kinerja model pada proses segmentasi citra hati dilakukan dengan menggunakan *confusion matrix*. *Confusion Matrix* merupakan pengukuran performa untuk masalah klasifikasi *machine learning* yang digunakan sebagai basis dalam perhitungan evaluasi kinerja model dalam prediksi. Hasil dari metode yang digunakan dalam segmentasi citra hati dapat memberikan kesimpulan tentang seberapa baik kinerja model arsitektur *U-Net* dalam segmentasi hati. Kinerja model yang diukur dan digunakan dalam penelitian ini adalah nilai akurasi, sensitivitas, spesifisitas, *koefisien jaccard*, dan *dice similarity coefficient* (DSC).

3. HASIL DAN PEMBAHASAN


Data yang digunakan dalam penelitian ini berupa citra hati dengan resolusi dimensi sebesar 256×256 piksel. Contoh hasil tahapan *pre-processing* data yang dilakukan pada penelitian ini dapat dilihat pada Gambar 3.



Gambar 3 Hasil *pre-processing* untuk segmentasi citra hati

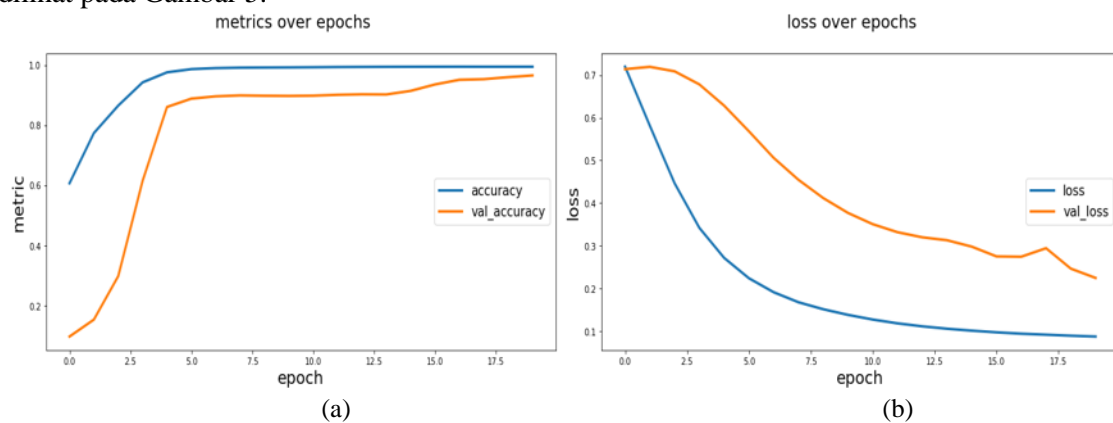
Pada Gambar 3 terlihat bahwa *input* citra bertipe RGB (*Red, Green, Blue*) yang memiliki tiga *channel*. Dari *input* citra tersebut dilakukan pengambilan salah satu *channel* yaitu *green channel* untuk mendapatkan citra dengan kualitas yang lebih baik. Citra hasil *green channel* tersebut dilakukan perbaikan kontras menggunakan *Histogram Equalization* (HE) dengan hasil kontras yang cukup bagus. Selanjutnya citra hasil HE dilakukan peningkatan kontras kembali menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk membuat fitur

hati terlihat lebih jelas. Grafik histogram perbandingan sebelum dan setelah tahapan perbaikan citra pada penelitian ini terlihat pada Gambar 4 berikut.



Gambar 4 Grafik histogram perbandingan (a) sebelum perbaikan citra (b) setelah perbaikan citra

Gambar 4 (a) menunjukkan bahwa sebaran grafik histogram pada saat sebelum dilakukan perbaikan citra masih tersebar tidak normal dengan tingginya yang berbeda-beda, sedangkan pada Gambar 4 (b) setelah dilakukan perbaikan citra terlihat bahwa sebaran grafik histogram sudah jauh lebih baik dan normal dengan sebaran yang merata dengan tinggi yang tidak berbeda jauh. Hal ini menunjukkan bahwa tahapan perbaikan citra dengan peningkatan kontras sudah sangat baik dilakukan. Hasil dari tahapan *pre-processing* data akan dilakukan segmentasi menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *U-Net*. Proses implementasi arsitektur pada penelitian ini terdiri dari proses *training* dan *testing*. Proses *training* dilakukan untuk melatih model agar bisa mempelajari pola dan mengenali fitur-fitur dari data. Pada proses ini, dataset yang digunakan dibagi dengan perbandingan sebesar 70:30 untuk data latih dan data validasi. Lalu selanjutnya dataset dilakukan optimalisasi menggunakan *Adam Optimizers* dengan *learning rate* 0,00001, *batch size* 8, *epoch* 20, dan menggunakan *loss function binary cross entropy* untuk memperkirakan nilai *loss*. Hasil dari proses *training* data ini menghasilkan nilai *accuracy* dan *loss* pada data latih, serta nilai *accuracy* dan *loss* pada data validasi. Grafik nilai *accuracy* dan *loss* yang didapatkan pada proses *training* dengan model arsitektur *U-Net* dapat dilihat pada Gambar 5.



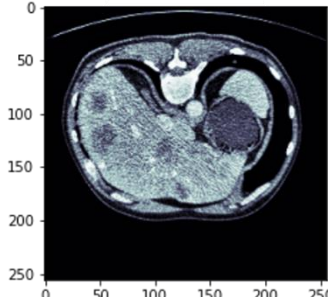
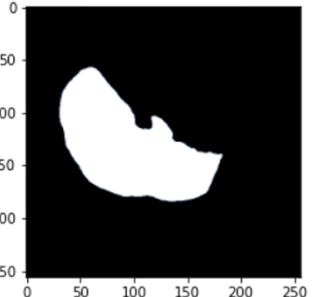
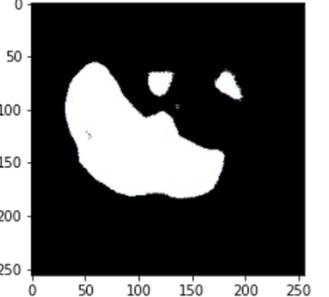
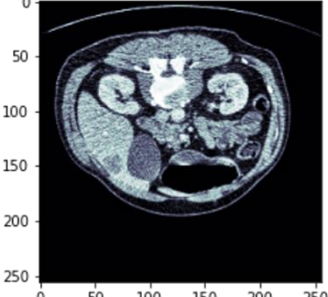
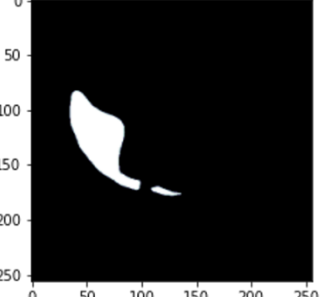
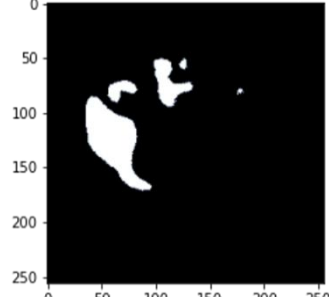
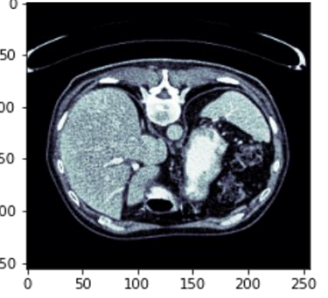
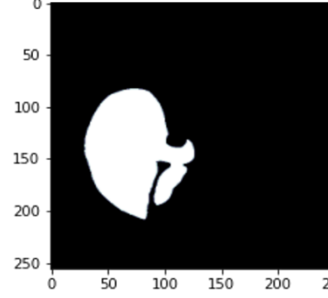
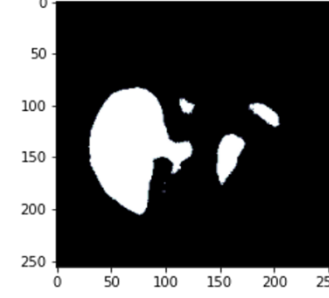
Gambar 5 Grafik yang didapatkan pada proses *training* (a) *accuracy* (b) *loss*

Pada Gambar 5 (a), terlihat bahwa grafik nilai akurasi pada data latih dan validasi selama proses *training* meningkat signifikan menuju 1 mulai dari *epoch* ke 2, hal ini menunjukkan bahwa model yang digunakan sudah sangat baik dalam mempelajari pola *input* yang diberikan. Pada Gambar 5 (b), terlihat bahwa grafik nilai *loss* pada data latih dan validasi selama proses *training*

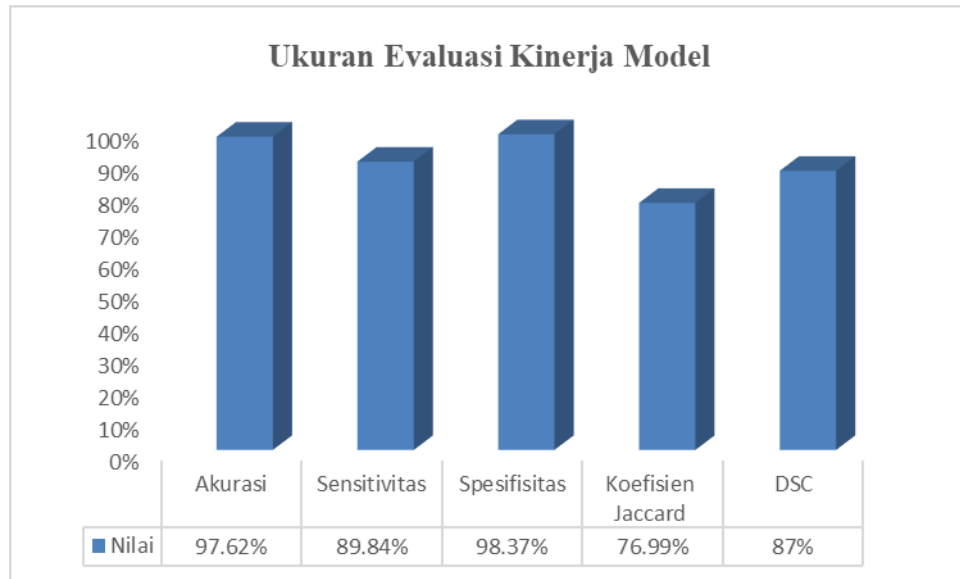
semakin menurun pada setiap *epoch* dan mendekati nilai nol yang artinya semakin kecil nilai *loss* maka semakin kecil juga tingkat kesalahan yang dilakukan model dalam mempelajari pola *input*. Hasil dari proses *training* selanjutnya disimpan pada sebuah model, dimana model tersebut akan dilakukan pengujian model arsitektur.

Pengujian model arsitektur merupakan rangkaian proses *testing*, dimana proses ini menggunakan data uji yang telah dibagi dari dataset sebanyak 400 data untuk melihat keakuratan model dalam melakukan prediksi segmentasi citra hati. Beberapa perbandingan citra *input*, *grountruth* dan hasil segmentasi dapat dilihat pada Tabel 2.

Tabel 2 Perbandingan citra *input*, *grountruth*, dan hasil segmentasi

Citra Input	Grountruth	Hasil Segmentasi
		
		
		

Pada Tabel 2, dapat dilihat bahwa hasil segmentasi citra hati menggunakan arsitektur *U-Net* sudah terlihat mirip dengan *grountruth*. Namun, hasil segmentasi yang didapatkan masih ada beberapa area pada *background* yang terprediksi sebagai hati. Selanjutnya, dari hasil prediksi didapatkan *confusion matrix* yang digunakan untuk mengukur hasil kinerja model seperti akurasi, sensitivitas, spesifisitas, *koefisien jaccard* dan DSC yang ditunjukkan pada Gambar 6.



Gambar 6 Grafik hasil pengukuran evaluasi kinerja model

Pada Gambar 6, menunjukkan bahwa terdapat 6 ukuran kinerja model yang dihitung pada penelitian ini. Untuk nilai akurasi diperoleh sebesar 97,62% artinya keakuratan model dalam melakukan segmentasi citra hati sudah sangat baik. Untuk nilai sensitivitas diperoleh sebesar 89,84% yang artinya kemampuan model dalam memprediksi piksel hati dengan benar sudah baik dan nilai spesifisitas sebesar 98,37% yang artinya kemampuan model dalam memprediksi piksel *background* dengan benar sudah sangat baik. Nilai *koefisien jaccard* diperoleh sebesar 76,99% yang artinya kemiripan antara citra hasil prediksi segmentasi dengan *grountruth* tergolong cukup baik, dan nilai DSC sebesar 87% memiliki arti harmonisasi antara nilai sensitivitas dan spesifisitas sudah tergolong baik. Hasil yang diperoleh selanjutnya dilakukan perbandingan hasil evaluasi kinerja model dengan penelitian sebelumnya yang dapat dilihat seperti pada Tabel 3.

Tabel 3 Perbandingan metode yang diusulkan dengan penelitian sebelumnya

Metode	Dataset	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	Jaccard (%)	DSC (%)
2D U-Net [27]	LiTS	96,2	-	-	-	73,5
U-Net+CycleGAN [28]	LiTS	-	88,78	83,56	-	84,7
V-Net+WGAN [29]	LiTS	94	-	-	-	90
H-DenseU-Net [30]	LiTS	-	-	-	39	92
Metode yang diusulkan	Liver	97,62	89,84	98,37	76,99	87

Pada Tabel 3 terlihat bahwa segmentasi citra hati menggunakan arsitektur *U-Net* memiliki hasil akurasi, sensitivitas, spesifisitas, dan koefisien jaccard yang paling tinggi dibandingkan penelitian sebelumnya, yaitu akurasi sebesar 97,62%, sensitivitas sebesar 89,84%, spesifisitas sebesar 98,37%, dan *koefisien jaccard* sebesar 76,99%. Namun, nilai DSC yang diperoleh masih lebih rendah dibandingkan dengan penelitian lain yaitu sebesar 87%. Dari keempat penelitian yang telah dilakukan sebelumnya, terlihat bahwa penelitian tersebut hanya mengukur 2 sampai 3 ukuran kinerja evaluasi saja. Berdasarkan perbandingan hasil penelitian yang telah dilakukan, dapat dikatakan bahwa metode yang diusulkan telah memberikan kinerja yang optimal dalam segmentasi citra hati.

4. KESIMPULAN DAN SARAN

Segmentasi citra hati menggunakan arsitektur *U-Net* telah menunjukkan hasil yang sangat baik dengan ukuran evaluasi kinerja akurasi dan spesifisitasnya sudah diatas 95%, sementara untuk nilai sensitivitas dan DSC sudah diatas 85%, namun untuk nilai *koefisien jaccard* masih dibawah 80%. Dari hasil tersebut menunjukkan bahwa arsitektur *U-Net* memiliki kemampuan yang sangat baik dalam memprediksi hasil objek yang berwarna putih (hati) dan hasil objek yang berwarna hitam (*background*) dalam segmentasi citra hati. Diharapkan untuk penelitian selanjutnya dapat melakukan segmentasi dengan jaringan semantik untuk melatih node karena sangat bermanfaat terutama dalam bidang medis serta melanjutkan ke tahap klasifikasi penyakit hati.

UCAPAN TERIMA KASIH

Penelitian/publikasi ini didanai oleh Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi Nomor SPPK 1418/LL2/PG/2022 tanggal 15 Juni 2022 melalui dana DIPA Nomor DIPA : SP DIPA-023.17.1.690523/2022 revisi ke-02 pada 22 April 2022.

DAFTAR PUSTAKA

- [1] M. Rela, N. R. Suryakari, and P. R. Reddy, "Liver Tumor Segmentation and Classification: A Systematic Review," *Proc. 2020 IEEE-HYDCON Int. Conf. Eng. 4th Ind. Revolution, HYDCON 2020*, pp. 21–26, 2020.
- [2] A. I. Falatehan, N. Hidayat, and K. C. Brata, "Sistem Pakar Diagnosis Penyakit Hati Menggunakan Metode Fuzzy Tsukamoto Berbasis Android," *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 2, no. 8, pp. 2373–2381, 2018.
- [3] T. R. Latifatul Khairiah, Tursina, "Sistem Pakar Diagnosis Penyakit Hati Dengan Metode Dempster Shafer Berbasis Android," *J. Coding Sist. Komput. Untan*, vol. 5, no. 2, pp. 57–66, 2017.
- [4] H. Sung *et al.*, "Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries," *CA. Cancer J. Clin.*, vol. 71, no. 3, pp. 209–249, 2021.
- [5] N. Alalwan, A. Abozeid, A. A. A. ElHabshy, and A. Alzahrani, "Efficient 3D Deep Learning Model for Medical Image Semantic Segmentation," *Alexandria Eng. J.*, vol. 60, no. 1, pp. 1231–1239, 2021.
- [6] A. Desiani, B. Suprihatin, S. Yahdin, A. I. Putri, and F. R. Husein, "Bi-path architecture of CNN segmentation and classification method for cervical cancer disorders based on pap-smear images," *IAENG Int. J. Comput. Sci.*, vol. 48, no. 3, pp. 1–10, 2021.
- [7] A. A. Riadi, A. A. Chamid, and A. Sokhibi, "Analisis Komparasi Metode Perbaikan Kontras Berbasis Histogram Equalization Pada Citra Medis," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 8, no. 1, pp. 383–388, 2017.
- [8] A. M. Anter and A. E. Hassenian, "CT liver tumor segmentation hybrid approach using neutrosophic sets, fast fuzzy c-means and adaptive watershed algorithm," *Artif. Intell. Med.*, vol. 97, no. September, pp. 105–117, 2019.
- [9] M. Rela, S. N. Rao, and P. R. Reddy, "Liver Tumor Segmentation using Superpixel based Fast Fuzzy C Means Clustering," *Int. J. Adv. Comput. Sci. Appl.*, vol. 11, no. 11, pp. 380–387, 2020.
- [10] L. Meng, Q. Zhang, and S. Bu, "Two-stage liver and tumor segmentation algorithm based on convolutional neural network," *Diagnostics*, vol. 11, no. 10, 2021.
- [11] S. M. Anwar, S. Awan, S. Yousaf, and M. Majid, "Segmentation of liver tumor for computer aided diagnosis," *2018 IEEE EMBS Conf. Biomed. Eng. Sci. IECBES 2018 -*

- Proc.*, pp. 366–370, 2019.
- [12] J. Cai, “Segmentation and Diagnosis of Liver Carcinoma Based on Adaptive Scale-Kernel Fuzzy Clustering Model for CT Images,” *J. Med. Syst.*, vol. 43, no. 11, 2019.
 - [13] R. Zhang, Z. Zhou, W. Wu, C. C. Lin, P. H. Tsui, and S. Wu, “An improved fuzzy connectedness method for automatic three-dimensional liver vessel segmentation in CT images,” *J. Healthc. Eng.*, vol. 2018, 2018.
 - [14] M. Wang and W. Deng, “Deep visual domain adaptation: A survey,” *Neurocomputing*, vol. 312, no. April, pp. 135–153, 2018.
 - [15] T. A. Soomro *et al.*, “Deep learning models for retinal blood vessels segmentation: a review,” *IEEE Access*, vol. 7, pp. 71696–71717, 2019.
 - [16] G. Du, X. Cao, J. Liang, X. Chen, and Y. Zhan, “Medical Image Segmentation based on U-Net: A Review,” *J. Imaging Sci. Technol.*, vol. 64, no. 2, pp. 1–12, 2020.
 - [17] T. Pranata, A. Desiani, B. Suprihatin, H. Hanum, and F. Efriliyanti, “Segmentation of the Lungs on X-Ray Thorax Image with CNN Architecture U-Net,” vol. 11, no. 2, pp. 101–111, 2022.
 - [18] X. He, Z. Yu, T. Wang, B. Lei, and Y. Shi, “Dense deconvolution net: Multi path fusion and dense deconvolution for high resolution skin lesion segmentation,” *Technol. Heal. Care*, vol. 26, no. S1, pp. S307–S316, 2018.
 - [19] N. Saeedizadeh, S. Minaee, R. Kafieh, S. Yazdani, and M. Sonka, “COVID TV-Unet: Segmenting COVID-19 chest CT images using connectivity imposed Unet,” *Comput. Methods Programs Biomed. Updat.*, vol. 1, no. March, p. 100007, 2021.
 - [20] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021.
 - [21] W. Chen, B. Yang, J. Li, and J. Wang, “An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks,” *IEEE Access*, vol. 8, pp. 178552–178562, 2020.
 - [22] M. M. Islam, T. N. Poly, B. A. Walther, H. C. Yang, and Y.-C. (Jack) Li, “Artificial intelligence in ophthalmology: a meta-analysis of deep learning models for retinal vessels segmentation,” *J. Clin. Med.*, vol. 9, no. 4, p. 1018, 2020.
 - [23] H. Ide and T. Kurita, “Improvement of learning for CNN with ReLU activation by sparse regularization,” *Proc. Int. Jt. Conf. Neural Networks*, vol. 2017-May, pp. 2684–2691, 2017.
 - [24] J. Shi *et al.*, “Improvement of damage segmentation based on pixel-level data balance using vgg-unet,” *Appl. Sci.*, vol. 11, no. 2, pp. 1–17, 2021.
 - [25] C. Wang, M. Gan, M. Zhang, and D. Li, “Adversarial convolutional network for esophageal tissue segmentation on OCT images,” *Biomed. Opt. Express*, vol. 11, no. 6, p. 3095, 2020.
 - [26] R. A. Pangestu, B. Rahmat, and F. T. Anggraeny, “Implementasi Algoritma CNN untuk Klasifikasi Citra Lahan dan Perhitungan Luas,” *Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 166–174, 2020.
 - [27] L. Han, Y. Chen, J. Li, B. Zhong, Y. Lei, and M. Sun, “Liver segmentation with 2.5D perpendicular UNets,” *Comput. Electr. Eng.*, vol. 91, no. January, p. 107118, 2021.
 - [28] B. Kim and J. C. Ye, “Cycle-consistent adversarial network with polyphase U-Nets for liver lesion segmentation,” *1st Conf. Med. Imaging with Deep Learn.*, no. Midl, pp. 1–3, 2018.
 - [29] J. Ma, Y. Deng, Z. Ma, K. Mao, and Y. Chen, “A Liver Segmentation Method Based on the Fusion of VNet and WGAN,” *Comput. Math. Methods Med.*, vol. 2021, 2021.
 - [30] X. Li, H. Chen, X. Qi, Q. Dou, C. W. Fu, and P. A. Heng, “H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes,” *IEEE Trans. Med. Imaging*, vol. 37, no. 12, pp. 2663–2674, 2018.