

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2.1 Penelitian Terdahulu

Referensi	[24]
Penulis & Tahun	Abdelrahman et al. (2023)
Judul	EfficientNet Family U-Net Models for Deep Learning Semantic Segmentation of Kidney Tumors on CT Images
Metode	EfficientNet-B0/B4 U-Net
Dataset	KiTS19
Kelas Segmentasi	Ginjal, Tumor
Ringkasan	Penelitian ini menggunakan U-Net dengan backbone EfficientNet-B0 dan EfficientNet-B4 untuk segmentasi tumor ginjal pada citra CT. Hasilnya menunjukkan bahwa penggunaan pretrained backbone dapat membantu meningkatkan kemampuan ekstraksi fitur dibandingkan encoder U-Net konvensional.
Hasil	mIoU 0,98; MDC $\approx$ 0,85
Referensi	[25]
Penulis & Tahun	Sun et al. (2023)
Judul	2.5D MFFAU-Net: A Convolutional Neural Network for Kidney Segmentation
Metode	2.5D MFFAU-Net
Dataset	KiTS19, KiTS21
Kelas Segmentasi	Ginjal, Tumor, Kista
Ringkasan	Memanfaatkan informasi spasial 2.5D dan mekanisme feature fusion untuk meningkatkan segmentasi tanpa kebutuhan komputasi sebesar model 3D.
Hasil	Mean Dice 0,924 (KiTS19); 0,875 (KiTS21)
Referensi	[26]

Penulis & Tahun	Uhm et al. (2023)
Judul Paper	Exploring 3D U-Net Training Configurations and Post-Processing Strategies for the MICCAI 2023 Kidney and Tumor Segmentation Challenge
Metode	Multi-scale 3D U-Net
Dataset	KiTS23
Kelas Segmentasi	Background, Ginjal, Kista, Tumor
Ringkasan	Mengevaluasi berbagai konfigurasi pelatihan 3D U-Net dan strategi post-processing untuk meningkatkan performa segmentasi ginjal, kista, dan tumor pada dataset KiTS23. Pendekatan multi-scale post-processing mampu mengurangi false positive dan meningkatkan kualitas segmentasi dibandingkan model dasar.
Hasil (MDC/Dice)	Dice Validation: Kidney 0,979, Masses 0,857, Tumor 0,826, Average Dice 0,887
Referensi	[27]
Penulis & Tahun	Shamija Sherryl R. M. R. & Jaya T. (2024)
Judul Paper	Multi-Scale and Spatial Information Extraction for Kidney Tumor Segmentation
Metode	Cascaded 3D U-Net multi-scale
Dataset	KiTS21
Kelas Segmentasi	Ginjal, Tumor, Cyst
Ringkasan	Penelitian ini mengusulkan metode Cascaded 3D U-Net berbasis multi-scale untuk segmentasi ginjal, tumor, dan kista pada dataset KiTS21. Pendekatan multi-scale digunakan untuk menangkap fitur pada berbagai ukuran objek, tetapi tetap membutuhkan komputasi tinggi karena menggunakan model 3D.
Hasil (MDC/Dice)	MDC 0.85
Referensi	[28]
Penulis & Tahun	Hu et al. (2024)

Judul Paper	STC-UNet: Renal Tumor Segmentation Based on Enhanced Feature Extraction
Metode	STC-UNet (Spatial-Temporal Convolution)
Dataset	Custom renal CT dataset (500+)
Kelas Segmentasi	Ginjal, Tumor
Ringkasan	Penelitian ini mengembangkan STC-UNet untuk segmentasi tumor ginjal dengan peningkatan ekstraksi fitur pada beberapa level jaringan. Model menunjukkan performa yang baik pada dataset CT ginjal khusus, tetapi dataset yang digunakan bukan dataset publik sehingga perbandingan dengan penelitian lain menjadi terbatas.
Hasil (MDC/Dice)	MDC 0.88
Referensi	[29]
Penulis & Tahun	Neha & Bansal (2024)
Judul Paper	Multi-Layer Feature Fusion with Cross-Channel Attention-Based U-Net for Kidney Tumor Segmentation
Metode	MFF + Cross-Channel Attention U-Net
Dataset	KiTS19
Kelas Segmentasi	Ginjal, Tumor
Ringkasan	Mengembangkan U-Net dengan feature fusion dan cross-channel attention untuk meningkatkan representasi fitur pada segmentasi tumor.
Hasil (MDC/Dice)	Dice Ginjal 0,97; Dice Tumor 0,96
Referensi	[30]
Penulis & Tahun	Irmawati et al. (2025)
Judul Paper	Advanced Kidney Tumor Segmentation Using Multi-Scale Attention
Metode	Multi-scale Attention U-Net
Dataset	KiTS23 + dataset klinis
Kelas Segmentasi	Ginjal, Tumor, Cyst
Ringkasan	Penelitian ini menerapkan Multi-scale Attention U-Net untuk segmentasi ginjal, tumor, dan kista menggunakan KiTS23 dan

	dataset klinis. Pendekatan attention dan multi-scale digunakan untuk meningkatkan kemampuan model dalam mengenali area lesi yang memiliki bentuk dan ukuran bervariasi.
Hasil (MDC/Dice)	Dice 0.90 (Tumor 0.87)
Referensi	[31]
Penulis & Tahun	Zhang et al. (2025)
Judul Paper	Multi-Scale Feature Fusion enhancement network for medical image segmentation
Metode	Multi-scale CNN U-Net
Dataset	Re-TMRS
Kelas Segmentasi	Ginjal, Tumor
Ringkasan	Penelitian ini mengembangkan jaringan berbasis multi-scale feature fusion untuk segmentasi tumor ginjal pada dataset Re-TMRS. Model memperoleh hasil mDice tinggi, tetapi fokus penelitian berada pada segmentasi tumor ginjal berbasis citra endoskopi, bukan CT scan.
Hasil (MDC/Dice)	MDice 0.91
Referensi	[32]
Penulis & Tahun	Gido et al. (2025)
Judul Paper	Kidney and Renal Tumor Segmentation by nnU-Net Using 3D CT Data from Different Sources
Metode	3D nnU-Net
Dataset	Multi-source CT Dataset
Kelas Segmentasi	Ginjal, Tumor
Ringkasan	Mengimplementasikan nnU-Net pada data CT ginjal yang berasal dari berbagai sumber untuk mengevaluasi kemampuan generalisasi model terhadap variasi karakteristik citra. Penelitian menunjukkan bahwa nnU-Net tetap mempertahankan performa segmentasi yang baik meskipun terdapat perbedaan distribusi data antar sumber.
Hasil (MDC/Dice)	Dice Ginjal $\approx 0,96$; Dice Tumor $\approx 0,84$

Referensi	[33]
Penulis & Tahun	Kim et al. (2025)
Judul Paper	Comparative Analysis of U-Net and U-Net++ for Kidney CT Image Segmentation
Metode	U-Net and U-Net++
Dataset	KiTS23
Kelas Segmentasi	Ginjal, Tumor, Kista
Ringkasan	Membandingkan performa U-Net dan U-Net++ pada segmentasi ginjal multi-kelas sebagai acuan pengembangan model segmentasi.
Hasil (MDC/Dice)	Mean Dice $\approx$ 0,91

Berdasarkan penelitian terdahulu yang telah dirangkum pada Tabel 2.1, dapat diketahui bahwa perkembangan penelitian segmentasi ginjal berbasis *deep learning* terus mengalami peningkatan, baik melalui modifikasi arsitektur U-Net maupun penambahan berbagai mekanisme ekstraksi fitur. Abdelrahman et al. [24] menunjukkan bahwa penggunaan *pretrained backbone* EfficientNet pada U-Net mampu meningkatkan kemampuan ekstraksi fitur dibandingkan encoder konvensional. Namun, penelitian tersebut hanya mengevaluasi segmentasi ginjal dan tumor menggunakan dataset KiTS19 sehingga belum mencakup segmentasi multi-kelas yang melibatkan kista. Selanjutnya, Sun et al. [25] mengembangkan arsitektur 2.5D MFFAU-Net yang memanfaatkan informasi spasial antar irisan CT dan mekanisme *feature fusion* sehingga menghasilkan performa segmentasi yang lebih baik dibandingkan pendekatan 2D konvensional. Meskipun demikian, model tersebut memiliki kompleksitas yang lebih tinggi karena memanfaatkan beberapa irisan citra secara bersamaan.

Penelitian oleh Uhm et al. [26] mengeksplorasi berbagai konfigurasi pelatihan 3D U-Net dan strategi *post-processing* pada dataset KiTS23. Hasil penelitian menunjukkan bahwa kombinasi konfigurasi pelatihan dan *multi-scale post-processing* mampu meningkatkan kualitas segmentasi ginjal, tumor, dan kista serta mengurangi *false positive*. Akan tetapi, penggunaan model tiga dimensi menyebabkan kebutuhan memori GPU dan waktu pelatihan menjadi lebih besar.

Permasalahan serupa juga ditemukan pada penelitian Shamija Sherryl R. M. R. dan Jaya T. [27] yang mengusulkan Cascaded 3D U-Net berbasis *multi-scale*. Pendekatan tersebut mampu menangkap informasi spasial secara lebih baik, namun tetap memiliki kompleksitas komputasi yang tinggi sehingga kurang efisien apabila diterapkan pada perangkat dengan sumber daya terbatas.

Hu et al. [28] mengembangkan STC-UNet dengan menambahkan mekanisme *Spatial-Temporal Convolution* untuk meningkatkan kemampuan ekstraksi fitur pada segmentasi tumor ginjal. Walaupun menghasilkan performa yang baik, penelitian tersebut menggunakan dataset CT khusus sehingga hasilnya sulit dibandingkan secara langsung dengan penelitian lain yang menggunakan dataset publik. Sementara itu, Neha dan Bansal [29] mengombinasikan *multi-layer feature fusion* dan *cross-channel attention* pada arsitektur U-Net untuk meningkatkan representasi fitur, sedangkan Irmawati et al. [30] memanfaatkan mekanisme *multi-scale attention* guna meningkatkan kemampuan model dalam mengenali lesi dengan ukuran dan bentuk yang beragam. Zhang et al. [31] juga mengembangkan jaringan berbasis *multi-scale feature fusion* untuk memperkuat representasi fitur pada proses segmentasi. Ketiga penelitian tersebut menunjukkan bahwa penambahan modul *attention* maupun *feature fusion* mampu meningkatkan performa segmentasi, tetapi menyebabkan arsitektur model menjadi semakin kompleks dan jumlah parameter yang harus dipelajari meningkat.

Selain itu, Gido et al. [32] mengevaluasi kemampuan generalisasi arsitektur 3D nnU-Net pada data CT ginjal yang berasal dari berbagai institusi. Hasil penelitian menunjukkan bahwa nnU-Net mampu mempertahankan performa segmentasi yang baik meskipun terdapat variasi karakteristik citra antar sumber data. Namun demikian, model yang digunakan masih berupa arsitektur tiga dimensi sehingga memerlukan kebutuhan komputasi yang tinggi. Penelitian oleh Kim et al. [33] membandingkan performa U-Net dan U-Net++ pada dataset KiTS23 sebagai acuan pengembangan model segmentasi multi-kelas. Hasil penelitian menunjukkan bahwa modifikasi arsitektur U-Net dapat meningkatkan performa segmentasi, tetapi penelitian tersebut belum mengevaluasi pengaruh penggunaan backbone CNN yang berbeda terhadap kemampuan ekstraksi fitur.

Berdasarkan keseluruhan penelitian tersebut, dapat disimpulkan bahwa sebagian besar penelitian terkini berfokus pada pengembangan arsitektur melalui penambahan mekanisme *attention*, *feature fusion*, pendekatan 2.5D maupun 3D, serta strategi *post-processing* untuk meningkatkan performa segmentasi [24]–[33]. Meskipun mampu menghasilkan nilai Dice yang tinggi, pendekatan-pendekatan tersebut umumnya diikuti dengan meningkatnya kompleksitas model, kebutuhan memori, dan waktu pelatihan. Di sisi lain, penelitian yang secara khusus membandingkan pengaruh penggunaan backbone DenseNet dengan tingkat kedalaman yang berbeda sebagai encoder pada arsitektur U-Net 2D untuk segmentasi multi-kelas ginjal menggunakan dataset KiTS23 masih sangat terbatas. Oleh karena itu, penelitian ini mengimplementasikan dan membandingkan DenseNet121, DenseNet169, dan DenseNet201 sebagai backbone pada arsitektur U-Net 2D untuk menganalisis pengaruh kedalaman jaringan terhadap kemampuan segmentasi ginjal, tumor, dan kista menggunakan metrik Dice Coefficient dan Mean Dice Coefficient. Dengan demikian, penelitian ini tidak hanya mengevaluasi performa segmentasi, tetapi juga memberikan analisis mengenai backbone DenseNet yang paling efektif sebagai encoder U-Net 2D dengan tetap mempertahankan efisiensi komputasi dibandingkan pendekatan segmentasi tiga dimensi.

2.2 Teori yang berkaitan

Bagian ini membahas teori-teori dasar yang berkaitan dengan segmentasi ginjal dan deep learning.

2.2.1 Penyakit Ginjal Kronis (CKD)

Penyakit Ginjal Kronis atau *Chronic Kidney Disease* (CKD) merupakan gangguan fungsi ginjal yang terjadi secara progresif dan berlangsung dalam jangka waktu lama. Ginjal merupakan organ vital dalam tubuh manusia yang memiliki fungsi utama untuk menyaring zat sisa metabolisme dan cairan berlebih dari darah melalui proses pembentukan urin. Selain itu, ginjal juga berperan dalam menjaga keseimbangan cairan tubuh, mengatur tekanan darah, mempertahankan keseimbangan elektrolit, serta membantu produksi hormon tertentu seperti eritropoietin yang berfungsi dalam pembentukan sel darah merah [34]. Ketika

fungsi ginjal mengalami penurunan secara bertahap, kemampuan tubuh dalam membuang zat sisa menjadi terganggu sehingga dapat menyebabkan berbagai komplikasi kesehatan yang serius.

CKD umumnya disebabkan oleh beberapa faktor utama, seperti diabetes melitus, hipertensi, infeksi ginjal, kelainan bawaan, hingga pertumbuhan tumor dan kista pada organ ginjal. Pada banyak kasus, penyakit ini berkembang tanpa menunjukkan gejala yang signifikan pada tahap awal sehingga sering disebut sebagai silent disease. Gejala biasanya mulai muncul ketika fungsi ginjal telah mengalami penurunan yang cukup berat, seperti pembengkakan tubuh, kelelahan, gangguan tekanan darah, hingga gangguan metabolisme tubuh [35]. Oleh karena itu, deteksi dini terhadap kelainan ginjal menjadi sangat penting agar penanganan medis dapat dilakukan lebih cepat dan risiko komplikasi dapat diminimalkan.

Dalam dunia medis, pemeriksaan pencitraan seperti *Ultrasonography* (USG), *Magnetic Resonance Imaging* (MRI), dan *Computed Tomography* (CT) scan sering digunakan untuk membantu proses diagnosis penyakit ginjal. Di antara metode tersebut, CT scan menjadi salah satu teknik pencitraan yang paling banyak digunakan karena mampu menghasilkan citra dengan resolusi tinggi dan detail anatomi yang baik [12]. Melalui citra CT scan, dokter dapat mengamati bentuk organ ginjal, mendeteksi adanya tumor maupun kista, serta mengevaluasi kondisi jaringan di sekitar ginjal secara lebih jelas.

Namun, proses analisis citra CT scan masih banyak dilakukan secara manual oleh radiolog. Segmentasi organ ginjal dan area lesi dilakukan dengan cara menandai bagian tertentu pada setiap irisan citra secara satu per satu. Proses tersebut membutuhkan waktu yang cukup lama dan sangat bergantung pada pengalaman tenaga medis. Selain itu, segmentasi manual juga memiliki potensi menghasilkan variasi interpretasi antar-radiolog (*inter-observer variability*), terutama pada area tumor atau kista yang memiliki batas jaringan kurang jelas [36]. Oleh karena itu, dibutuhkan sistem otomatis yang mampu membantu proses segmentasi citra medis secara lebih cepat, konsisten, dan akurat.

2.2.2 Deep Learning

Deep Learning merupakan salah satu cabang dari kecerdasan buatan (*Artificial Intelligence*) dan *Machine Learning* yang menggunakan jaringan saraf tiruan (*Artificial Neural Network*) dengan banyak lapisan untuk mempelajari pola dari data dalam jumlah besar [37]. Konsep utama *Deep Learning* adalah kemampuan model untuk melakukan pembelajaran representasi fitur secara otomatis tanpa memerlukan proses ekstraksi fitur manual seperti pada metode konvensional. Dengan memanfaatkan banyak lapisan jaringan (*deep architecture*), model dapat mempelajari fitur sederhana hingga fitur kompleks secara bertahap.

Perkembangan *Deep Learning* didukung oleh meningkatnya kemampuan komputasi perangkat keras, terutama penggunaan *Graphics Processing Unit* (GPU), serta ketersediaan data dalam jumlah besar. Dalam beberapa tahun terakhir, *Deep Learning* telah menunjukkan performa yang sangat baik pada berbagai bidang, seperti pengolahan citra, pengenalan suara, pemrosesan bahasa alami, hingga sistem rekomendasi [38]. Pada bidang pengolahan citra, *Deep Learning* mampu mengenali pola visual dengan tingkat akurasi yang tinggi sehingga banyak digunakan dalam aplikasi klasifikasi citra, deteksi objek, dan segmentasi citra.

Dalam bidang *medical image analysis*, *Deep Learning* memberikan kontribusi yang sangat besar karena mampu membantu proses diagnosis penyakit melalui analisis citra medis secara otomatis. Teknologi ini telah diterapkan pada berbagai jenis citra medis, seperti CT scan, MRI, X-ray, dan USG. Salah satu penerapan yang paling banyak digunakan adalah *semantic segmentation*, yaitu proses klasifikasi setiap piksel citra ke dalam kelas tertentu [39]. Pada kasus citra CT ginjal, *semantic segmentation* digunakan untuk memisahkan area ginjal, tumor, dan kista dari latar belakang secara otomatis.

Keunggulan utama *Deep Learning* dibandingkan metode tradisional terletak pada kemampuannya dalam mengekstraksi fitur kompleks secara otomatis langsung dari data mentah. Pada metode konvensional, proses ekstraksi fitur dilakukan secara manual berdasarkan karakteristik tertentu, seperti tekstur atau bentuk objek. Pendekatan tersebut sering kali kurang optimal ketika digunakan pada citra medis yang memiliki karakteristik jaringan kompleks dan variasi

intensitas tinggi. Dengan menggunakan *Deep Learning*, model dapat mempelajari karakteristik citra secara langsung sehingga mampu menghasilkan performa segmentasi yang lebih baik.

2.2.3 CNN

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *Deep Learning* yang dirancang khusus untuk pengolahan data berbentuk citra [40]. CNN memiliki kemampuan untuk mengenali pola visual pada citra melalui proses konvolusi (*convolution*) sehingga sangat efektif digunakan dalam berbagai tugas pengolahan citra, seperti klasifikasi, deteksi objek, dan segmentasi citra. Berbeda dengan metode tradisional yang memerlukan ekstraksi fitur secara manual, CNN mampu mempelajari fitur penting secara otomatis dari data pelatihan.

Secara umum, CNN terdiri dari beberapa lapisan utama, yaitu *convolution layer*, *activation layer*, *pooling layer*, dan *fully connected layer*. Pada *convolution layer*, filter atau kernel digunakan untuk mengekstraksi fitur tertentu dari citra input, seperti tepi, sudut, tekstur, dan pola bentuk objek. Hasil proses konvolusi kemudian diteruskan ke *activation layer* yang biasanya menggunakan fungsi aktivasi ReLU (Rectified Linear Unit) untuk memperkenalkan sifat non-linear pada model [41].

Selanjutnya, *pooling layer* digunakan untuk mengurangi ukuran dimensi fitur sehingga dapat menurunkan kompleksitas komputasi dan membantu mengurangi risiko *overfitting*. Salah satu metode *pooling* yang paling umum digunakan adalah *max pooling*, yaitu memilih nilai maksimum dari area tertentu pada *feature map*. Setelah proses ekstraksi fitur selesai dilakukan, fitur yang dihasilkan akan diteruskan ke *fully connected layer* untuk melakukan proses klasifikasi berdasarkan pola yang telah dipelajari model.

CNN memiliki beberapa keunggulan dalam pengolahan citra medis. Salah satunya adalah kemampuan untuk mempelajari representasi fitur secara hierarkis, mulai dari fitur sederhana hingga fitur kompleks. Pada citra CT scan ginjal, CNN mampu mengenali perbedaan karakteristik antara jaringan ginjal normal, tumor, dan kista berdasarkan pola intensitas dan tekstur citra [42]. Oleh karena itu, CNN


banyak digunakan sebagai backbone dalam berbagai arsitektur segmentasi medis modern, termasuk U-Net.

Selain itu, penggunaan CNN pada segmentasi citra medis juga memungkinkan proses analisis dilakukan secara otomatis dengan tingkat akurasi yang tinggi. Hal ini sangat membantu dalam mengurangi beban kerja radiolog dan mempercepat proses diagnosis medis. Dalam penelitian ini, CNN digunakan sebagai backbone encoder pada arsitektur U-Net untuk membantu proses ekstraksi fitur citra CT scan ginjal secara lebih mendalam dan representatif.

2.3 Teori tentang Framework yang digunakan

2.3.1 CRISP-DM

Metode penelitian yang digunakan dalam penelitian ini adalah metode kuantitatif eksperimental dengan pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM). Metode kuantitatif eksperimental digunakan karena penelitian ini bertujuan untuk mengimplementasikan, melatih, menguji, dan membandingkan performa beberapa model deep learning berdasarkan hasil metrik evaluasi numerik. Model yang digunakan dalam penelitian ini adalah arsitektur U-Net 2D dengan backbone DenseNet121, DenseNet169, dan DenseNet201 untuk melakukan segmentasi multi-kelas ginjal pada citra CT scan.



Gambar 2.1 CRISP-DM [43]


CRISP-DM dipilih karena memiliki tahapan kerja yang sistematis dalam pengolahan data, mulai dari pemahaman masalah, pemahaman data, persiapan data, pemodelan, hingga evaluasi seperti pada Gambar 3.1. Dalam konteks penelitian ini,

CRISP-DM digunakan untuk mengatur alur penelitian agar proses pengembangan model segmentasi dapat dilakukan secara terstruktur. Tahapan tersebut dimulai dari identifikasi permasalahan segmentasi citra ginjal, pemahaman dataset KiTS23, proses praproses data CT scan menjadi citra dua dimensi, pembangunan model U-Net berbasis DenseNet, hingga evaluasi performa model menggunakan Mean Dice Coefficient dan Dice Coefficient pada setiap kelas segmentasi.

Secara umum, CRISP-DM terdiri dari enam tahapan, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Namun, pada penelitian ini tahap *Deployment* tidak dilakukan karena fokus penelitian hanya terbatas pada implementasi dan evaluasi model segmentasi. Penelitian ini tidak membahas penerapan model ke dalam sistem klinis, aplikasi berbasis web, maupun sistem bantu diagnosis yang siap digunakan oleh pengguna akhir. Oleh karena itu, penelitian ini hanya mencakup lima tahapan utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, dan *Evaluation*.

2.3.2 U-Net

U-Net merupakan salah satu arsitektur *Deep Learning* yang paling populer dalam bidang segmentasi citra medis [13]. Arsitektur ini diperkenalkan oleh Olaf Ronneberger pada tahun 2015 untuk segmentasi citra biomedis [44]. Nama U-Net berasal dari bentuk arsitekturnya yang menyerupai huruf “U”.



Gambar 2.2 Arsitektur U-Net [45]

Terlihat dari Gambar 2.2, Arsitektur tersebut terdiri dari dua bagian utama yaitu encoder disebelah kiri dan decoder di sebelah kanan. Encoder berfungsi untuk mengekstraksi fitur dari citra input melalui proses konvolusi dan downsampling, sedangkan decoder berfungsi untuk merekonstruksi hasil segmentasi melalui proses upsampling.

Pada bagian encoder, ukuran citra secara bertahap diperkecil untuk memperoleh fitur yang lebih abstrak dan mendalam. Setiap proses downsampling biasanya dilakukan menggunakan operasi max pooling. Semakin dalam jaringan, model akan mempelajari fitur yang semakin kompleks. Selanjutnya, pada bagian decoder, ukuran feature map akan diperbesar kembali menggunakan proses upsampling sehingga model dapat menghasilkan output segmentasi dengan resolusi yang sama seperti citra input.

Salah satu keunggulan utama U-Net adalah penggunaan skip connection yang menghubungkan encoder dan decoder pada tingkat resolusi yang sama [13]. Skip connection memungkinkan informasi spasial dari encoder diteruskan langsung ke decoder sehingga detail objek pada citra dapat dipertahankan dengan lebih baik.


Hal ini sangat penting dalam segmentasi citra medis karena batas objek, seperti tumor dan kista, sering kali memiliki ukuran kecil dan bentuk yang kompleks.

U-Net memiliki performa yang sangat baik pada segmentasi citra medis meskipun jumlah data pelatihan relatif terbatas. Oleh karena itu, arsitektur ini banyak digunakan dalam berbagai penelitian segmentasi organ medis seperti paru-paru, otak, hati, dan ginjal. Selain itu, U-Net juga fleksibel untuk dikombinasikan dengan berbagai backbone CNN guna meningkatkan kemampuan ekstraksi fitur model.

2.3.2.1 DenseNet121

DenseNet121 merupakan salah satu varian dari arsitektur DenseNet (*Densely Connected Convolutional Network*) yang diperkenalkan oleh Gao Huang pada tahun 2017 [46]. DenseNet dirancang untuk mengatasi beberapa kelemahan pada CNN konvensional, seperti masalah vanishing gradient, redundansi fitur, dan penggunaan parameter yang terlalu besar.

Karakteristik utama DenseNet adalah konsep *dense connectivity*, yaitu setiap lapisan menerima masukan dari seluruh lapisan sebelumnya dan meneruskan hasil fitur ke seluruh lapisan berikutnya. Dengan mekanisme tersebut, informasi dan gradien dapat mengalir dengan lebih baik di dalam jaringan sehingga proses pelatihan menjadi lebih stabil. Selain itu, penggunaan koneksi padat juga memungkinkan fitur yang telah dipelajari sebelumnya dapat digunakan kembali (*feature reuse*) sehingga model menjadi lebih efisien dalam penggunaan parameter [46].




Gambar 2.3 Arsitektur DenseNet121 [47]

Dapat dilihat dari Gambar 2.3, DenseNet121 terdiri dari 121 lapisan yang tersusun dalam beberapa dense block dan transition layer. Dense block digunakan untuk melakukan ekstraksi fitur melalui serangkaian operasi konvolusi, sedangkan transition layer digunakan untuk mengurangi ukuran *feature map* agar kompleksitas komputasi tetap terkontrol [47]. Dibandingkan dengan arsitektur CNN lain yang memiliki jumlah parameter besar, DenseNet121 mampu menghasilkan performa yang baik dengan jumlah parameter yang relatif lebih kecil [47].

Pada penelitian ini, DenseNet121 digunakan sebagai backbone encoder pada arsitektur U-Net. Penggunaan DenseNet121 diharapkan mampu meningkatkan kemampuan model dalam mengekstraksi fitur penting dari citra CT scan ginjal sehingga hasil segmentasi area ginjal, tumor, dan kista menjadi lebih akurat.

2.3.2.2 DenseNet169

DenseNet169 merupakan pengembangan dari DenseNet121 dengan jumlah lapisan yang lebih banyak, yaitu sebanyak 169 lapisan [38]. Struktur dasar DenseNet169 tetap menggunakan konsep *dense connectivity* yang memungkinkan setiap lapisan saling terhubung satu sama lain. Dengan jumlah lapisan yang lebih dalam, DenseNet169 memiliki kemampuan untuk mempelajari representasi fitur yang lebih kompleks dibandingkan DenseNet121 [38].



Gambar 2.4 Arsitektur DenseNet169 [48]


Semakin dalam arsitektur jaringan, semakin banyak pula pola dan karakteristik citra yang dapat dipelajari model. Pada citra medis, kemampuan tersebut sangat penting karena objek seperti tumor dan kista sering memiliki bentuk serta intensitas yang bervariasi. Dilihat dari Arsitektur DenseNet169 pada Gambar 2.4, DenseNet169 mampu mempelajari detail fitur yang lebih kompleks sehingga berpotensi meningkatkan kualitas segmentasi pada citra CT scan ginjal.

Namun, peningkatan jumlah lapisan juga menyebabkan kebutuhan komputasi menjadi lebih besar dibandingkan DenseNet121. Proses pelatihan memerlukan memori GPU yang lebih tinggi dan waktu pelatihan yang lebih lama. Oleh karena itu, diperlukan evaluasi untuk mengetahui apakah peningkatan kompleksitas jaringan benar-benar memberikan peningkatan performa segmentasi yang signifikan.

Dalam penelitian ini, DenseNet169 digunakan sebagai salah satu backbone encoder U-Net untuk dibandingkan performanya terhadap DenseNet121 dan DenseNet201 berdasarkan nilai Mean Dice Coefficient dan Dice Coefficient pada setiap kelas segmentasi.

2.3.2.3 DenseNet201

DenseNet201 merupakan varian DenseNet dengan jumlah lapisan terdalam yang digunakan dalam penelitian ini, yaitu sebanyak 201 lapisan [49]. Sama seperti varian DenseNet lainnya, DenseNet201 menggunakan konsep dense connectivity untuk meningkatkan aliran informasi antar lapisan dan memaksimalkan penggunaan fitur yang telah dipelajari sebelumnya.



Gambar 2.5 Arsitektur DenseNet201 [49]

Dengan kedalaman jaringan yang lebih tinggi, DenseNet201 memiliki kemampuan representasi fitur yang lebih kompleks dan mendalam dibandingkan DenseNet121 maupun DenseNet169. Terlihat dari Arsitektur DenseNet201 pada Gambar 2.5, Hal tersebut memungkinkan model untuk mengenali pola-pola kecil dan karakteristik visual yang sulit dibedakan pada citra CT scan ginjal, terutama pada area tumor dan kista yang memiliki ukuran relatif kecil [49].

Meskipun memiliki potensi performa yang lebih baik, penggunaan DenseNet201 juga memiliki konsekuensi terhadap meningkatnya kebutuhan sumber daya komputasi. Semakin dalam jaringan, semakin besar kebutuhan memori dan waktu pelatihan yang diperlukan model. Oleh karena itu, penggunaan DenseNet201 perlu dievaluasi untuk mengetahui keseimbangan antara kompleksitas model dan performa segmentasi yang dihasilkan.

Dalam penelitian ini, DenseNet201 digunakan sebagai backbone encoder pada arsitektur U-Net 2D untuk mengetahui pengaruh kedalaman jaringan terhadap kemampuan segmentasi multi-kelas citra CT scan ginjal. Hasil performa

DenseNet201 kemudian dibandingkan dengan DenseNet121 dan DenseNet169 menggunakan metrik Mean Dice Coefficient dan Dice Coefficient pada setiap kelas segmentasi.

2.3.3 Test Time Augmentation

Test Time Augmentation (TTA) merupakan teknik yang digunakan pada tahap inferensi atau pengujian model untuk meningkatkan stabilitas dan robustnes hasil prediksi tanpa memerlukan proses pelatihan ulang. Berbeda dengan data augmentation yang diterapkan selama proses pelatihan, TTA dilakukan dengan menghasilkan beberapa variasi dari citra masukan pada saat prediksi, kemudian menggabungkan hasil prediksi dari seluruh variasi tersebut untuk memperoleh prediksi akhir yang lebih stabil[50].

Pada proses TTA, citra masukan dapat diberikan beberapa transformasi sederhana seperti *horizontal flip*, *vertical flip*, rotasi, maupun transformasi lainnya yang tidak mengubah informasi utama pada citra [51]. Setiap variasi citra kemudian diprediksi secara terpisah oleh model. Hasil prediksi yang diperoleh dikembalikan ke orientasi semula (*inverse transformation*) dan selanjutnya digabungkan menggunakan metode rata-rata probabilitas (*probability averaging*) atau metode agregasi lainnya. Pendekatan ini memungkinkan model memanfaatkan informasi dari berbagai variasi citra sehingga dapat mengurangi sensitivitas terhadap perubahan orientasi objek dan meningkatkan konsistensi hasil segmentasi.

Pada penelitian segmentasi citra medis, TTA sering digunakan untuk meningkatkan kualitas segmentasi karena objek anatomi dapat memiliki variasi bentuk, ukuran, dan orientasi yang berbeda. Dengan menerapkan TTA, model diharapkan mampu menghasilkan prediksi yang lebih robust terhadap variasi citra CT scan sehingga kesalahan segmentasi dapat diminimalkan. Selain itu, TTA memiliki keunggulan karena dapat meningkatkan performa inferensi tanpa menambah kompleksitas proses pelatihan maupun mengubah parameter model yang telah diperoleh sebelumnya.

Dalam penelitian ini, TTA diterapkan pada model U-Net 2D berbasis backbone DenseNet169 dengan menggunakan transformasi horizontal flip dan vertical flip pada tahap inferensi. Hasil prediksi dari setiap transformasi kemudian dikembalikan ke orientasi awal dan dirata-ratakan untuk menghasilkan mask segmentasi akhir yang digunakan pada proses evaluasi.

2.4 Teori tentang Tools yang digunakan

2.4.1 Python

Python merupakan bahasa pemrograman tingkat tinggi yang banyak digunakan dalam pengembangan aplikasi, analisis data, kecerdasan buatan, dan pembelajaran mesin [52]. Python memiliki sintaks yang sederhana dan mudah dipahami sehingga sering digunakan dalam penelitian akademik maupun pengembangan sistem berbasis machine learning [53]. Selain itu, Python bersifat open-source dan didukung oleh komunitas yang sangat luas, sehingga tersedia banyak pustaka atau library yang dapat membantu proses pengolahan data, pelatihan model, visualisasi hasil, hingga evaluasi performa model.

Dalam bidang deep learning dan pengolahan citra medis, Python menjadi salah satu bahasa pemrograman yang paling umum digunakan karena mendukung berbagai pustaka ilmiah seperti NumPy, TensorFlow, PIL, Matplotlib, dan Seaborn [52]. Pustaka-pustaka tersebut memungkinkan proses penelitian dilakukan secara lebih terstruktur, mulai dari membaca data citra, melakukan praproses data, membangun arsitektur model, melatih model, hingga menampilkan hasil evaluasi dalam bentuk grafik maupun visualisasi citra [53]. Oleh karena itu, Python digunakan dalam penelitian ini sebagai bahasa utama untuk mengimplementasikan model U-Net 2D berbasis DenseNet dalam segmentasi multi-kelas citra CT scan ginjal.

Python juga memiliki keunggulan dalam integrasi dengan perangkat keras pendukung komputasi seperti GPU. Hal ini sangat penting dalam pelatihan model deep learning karena proses komputasi pada jaringan saraf tiruan membutuhkan sumber daya yang besar. Dengan dukungan pustaka seperti TensorFlow, Python mampu memanfaatkan GPU untuk mempercepat proses pelatihan model. Dalam

penelitian segmentasi citra medis, penggunaan Python membantu peneliti melakukan eksperimen secara fleksibel, baik dalam mengatur struktur model, parameter pelatihan, maupun proses evaluasi hasil segmentasi.

2.4.1.1 NumPy

NumPy atau Numerical Python merupakan pustaka Python yang digunakan untuk melakukan komputasi numerik dan pengolahan data berbasis array multidimensi [54]. NumPy menyediakan struktur data utama berupa ndarray yang memungkinkan proses penyimpanan dan manipulasi data numerik dilakukan secara efisien. Dalam konteks pengolahan citra digital, citra dapat direpresentasikan sebagai array numerik yang berisi nilai piksel [54]. Oleh karena itu, NumPy sangat penting dalam proses pengolahan citra karena memungkinkan operasi matematis terhadap citra dilakukan dengan cepat dan efisien.

Pada penelitian segmentasi citra CT scan ginjal, NumPy digunakan untuk membantu proses manipulasi data citra dan mask segmentasi. Citra CT scan yang telah dikonversi menjadi format dua dimensi dapat direpresentasikan sebagai array dengan ukuran tertentu, misalnya tinggi, lebar, dan jumlah kanal warna. Sementara itu, mask segmentasi juga dapat direpresentasikan sebagai array yang berisi label kelas untuk setiap piksel, seperti background, ginjal, tumor, dan kista. Dengan menggunakan NumPy, proses seperti normalisasi nilai piksel, konversi tipe data, penggabungan array, serta pembentukan data input dan label dapat dilakukan secara lebih mudah.

Selain itu, NumPy juga berperan dalam proses evaluasi model. Hasil prediksi model segmentasi biasanya berbentuk array probabilitas atau array label kelas. Data tersebut dapat diolah menggunakan NumPy untuk menghitung nilai evaluasi seperti Dice Coefficient dan Mean Dice Coefficient. Operasi matematika seperti penjumlahan piksel, perhitungan irisan (intersection), dan perhitungan total area prediksi maupun ground truth dapat dilakukan secara efisien menggunakan fungsi-fungsi yang tersedia pada NumPy. Oleh karena itu, NumPy menjadi salah satu pustaka dasar yang sangat penting dalam penelitian berbasis pengolahan citra dan deep learning.

2.4.1.2 TensorFlow

TensorFlow merupakan salah satu pustaka open-source yang digunakan untuk membangun, melatih, dan menguji model machine learning maupun deep learning [55]. TensorFlow dikembangkan untuk mendukung komputasi numerik berskala besar dan mampu berjalan pada CPU maupun GPU [56]. Dalam penelitian berbasis deep learning, TensorFlow banyak digunakan karena menyediakan berbagai komponen yang dibutuhkan untuk membangun jaringan saraf tiruan, seperti layer konvolusi, fungsi aktivasi, optimizer, loss function, hingga metrik evaluasi [56].

TensorFlow juga menyediakan API tingkat tinggi bernama Keras yang memudahkan proses pembangunan model deep learning. Dengan menggunakan Keras, arsitektur model dapat dirancang secara modular melalui penggunaan layer-layer seperti Conv2D, MaxPooling2D, UpSampling2D, BatchNormalization, Dropout, dan Concatenate. Hal ini sangat relevan dengan implementasi U-Net karena arsitektur U-Net terdiri dari proses encoder, decoder, dan skip connection yang membutuhkan penggabungan feature map dari beberapa lapisan. TensorFlow memungkinkan seluruh struktur tersebut dibangun secara fleksibel sesuai kebutuhan penelitian.

Dalam penelitian ini, TensorFlow digunakan untuk mengimplementasikan arsitektur U-Net 2D dengan backbone DenseNet121, DenseNet169, dan DenseNet201. Backbone DenseNet dapat digunakan sebagai bagian encoder untuk mengekstraksi fitur dari citra CT scan ginjal. Selanjutnya, bagian decoder U-Net dibangun untuk mengembalikan resolusi feature map sehingga menghasilkan output segmentasi dengan jumlah kelas yang sesuai, yaitu background, ginjal, tumor, dan kista. TensorFlow juga digunakan dalam proses pelatihan model, mulai dari pembacaan data, augmentasi data, pengaturan batch size, perhitungan loss, hingga penyimpanan model terbaik.

Selain untuk membangun model, TensorFlow juga mendukung proses evaluasi performa model. Hasil prediksi segmentasi dapat dibandingkan dengan ground truth untuk menghitung metrik seperti Dice Coefficient dan Mean Dice Coefficient. TensorFlow juga memungkinkan proses pelatihan dipantau melalui nilai loss dan

metrik pada setiap epoch. Dengan demikian, TensorFlow menjadi tools utama dalam penelitian ini karena berperan langsung dalam pembangunan, pelatihan, dan evaluasi model segmentasi citra CT scan ginjal.

2.4.1.3 Python Image Library (PIL)

Python Image Library atau PIL merupakan pustaka Python yang digunakan untuk membuka, memproses, dan menyimpan citra digital [57]. Dalam perkembangannya, PIL sudah tidak dikembangkan secara aktif dan kemudian dilanjutkan melalui pustaka bernama Pillow. Meskipun demikian, istilah PIL masih sering digunakan karena Pillow tetap menyediakan modul dengan nama PIL dalam penggunaannya. Pustaka ini mendukung berbagai format citra seperti PNG, JPEG, BMP, dan TIFF, sehingga sangat berguna dalam proses pengolahan citra digital [57].

Dalam penelitian segmentasi citra medis, PIL digunakan untuk membaca file citra dan mask segmentasi yang tersimpan dalam format gambar [58]. Citra CT scan yang telah dikonversi menjadi bentuk 2D slice dapat dibuka menggunakan PIL, kemudian diubah menjadi array numerik agar dapat diproses lebih lanjut menggunakan NumPy atau TensorFlow. Selain itu, PIL juga dapat digunakan untuk mengubah ukuran citra (resize), mengonversi mode warna, serta menyimpan kembali hasil citra setelah proses pengolahan tertentu.

PIL juga berperan dalam memastikan format input sesuai dengan kebutuhan model. Pada model deep learning, citra input harus memiliki ukuran dan jumlah kanal yang seragam. Misalnya, citra input perlu disesuaikan ke ukuran tertentu agar dapat diterima oleh backbone DenseNet. Jika citra memiliki format grayscale, citra tersebut dapat dikonversi menjadi tiga kanal agar sesuai dengan format input model pretrained yang umumnya menggunakan citra RGB. Proses-proses seperti ini dapat dilakukan menggunakan PIL sebelum data masuk ke tahap pelatihan model.

Dalam penelitian ini, PIL digunakan sebagai salah satu tools pendukung dalam proses praproses data citra CT scan dan mask segmentasi. Dengan bantuan PIL, data citra dapat dibaca dan disiapkan terlebih dahulu sebelum dikonversi menjadi array numerik. Hal ini penting agar data yang digunakan dalam pelatihan model

memiliki format yang konsisten dan sesuai dengan kebutuhan arsitektur U-Net 2D berbasis DenseNet.

2.4.1.4 Matplotlib

Matplotlib merupakan pustaka Python yang digunakan untuk membuat visualisasi data dalam bentuk grafik, plot, dan gambar [59]. Pustaka ini banyak digunakan dalam analisis data dan penelitian ilmiah karena mampu menghasilkan visualisasi yang jelas dan fleksibel. Matplotlib mendukung berbagai jenis visualisasi, seperti grafik garis, diagram batang, histogram, scatter plot, serta visualisasi citra. Dalam penelitian berbasis deep learning, Matplotlib sering digunakan untuk menampilkan grafik proses pelatihan dan hasil prediksi model.

Pada penelitian segmentasi citra CT scan ginjal, Matplotlib digunakan untuk menampilkan grafik nilai loss dan metrik evaluasi selama proses pelatihan model. Grafik tersebut berguna untuk melihat perkembangan performa model dari setiap epoch, baik pada data pelatihan maupun data validasi. Melalui grafik ini, peneliti dapat menganalisis apakah model mengalami peningkatan performa, overfitting, atau underfitting. Misalnya, jika nilai loss pada data pelatihan terus menurun tetapi loss pada data validasi meningkat, maka model kemungkinan mengalami overfitting.

Selain digunakan untuk menampilkan grafik pelatihan, Matplotlib juga digunakan untuk memvisualisasikan hasil segmentasi. Citra input, ground truth mask, dan predicted mask dapat ditampilkan berdampingan agar hasil prediksi model dapat dianalisis secara visual. Visualisasi ini penting karena evaluasi segmentasi tidak hanya dilihat dari nilai metrik numerik, tetapi juga dari kemampuan model dalam membentuk area segmentasi yang sesuai dengan struktur anatomi sebenarnya. Dengan demikian, Matplotlib membantu peneliti memahami kualitas hasil segmentasi secara lebih jelas.

Matplotlib juga dapat digunakan untuk membuat grafik perbandingan performa antar model, seperti perbandingan nilai Mean Dice Coefficient dari DenseNet121, DenseNet169, dan DenseNet201. Grafik tersebut dapat mempermudah proses interpretasi hasil penelitian karena perbedaan performa antar backbone dapat dilihat

secara visual. Oleh karena itu, Matplotlib menjadi salah satu tools penting dalam tahap analisis dan penyajian hasil penelitian.

2.4.1.5 Seaborn

Seaborn merupakan pustaka visualisasi data berbasis Python yang dibangun di atas Matplotlib [60]. Pustaka ini dirancang untuk menghasilkan visualisasi statistik yang lebih informatif dan lebih mudah dibaca. Seaborn menyediakan tampilan grafik yang lebih rapi serta mendukung berbagai jenis visualisasi seperti heatmap, barplot, lineplot, boxplot, dan distribusi data [60]. Dalam penelitian berbasis data, Seaborn sering digunakan untuk membantu menganalisis pola, hubungan antar variabel, serta perbandingan hasil eksperimen.

Dalam penelitian segmentasi citra CT scan ginjal, Seaborn dapat digunakan untuk menampilkan hasil evaluasi model dalam bentuk visualisasi yang lebih terstruktur. Misalnya, nilai Dice Coefficient pada setiap kelas segmentasi dapat divisualisasikan menggunakan barplot untuk membandingkan performa DenseNet121, DenseNet169, dan DenseNet201. Dengan visualisasi tersebut, perbedaan kemampuan masing-masing backbone dalam melakukan segmentasi kelas background, ginjal, tumor, dan kista dapat diamati dengan lebih mudah.

Selain itu, Seaborn juga dapat digunakan untuk membuat heatmap dari hasil evaluasi model. Heatmap berguna untuk menampilkan nilai performa dalam bentuk matriks warna, sehingga pembaca dapat dengan cepat mengetahui model mana yang memiliki performa lebih baik pada kelas tertentu. Dalam konteks penelitian ini, heatmap dapat digunakan untuk membandingkan nilai Dice Coefficient antar kelas dan antar backbone. Hal ini membantu memperjelas analisis hasil penelitian, terutama ketika jumlah data evaluasi yang ditampilkan cukup banyak.

Meskipun Seaborn tidak digunakan secara langsung dalam proses pelatihan model, pustaka ini memiliki peran penting dalam tahap analisis dan penyajian hasil. Visualisasi yang baik dapat membantu menjelaskan performa model secara lebih komunikatif dan mudah dipahami. Oleh karena itu, Seaborn digunakan sebagai tools pendukung untuk menampilkan hasil evaluasi model segmentasi multi-kelas ginjal secara lebih informatif dan sistematis.

2.5 Teori tentang Teknik Evaluasi yang dilakukan

2.5.1.1 Dice Coefficient

Dice Coefficient merupakan metrik evaluasi yang digunakan untuk mengukur tingkat kemiripan atau overlap antara hasil prediksi model dengan ground truth [61]. Pada segmentasi citra medis, Dice Coefficient banyak digunakan karena mampu menunjukkan seberapa besar area hasil segmentasi yang benar-benar sesuai dengan area target sebenarnya. Nilai Dice Coefficient berada pada rentang 0 sampai 1. Nilai 0 menunjukkan bahwa tidak terdapat kesesuaian antara prediksi dan ground truth, sedangkan nilai 1 menunjukkan bahwa hasil prediksi sama sepenuhnya dengan ground truth.

Secara umum, Dice Coefficient menghitung perbandingan antara dua kali jumlah area irisan antara prediksi dan ground truth dengan total area prediksi dan ground truth. Dalam konteks segmentasi citra, area tersebut dihitung berdasarkan jumlah piksel yang termasuk ke dalam kelas tertentu. Rumus Dice Coefficient dapat dituliskan sebagai berikut:

$$DC = \frac{2 | P \cap G |}{| P | + | G |}$$

Rumus 2.1 Rumus Dice Coefficient

- DC = Dice Coefficient
- P = *Predicted Mask*
- G = *Ground Truth*

Pada penelitian ini, Dice Coefficient dihitung untuk setiap kelas segmentasi, yaitu background, ginjal, tumor, dan kista. Perhitungan dilakukan dengan membandingkan mask hasil prediksi model dengan mask ground truth pada masing-masing kelas. Misalnya, untuk menghitung Dice Coefficient kelas tumor, piksel yang termasuk tumor pada hasil prediksi akan dibandingkan dengan piksel tumor pada ground truth. Semakin besar area yang tumpang tindih antara prediksi dan ground truth, maka semakin tinggi nilai Dice Coefficient yang diperoleh.

Dice Coefficient sangat sesuai digunakan dalam penelitian ini karena segmentasi multi-class ginjal memiliki ketidakseimbangan jumlah piksel antar

kelas. Area background biasanya memiliki jumlah piksel yang jauh lebih besar dibandingkan ginjal, tumor, dan kista. Jika hanya menggunakan metrik akurasi biasa, hasil evaluasi dapat terlihat tinggi karena model banyak memprediksi background dengan benar. Namun, hal tersebut belum tentu menunjukkan bahwa model mampu mengenali kelas yang lebih kecil seperti tumor dan kista. Oleh karena itu, Dice Coefficient digunakan agar performa segmentasi pada setiap kelas dapat dianalisis secara lebih tepat.

2.5.1.2 Mean Dice Coefficient

Mean Dice Coefficient merupakan nilai rata-rata dari Dice Coefficient seluruh kelas segmentasi. Metrik ini digunakan untuk memberikan gambaran umum mengenai performa model secara keseluruhan [62]. Jika Dice Coefficient menilai performa model pada satu kelas tertentu, maka Mean Dice Coefficient digunakan untuk menilai kemampuan model dalam melakukan segmentasi terhadap seluruh kelas yang digunakan dalam penelitian.

Rumus Mean Dice Coefficient dapat dituliskan sebagai berikut:

$$MDC = \frac{1}{N} \sum_{i=1}^N DC_i$$

Rumus 2.2 Rumus Mean Dice Coefficient

- MDC = Mean Dice Coefficient
- N = jumlah kelas segmentasi
- DC_i = nilai Dice Coefficient pada kelas ke-i

Mean Dice Coefficient digunakan untuk membandingkan performa keseluruhan dari model U-Net 2D dengan backbone DenseNet121, DenseNet169, dan DenseNet201. Model dengan nilai Mean Dice Coefficient yang lebih tinggi menunjukkan bahwa model tersebut memiliki kemampuan segmentasi yang lebih baik secara rata-rata pada seluruh kelas. Namun, nilai Mean Dice Coefficient tetap perlu dianalisis bersama dengan Dice Coefficient tiap kelas agar performa model pada kelas tertentu, terutama tumor dan kista, dapat diketahui secara lebih rinci.

Dalam penelitian ini, penggunaan Mean Dice Coefficient membantu menentukan backbone DenseNet yang menghasilkan performa terbaik secara keseluruhan. Sementara itu, Dice Coefficient tiap kelas digunakan untuk melihat kemampuan model dalam mengenali masing-masing kelas segmentasi. Dengan menggunakan kedua metrik tersebut, evaluasi model dapat dilakukan secara lebih menyeluruh, baik dari sisi performa umum maupun performa spesifik pada setiap kelas.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA