

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Sejumlah penelitian sebelumnya telah mengembangkan berbagai metode segmentasi untuk mendeteksi lesi kulit, khususnya melanoma, dengan pendekatan berbasis *deep learning*. Setiap studi memiliki fokus, metode, dan hasil evaluasi yang berbeda-beda tergantung kompleksitas citra dan arsitektur model yang digunakan. Tabel 2.1 merangkum beberapa penelitian terdahulu yang relevan, mencakup permasalahan yang diangkat, metode yang digunakan, serta hasil yang diperoleh berdasarkan metrik evaluasi masing-masing.

Tabel 2.1 Penelitian Terdahulu

Judul (tahun)	Metode	Hasil
<i>Melanoma Multi-class Segmentation Using Different U-Net Type Architectures</i> (2021) [13]	<i>U-Net, U-Net++, MultiResUNet</i>	Akurasi 84.65%, Validasi Akurasi 74.50%, Dice 70.96%
<i>Skin Lesion Segmentation Based on Vision Transformers and Convolutional Neural Networks</i> (2022) [9]	Perbandingan <i>U-Net</i> dan model berbasis attention seperti <i>TransUNet</i> dan <i>SwinUNet</i>	IoU: 83.77%; Dice: 84.12%; Precision: 86.31%; Recall: 98.61%; Akurasi: 87.93%
<i>Multiscale Attention U-Net for Skin Lesion Segmentation</i> (2022) [12]	<i>Multiscale Attention U-Net</i>	ISIC 2017: F1: 90.32%, Jaccard: 95.76%; ISIC 2018: F1 meningkat 25% ke 89.60%
<i>A Convolutional Neural Network for Skin Lesion Segmentation Using Double U-Net Architecture</i> (2022) [11]	<i>Double U-Net Architecture, U-Net</i>	DSC (Dice Similarity Coefficient): 0.862, Precision: 0.766, Recall: 0.927
<i>Improving Automatic Melanoma Diagnosis Using Deep Learning</i> (2023) [10]	<i>U-Net++ dengan encoder EfficientNet-B4 dan cascade generalization, U-Net</i>	IoU: 0.280; Recall: 89.3%; Akurasi: 85%

Judul (tahun)	Metode	Hasil
<i>Segmentation of Skin Cancer using Fuzzy U-Network</i> (2023) [19]	<i>MFO-Fuzzy U-Net dengan bilateral filter, dan U-Net</i>	Akurasi: 99.13%; Spesifisitas: 94.65%; Presisi: 96.37%; Recall: 95.78%; F1: 97.49%
<i>Hybrid Channel and Spatial Attention U-Net</i> (2024) [14]	<i>Hybrid Channel dan Spatial Attention U-Net</i>	Akurasi: 97.15%; Spesifisitas: 99.62%; Sensitivitas: 97.10%
<i>SUTrans-NET: A Hybrid Transformer Approach to Skin Lesion Segmentation</i> (2024) [15]	<i>SUTrans-NET (CNN + Transformer dual encoder), U-Net</i>	IoU: 78.28%; Dice: 86.32%; Akurasi: 93.90%; Sensitivitas: 86.18%; Spesifisitas: 97.56%
<i>Melanoma Skin Cancer Identification with Explainability Utilizing Mask Guided Technique</i> (2024) [17]	<i>U2-Net, U-Net, ViT</i>	IoU: 0,93, recall 92,77%, dan loss 11,65%
<i>TESL-Net: A Transformer-Enhanced CNN for Accurate Skin Lesion Segmentation</i> (2024) [16]	<i>U-Net + Swin Transformer + Bi-ConvLSTM</i>	IoU 86.91%, Dice 90.09%, Akurasi 95.80%, Sensitivitas 91.10%, Spesifisitas 97.29%

Tabel 2.1 merupakan penelitian terdahulu dari penggunaan U-Net dalam segmentasi lesi kulit, penelitian yang melakukan evaluasi terhadap tiga varian arsitektur U-Net, yaitu U-Net, U-Net++, dan MultiResUNet, untuk tugas segmentasi multi-kelas pada melanoma. Dari ketiga model tersebut, hasil dari U-Net menunjukkan akurasi sebesar 84.65%, akurasi validasi 74.50%, dan Dice coefficient 70.96% [13]. Setelah itu, dalam studi yang dilakukan pada tahun 2022 [9], yang menganalisis berbagai arsitektur segmentasi, termasuk U-Net, *Attention U-Net*, TransUNet, dan SwinUNet, menggunakan dataset ISIC 2018. U-Net mencapai IoU 83,77%, Dice 84,12%, presisi 86,31%, *recall* 98,61%, dan akurasi 87,93%. Meskipun model berbasis *attention* menunjukkan performa lebih tinggi, U-Net tetap menjadi baseline yang andal berkat kesederhanaan arsitektur dan efisiensi pelatihannya.

Pentingnya adaptasi arsitektur U-Net juga tercermin dari penelitian tentang segmentasi gambar dermoskopi kulit menggunakan algoritma U-Net pada tahun

2022 yang membuktikan bahwa model U-Net yang menggunakan dataset ISIC 2017 dan ISIC 2019 mendapatkan statistik yang tinggi, yaitu *F1 score* mencapai 90,32% dan indeks *Jaccard* 95,76% pada ISIC 2017, mengungguli MCGU-Net ($F1 = 89,27\%$, $Jaccard = 95,70\%$). Pada ISIC 2018, metode ini meningkatkan *F1 score* U-Net sebesar 25%, mencapai 89,60%, yang menunjukkan kemampuannya dalam menangani pola lesi yang lebih kompleks [12]. Sebuah penelitian mengembangkan arsitektur *Double U-Net* untuk segmentasi lesi kulit, menggunakan dua jaringan U-Net berurutan yang dilengkapi VGG-19, ASPP, dan *Squeeze and Excitation* untuk meningkatkan akurasi. Setelah dilatih pada dataset PH2 dan diuji pada ISIC-2016, model mencatatkan DSC 0,862, presisi 0,766, dan *recall* 0,927. Hasil ini menunjukkan performa segmentasi tinggi dan menjadikan *Double U-Net* metode yang kompetitif dalam segmentasi citra medis [11]. Hasil ini mengindikasikan bahwa arsitektur *Double U-Net* mampu melakukan segmentasi lesi kulit dengan akurasi tinggi serta tumpang tindih yang cukup baik terhadap area target, menjadikannya metode yang kompetitif untuk tugas segmentasi citra medis berbasis *deep learning*.

Seiring berkembangnya teknologi dan meningkatnya kebutuhan akan akurasi segmentasi pada citra dermoskopi, berbagai modifikasi dan penggabungan metode pun mulai diterapkan untuk mengatasi keterbatasan dari model dasar seperti U-Net. Pada Penelitian di tahun 2023 menggunakan algoritma U-Net++ dengan *encoder* EfficientNet-B4 untuk segmentasi jaringan pigmen tidak beraturan pada citra melanoma yang menghasilkan IoU 0,280. Untuk klasifikasi, diterapkan *cascade generalization* yang menggabungkan ResNet50 dan *Random Forest*, dengan *recall* 89,3% dan akurasi 85%, meningkat 11% dan 2% dibandingkan model awal [10]. Guna meningkatkan kualitas input, penelitian pada tahun 2023 mengusulkan algoritma baru bernama MFO-Fuzzy U-Net, yang menggabungkan Fuzzy U-Net dan Mayfly Optimizer untuk segmentasi melanoma. Gambar dari

dataset ISIC difilter menggunakan *bilateral filter* sebelum segmentasi. Model ini mengungguli U-Net, FCN, dan LinkNet-B7 dengan akurasi 99,13%, spesifisitas 94,65%, presisi 96,37%, *recall* 95,78%, dan *F1 score* 97,49%, menjadikannya salah satu pendekatan paling menjanjikan dalam segmentasi lesi kulit [19]. Memperkuat temuan tersebut, studi lanjutan di tahun 2024 menggunakan *Hybrid channel* dan *spatial attention* U-Net untuk mengatasi masalah segmentasi lesi kulit yang sering terganggu dikarenakan faktor seperti rambut, pigmentasi, ataupun tahi lalat. Hasil model U-Net memberikan model dengan performa yang baik, yaitu adalah 97,15%, 99,62%, 97,10%. Angka tersebut membuktikan bahwa model U-Net efektif dalam segmentasi lesi kulit [14].

Sebagai bentuk inovasi yang lebih optimal, penelitian pada tahun 2024 memperkenalkan SUTrans-NET, sebuah model segmentasi lesi kulit yang memadukan kekuatan arsitektur U-Net dengan kemampuan *Transformer* melalui pendekatan *dual encoder*. U-Net, yang telah terbukti andal dalam menangani berbagai tantangan segmentasi citra medis, menjadi fondasi utama dalam pengembangan SUTrans-NET. Penggabungan ini dirancang untuk memperkuat representasi lokal dan global pada citra dermoskopi. Hasil pengujian pada dataset ISIC 2017 menunjukkan kinerja superior dengan IoU sebesar 78,28%, *Dice* 86,32%, akurasi 93,90%, sensitivitas 86,18%, dan spesifisitas 97,56%. Keberhasilan SUTrans-NET tidak lepas dari keunggulan struktural U-Net sebagai arsitektur dasar yang efisien, fleksibel, dan terbukti efektif dalam segmentasi lesi kulit, serta kemampuannya untuk diadaptasi ke dalam *framework* yang lebih kompleks [15].


Penelitian lainnya menyoroti peran penting model U-Net dalam tahap segmentasi gambar untuk deteksi kanker kulit melanoma. menunjukkan bahwa model U-Net berperan penting dalam segmentasi gambar untuk deteksi melanoma, dengan hasil segmentasi yang baik (IoU 0,93, *recall* 92,77%, dan *loss* 11,65%)

menggunakan dataset ISIC 2018 dan HAM10000. Integrasi segmentasi U-Net ke dalam pipeline klasifikasi terbukti meningkatkan akurasi model CNN dan ViT dengan membantu fokus pada area lesi dan mengurangi gangguan dari kulit sehat [17]. Pendekatan berbasis segmentasi ini membantu mengurangi gangguan dari area kulit sehat, memperjelas struktur lesi, dan meningkatkan keandalan sistem dalam mengidentifikasi melanoma. Pada penelitian yang mengintegrasikan arsitektur U-Net dengan Swin Transformer dan Bi-ConvLSTM untuk meningkatkan kemampuan model dalam menangkap dependensi spasial dan temporal pada citra medis. Model ini menunjukkan performa yang sangat baik dengan capaian metrik evaluasi pada dataset ISIC 2017 yaitu IoU sebesar 86.91%, *Dice coefficient* 90.09%, akurasi 95.80%, sensitivitas 91.10%, dan spesifisitas 97.29% [16].

2.2 Tinjauan Teori

2.2.1 Kanker Kulit

Kanker kulit adalah kondisi ketika sel-sel kulit mengalami perubahan menjadi ganas, yang menyebabkan pertumbuhan sel secara abnormal dan merusak DNA [20]. Jenis kanker ini secara umum terbagi menjadi beberapa kategori utama, seperti karsinoma sel skuamosa (*Squamous cell carcinoma*) serta karsinoma sel basal (*Basal cell carcinoma*) [21]. Gambar 2.1 merupakan gambar yang diambil dari pasien yang mengalami kanker kulit berdasarkan jenisnya.




Gambar 2.1. Types of Skin Cancer [21]

Gambar 2.1 menampilkan melanoma, melanoma secara fisik dapat didiagnosa secara mandiri. Dengan mengidentifikasi ciri-ciri melanoma seperti memperhatikan perubahan pada tahi lalat atau bercak kulit dengan menggunakan metode ABCDE, yaitu Asimetri (bentuk tidak simetris), *Border* atau tepi yang tidak rata dan kasar, *Color* atau warna yang tidak merata dengan campuran beberapa warna, Diameter lebih dari 6 mm, serta Evolusi atau perubahan ukuran, bentuk, dan warna dari waktu ke waktu. Selain itu, waspadai tahi lalat yang mudah berdarah, gatal, atau nyeri, serta munculnya pembengkakan atau kemerahan di sekitarnya [22]. Melanoma dikenal sebagai jenis yang paling agresif karena memiliki potensi tinggi untuk menyebar ke organ lain (metastasis), sehingga tingkat harapan hidup penderitanya cenderung rendah [23].

2.2.2 Segmentasi

Segmentasi dalam machine learning merujuk pada proses membagi data ke dalam kelompok-kelompok yang memiliki karakteristik serupa. Proses ini dapat diterapkan dalam berbagai bidang, seperti pengolahan citra, data pelanggan, dan lainnya, dengan tujuan untuk mendukung analisis yang lebih spesifik dan pengambilan keputusan yang lebih tepat sasaran [24].




Gambar 2.2 The basic architecture of the neural network model for image segmentation [50]

Gambar 2.2, merupakan proses segmentasi dilakukan menggunakan arsitektur *encoder-decoder*. Gambar *RGB* sebagai input akan diproses oleh bagian *encoder* untuk mengekstraksi fitur-fitur penting melalui operasi konvolusi dan pooling. Setelah itu, bagian *decoder* akan merekonstruksi kembali fitur tersebut menjadi peta segmentasi (*segmentation mask*), yaitu gambar keluaran yang setiap pikselnya telah diklasifikasikan ke dalam kelas tertentu [25]. Hasil akhirnya adalah sebuah citra baru di mana tiap elemen gambar diberi label warna berbeda sesuai dengan kategori objeknya. Pendekatan ini sejalan dengan konsep dalam *deep learning*, di mana segmentasi digunakan untuk memahami struktur dan isi gambar secara mendetail pada tingkat piksel. Pada penelitian ini, segmentasi yang akan diteliti adalah segmentasi dalam pengolahan citra, khususnya pada kanker kulit jenis melanoma.

2.2.3 Knowledge Discovery in Databases (KDD)

KDD atau *Knowledge Discovery in Databases* adalah metode yang sering dipakai untuk mencari pola tersembunyi dari kumpulan data yang besar [8]. Umumnya teknik ini dipakai bersama data mining, tujuannya agar proses deteksi penyakit seperti kanker kulit dapat dilakukan dengan lebih akurat dan efisien. KDD sendiri memiliki beberapa langkah penting, berawal dari memilih data yang relevan, membersihkan data atau menyiapkan data (pra-pemrosesan), mengubah bentuk data (transformasi), lalu masuk ke proses data mining untuk mencari pola, dan terakhir dievaluasi hasilnya [26]. Alur proses KDD bisa dilihat di Gambar 2.3.



Gambar 2.3. Knowledge Discovery in Databases (KDD) Process [27]

Gambar 2.3 menampilkan, proses *Knowledge Discovery in Databases* (KDD) terdiri dari serangkaian tahapan sistematis yang bertujuan untuk mengekstraksi pengetahuan yang berguna dari kumpulan data yang besar dan kompleks. Tahapan pertama dalam proses ini adalah *data selection* atau seleksi

data, yang bertujuan untuk memilih subset data yang relevan dari keseluruhan kumpulan data yang tersedia. Proses seleksi ini penting untuk memastikan bahwa hanya data yang memiliki nilai informatif terhadap tujuan analisis yang akan digunakan, sehingga dapat meningkatkan efisiensi dan efektivitas tahapan selanjutnya.

Setelah data yang relevan terpilih, proses berlanjut ke tahap *data preprocessing* atau praproses data. Pada tahap ini dilakukan serangkaian kegiatan seperti pembersihan data (menghilangkan nilai yang hilang, duplikat, atau tidak konsisten), normalisasi, serta integrasi data dari berbagai sumber jika diperlukan. Praproses berfungsi untuk meningkatkan kualitas data agar siap digunakan dalam tahap analisis berikutnya dan untuk meminimalkan kesalahan yang mungkin muncul selama proses *data mining*. Tahap selanjutnya adalah *data transformation* atau transformasi data, yaitu proses pengubahan data praproses ke dalam bentuk atau format yang sesuai dengan kebutuhan metode analisis yang akan diterapkan. Ini dapat mencakup pengkodean variabel, reduksi dimensi, atau konversi data ke dalam struktur fitur yang lebih informatif dan mudah ditangani oleh algoritma *data mining*.


Inti dari proses KDD adalah tahap *data mining*, yaitu penerapan teknik-teknik analitik dan algoritmik untuk menemukan pola, hubungan, anomali, atau struktur tersembunyi dalam data. Teknik *data mining* dapat mencakup klasifikasi, klusterisasi, asosiasi, regresi, atau metode prediktif lainnya, tergantung pada tujuan analisis dan jenis data yang digunakan. Hasil yang diperoleh dari proses ini merupakan output awal yang mengandung potensi informasi. Namun, sebelum hasil tersebut dapat dianggap sebagai pengetahuan, perlu dilakukan tahap *interpretation* atau evaluasi. Pada tahap ini, pola atau model yang ditemukan dianalisis lebih lanjut untuk menilai validitas, utilitas, dan relevansinya terhadap permasalahan yang sedang dikaji. Interpretasi juga dapat melibatkan visualisasi hasil, umpan balik dari

pakar domain, atau pengujian terhadap data baru untuk menilai konsistensi performa model.

Akhir dari seluruh proses KDD adalah terciptanya *knowledge* atau pengetahuan yang terverifikasi, yang dapat digunakan sebagai dasar dalam pengambilan keputusan strategis. Pengetahuan ini bersifat aplikatif dan dapat dimanfaatkan dalam berbagai bidang, termasuk sistem pendukung keputusan (*Decision Support Systems*), analisis tren bisnis, pengelompokan perilaku pelanggan, diagnosis medis berbantuan komputer, dan analisis data skala besar lainnya yang membutuhkan wawasan mendalam dari data yang kompleks. Dengan demikian, tahapan-tahapan dalam proses KDD membentuk kerangka kerja yang terintegrasi, yang tidak hanya fokus pada analisis data secara teknis, tetapi juga menjamin bahwa informasi yang dihasilkan benar-benar bernilai secara praktis dan dapat digunakan untuk pengambilan keputusan yang lebih tepat dan berbasis data [27].

2.2.4 Deep Learning

Deep learning merupakan salah satu cabang dari machine learning yang mengandalkan arsitektur jaringan saraf tiruan berlapis-lapis (*deep neural networks*) untuk memproses dan menganalisis data dalam skala besar dan kompleks. Teknik ini dirancang untuk meniru cara kerja otak manusia dalam mengenali pola dan melakukan pembelajaran dari data secara otomatis, tanpa memerlukan pemrograman aturan secara eksplisit [28].




Gambar 2.4 Hubungan Hierarkis antara Artificial Intelligence, Machine Learning, dan Deep Learning [29]

Gambar 2.4 merupakan ilustrasi yang menunjukkan struktur berlapis dari tiga komponen utama dalam pengembangan teknologi kecerdasan buatan, yaitu *Artificial Intelligence (AI)*, *Machine Learning (ML)*, dan *Deep Learning (DL)*. *Artificial Intelligence* mencakup keseluruhan metode yang bertujuan untuk menciptakan sistem yang mampu meniru kemampuan berpikir dan bertindak seperti manusia. Di dalam cakupan AI, *Machine Learning* hadir sebagai bidang yang mengembangkan algoritma yang memungkinkan sistem belajar dan meningkatkan kinerja berdasarkan pengalaman atau data historis tanpa intervensi pemrograman eksplisit. Selanjutnya, *Deep Learning* merupakan bagian dari *Machine Learning* yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk mengenali pola yang lebih kompleks dan mendalam dari data [29]. Dengan demikian, gambar 2.4 tersebut memperjelas bahwa *Deep Learning* berada di dalam lingkup *Machine Learning*, dan *Machine Learning* merupakan bagian dari ranah AI secara keseluruhan.

2.2.5 Convolutional Neural Network (CNN)

CNN yang telah berhasil diterapkan pada studi terdahulu, bekerja dalam tugas klasifikasi dan deteksi [30]. Meskipun awalnya digunakan dalam konteks pemantauan struktur komposit, prinsip kerja jaringan ini tetap relevan dan dapat diadaptasi untuk kebutuhan segmentasi citra medis, termasuk dalam mendeteksi kanker kulit melalui pendekatan berbasis *deep learning*. Gambar 2.5 berikut menyajikan struktur umum CNN yang dapat menjadi acuan dalam memahami alur kerja model U-Net yang digunakan dalam penelitian ini.




Gambar 2.5 Convolutional neural network (CNN) model architecture [31]

Gambar 2.5 menunjukkan arsitektur CNN yang terdiri atas beberapa blok utama. Proses dimulai dari input berupa citra medis (dalam hal ini CT scan), kemudian melewati serangkaian lapisan konvolusi yang dikombinasikan dengan *normalisasi batch* dan fungsi aktivasi ReLU untuk mengekstraksi fitur spasial.

Setiap blok konvolusi diikuti oleh lapisan *max-pooling* untuk mereduksi dimensi spasial sekaligus mempertahankan fitur penting. Setelah beberapa tahap ekstraksi fitur, data kemudian diratakan (*flatten*) dan diteruskan ke lapisan *fully connected* dengan dropout untuk mencegah *overfitting*. Akhirnya, hasil klasifikasi diperoleh melalui lapisan *softmax*. Konsep dasar arsitektur ini selaras dengan prinsip kerja U-Net, khususnya dalam hal pembelajaran hierarkis fitur dari citra medis, sehingga dapat memberikan gambaran pendukung bagi implementasi model segmentasi kanker kulit dalam penelitian ini.

2.2.6 U-NET Architecture

Arsitektur yang digunakan dalam penelitian ini adalah U-Net, sebuah model Convolutional Neural Network (CNN) yang dirancang khusus untuk segmentasi citra medis. Arsitektur U-Net pertama kali diperkenalkan oleh *Olaf Ronneberger, Philipp Fischer, dan Thomas Brox* dari *University of Freiburg*, Jerman, pada tahun 2015. Model ini dikembangkan khusus untuk tugas segmentasi citra biomedis dan diperkenalkan dalam konferensi *MICCAI 2015* [32]. Proses *encoder-decoder* memungkinkan model menangkap informasi global sekaligus mempertahankan detail lokal dalam citra. Keunggulan utama U-Net terletak pada kemampuannya dalam melakukan segmentasi presisi tinggi [33], bahkan dengan jumlah data yang terbatas, menjadikannya pilihan yang sangat sesuai untuk tugas segmentasi kanker kulit. Dengan memanfaatkan dataset ISIC 2017, penelitian ini bertujuan untuk mengevaluasi dan meningkatkan efektivitas U-Net dalam melakukan segmentasi lesi kanker kulit dengan tingkat akurasi yang tinggi. U-Net memiliki struktur *encoder-decoder* dengan mekanisme *skip connection* yang memungkinkan fitur spasial dari citra input tetap terjaga hingga tahap akhir. Struktur dari algoritma U-Net akan ditampilkan pada Gambar 2.6.



Gambar 2.6 Struktur U-Net [32]

Gambar 2.6 Merupakan gambaran bagaimana U-Net memanfaatkan struktur berbasis *encoder-decoder* dengan *skip connections*. Pada bagian *encoder*, gambar input melewati beberapa lapisan konvolusi yang diikuti oleh normalisasi *batch* dan fungsi aktivasi ReLU untuk mengekstrak fitur dan mengurangi resolusi gambar secara bertahap [32]. Di sisi *decoder*, informasi yang telah diproses pada *encoder* dipulihkan dengan menggunakan operasi *upsampling* dan penggabungan (*concatenation*) untuk membangun kembali citra dengan resolusi tinggi, sambil mempertahankan detail penting. Proses penggabungan antara *encoder* dan *decoder* dilakukan dengan cara "*copy and crop*", yang memastikan bahwa detail lokal dari citra asli tetap dipertahankan pada hasil segmentasi output [34].

2.2.7 Akurasi dan *Dice Score*

Accuracy atau akurasi merupakan salah satu metrik evaluatif yang digunakan untuk mengukur sejauh mana model mampu melakukan prediksi secara keseluruhan dengan benar [35]. Dalam konteks segmentasi citra, metrik ini menunjukkan persentase total piksel yang berhasil diklasifikasikan secara tepat, baik sebagai bagian dari objek yang diminati maupun latar belakang, terhadap keseluruhan piksel dalam citra.

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} \quad (2.1)$$

Rumus 2.1 menjelaskan bahwa TP (*True Positive*) dan TN (*True Negative*) masing-masing mewakili jumlah prediksi benar untuk kelas positif dan negatif, sementara FP (*False Positive*) dan FN (*False Negative*) menunjukkan jumlah kesalahan prediksi. Akurasi digunakan untuk mengukur seberapa baik model dalam mengklasifikasikan data secara keseluruhan [36].

Sementara itu, *Dice score* atau *Dice Similarity Coefficient* adalah ukuran statistik yang digunakan untuk menilai tingkat kesesuaian antara hasil segmentasi model dengan referensi kebenaran (*ground truth*) [37]. *Dice score* secara khusus memperhitungkan keseimbangan antara kesalahan klasifikasi positif dan negatif, dengan menilai seberapa besar area tumpang tindih antara prediksi model dan anotasi yang benar [38]. Nilai *Dice* berada pada skala antara 0 hingga 1, di mana nilai mendekati 1 mencerminkan kecocokan segmentasi yang tinggi. Formula yang

digunakan dalam perhitungan *Dice* ada pada gambar 2.8.

$$Dice = 2 \times \frac{Y \cap Y_{pred}}{Y + Y_{pred}} \quad (2.2)$$

Rumus 2.2 merupakan *Dice formula* yang dapat digunakan sebagai metrik evaluasi, didefinisikan sebagai dua kali jumlah piksel yang merupakan irisan antara mask *ground truth* dan mask hasil prediksi, kemudian dibagi dengan total jumlah piksel dari kedua mask tersebut [39].

Dalam penelitian ini, accuracy mengukur persentase piksel yang diklasifikasikan dengan benar secara keseluruhan, namun kurang efektif pada data yang tidak seimbang. Oleh karena itu, *Dice coefficient* lebih sering digunakan karena fokus pada tumpang tindih antara hasil prediksi dan *ground truth*, sehingga memberikan evaluasi yang lebih akurat terhadap kualitas segmentasi area kanker.

2.2.8 Hyperparameter

Hyperparameter adalah nilai-nilai yang ditentukan sebelum training dimulai dan mengatur bagaimana proses pembelajaran berlangsung. *Hyperparameter* tidak dipelajari oleh model, melainkan ditentukan oleh engineer dan tetap konstan selama pelatihan. Nilai-nilai ini memengaruhi bagaimana model mempelajari parameter yang optimal, tetapi tidak menjadi bagian dari model yang telah dilatih. Contoh *hyperparameter* meliputi learning rate, jumlah epoch, dan arsitektur jaringan [40].

Hyperparameter yang digunakan dalam penelitian ini meliputi epoch, batch size, learning rate, optimizer, patience, dan loss function, yang semuanya

ditentukan sebelum proses training dimulai dan berperan penting dalam mengarahkan proses pembelajaran model.

Epoch digunakan untuk menentukan jumlah siklus penuh di mana seluruh dataset dilatih melalui model [41]. Semakin besar nilai *epoch*, semakin banyak kesempatan model untuk belajar dari data, namun jika terlalu besar dapat menyebabkan *overfitting* [42]. *Batch size* menentukan jumlah sampel data yang diproses sebelum model diperbarui. Nilai ini memengaruhi stabilitas dan kecepatan pelatihan [43]. *Learning rate* mengatur seberapa besar langkah pembaruan bobot model pada setiap iterasi, nilai yang terlalu besar bisa membuat model tidak konvergen, sementara nilai yang terlalu kecil bisa memperlambat proses belajar [44]. *Optimizer* seperti *Adam* berfungsi untuk menyesuaikan bobot secara efisien selama pelatihan dengan mempertimbangkan gradien dan momen sebelumnya [45]. *Patience* digunakan dalam mekanisme *early stopping* untuk menghentikan pelatihan jika tidak ada peningkatan performa dalam jumlah *epoch* tertentu [41]. Terakhir, *loss function* seperti *CrossEntropyLoss* digunakan untuk mengukur seberapa jauh prediksi model dari label yang sebenarnya, dan menjadi acuan utama dalam pembaruan bobot selama *training* [46].