

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2. 1 Penelitian Terdahulu

No	Ref	Judul	Penulis, Dataset, Tahun	Model	Hasil
1	[19]	Brain Tumor Classification and Segmentation in MR Images Using EfficientNet and U-Net++ Models	Reema Alkharaan, Jana Alobaidi, Joud Bakarman, and Hala Alshamlan Brisc 2025 (2026)	ResUNet, EfficientNet-B4, EfficientNet-B4 U-Net, Attention U-Net, U-Net 2D, U-net++	Research Gap: Diperlukan penelitian yang meningkatkan generalisasi dan interpretabilitas model untuk mendukung penerapan klinis Kelemahan: Model belum divalidasi pada dataset lain dan lingkungan klinis. Perbedaan: Penelitian ini mengintegrasikan klasifikasi dan segmentasi Tumor Otak Kontribusi Penelitian: Mengembangkan framework untuk klasifikasi dan segmentasi tumor otak dengan performa yang tinggi.
2	[20]	BRISC: Annotated Dataset for Brain Tumor Segmentation and Classification	Amirreza Fateh, Yasin Rezvani, Sara Moayedi, Sadjad Rezvani, Fatemeh Fateh, Mansoor Fateh, VahidAbolghasem Brisc 2025 (2026)	ResNet50, ResNet101, DenseNet121, DenseNet169, MobileNet V2, MobileNet V3, EfficientNet B0,	Research Gap: Diperlukan dataset yang lebih seimbang, beragam, dan memiliki anotasi yang konsisten untuk meningkatkan generalisasi model segmentasi Kelemahan: Dataset hanya menggunakan citra MRI T1-weighted

				EfficientNet B2, Xception, VGG16, VGG19, InceptionV3	sehingga penerapannya pada jenis MRI lain masih terbatas Perbedaan: Penelitian berfokus pada pengembangan dataset BRISC untuk segmentasi dan klasifikasi Tumor Otak Kontribusi Penelitian: Mengembangkan dataset BRISC yang seimbang, dan dilengkapi anotasi ahli untuk segmentasi serta klasifikasi tumor otak
3	[21]	Comparative Evaluation of CNN and Transformer-Based Models for Brain Tumor MRI Segmentation	Yakup Kuzhan and Mücahid Günay Brisc 2025 (2026)	FCN, Swin U-Net, U-Net, DeepLabV3+, ResNet-50, Attention U-Net	Research Gap: Masih diperlukan evaluasi model segmentasi pada berbagai konfigurasi dan dataset untuk meningkatkan generalisasi hasil Kelemahan: Evaluasi hanya dilakukan pada satu dataset sehingga generalisasi model masih terbatas Perbedaan: Penelitian membandingkan model CNN dan Transformer Kontribusi Penelitian: Menyediakan perbandingan yang adil antara model CNN dan Transformer menggunakan dataset, hyperparameter, dan metrik evaluasi yang sama.

4	[22]	Deep Learning-Based Brain Tumor Classification in MRI with External Validation Across Multiple Datasets	Filipe Ferreira Viana, Leandro Henrique Furtado Pinto Silva, João, Fernando Mari BrisC 2025 (2026)	ResNet-50, DenseNet-121, ViT-16	Research Gap: Masih diperlukan penelitian untuk meningkatkan konsistensi performa model pada dataset MRI yang berbeda. Kelemahan: Performa model masih menurun pada pengujian menggunakan dataset eksternal. Perbedaan: Penelitian berfokus pada klasifikasi tumor otak menggunakan ResNet-50, DenseNet-121, dan ViT-B16 Kontribusi Penelitian: Menunjukkan bahwa data augmentation progresif dapat meningkatkan generalisasi model pada dataset eksternal.
5	[23]	Do Synthetic Brain MRIs Reliably Improve Tumour Classification? A StyleGAN2-ADA Class-Plane Augmentation Study on BRISC 2025	José Rafael Noriega Cedeño BrisC 2025 (2026)	StyleGAN2-ADA, Random Forest, CNN, MobileViT V2,	Research Gap: Diperlukan validasi pada dataset MRI tambahan dan evaluasi eksternal untuk memastikan manfaat augmentasi sintetis. Kelemahan: Hasil peningkatan akurasi relatif kecil dan masih memerlukan validasi lebih lanjut sebelum diterapkan Perbedaan: Penelitian berfokus pada pengaruh augmentasi sintetis berbasis StyleGAN2-

					ADA terhadap klasifikasi tumor otak Kontribusi Penelitian: Mengevaluasi efektivitas augmentasi sintetis berbasis StyleGAN2-ADA pada beberapa arsitektur klasifikasi
6	[24]	Efficient U-Net Architecture with Multiple Encoders and Attention Mechanism Decoders for Brain Tumor Segmentation	Ilyasse Aboussaleh, Jamal Riff, Khalid El Fazazy, Mohamed Adnane Mahraz and Hamid Tairi BraTS 2020 (2023)	U-Net, VGG-19, MobileNet V2, ResNet50,	Research Gap: Masih diperlukan pengembangan metode segmentasi yang mampu meningkatkan akurasi pada seluruh jenis area tumor Kelemahan: Performa segmentasi pada enhancing tumor masih lebih rendah dibanding whole tumor dan tumor core Perbedaan: Menggunakan U-Net dengan multiple encoders Kontribusi Penelitian: Mengembangkan arsitektur U-Net dengan multiple encoder, BiFPN, dan attention decoder yang meningkatkan performa segmentasi.
7	[25]	Enhancing Brain Tumor Classification Using Vision Transformers with Colormap-Based Feature Representation on BRISC2025 Dataset	Faisal Ahmed Brisc 2025 (2026)	ResNet50, ResNet101, EfficientNet B2	Research Gap: Diperlukan Vision Transformer yang lebih efisien dan validasi pada dataset yang lebih beragam Kelemahan: Model masih bergantung pada pretrained Vision Transformer dan belum

					diuji pada dataset eksternal. Perbedaan: Menggunakan Vision Transformer dengan colormap Kontribusi Penelitian: Mengembangkan Vision Transformer berbasis colormap untuk meningkatkan klasifikasi tumor otak
8	[26]	Swin-HAFNet: A Hierarchical Multi-Task Transformer for Brain Tumor Segmentation and Classification	Amirreza Fateh, Yasin Rezvani, Sadjad Rezvani, Mansoor Fateh, Vahid Abolghasemi Brisc 2025 (2026)	ResNet50, ResNet101, DenseNet121, DenseNet169, MobileNet V2, MobileNet V3, EfficientNet B0, EfficientNet B1, EfficientNet B2, Xception, VGG16, VGG19, InceptionV3, Swin-HAFNet (our	Research Gap: Diperlukan model yang lebih efisien untuk segmentasi dan klasifikasi tumor otak secara bersamaan Kelemahan: Performa masih dipengaruhi oleh tumor kecil, bentuk tidak beraturan, dan variasi protokol MRI, serta membutuhkan komputasi yang tinggi Perbedaan: Menggunakan arsitektur Swin-HAFNet untuk segmentasi dan klasifikasi secara bersamaan, Kontribusi Penelitian: Mengembangkan arsitektur Swin-HAFNet yang mengintegrasikan segmentasi dan klasifikasi dalam satu framework
9	[27]	A systematic evaluation of pre-trained encoder	Marwa Abbas, Ashraf A. M. Khalaf, Hussein Mogahed, Aziza I.	ResNet34, ResNet50, ResNet101, VGG-16,	Research Gap: Diperlukan peningkatan interpretabilitas model dan

		architectures for multimodal brain tumor segmentation using U-Net-based architectures	Hussein, Lamy Gaber, M. Mourad Mabrook BraTS 2019 (2025)	VGG-19, InceptionV3 , DenseNet121, SE ResNet18, SE ResNet34, Efficient Net B2, MobilenetV2	validasi pada dataset multi-center Kelemahan: Model belum divalidasi pada dataset dan belum menerapkan Explainable AI (XAI). Perbedaan: Menggunakan U-Net dengan encoder ResNet-50 Kontribusi Penelitian: Mengembangkan ResUNet50 yang meningkatkan akurasi segmentasi sekaligus mengurangi parameter dan waktu inferensi dibanding U-Net.
10	[28]	Automatic Brain Tumor Segmentation: Advancing U-Net With ResNet50 Encoder for Precise Medical Image Analysis	SHOFFAN SAIFULLAH, RAFAL DREŻEWSKI, ANTON YUDHANA, AND ANDIKO PUTRO SURYOTOMO T1-CE MRI dataset and BraTS 2018 (2025)	CNN-based model, Edge U-Net, U-Net with AT, U-Net Modality, SegNet	Research Gap: Belum tersedia metode segmentasi yang mampu menggeneralisasi berbagai karakteristik tumor dan citra MRI. Kelemahan: Akurasi segmentasi masih dipengaruhi oleh variasi bentuk, ukuran, dan batas tumor. Perbedaan: Menggunakan U-Net dengan encoder ResNet-50 pada dataset Kaggle dan BraTS 2018. Kontribusi Penelitian: Mengembangkan arsitektur ResUNet50 yang mengintegrasikan

					ResNet-50 sebagai encoder pada U-Net,
--	--	--	--	--	---------------------------------------


Berdasarkan tabel penelitian terdahulu, dapat disimpulkan bahwa metode deep learning telah menunjukkan perkembangan yang signifikan dalam klasifikasi dan segmentasi tumor otak berbasis citra Magnetic Resonance Imaging (MRI). Berbagai arsitektur, seperti U-Net dengan backbone ResNet-50, multiple encoder, Vision Transformer, Swin Transformer, attention mechanism, serta teknik augmentasi citra sintetis telah berhasil meningkatkan performa model dalam mendeteksi maupun mensegmentasi tumor otak. Selain itu, beberapa penelitian juga menunjukkan bahwa penggunaan transfer learning, attention mechanism, dan backbone yang lebih kuat mampu meningkatkan nilai *Dice Coefficient*, *Intersection over Union* (IoU), serta akurasi segmentasi dibandingkan metode konvensional.

Meskipun demikian, penelitian-penelitian terdahulu masih menunjukkan beberapa keterbatasan. Sebagian besar penelitian berfokus pada pengembangan atau peningkatan satu arsitektur tertentu, sedangkan penelitian yang membandingkan pengaruh penggunaan backbone yang berbeda pada arsitektur U-Net terhadap performa segmentasi masih terbatas. Selain itu, beberapa penelitian juga masih menghadapi tantangan dalam kemampuan generalisasi model, efisiensi komputasi, serta validasi pada dataset yang lebih beragam.

Berdasarkan research gap tersebut, penelitian ini melakukan analisis komparatif terhadap dua backbone, yaitu ResNet-50 dan MobileNetV2, pada arsitektur U-Net untuk segmentasi tumor otak menggunakan dataset BRISC2025. Analisis dilakukan menggunakan metrik evaluasi yang sama sehingga perbedaan performa kedua backbone dapat dibandingkan secara objektif. Sebagai bentuk implementasi, model dengan performa terbaik selanjutnya diterapkan ke dalam website yang memungkinkan untuk melakukan segmentasi citra MRI.

2.2 Teori yang berkaitan

2.2.1 Tumor Otak




gambar 2. 1 Tumor Otak[29].

Tumor otak adalah penyakit dengan angka morbiditas dan mortalitas yang tinggi. Di era sekarang, di mana harapan hidup meningkat, insiden tumor otak juga meningkat. Pengobatan tumor otak membutuhkan penyedia layanan medis untuk memiliki pemahaman dasar tentang diagnosis dan manajemen tumor otak. Tumor otak yang paling umum adalah meningioma, glioma, adenoma hipofisis, dan metastasis otak. Pengobatan setiap jenis tumor otak berbeda dan multidisiplin yang melibatkan bidang ilmiah lain selain bedah saraf[30].

Tumor otak dapat menyebabkan kematian jika tidak diobati. Kompleksitas tumor otak menimbulkan tantangan bagi penyedia layanan kesehatan dalam mendiagnosis dan merawat pasien yang terkena. Biopsi tumor otak tidak semudah biopsi bagian tubuh lainnya, karena harus dilakukan dengan pembedahan. Oleh karena itu, kebutuhan akan metode lain untuk diagnosis akurat tanpa pembedahan sangat penting. Pencitraan Resonansi Magnetik (MRI) adalah pilihan terbaik dan paling umum digunakan untuk mendiagnosis tumor otak[31].


2.2.2 Otak Normal



gambar 2. 2 Otak Normal[32]

Otak adalah organ kompleks yang melakukan berbagai fungsi yang saling terkait [33]. Otak normal menjadi bagian dari sistem saraf yang bertanggung jawab untuk mengatur aktivitas tubuh manusia. Setiap bagian melakukan tugas tertentu yang berkaitan dengan pengendalian aktivitas motorik dan kognitif. Otak normal tidak mengalami pertumbuhan sel abnormal. Aktivitas fisik teratur mendukung fungsi otak normal, sementara kurangnya olahraga berkontribusi pada perkembangan berbagai gangguan otak. Olahraga meningkatkan aliran darah ke otak, mendorong pelepasan faktor neurotropik seperti *Brain-Derived Neurotrophic Factor* (BDNF), yang mendukung kesehatan neuron, plastisitas sinaptik, dan fungsi kognitif[34].

2.2.3 Glioma



gambar 2. 3 Glioma[35].

Glioma merupakan jenis tumor otak primer ganas yang paling umum dan menyumbang dengan proporsi sekitar 80% hingga 85% dari seluruh kasus

tumor otak ganas pada orang dewasa. Glioma terdiri dari kelompok heterogen yang berasal dari sel glial, dan dapat menyebar secara difus ke jaringan parenkim otak. Menurut klasifikasi dari *World Health Organization* (WHO), glioma dibagi menjadi dua kategori utama, yaitu glioma tingkat rendah (tingkat I dan II) serta glioma tingkat tinggi (tingkat III dan IV), yang ditentukan berdasarkan karakteristik histologi[36].

Tingkat keganasan yang tinggi, angka mortalitas, dan resiko kekambuhan yang menyebabkan glioma menjadi penyumbang sebagian besar kematian pada pasien dengan tumor otak primer[36]. Secara umum, glioma dikelompokkan menjadi dua kategori utama, yaitu glioma sirkumskripsi dan glioma difus. Glioma sirkumskripsi cenderung lebih jinak, dan dapat disembuhkan dengan melakukan pengangkatan tumor secara menyeluruh. Sebaliknya. Glioma difus bersifat lebih ganas dan tidak dapat disembuhkan melalui operasi saja[37].

2.2.4 Meningioma




gambar 2. 4 Meningioma[35].

Meningioma merupakan tumor meninges yang terutama berasal dari sel penutup arachnoid, tetapi dapat terjadi namun jarang muncul sebagai tumor primer di lokasi lain, seperti di dalam ventrikel. Secara epidemiologis, meningioma mewakili sekitar 24–30% dari seluruh tumor intrakranial primer dan lebih sering ditemukan pada wanita, terutama pada usia paruh baya hingga lanjut usia. Berdasarkan klasifikasi tumor Sistem Saraf Pusat (SSP) oleh *World Health Organization* (WHO), meningioma dibagi menjadi tiga tingkat, yaitu

jinak (grade I) yang merupakan tipe paling sering ditemukan, atipikal (grade II), dan anaplastik (grade III) [38].

Sebagian besar didasarkan pada karakteristik histopatologis yang berkaitan dengan perkembangan tumor, potensi kekambuhan, serta tingkat kelangsungan hidup[38]. tumor ini sering kali terdeteksi secara tidak sengaja karena pertumbuhannya yang cenderung lambat, Namun, seiring dengan peningkatan ukuran, tumor mulai menimbulkan gejala akibat efek massa yang ditimbulkannya serta adanya pembengkakan jaringan di sekitarnya yang dikenal sebagai edema peritumoral[39].

2.2.5 Pituitary tumor



gambar 2. 5 Pituitary[35].

Tumor pituitary merupakan istilah umum yang mencakup berbagai jenis tumor yang berasal dari area sistem hipotalamus–pituitari. Sebagian besar pituitary tumor termasuk dalam kategori pituitary adenomas, yang baru baru ini disebut sebagai pituitary neuroendocrine tumours. Secara klinis, prevalensi *pituitary adenomas* diperkirakan sekitar 1 dari 1000 individu. Sementara itu, jenis tumor pituitari lainnya, seperti kraniofaringioma dan pituicytoma, tergolong sangat jarang terjadi[40].

Tumor pituitary yang berasal dari sel endokrin pada pituitary anterior tergolong cukup sering ditemukan dan pada umumnya dapat ditangani secara efektif melalui tindakan pembedahan maupun terapi medis. Namun demikian, terdapat sebagian kecil pituitary tumor yang menunjukkan sifat lebih agresif,

seperti kekambuhan lokal berulang atau perkembangan tumor meskipun telah diberikan pengobatan gabungan pembedahan, medis, atau radioterapi[34].

Tumor ini dikenal sebagai pituitari agresif (*aggressive pituitary tumors/APT*), yang juga disebut sebagai *pituitary neuroendocrine tumors* agresif (*PitNET*), atau dalam kasus yang sangat jarang, tumor ini dapat mengalami metastasis dan diklasifikasikan sebagai karsinoma hipofisis (*PC*) atau *PitNET metastatic*[34].

2.2.6 MRI (*Magnetic Resonance Imaging*)

Magnetic Resonance Imaging (MRI) adalah teknik pencitraan non-invasif yang menggunakan medan magnet kuat dan gelombang radio untuk menghasilkan gambar detail dari struktur internal[41]. Teknologi MRI, sebagai terobosan besar dalam teknologi medis, tidak hanya merevolusi bidang diagnosis medis, tetapi juga menyediakan alat yang ampuh untuk menjaga kesehatan manusia dalam pencitraan struktur internal non-invasif[42].

Dibandingkan dengan sinar X dan CT scan tradisional, teknologi MRI memiliki keunggulan yang signifikan. Pertama, teknologi MRI sepenuhnya menghilangkan efek radiasi berbahaya dan sebagai gantinya menggunakan medan magnet dan sinyal frekuensi radio yang aman untuk deteksi non-invasif. Ini berarti bahwa selama pemeriksaan medis, pasien tidak akan dirugikan oleh radiasi berbahaya apa pun dan dapat menjalani pemeriksaan dengan aman[42].

Kedua, teknologi MRI menyediakan gambar definisi tinggi dan kontras tinggi, yang dapat lebih akurat mengungkapkan struktur internal dan perubahan abnormal tubuh manusia. Hal ini menjadikan teknologi MRI tak tertandingi dalam mendiagnosis berbagai penyakit, khususnya mahir dalam mengungkapkan perubahan halus pada struktur jaringan lunak dan sistem pembuluh darah [42].

Dalam penelitian ini, citra MRI digunakan sebagai data input utama untuk proses segmentasi tumor otak. Setiap citra MRI dipasangkan dengan mask segmentasi sebagai *ground truth* yang digunakan untuk melatih model *deep learning* dalam mengenali area tumor. Penggunaan MRI dipilih karena mampu

memberikan informasi spasial dan tekstur yang baik sehingga membantu model dalam mempelajari pola tumor secara lebih optimal.

2.2.7 CNN (*Convolutional Neural Network*)

Convolutional Neural Network (CNN) adalah salah satu jaringan yang paling signifikan di bidang deep learning [43]. Jaringan saraf konvolusional (CNN/ConvNet) menggunakan neuron dengan bias dan bobot yang dapat dipelajari. Skor klasifikasi dihasilkan setelah setiap neuron menghitung hasil perkalian titik menggunakan data yang telah diberikan. Dengan menggabungkan karakteristik spesifik ke dalam struktur jaringan menggunakan CNN, kita dapat meningkatkan efektivitas fungsi feedforward dan meneruskan parameter[44].

Meskipun terdapat banyak variasi model CNN, arsitektur keseluruhannya pada dasarnya sama dan mengikuti paradigma tetap, yang terdiri dari lapisan input, lapisan konvolusi dan pooling yang disusun secara bergantian, satu atau lebih lapisan yang terhubung sepenuhnya, fungsi aktivasi, dan lapisan output di bagian akhir[45].

Bagian pertama jaringan terdiri dari sejumlah lapisan konvolusi dan pooling yang disusun secara bergantian untuk membentuk ekstraktor fitur, di mana berbagai operasi dapat dilakukan untuk memproses data input mentah yang telah diproses sebelumnya menjadi representasi fitur yang lebih abstrak dan tingkat tinggi. Lapisan yang terhubung sepenuhnya digunakan dalam kombinasi dengan fungsi aktivasi untuk menjalankan tugas-tugas seperti klasifikasi atau regresi pada fitur yang diekstrak[45].

CNN banyak digunakan pada bidang computer vision seperti klasifikasi gambar, deteksi objek, segmentasi citra, dan pengenalan wajah karena memiliki kemampuan yang baik dalam memahami pola visual. Dalam penelitian ini, CNN digunakan sebagai dasar utama dalam pembangunan model segmentasi citra MRI tumor otak menggunakan arsitektur U-Net dengan backbone ResNet50 dan MobileNetV2.

2.2.8 Deep Learning

Deep learning semakin banyak digunakan dalam analisis citra medis [46]. Deep learning adalah bidang baru dalam machine learning yang telah mendapatkan popularitas dalam beberapa waktu terakhir. Deep learning mengacu pada arsitektur yang berisi banyak lapisan tersembunyi (jaringan dalam) untuk mempelajari berbagai fitur dengan berbagai tingkat abstraksi[47].

Algoritma *deep learning* berupaya memanfaatkan struktur yang tidak diketahui dalam distribusi input untuk menemukan representasi yang baik, seringkali pada beberapa tingkatan, dengan fitur tingkat tinggi yang dipelajari didefinisikan dalam hal fitur tingkat rendah. *Deep learning* memungkinkan memasukkan data mentah (piksel dalam kasus data gambar) ke dalam algoritma pembelajaran tanpa terlebih dahulu mengekstrak fitur atau mendefinisikan vektor fitur. Algoritma *deep learning* dapat mempelajari kumpulan fitur yang tepat, dan melakukannya dengan cara yang jauh lebih baik daripada mengekstrak fitur-fitur ini menggunakan pengkodean manual[47].

Dalam penelitian ini, deep learning digunakan untuk membangun model segmentasi tumor otak berbasis U-Net dengan backbone ResNet50 dan MobileNetV2. Model dilatih menggunakan dataset citra MRI untuk mempelajari karakteristik area tumor sehingga mampu menghasilkan segmentasi secara otomatis.

2.3 Algoritma yang digunakan

2.3.1 U-NET

U-net adalah teknik segmentasi gambar yang dikembangkan terutama untuk tugas-tugas segmentasi gambar [46]. Model U-Net, yang dilatih secara end-to-end untuk prediksi piksel demi piksel, telah muncul sebagai arsitektur encoder-decoder yang sangat ampuh, sebagian besar karena kinerjanya yang mutakhir dalam segmentasi citra biomedis bahkan ketika data pelatihan berlabel kecil.

Arsitektur U-Net terdiri dari sub-jaringan encoder untuk menangkap konteks dengan mengkodekan gambar masukan ke dalam representasi fitur tingkat rendah pada beberapa level dan sub-jaringan decoder untuk

memproyeksikan representasi fitur ini secara semantik ke dalam ruang piksel dalam upaya untuk memungkinkan lokalisasi yang tepat melalui *transposed convolutions*[48].

Dalam U-Net, *skip connection* yang digunakan antara encoder dan decoder memerlukan penggabungan (concatenation) pada level yang sama. Namun, penggabungan ini, meskipun berada pada level yang sama, tidak serupa secara semantik. Oleh karena itu, beberapa varian U-Net telah diusulkan, dengan beberapa mencoba mengubah tulang punggung (backbone) sementara yang lain memodifikasi koneksi lewat antara encoder dan decoder[49]. U-Net digunakan dalam segmentasi citra medis karena mampu menghasilkan segmentasi yang akurat meskipun menggunakan data pelatihan yang relatif terbatas. Selain itu, arsitektur U-Net telah berhasil diterapkan pada berbagai modalitas citra medis dan menjadi dasar pengembangan berbagai varian segmentasi[50].

Dalam penelitian ini, arsitektur U-Net digunakan untuk melakukan segmentasi tumor otak pada citra MRI. Model U-Net dikombinasikan dengan backbone ResNet50 dan MobileNetV2 pada bagian encoder untuk meningkatkan kemampuan ekstraksi fitur

2.3.2 Transfer Learning

transfer learning merupakan teknik deep learning yang memanfaatkan model yang telah dilatih sebelumnya pada dataset besar untuk menyelesaikan tugas baru yang serupa. Metode ini memungkinkan model menggunakan pengetahuan yang telah dipelajari sebelumnya sehingga proses pelatihan menjadi lebih cepat dan efisien.


Transfer learning digunakan di berbagai bidang seperti pencitraan medis, perawatan kesehatan, prediksi cacat perangkat lunak, dll. Seiring pertumbuhan deep learning, transfer learning menjadi bagian integral dalam banyak aplikasi, terutama di bidang pencitraan medis. Untuk mengatasi kekurangan data, teknik transfer learning digunakan[51].

Metode ini memungkinkan penggunaan pengetahuan yang diperoleh dari tugas lain untuk menangani masalah baru tetapi serupa secara efektif dan cepat.

Dalam transfer learning, berbagai jenis arsitektur standar dibangun dan dirancang untuk ImageNet dengan bobot pra-terlatih masing-masing yang disempurnakan pada tugas-tugas medis yang berkisar dari mengidentifikasi penyakit mata, memahami rontgen dada, deteksi dini penyakit Alzheimer, dll[51].

Sejak awal era *Machine Learning* (ML), *transfer learning* telah menjadi eksplorasi yang menarik bagi para ilmuwan. Sebelum munculnya model deep learning, transfer learning dikenal sebagai adaptasi domain dan berfokus pada kumpulan data homogen dan bagaimana menghubungkan kumpulan data tersebut satu sama lain karena sifat algoritma ML[52].

2.3.3 ResNet50



gambar 2. 6 arsitektur ResNet50[53]


ResNet-50 adalah arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Microsoft Research Asia. ResNet-50, arsitektur CNN yang sangat populer dalam pengolahan gambar dan memiliki kinerja yang baik dalam mengenali objek dalam gambar. [54]. Salah satu fitur utama ResNet50 adalah struktur residual yang diperkenalkannya. Struktur ini memungkinkan jaringan untuk langsung meneruskan input ke output, dan untuk membuat koneksi antar

lapisan dengan memperkenalkan blok residual di antara lapisan yang berbeda[16].

Metode koneksi ini memungkinkan jaringan untuk membangun lapisan yang lebih dalam, secara efektif mengatasi masalah pelatihan jaringan yang dalam seperti hilangnya gradien dan ekspresi yang terbatas. Hal ini membuat jaringan lebih mudah dilatih sekaligus memungkinkan pemetaan identitas. Akibatnya, ia telah mencapai kinerja yang sangat baik dalam tugas pengujian seperti klasifikasi dan deteksi gambar, pengenalan objek, dan pengenalan fitur [55].

ResNet-50 memiliki sekitar 25 juta parameter yang dapat dilatih. ResNet-50 awalnya dikembangkan sebagai model benchmark untuk berbagai tugas visi komputer, dan sejak itu telah memengaruhi banyak arsitektur jaringan lain yang berhasil melatih jaringan yang lebih dalam lagi[16]. Dalam penelitian ini, ResNet50 digunakan sebagai backbone encoder pada arsitektur U-Net. Penggunaan ResNet50 bertujuan untuk meningkatkan kemampuan model dalam mengenali karakteristik tumor otak pada citra MRI sehingga hasil segmentasi menjadi lebih akurat.

2.3.4 MobileNetV2



gambar 2. 7 Arsitektur MobileNetV2[56]

MobileNetV2 adalah arsitektur yang dikembangkan oleh Google yang didasarkan pada 1,4 juta gambar dari 1000 kelas. Ini adalah arsitektur DCNN canggih yang berkinerja baik pada perangkat seluler. Dalam MobileNetV2, tidak perlu melatih model dari awal, hanya mengubah lapisan keluaran terakhir sesuai dengan domain.[57].

MobileNetV2 memiliki dua jenis lapisan, yaitu lapisan konvolusi, dikelompokkan ke dalam blok bottleneck yang menggabungkan konvolusi standar, depthwise, dan ekspansi/proyeksi dengan normalisasi batch dan fungsi aktivasi, dan lapisan klasifikasi, yang menggunakan pooling dan lapisan terhubung penuh[17].

Sifat MobileNetV2 yang ringan memungkinkan penyebaran yang mudah pada perangkat seluler, sehingga praktis untuk digunakan di lapangan. Akurasi dan ketahanan model yang tinggi menjadikannya alat yang efektif untuk penilaian kualitas dan penyortiran secara real-time, memastikan hanya produk terbaik yang sampai ke pasar. Selain itu, skalabilitas dan efisiensi model memberikan solusi serbaguna untuk berbagai tugas klasifikasi[58].

Karena sifatnya yang ringan dan efisien, MobileNetV2 banyak digunakan dalam berbagai penelitian deep learning yang memerlukan keseimbangan antara akurasi dan efisiensi komputasi. Dalam penelitian ini, MobileNetV2 digunakan sebagai backbone encoder pada arsitektur U-Net untuk membandingkan performa segmentasi terhadap backbone ResNet50.

2.3.5 Dice Coefficient

$$DSC = \frac{2TP}{FP + FN + 2TP}$$

Rumus 2. 1 *Dice Coefficient* [59]

Secara umum, tugas segmentasi pembelajaran mesin biasanya menggunakan *Dice Coefficient* untuk mengevaluasi kinerja model. Mengingat bahwa kita mengukur persentase piksel dalam gambar prediksi yang diklasifikasikan dengan benar (dibandingkan dengan gambar ground-truth), skor Dice didefinisikan sebagai dua kali luas tumpang tindih dibagi dengan jumlah total piksel di kedua gambar *ground truth* dan prediksi. Meskipun skor Dice dapat menunjukkan tumpang tindih, hal itu belum tentu mewakili geometri prediksi dengan cukup baik[60].

Meskipun DSC (*Dice Similarity Coefficient*) adalah metrik yang banyak digunakan untuk mengevaluasi kesamaan antara volume yang tersegmentasi otomatis dan volume referensi, ia memiliki beberapa keterbatasan yang perlu dipertimbangkan ketika menafsirkan hasilnya. DSC tidak memberikan informasi tentang lokasi kesalahan segmentasi. Nilai DSC yang rendah dapat disebabkan oleh kesalahan yang terjadi dipinggiran wilayah yang tersegmentasi, yang mungkin kurang kritis daripada kesalahan di dekat pusat. DSC dapat sensitif terhadap pilihan ambang batas segmentasi dan resolusi gambar[61]. Menurut pedoman, indeks Dice < 0,6, 0,6–0,8, 0,8–1,0, dan 1,0 menunjukkan konsistensi yang tidak memadai, baik, sangat baik, dan ideal, masing-masing[62]. Biasanya, jika loss pelatihan terus menurun sementara loss validasi mulai meningkat, ini menunjukkan overfitting[63].

Dalam penelitian ini, *Dice Coefficient* digunakan sebagai metrik evaluasi utama untuk mengukur performa model U-Net dengan backbone ResNet-50 dan MobileNetV2 pada proses segmentasi tumor otak menggunakan citra MRI. Selain digunakan sebagai metrik evaluasi, penelitian ini juga menggunakan loss dalam proses pelatihan model untuk membantu meningkatkan kualitas segmentasi area tumor.

2.3.6 Intersection over Union

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} = \frac{|A \cap B|}{|A \cup B|}$$

Rumus 2. 2 Intersection Over Union[64].

Indeks Jaccard, yang dikenal sebagai *intersection over union* (IoU), adalah metrik yang banyak digunakan dalam evaluasi model segmentasi semantik. Daya tariknya terletak pada invariansi skalanya dan kemampuannya yang unggul untuk mencerminkan kualitas persepsi model dibandingkan dengan akurasi piksel. Sejalan dengan prinsip-prinsip minimisasi risiko empiris dalam teori pembelajaran statistik, metrik yang digunakan untuk evaluasi juga harus dioptimalkan selama pelatihan[65].

Metrik ini banyak digunakan dalam domain segmentasi citra biomedis karena indikasi yang luar biasa dan proyeksi yang ringkas. Nilainya setara dengan proporsi konvergensi dan konjungsi dari dua jalur, dan hasil 1 *symbolizes* bahwa penilaian segmentasi benar-benar sesuai dengan garis dasar[66].

Intersection over Union (IoU) digunakan dalam banyak tugas. Untuk tugas segmentasi, IoU digunakan untuk mengevaluasi akurasi prediksi piksel atau titik, yang mencerminkan kualitas fitur yang dipelajari. Kerugian entropi silang adalah fungsi kerugian yang banyak digunakan untuk tugas segmentasi. Untuk mengurangi masalah ketidakseimbangan kelas, focal loss diusulkan. Dengan belajar lebih baik pada contoh yang sulit, IoU (*Input/Output Unit*) per piksel atau per titik ditingkatkan[67]. *Intersection Over Union* adalah rasio irisan terhadap gabungan dari wilayah yang diprediksi dan wilayah sebenarnya, dengan nilai berkisar dari [0, 1][14]. Rentang nilai semua metrik yang disajikan berkisar dari nol (terburuk) hingga satu (terbaik)[68]. Perbedaan yang semakin besar antara akurasi pelatihan dan validasi menunjukkan bahwa model mulai mengalami overfitting[69].

Dalam penelitian ini, *Intersection over Union* digunakan sebagai metrik evaluasi untuk mengukur performa segmentasi tumor otak pada citra MRI. Metrik ini digunakan untuk membandingkan hasil segmentasi dari model U-Net dengan backbone ResNet50 dan MobileNetV2. Penggunaan IoU bersama *Dice Coefficient* membantu memberikan evaluasi yang lebih menyeluruh terhadap kemampuan model dalam menghasilkan segmentasi area tumor secara akurat.

2.4 Tools dan software yang digunakan

2.4.1 Jupyter Notebook

Jupyter Notebook adalah lingkungan berbasis web yang dapat digunakan sebagai buku catatan pribadi interaktif. Ia berjalan di lingkungan IPython, [70]. Jupyter Notebook banyak digunakan dalam bidang data science, machine learning, dan pengolahan citra karena mampu menggabungkan proses penulisan kode dengan dokumentasi dalam satu lingkungan kerja.

Dengan kata lain, seperti halnya *Python*, bahasa lain dapat digunakan, seperti MATLAB, R, dan Julia. Oleh karena itu, keuntungan utama lainnya adalah interaktivitas tinggi dari lingkungan *Jupyter Notebook*, melalui pertukaran konten multimedia dan eksekusi kode tertulis. Pengguna tidak memerlukan pengetahuan sebelumnya tentang pemrograman komputer untuk berinteraksi atau memvisualisasikan konten buku catatan, yang memperkuat kapasitas transmisi pengetahuan dan penggunaannya sebagai alat pengajaran[70].

Jupyter Notebook adalah sistem yang paling banyak digunakan untuk pemrograman interaktif berbasis literasi [71]. Pada penelitian ini, *Jupyter Notebook* digunakan sebagai media utama dalam proses pengembangan model segmentasi citra MRI. Seluruh tahapan penelitian, mulai dari preprocessing data, pelatihan model, evaluasi performa, hingga visualisasi hasil segmentasi dilakukan menggunakan *Jupyter Notebook*. Penggunaan notebook ini memudahkan dalam menjalankan kode secara bertahap sehingga hasil dari setiap proses dapat langsung diamati dan dianalisis.

Selain itu, *Jupyter Notebook* mendukung integrasi dengan berbagai library Python seperti *TensorFlow*, *Keras*, *NumPy*, *Pandas*, dan *Matplotlib* yang sangat dibutuhkan dalam pengembangan model *deep learning*. Tampilan yang interaktif juga membantu dalam memvisualisasikan hasil training model berupa grafik akurasi, loss, maupun hasil segmentasi citra MRI secara langsung.

2.4.2 Python

Python adalah bahasa pemrograman yang digunakan dalam penelitian ini. Bahasa ini dipilih karena tidak sulit untuk dipelajari dan dipahami [72]. *Python* dapat diintegrasikan dengan baik dengan C/C++ sehingga modul kinerja eksternal atau berbasis kode dapat dipanggil dengan mudah. Selain itu, ia menawarkan berbagai macam pustaka ilmiah, misalnya pemrosesan dan analisis data, pembuatan grafik dan antarmuka pengguna grafis[73].

Python telah memperkuat dirinya sebagai bahasa pemrograman utama, dengan kehadiran yang substansial di berbagai domain aplikasi, dan minat yang

kuat dari komunitas penelitian. Dari pengembangan web hingga analisis data, komputasi ilmiah, dan pembelajaran mesin, keserbagunaan *Python* telah menjadikannya bahasa pilihan bagi banyak pengembang dan organisasi[74].

Sintaksnya yang elegan dan ringkas, ditambah dengan ekosistem pustaka dan kerangka kerja yang luas, telah menjadikannya sangat diperlukan dalam lanskap perangkat lunak modern. Salah satu alasan utama adopsi *Python* yang meluas adalah sifat dinamisnya, yang dipuji oleh pengembang karena fleksibilitas dan ekspresivitasnya[74].

Dalam penelitian ini, *Python* digunakan sebagai bahasa pemrograman utama untuk membangun model segmentasi tumor otak menggunakan arsitektur U-Net dan MobileNetV2. *Python* dipilih karena memiliki banyak library pendukung yang mempermudah proses pengolahan data, visualisasi, serta pembangunan model deep learning.

2.4.3 *Pandas*

Pandas adalah pustaka *Python* yang digunakan untuk pengolahan dan analisis data yang memiliki struktur data yang efektif seperti *DataFrame*. *Pandas* menyediakan struktur data yang cepat dan fleksibel, seperti data frame CD, yang dirancang untuk bekerja dengan data terstruktur dengan sangat cepat dan intuitif [75].

Pandas memiliki fungsi untuk menganalisis, membersihkan, mengeksplorasi, dan memanipulasi data. *Pandas* memungkinkan analisis data dalam jumlah besar dan pengambilan kesimpulan berdasarkan teori statistik. Ia menyederhanakan pemuatan data dari berbagai format, seperti CSV, Excel, dan DBMS, dengan merampingkan proses impor data ke *Python*[76].

Pandas juga membantu dalam pembersihan data dengan mengelola nilai yang hilang, duplikat, dan transformasi format. Ia memberdayakan eksplorasi data dengan alat untuk menghitung statistik, visualisasi data, dan menghasilkan laporan ringkasan. *Pandas* mendukung operasi transformasi data seperti pivoting, melting, dan merging, serta memungkinkan analisis data melalui pengelompokan, agregasi, dan perhitungan statistik[76].

2.4.4 Matplotlib

Matplotlib adalah salah satu pustaka *Python* yang paling populer untuk membuat plot statis, animasi, dan interaktif. Keunggulan *Matplotlib* terletak pada fleksibilitasnya, memungkinkan pengguna untuk menghasilkan berbagai macam plot, termasuk grafik garis, grafik batang, plot sebaran, dan visualisasi 3D. Dalam studi mereka, Cid-Fuentes dkk. menyoroti kemampuan *Matplotlib* untuk berintegrasi dengan pustaka lain seperti *NumPy* dan *Pandas*, sehingga memudahkan visualisasi data langsung dari array terstruktur dan *DataFrame*[77].

Matplotlib banyak digunakan untuk visualisasi data. Perpustakaan ini juga menyediakan antarmuka pemrograman berorientasi objek (API), yang dapat digunakan untuk menyematkan plot tersebut ke dalam aplikasi. Fitur utama *Matplotlib*, dapat digunakan sebagai pengganti MATLAB, dengan keunggulan gratis dan open-source, mendukung puluhan backend dan jenis output, yang bisa menggunakannya terlepas dari sistem operasi yang digunakan atau format output yang diinginkan[75].

Matplotlib sangat berguna untuk analisis korelasi antar variabel, memvisualisasikan interval kepercayaan 95 persen dari model, mendeteksi outlier menggunakan scatter plot, dan memvisualisasikan distribusi data untuk mendapatkan wawasan instan [75].

Dalam penelitian ini, *Matplotlib* digunakan untuk menampilkan grafik *training* dan *validation* seperti *accuracy*, *Dice Coefficient*, *IoU*, serta *loss* selama proses pelatihan model berlangsung. Grafik tersebut membantu dalam mengamati perkembangan performa model pada setiap *epoch*. Selain digunakan untuk visualisasi grafik pelatihan, *Matplotlib* juga digunakan untuk menampilkan hasil segmentasi citra MRI yang dihasilkan model. Dengan visualisasi tersebut, peneliti dapat membandingkan citra asli, mask ground truth, dan hasil prediksi model sehingga kualitas segmentasi dapat dianalisis secara visual.

2.4.5 *Tensorflow*

TensorFlow merupakan pustaka yang digunakan untuk komputasi numerik berkinerja tinggi dengan sekitar 35.000 komentar serta komunitas yang aktif sekitar 1.500 kontributor. Pustaka ini digunakan di berbagai bidang ilmiah [75]. Versi pertama *TensorFlow* dirilis pada tahun 2015 dan bertujuan untuk menyatukan berbagai pustaka ke dalam paket yang kohesif yang dapat digunakan untuk menyelesaikan berbagai masalah pembelajaran mesin [33].

Hal ini menghasilkan banyak fleksibilitas saat mendesain model jaringan, karena ada pustaka seperti *Contrib* dan *Keras* yang dapat digunakan untuk mendefinisikan lapisan. Bagi pengguna yang berpengalaman, kerangka kerja ini menawarkan semua alat yang diperlukan, namun, fakta bahwa berbagai pustaka disatukan juga berarti bahwa beberapa interaksi lebih kompleks dan lebih sulit dipahami [78].

Selain perbaikan pada masalah sebelumnya, *TensorFlow 2.0* juga menambahkan fitur baru seperti modul *TensorFlow Datasets* yang menyediakan cara mudah untuk memasukkan data ke jaringan dan abstraksi baru dari model yang dibuat selama runtime, yang berarti bahwa jaringan dapat dilatih pada GPU lokal atau bahkan lingkungan multi-GPU tanpa perlu modifikasi apa pun [78].

Dalam penelitian ini, *TensorFlow* digunakan sebagai framework utama untuk membangun, melatih, dan mengevaluasi model segmentasi citra MRI tumor otak. Framework ini digunakan untuk implementasi arsitektur U-Net, preprocessing data, training model, serta perhitungan metrik evaluasi

2.4.6 *Early Stopping*

Penghentian dini (*early stopping*) adalah teknik regularisasi untuk jaringan saraf dalam (deep neural networks) yang menghentikan pelatihan setelah sejumlah *epoch* tertentu ketika kinerja model berhenti meningkat pada dataset validasi yang ditahan. Pada intinya, selama pelatihan, bobot model terbaik disimpan dan diperbarui. Ketika perubahan parameter tidak lagi memberikan

peningkatan (setelah sejumlah iterasi tertentu), pelatihan dihentikan dan parameter terbaik terakhir digunakan[79].

Penghentian dini (*early stopping*) adalah teknik sederhana yang mengatur pelatihan model dan mengurangi biaya komputasi dengan menghentikan proses pelatihan ketika tidak ada peningkatan lebih lanjut yang diamati dalam kinerja model pada set validasi. Secara khusus, metode ini menghentikan pelatihan pada saat yang tepat, mencegah pelatihan yang berlebihan sambil menghemat sumber daya komputasi dan mengurangi ketergantungan pada metode regularisasi intensif komputasi lainnya dalam pelatihan model.

Ukuran dan kompleksitas model dan dataset yang semakin besar membuat manfaat ini semakin penting, karena hal ini menyebabkan peningkatan biaya komputasi yang signifikan terkait dengan pelatihan model tingkat lanjut[80]. Dengan menggunakan *Early Stopping*, proses training dapat dihentikan sebelum model mengalami overfitting yang berlebihan.

Pada penelitian ini, *Early Stopping* digunakan untuk memantau nilai *validation loss* selama proses pelatihan model segmentasi. Jika nilai *validation loss* tidak mengalami penurunan dalam jumlah *epoch* tertentu, maka proses training akan dihentikan secara otomatis. Penggunaan teknik ini membantu menghasilkan model yang lebih optimal dan memiliki kemampuan generalisasi yang lebih baik terhadap data baru.

2.4.7 Adam Optimizer

Adam optimizer banyak digunakan karena ketangguhan dan efisiensinya di berbagai macam tugas. Adam optimizer, salah satu algoritma optimasi paling populer, telah mendapatkan pengakuan luas di bidang pembelajaran mendalam karena kemampuannya yang sangat baik dan kinerja komputasi yang efisien[81].

Dengan menggabungkan metode momentum dengan mekanisme penyesuaian laju pembelajaran adaptif, algoritma optimasi Adam meningkatkan stabilitas dan kecepatan konvergensi proses pelatihan. Meskipun demikian, para peneliti telah menemukan bahwa algoritma original

adam memiliki beberapa masalah dalam aplikasi praktis: pengoptimal Adam masih memiliki keterbatasan dalam menemukan solusi optimal global, terutama ketika berurusan dengan permukaan kerugian yang kompleks, di mana pengoptimal Adam standar dapat jatuh ke minimum lokal atau konvergen lambat dalam situasi tertentu[81].

Dalam penelitian ini, *Adam Optimizer* digunakan pada proses pelatihan model U-Net dengan backbone MobileNetV2. Adam dipilih karena memiliki kemampuan konvergensi yang baik dan mampu bekerja secara efektif pada dataset citra medis yang kompleks. *Adam Optimizer* mampu menyesuaikan learning rate secara otomatis untuk setiap parameter model. Hal ini membantu model mencapai performa yang lebih optimal serta mempercepat proses pelatihan

2.4.8 Epoch

Epoch adalah jumlah pengulangan proses pembelajaran yang dilakukan oleh pembelajaran mesin. Semakin besar jumlah *epoch*, semakin banyak waktu yang dibutuhkan untuk pemrosesan. Ini tidak berarti bahwa jumlah *epoch* yang lebih besar akan menghasilkan nilai akurasi yang lebih tinggi. Jumlah *epoch* yang digunakan untuk mendapatkan nilai RMSE minimum tentu akan memengaruhi waktu eksekusi program[82].

Jumlah *epoch* yang lebih besar akan membutuhkan lebih banyak waktu, dan jumlah *epoch* yang lebih kecil akan mempercepat waktu eksekusi program[82]. *Epoch* menggambarkan jumlah waktu pelatihan jaringan saraf hingga pelatihan dihentikan. Model tidak akan sesuai dengan data pelatihan (under-fitting) ketika *epoch* terlalu kecil, dan model akan mengalami over-fitting ketika nilai ini terlalu besar[83].

Pada setiap *epoch*, model akan mempelajari pola dari data training melalui proses forward propagation dan backpropagation. Setelah seluruh data diproses, model akan memperbarui bobot berdasarkan hasil perhitungan error atau loss. Semakin banyak *epoch* yang digunakan, maka model memiliki kesempatan lebih besar untuk mempelajari pola data.

Pada penelitian ini, *epoch* digunakan dalam proses pelatihan model U-Net dengan backbone MobileNetV2 untuk segmentasi tumor otak pada citra MRI. Jumlah *epoch* ditentukan untuk memperoleh performa model yang optimal berdasarkan hasil training dan validation. Selain itu, penggunaan *epoch* juga dipadukan dengan teknik *Early Stopping* supaya proses pelatihan dapat berhenti secara otomatis ketika performa model tidak mengalami peningkatan sehingga dapat mengurangi risiko overfitting.

2.4.9 Learning Rate

Learning rate merupakan hyperparameter dalam proses pelatihan model deep learning yang digunakan untuk mengatur besar kecilnya perubahan bobot model pada setiap iterasi training. Learning rate memiliki peran penting dalam menentukan kecepatan dan kestabilan proses pembelajaran model.

menunjukkan bahwa *learning rate* merupakan strategi efektif untuk meningkatkan stabilitas pelatihan model neural menggunakan batch besar. Berbeda dengan LeRaC (*learning rate curriculum*), pendekatan ini tidak menggunakan *learning rate* yang berbeda untuk setiap lapisan. Selain itu, strategi ini *restarts learning rate* pada momen yang berbeda selama seluruh proses pelatihan, sedangkan LeRaC hanya diterapkan selama beberapa *epoch* pelatihan pertama[84].

Learning rate dipandang sebagai parameter hiper absolut untuk disetel dan sangat memengaruhi pelatihan model dengan algoritma penurunan gradien. Studi telah menghasilkan beberapa teknik laju pembelajaran termasuk peluruhan akar kuadrat terbalik, peluruhan linier, peluruhan eksponensial, dan peluruhan kosinus [85]..

Learning rate memiliki prosedur yang bervariasi yang didasarkan pada masalah optimasi. Salah satu keterbatasannya adalah pemilihan learning rate yang sesuai untuk aplikasi tertentu[85]. Dalam penelitian ini, *learning rate* digunakan untuk mengatur proses pembelajaran model segmentasi tumor otak berbasis U-Net dan MobileNetV2. Pemilihan *learning rate* yang tepat membantu model mencapai performa yang lebih optimal, mempercepat proses

konvergensi, serta meningkatkan stabilitas selama proses pelatihan berlangsung.



UMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA