

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2. 1 Tabel Penelitian Terdahulu

No.	Paper Pembanding	Metode	Hasil	Ringkasan
1	[24] P. Schelb et al. (2021)	U-Net	DSC 0.22 (untuk lesi/tumor prostat)	Penelitian ini membandingkan segmentasi otomatis menggunakan deep learning dengan radiolog segmentasi manual, hasilnya menunjukkan performa rendah pada lesi tumor kecil, dengan tujuan untuk memotivasi perbaikan model untuk mendekati akurasi manusia.
2	[25] J. F. Flaño et al. (2022)	Deep learning berbasis CNN	DSC 0.276 (untuk lesi/tumor prostat, threshold 0.25)	Penelitian ini menggunakan sistem otomatis dalam melakukan lokalisasi, segmentasi, dan estimasi menggunakan Grade Gleason, hasil dair model ini menunjukkan performa yang rendah pada lesi benign dan ganas yang menyoroti adanya tantangan variabilitas data multiparametrik.
3	[26] J. Li et al. (2023)	3D residual CNN dengan deep supervision	DSC 0.60 Tumor Prostat	Penelitian ini menerapkan model 3D deep learning pada ADC Citra MRI untuk segmentasi tumor pada volume 3D, yang dimana mempunyai hasil DSC rendah di berbagai scanner MRI yang melakukan penekanan pada kebutuhan generalisasi untuk dose escalation radioterapi.
4	[27] S. Li, Y. Wang, and J. Zhang.(2025)	Fully automatic 3D fusion-based	DSC 0.212 untuk Tumor Prostat	Penelitian ini melakukan penerapan pada metode 3D deep learning untuk segmentasi tumor langsung pada data MRI-TRUS, dengan hasil performa model yang rendah pada baseline untuk akurasi bedah.

5	[28] M. Bardis et al. (2020)	U-Net	DSC 0.424 pada Prostat	Pada penelitian ini melakukan pemodelan dan evaluasi performa U-Net pada data yang terbatas, DSC sangat rendah dikarenakan pada sampel kecil yang menekankan dampak ukuran dataset terhadap stabilitas segmentasi prostat secara keseluruhan.
6	[29] D. D. Gunashekar et al.	U-Net based CNN	0.62 (whole gland prostat), 0.31 (tumor prostat)	Penelitian ini melakukan pemodelan dengan deep learning pada multi-parametrik MRI (mpMRI) volumetrik (3D-adapted U-Net) dengan ground truth pada histopatologi, yang menghasilkan Dice Score Coefficient (DSC) sangat rendah pada tumor yang menyoroti adanya tantangan variabilitas juga heterogenitas pada lesi tumor.

Dalam beberapa tahun terakhir, Tabel 2.1 menunjukkan kemajuan penelitian dengan menggunakan metode dan model dari deep learning telah berevolusi sesuai dengan paradigma dari segmentasi prostat dan juga tumor prostat pada data citra MRI, yang mempunyai tujuan utama dalam mengubah arah penelitian yang awalnya anotasi manual yang rentan terkena kesalahan dan variabilitas antar-observer. Penelitian yang dilakukan [24], mempelopori adanya penggunaan evaluasi model U-Net pada data yang sangat terbatas untuk segmentasi prostat secara keseluruhan, mencapai Dice Score Coefficient (DSC) hingga 0.867 pada 320 kasus *training* dengan waktu inferensi hanya 0.24 detik per kasus, yang dimana menunjukkan efisiensi komputasi model dalam mengatasi adanya kasus heterogenitas data melalui augmentasi dan normalisasi. Studi ini yang dilakukan menggunakan kurva asimtotik antara ukuran dataset dan performa, mempunyai hasil dari DSC 0.877 pada 1000 kasus.

Dalam melakukan perbandingan pada penelitian dengan anotasi manual, penelitian yang dilakukan oleh [25] membandingkan U-Net biparametrik dengan melakukan segmentasi anotasi radiolog untuk segmentasi lesi whole gland prostat, yang dimana menghasilkan Dice Score Coefficient (DSC) 0.22 yang lebih rendah

dibandingkan 0.48-0.52 antar-radiolog, terkadang model AI mempunyai prediktif deteksi kanker prostat signifikan klinis (csPCa). Pada penelitian ini mempunyai temuan dalam menjawab kebutuhan lebih baik yang mendekati dengan akurasi manusia pada lesi tumor kecil, dengan analisis penelitian yang menggunakan linear mixed model dikonfirmasi bahwa independensi dari ukuran lesi atau zona prostat, sehingga nantinya dapat diekspektasi pada AI dalam delineasi batas yang sering hilang.

Dalam melakukan penelitian untuk deteksi dan segmentasi otomatis csPCa, penelitian yang dilakukan oleh [26] melakukan integrasi menggunakan 3D Retina U-Net untuk melakukan pemrosesan mpMRI (Multiparametrik MRI) multi-channel seperti T2, DW, ADC, DCE, yang dimana meraih hasil sensitivitas 1.00 dan AUC 0.95-0.96 untuk lesi GGG ≥ 2 , melampaui hasil dari PI-RADS radiolog dalam kurva ROC, meskipun Dice Score Coefficient (DSC) segmentasi lesi ini hanya menghasilkan 0.276, namun batas sering kabur dan ukurannya sangat kecil. Model ini memanfaatkan metode dalam zonal prior (DSC 0.894-0.941 untuk prostat), dengan ensemble pada jaringan untuk generalisasi antar-dataset seperti ProstateX dan IVO, dengan melakukan augmentasi untuk mengatasi urutan yang hilang, sehingga nantinya dapat mendukung biopsi targeted dan terapi fokal secara efisien dan akurat

Dalam meningkatkan kepercayaan dan explainability pada metode deep learning ini, penelitian yang dilakukan oleh [27] melakukan adaptasi menggunakan model dari U-Net 3D dengan Grad-CAM untuk melakukan segmentasi prostat dengan (DSC 0.62) dan tumor prostat dengan (DSC 0.31-0.32) pada multiparametrik-MRI dari 122 pasien, dengan divalidasi terhadap histopatologi seluruh mount, yang dimana setara dengan anotasi radiolog sebesar (DSC 0.32). Heatmap Grad-CAM yang disebutkan mengonfirmasi adanya fokus pada fitur tumor melalui sanity check (MI dan SSIM mendekati 0), yang dimana meskipun Dice Score Coefficient rendah disebabkan adanya bias registrasi histo-MRI dan artefak pasca-biopsi, sehingga nantinya model yang dikembangkan yaitu explainable ini berfungsi sebagai alat awal untuk kontur ahli.

Efisiensi dalam komputasi dan generalisasi model antar scanner menjadi fokus utama dalam penelitian yang dilakukan oleh [28], yang di mana MRRN-DS (3D residual CNN dengan deep supervision) telah mencapai akurasi Dice Score Coefficient sebesar DSC 0.60 internal, 0.54 eksternal, dan 0.45 inter-rater untuk dominant index lesion (DIL) pada parametrik ADC MRI, yang dimana mengungguli U-Net yang mendapatkan akurasi sebesar (0.58) dengan korelasi negatif kuat terhadap Gleason Score $\geq 4+3$. Evaluasi yang dilakukan menggunakan 5-fold CV dan Wilcoxon test $p < 0.05$ yang menunjukkan superioritas pada lesi besar dan zona perifer, walaupun recall yang dihasilkan rendah pada lesi tumor prostat kecil yang diatasi melalui augmentasi pada model, memungkinkan standarisasi untuk dose escalation radioterapi.

Penelitian yang dilakukan oleh [29] memberikan usulan dalam menggunakan framework registrasi enhanced berbasis end-to-end untuk fusi data MRI-TRUS, yang dimana meraih hasil DSC 0.212 yang mendapatkan peningkatan 81.2% dari TRUS-only yang hanya menghasilkan 0.117 dengan model Transformer-based multi-modal menggunakan multi-prametrik MRI(T2, ADC, DWI), dalam mengatasi adanya misalignment spasial dan SNR rendah TRUS yang melewati 52% dari keseluruhan lesi.

2.2 Teori Topik Penelitian

2.2.1 Kanker Prostat

Kanker prostat merupakan salah satu jenis kanker paling umum yang pria di seluruh dunia, dampaknya sangatlah signifikan terhadap kesehatan secara global. Data terbaru menunjukkan, kanker prostat menjadi kanker kedua paling sering didiagnosis pada pria, dengan lebih dari 1,4 juta kasus baru dan 400 ribu mengalami kematian pada tahun 2022 [30]. Kondisi ini berkembang secara perlahan dan hampir tanpa gejala awal yang mencolok, sehingga deteksi dini menjadi kunci utama untuk meningkatkan tingkat kelangsungan hidup pada pria yang terkena kanker prostat ini. Secara biologis, kanker prostat muncul dari sel-sel kelenjar prostat yang mengalami mutasi genetik, menyebabkan pertumbuhan yang tidak normal/abnormal yang dapat menyebar secara cepat ke area lain seperti tulang atau kelenjar getah bening. Faktor-faktor seperti usia, riwayat keluarga, dan gaya hidup

memainkan peran penting dalam perkembangannya, membuatnya menjadi topik penelitian yang terus berkembang untuk dicari solusi pencegahannya dan pengobatannya agar lebih efektif dan akurat. Epidemiologi kanker prostat mendapati pola variasi geografis yang unik, seperti contohnya, kasus lebih tinggi di negara-negara Barat dibandingkan Asia, yang kemungkinan besar dipengaruhi oleh perbedaan pola makan.

Staging kanker prostat merupakan langkah utama dan sangat penting dalam menentukan strategi pengobatan, yang biasanya mengikuti sistem TNM (Tumor, Node, Metastasis) untuk klasifikasi tingkat penyebaran penyakit. Pada stadium I, kanker prostat terbatas pada prostat dan sulit di deteksi melalui pemeriksaan fisik, dengan ukuran tumor kecil yang hanya mempengaruhi satu sisi kelenjar prostat, sering ditemukan secara kebetulan melalui tes PSA (*Prostate-Specific Antigen*) [31]. Stadium II menunjukkan kanker yang masih terdapat di prostat tetapi lebih besar, dibagi menjadi beberapa bagian seperti IIa (kurang dari setengah satu sisi), IIb (lebih dari setengah satu sisi), dan IIc (melibatkan kedua sisi), di mana risiko penyebaran kanker prostat mulai meningkat meskipun prognosis tetap baik dengan intervensi dini. Kemudian, stadium III mulai melibatkan invasi ke jaringan sekitar kelenjar mani atau *vesikula seminalis*, tanpa metastasis jauh, yang memerlukan pendekatan multimodal untuk mengendalikan penyebaran disekitar. Terakhir, stadium IV merujuk kepada metastasis ke kelenjar getah bening jauh atau organ lain seperti misalnya tulang, di mana nantinya pengobatan lebih difokuskan pada perawatan paliatif dan pengendalian gejala daripada penyembuhan total, dengan tingkat kelangsungan hidup lima tahun yang turun drastis menjadi sekitar 30-40% [32].

Salah satu tantangan utama dalam memahami kanker prostat adalah mendeteksi tumor secara akurat dan konsisten, terutama pada lesi yang sering kali tidak terlalu terang atau terlihat jelas pada pencitraan medis seperti MRI. Dalam hal ini, multiparametrik MRI (mpMRI) berperan penting dalam evaluasi morfologi prostat, termasuk pada deteksi lesi klinis yang signifikan (csPCa), penilaian zona transisi

dan zona perifer, perubahan pada volume kelenjar, hingga pemahaman tumor yang sulit dibedakan dari jaringan normal. Namun, pemahaman citra MRI secara manual sangatlah bergantung pada keahlian dari radiolog, bisa memakan waktu yang sangat lama (hingga 30-45 menit per kasus), serta rentan terhadap adanya variabilitas antar pengamat, di mana tingkat kesepakatan inter-observer hanya mencapai 60-70% untuk skor PI-RADS, yang dimana dapat menyebabkan kesalahan diagnosis hingga 20% pada lesi kecil atau heterogen. Selain itu, faktor seperti gerakan pasien dan kualitas gambar yang rendah yang dapat menyebabkan noise atau distorsi, dapat semakin memperburuk akurasi.

Di sisi yang lain, segmentasi gambar MRI, khususnya pada MRI prostat, memainkan peran penting dan sangat krusial dalam meningkatkan kelangsungan hidup dengan memungkinkan deteksi dini dan perencanaan terapi yang lebih presisi dan akurat. Melalui segmentasi otomatis berbasis deep learning, seperti model U-Net, batas tumor dapat dipahami dengan akurasi yang tinggi, mengurangi variabilitas inter-observer hingga 20% dan memfasilitasi biopsi targeted yang menghindari *random sampling* yang sering kali gagal mendeteksi lesi. Tugas segmentasi ini tidak hanya meningkatkan akurasi sensitivitas diagnosis hingga 91% pada stadium awal, tetapi juga mendukung keputusan dalam perencanaan radioterapi dengan menghitung volume tumor secara akurat, yang dapat mengurangi dosis dari radiasi pada jaringan yang sehat dan meminimalisir efek samping seperti kerusakan rektum. Studi menunjukkan bahwa integrasi antara segmentasi dalam workflow klinis dapat meningkatkan tingkat kelangsungan hidup lima tahun hingga 15% pada pasien stadium III dengan pemantauan respons terapi secara real-time, di mana perubahan volume tumor yang terdeteksi memicu penyesuaian pengobatan sebelum metastasis terjadi. Segmentasi memungkinkan adanya pengembangan model prediksi prognosis berbasis AI, yang menggabungkan data imaging dengan faktor klinis untuk stratifikasi risiko personal, sehingga mengoptimalkan alokasi sumber daya kesehatan dan mengurangi beban overtreatment secara keseluruhan.

2.2.2 MRI

Magnetic Resonance Imaging (MRI) telah menjadi alat diagnosa utama dalam mendeteksi kanker prostat, memberikan visualisasi yang detail tanpa adanya radiasi ionisasi yang berbahaya. Teknik ini menggunakan medan magnet yang kuat dan gelombang radio untuk menghasilkan gambar beresolusi tinggi dari jaringan lunak, khususnya prostat, yang dimana sulit dibedakan dengan metode lain seperti USG. Studi menunjukkan bahwa menggunakan MRI mempunyai sensitivitas hingga 91% dalam mendeteksi kanker prostat klinis signifikan (csPCa), terutama pada pasien dengan kadar PSA di zona abu-abu (4-10 ng/mL) [33]. Protokol standar yang ada seperti multiparametrik MRI (mpMRI) menggabungkan antara *T2-weighted* (T2W), *diffusi-weighted imaging* (DWI), dan *dynamic contrast-enhanced* (DCE) untuk meningkatkan akurasi, memungkinkan pemahaman dan identifikasi lesi mencurigakan dengan skor PI-RADS (*Prostate Imaging Reporting and Data System*). Keunggulan pada MRI terletak pada kemampuannya mendeteksi tumor bersifat subklinis, yang dimana sering sekali terlewatkan oleh biopsi acak, sehingga mengurangi prosedur invasif yang tidak perlu.

Tantangan paling utama dari *Magnetic Resonance Imaging* (MRI) adalah biaya tinggi dan waktu pemindaian yang sangat panjang, yang dimana membatasi akses di beberapa negara-negara berkembang, tetapi inovasi-inovasi seperti MRI 3T atau *compressed sensing* berpotensi mengurangi hal ini. Selain deteksi, penggunaan MRI juga berperan penting dalam perencanaan terapi, seperti *focal therapy* atau *brachytherapy*, di mana segmentasi secara akurat pada tumor esensial untuk menghindari kerusakan jaringan yang sehat. Penelitian mengonfirmasi spesifisitas MRI sebesar 37% untuk csPCa, menekankan perlunya integrasi dengan biomarker lain untuk diagnosis yang lebih komprehensif. *Magnetic Resonance Imaging* (MRI) tidak hanya dilihat sebagai alat atau revolusi diagnosis pada kanker prostat, namun juga sebagai pembuka era pengobatan yang bersifat personalisasi, di mana data gambar menjadi keputusan utama klinis yang tepat waktu dan efisien.

2.2.3 Segmentasi

Segmentasi pada gambar medis merupakan proses paling krusial dalam mengisolasi sebuah struktur anatomi atau sebuah patologi dalam gambar pencitraan, seperti MRI prostat, yang memungkinkan analisis kuantitatif dan perencanaan pengobatan yang sangat presisi. Teknik-teknik tradisional seperti misalnya thresholding dan deteksi tepi telah menjadi fondasi utama sejak lama, namun teknik tradisional ini sering kali gagal dalam menangani kompleksitas jaringan lunak yang bersifat heterogen[34]. Dalam konteks penyakit kanker prostat, segmentasi yang akurat pada tumor sangatlah esensial untuk menghitung volume dari lesi, yang berkorelasi dengan stadium Gleason dan prognosis. Segmentasi tidak berhenti hanya digunakan untuk akurasi teknis, namun juga untuk membantu tenaga medis dalam mengurangi waktu anotasi manual, yang sering kali memakan waktu berjam-jam per kasus. Di masa yang akan datang, segmentasi diharapkan menjadi standar dalam melakukan tugas klinis yang dimana intervensi manusia di minimalisir hanya untuk kasus ambigu saja.

2.2.4 Deep Learning

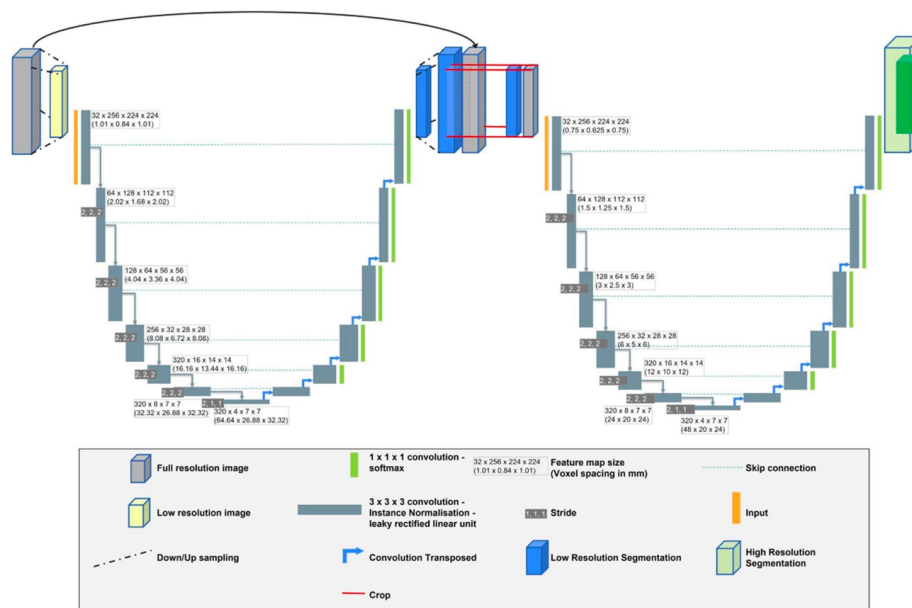
Deep learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis (*layered artificial neural networks*), yang dimana telah merevolusi pandangan segmentasi gambar medis dengan kemampuan ekstraksi fitur otomatis dari data volumetrik yang besar. *Deep Learning* sendiri mengkategorikan metodenya menjadi encoder-decoder, transformer-based model hingga hybrid, yang dimana mempunyai fokus dalam pengaplikasian kepada kasus segmentasi seperti segmentasi tumor otak hingga lesi kulit. Dalam kasus yang menggunakan MRI prostat, penggunaan model deep learning mempunyai keunggulannya sendiri seperti menangani ketidakseimbangan kelas, yang di mana piksel tumor jauh lebih sedikit daripada jaringan normal, yaitu dengan melalui loss function khusus seperti focal loss, yang khusus dirancang untuk meningkatkan sensitivitas terhadap area minoritas / kecil. Keunggulan menggunakan *deep*

learning terletak pada generalisasi lintas dataset, meskipun tetap membutuhkan komputasi yang sangat tinggi dan data anotasi yang berkualitas.

Keunggulan lainnya adalah model mampu belajar representasi hierarkis dari berbagai macam tingkat resolusi, sehingga selalu dapat beradaptasi terhadap berbagai macam kasus atau berbagai macam rumah sakit, protokol pemindaian penyakit hingga vendor scanner. Namun dari segala keunggulannya tersebut, tantangan akan tetap ada seperti kebutuhan komputasi yang tinggi, keterbatasan ahli anotasi dan variasi interpretasi antar-radiolog. Selain keunggulan dan tantangannya, penerapan *deep learning* dalam segmentasi medis sangat membawa dampak yang signifikan bagi *workflow* klinis. Segmentasi secara otomatis dapat membantu tenaga medis mengurangi waktu anotasi manual yang biasanya memakan waktu lama, meningkatkan konsistensi antar-pengamat, serta memberikan informasi yang lebih stabil untuk keperluan diagnosis, pengambilan keputusan pengobatan maupun perencanaan terapi.

2.2.5 3D nnU-Net

3D nnU-Net merupakan framework yang melakukan segmentasi medis berbasis *self-configuring* yang diperkenalkan oleh Isensee pada tahun 2018 sebagai pengembangan dari arsitektur U-Net. Berbeda dengan model deep learning yang konvensional yang membutuhkan penyesuaian manual seperti dataset dan lain-lainnya, nnU-Net dirancang secara otomatis untuk melakukan konfigurasi kepada seluruh pipeline, mulai dari *preprocessing*, arsitektur model, strategi dalam melakukan training hingga *postprocessing* berdasarkan dataset yang disediakan. Framework 3D nnU-Net ini muncul didasarkan pada kebutuhan untuk menyelesaikan tantangan dalam segmentasi medis, dimana dataset yang berbeda-beda pasti mempunyai resolusi, kontras dan ukuran volume yang berbeda – beda, maka dari itu 3D nnU-Net mengkonfigurasi itu semua secara otomatis. Framework varian 3D nnU-Net ini sangat relevan pada data volumetrik seperti MRI prostat karena mampu memahami spasial antar slice secara penuh, sehingga memberikan segmentasi yang lebih konsisten dibandingkan dengan pendekatan 2D.



Gambar 2. 1 Arsitektur nnU-Net[35]

Keunggulan utama yang didapatkan dari 3D nnU-Net adalah kemampuannya dalam beradaptasi dengan dataset baru tanpa memerlukan perubahan secara manual dari peneliti. Sistem yang dimiliki oleh 3D nnU-Net otomatis menentukan ukuran patch, skema normalization, augmentasi yang lebih terukur, jumlah filter hingga kedalaman jaringan yang optimal untuk masing-masing dataset. nnU-Net terbukti menghasilkan performa yang akurat dan telah mencapai state-of-the-art (SOTA) pada berbagai benchmark internasional. Pendekatan menggunakan 3D nnU-Net memberikan konteks spasial yang menyeluruh, sehingga nantinya dapat mendeteksi struktur kecil seperti lesi prostat atau tumor kecil pada PET-CT dengan Dice score yang tinggi. Model nnU-Net sendiri mendukung ensemble learning, multi-stage training, serta patch-based training yang akan lebih efisien pada GPU dengan kapasitas yang terbatas.

Meskipun 3D nnU-Net mempunyai banyak sekali keunggulan, namun tetap saja terdapat sejumlah keterbatasan. Model 3D nnU-Net dalam melakukan proses training dan inference 3D membutuhkan memori dari GPU yang besar, terutama jika volume dari gambar tersebut mempunyai resolusi yang tinggi, sehingga patching harus diterapkan agar memberikan ruang bagi keterbatasan komputasi.

Model 3D nnU-Net ini juga masih ada beberapa kekurangan seperti training yang sepenuhnya otomatis yang membuat peneliti tidak mempunyai fleksibilitas dalam menyesuaikan arsitektur untuk kebutuhan spesifik dan waktu yang dibutuhkan untuk training relatif panjang karena nnU-Net menggunakan strategi dari augmentasi dan optimasi yang efektif.


Dari segala kelebihan dan kekurangannya, model nnU-Net terus dikembangkan melalui varian seperti 3D full-resolution model, mixed 2D and 3D model. Framework nnU-net ini sendiri berhasil dalam melakukan berbagai macam tugas segmentasi seperti misalnya segmentasi pada organ otak dan tumornya, paru, hati hingga tumor prostat dengan heterogenitas yang tinggi. Selain dari segmentasinya yang sangat akurat, ekosistem dari nnU-Net memungkinkan adanya integrasi dengan berbagai macam pendekatan pembelajaran terupdate seperti misalnya *domain adaption*, *transfer learning* hingga *meta learning*, yang diharapkan mempunyai performa stabil ketika diaplikasikan pada dataset lintas yang memiliki variasi yang berbeda dalam protokol pencitraan terutama pada MRI. Kemampuan nnU-Net sendiri sangat baik, dimana dapat dikombinasikan dengan model lain seperti V-Net atau model transformer-based encoder, yang semakin memperluas potensi mendeteksi struktur anatomi yang kompleks hingga lesi / tumor yang berukuran kecil.

2.3 Teori Tools dan library yang digunakan

2.3.1 Jupyter Notebook

Jupyter Notebook adalah lingkungan interaktif yang berbasis web untuk melakukan eksekusi kode modular, visualisasi data dan juga narasi dalam satu dokumen, yang dimana menjadikannya alat utama dalam eksplorasi data science. Jupyter Notebook dikembangkan oleh IPython Notebook yang mendukung kernel *multi-language* seperti Python untuk memfasilitasi workflow dimana antara kode, output dan penjelasan dari codenya di ekspor sebagai format file .ipynb. Pada penelitian sebuah survei, sekitar 40% dari praktisi data science memilih Jupyter Notebook untuk analisis dan pembelajaran mendalam, yang dimana wajar karena kemampuannya menangani iterasi cepat tanpa mengulang kompilasinya. Kelebihan

dari Jupyter Notebook adalah integrasinya dengan ekstensi seperti misalnya nbconvert untuk mengubah ke format PDF dan HTML. Notebook sendiri juga mendukung adanya eksplorasi parameter model seperti tuning hyperparameter U-Net yang membuatnya sangat essential untuk debugging dan dokumentasi evaluasinya.



Gambar 2. 2 Jupyter Notebook

Dalam era cloud yang semakin berkembang, Jupyter Notebook berbasis JupyterHub memungkinkan skalabilitas untuk tim divisi pada institusi yang besar, dengan keamanan autentikasi dari *Lightweight Directory Access Protocol* (LDAP). Notebook juga memfasilitasi pipeline dari data loading, training hingga evaluasi model yang dimana memastikan traceability secara keseluruhan dan Jupyter Notebook merepresentasikan paradigma dari programming yang fleksibel. JupyterLab juga kembali menambah fitur seperti tab multi-file dan terminal yang terintegrasi untuk meningkatkan produktivitas dari eksperimen panjang seperti training model.

2.3.2 Python

Python adalah bahasa pemrograman tingkat tinggi yang sering digunakan dan sering dikenal dengan sintaks sederhana dan ekosistem dari librarynya yang kaya, menjadikannya pilihan bahasa pemrograman untuk mesin pembelajaran dan *scientific computing*. Python sudah mendukung lebih dari 80% proyek mesin pembelajaran dikarenakan fleksibilitasnya dalam handling data yang besar serta integrasinya pada *Application Programming Interface* (API). Dalam konteks medis seperti melakukan segmentasi MRI, Python dapat memungkinkan scripting otomatis untuk pipeline dari model end-to-end, mulai dari import gambar hingga

inferensi model yang dituju. Python sendiri terus dikembangkan karena komunitasnya yang besar dan mendapatkan dukungan yang sangat luas, seperti tools yang ada Python seperti pip untuk dependensi, juga adanya pembaruan pada library-library inti seperti NumPy, PyTorch, TensorFlow, SimpleITK dan scikit-image yang sangat penting dalam pemrosesan citra medis.



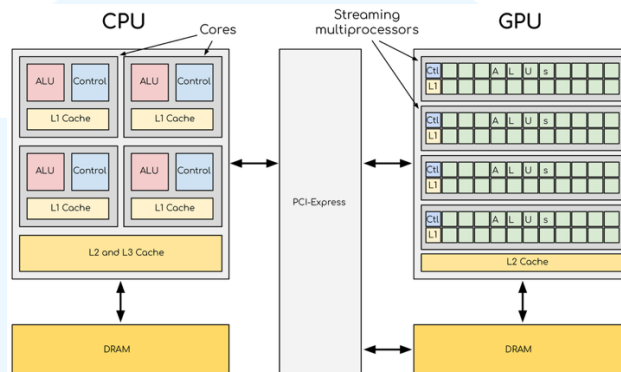
Gambar 2. 3 Python

Python juga mempunyai kompatibilitas yang baik dengan GPU yang dikenal cepat dalam melakukan pemrosesan citra medis yaitu GPU melalui CUDA yang sangat mempercepat proses training model *deep learning* secara signifikan. Package yang sering digunakan seperti pip dan conda juga sangat memudahkan pengelolaan data, sehingga nantinya peneliti dapat membangun lingkungan eksperimen yang konsisten dan akurat. Dalam penelitian medis, bahasa Python tidak hanya digunakan sebagai bahasa pemrograman, namun juga sebagai platform komputasi yang menggabungkan berbagai macam komponen seperti analisis statistik, visualisasi hasil model *deep learning* yang digunakan, rekonstruksi 3D hingga implementasi model algoritma segmentasi yang dimana menjadikannya fondasi utama dalam mengembangkan teknologi di bidang kesehatan.

2.3.3 CUDA

CUDA (*Compute Unified Device Architecture*) adalah platform komputasi dan model pemrograman yang dikembangkan oleh NVIDIA untuk memungkinkan percepatan menggunakan *Graphics Processing Unit* (GPU). CUDA sendiri memberikan akses kepada developer untuk mengakses ribuan core GPU yang dirancang secara paralel, sehingga nantinya tugas komputasi intensif seperti misalnya training model *deep learning* yang terkenal berat dapat diproses secara

jauh lebih cepat dibandingkan dengan CPU. Penggunaan CUDA dalam operasi matematis seperti *Convolutional*, *matrix multiplication* dan *tensor operation* dapat dilakukan secara langsung dan masif, menjadikannya sebagai fondasi utama ketika ingin melakukan percepatan perjalanan algoritma pembelajaran mendalam.



Gambar 2. 4 Perbedaan penggunaan CPU dan GPU

Dalam konteks medis, khususnya pada kasus segmentasi pada gambar MRI, CUDA sangatlah berperan penting dalam mempercepat proses traingin model seperti misalkan 3D nnU-Net, U-Net atau arsitektur deep learning lainnya. Pemrosesan terhadap data volumetrik yang sangat besar seperti 3D MRI sangat membutuhkan komputasi yang intensif, akurat dan cepat, maka dari itu penggunaan dari CPU tidak akan efisien. CUDA sendiri memberikan kernel yang sangat dioptimalkan untuk operasi model deep learning, sehingga yang tadinya membutuhkan hari ke hari untuk training model deep learning, pada saat menggunakan CUDA menjadi hanya beberapa jam saja. Integrasi CUDA dengan framework seperti PyTorch dan TensorFlow juga membuat kemudahan pemindahan komputasi dari CPU ke GPU, yang dimana hanya memindahkan fungsi tensor ke perangkat `cuda()`. CUDA sendiri juga menyediakan *Application Programming Interface* (API) bertingkat rendah yang memungkinkan peneliti mengoptimasi lanjutan dan menyesuaikan proses dari komputasi sesuai dengan kebutuhan eksperimen.

2.3.4 PyTorch Environment

PyTorch Environment merupakan ekosistem dari deep learning yang dikembangkan oleh Meta AI dan komunitas-komunitas open source dan sekarang

menjadi salah satu framework dominan untuk melakukan riset ataupun produksi model berbasis jaringan saraf dalam (*Deep Neural Network*). PyTorch sendiri dikenal sebagai *dynamic computation graph* yang memudahkan peneliti dalam proses debugging, eksperimen arsitektur model baru dan pengembangan model yang kompleks seperti misalnya U-Net, nnU-Net ataupun model 3D lainnya yang digunakan untuk segmentasi medis. Framework PyTorch ini sendiri mengalami peningkatan yang signifikan seperti compiler graph-level yang dapat mengoptimalkan eksekusi dari model dan meningkatkan performa hingga 2x lipat tanpa mengubah arsitektur dari model ataupun kode training, yang dimana ini membuat PyTorch menjadi fondasi utama dalam melakukan tugas komputasi besar seperti segmentasi MRI berbasis 3D.

Dalam melakukan deployment, framework dari PyTorch menyediakan beberapa fitur seperti misalnya TorchServe, yang memungkinkan model yang dikembangkan untuk riset medis dapat diubah menjadi inferensi yang stabil dan siap digunakan untuk workflow klinis. Maka dari itu, penggunaan PyTorch ini sangat relevan dan penting untuk pengembangan sistem segmentasi medis secara otomatis di rumah sakit, dimana model dituntut untuk bekerja secara konsisten di berbagai kasus pasien. PyTorch juga mempunyai beberapa fitur lain yang tidak kalah penting seperti *automatic mixed precision* (AMP) yang membantu mengatasi permasalahan penggunaan memori GPU yang tinggi, sehingga training model menjadi berat, besar dan lambat. Namun, dengan menggunakan fitur tersebut dapat dilakukan secara efisien tanpa mengorbankan akurasi dari model yang dikembangkan.

2.3.5 NumPy

NumPy merupakan library dalam ekosistem Python yang dibuat untuk komputasi yang bersifat numerik performa tinggi. NumPy menyediakan numerik tersebut dalam bentuk struktur array multidimensi yang jauh lebih efisien dibandingkan dengan struktur data native lain dari Python, baik dari sisi kecepatan ataupun penggunaan memorinya. Operasi yang dilakukan oleh NumPy sendiri dimulai dari manipulasi pada array, fungsi statistik, transformasi pada linear hingga

operasi matematika yang kompleks dilakukan melalui *vectorized operations* tanpa menggunakan loop eksplisit sehingga menghasilkan performa yang baik terutama pada data berbentuk MRI 3D. Fitur lain yang dimiliki oleh NumPy adalah broadcasting yang merupakan kemampuan dalam melakukan operasi antar array dengan bentuk yang berbeda tanpa perlu menyalin pada data tambahan, sehingga dapat mempercepat proses normalisasi intensitas, perhitungan voxel-wise pada data MRI dan transformasi geometrik. Dalam kasus segmentasi medis, tugas NumPy sangat penting untuk melakukan penghitungan metrik dasar dari tahapan preprocessing hingga ekstraksi patch 3D sebelum nantinya data dimasukkan ke model *deep learning*.

Dalam melakukan pengembangan model deep learning di semua aspek berbasis PyTorch, NumPy berperan sebagai fondasi utama dalam memanipulasi data sebelum diubah menjadi tensor PyTorch. Konversi ini terdiri antara `numpy.ndarray` dan `torch.Tensor` yang sangat umum digunakan untuk pipeline seperti augmentasi data, cropping 3D hingga penghitungan loss berbasis mask. NumPy juga mempunyai fitur yaitu *masked arrays* untuk menangani data-data yang hilang atau korup dengan melakukan fitur random module untuk simulasi dan augmentasi awal, serta mendukung beberapa macam ekstensi performa seperti CuPy dan integrasi array melalui JAX, yang memungkinkan adanya diferensiasi secara otomatis.

2.3.6 Matplotlib

Matplotlib merupakan salah satu library visualiasi yang paling sering digunakan dalam ekosistem Python, yang dimana dirancang untuk menghasilkan grafik 2D hingga 3D yang bersifat statis, interaktif dan animatif. Matplotlib menyediakan kontrol tingkat yang rendah di hampir seluruh elemen grafis, mulai dari garis, warna, tipe marker hingga letak yang kompleks sekalipun menggunakan subplot, sehingga memungkinkan peneliti dalam membuat sebuah visualisasi yang sepenuhnya dapat disesuaikan dengan kebutuhan. Matplotlib sendiri mendukung berbagai macam *backend* seperti Agg, TkAgg dan Qt, memungkinkan integrasi yang fleksibel dengan penggunaan Jupyter Notebook. Skalabilitas tinggi yang

disediakan oleh Matplotlib dalam mengubah gambar menjadi format PNG, PDF, SVG maupun EPS tetap menjadi standar emas visualisasi pada Python.

Selain melakukan visualisasi dasar yang interaktif, Matplotlib juga mempunyai kompatibilitas yang kuat dengan library-library yang lain seperti NumPy, Pandas, SciPy dan juga PyTorch. Kolaborasi antar library ini dapat membawa pembuatan grafik analisis yang kompleks seperti *statistical plots*, *time-series visualization*, *heatmaps*, *3D surface plots*, hingga visualisasi dalam bentuk animasi yang bisa berubah dari waktu ke waktu. Fitur yang disediakan oleh Matplotlib seperti rcParams mendukung adanya gaya visual untuk beberapa penelitian, seperti *Animation API* yang memudahkan pembuatan video atau GIF dalam merepresentasikan dinamika sebuah proses, seperti mengubah parameter model training. Matplotlib sangatlah cocok sebagai alat visualisasi utama dalam Python karena memberikan informasi yang baik dan dapat digunakan di berbagai bidang seperti fisika, biologi, ekonomi hingga astronomi.

Dalam konteks segmentasi medis berbasis deep learning, Matplotlib sendiri sering digunakan dan memainkan peran penting dalam melakukan eksplorasi data, monitoring hasil dari pelatihan model dan validasi hasil dari segmentasi. Matplotlib dapat memunculkan visualisasi slice MRI beserta *overlay mask* yang digunakan untuk prediksi dan juga memunculkan berbagai macam visualisasi seperti kurva metrik (*Dice Score*, *Intersection Over Union (IOU)*, and *loss*), serta membuat sebuah *line plot* untuk memantau hasil dan stabilitas dari training. Visualisasi yang dimunculkan pada path 3D, distribusi antar intensitas voxel hingga *heatmap* representasi fitur juga dapat lakukan pada library Matplotlib untuk memahami jalannya model selama melakukan proses pengembangan. Matplotlib juga dapat membuat visualisasi yang membantu peneliti dalam membandingkan gambar atau yang sering disebut sebagai grafik komparatif antara gambar asli, *Ground Truth* dan Predicted untuk membantu memastikan kualitas dari model sebelum diterapkan dalam workflow klinis.

2.3.7 Albumentations

Albumentations adalah library yang digunakan untuk melakukan augmentasi pada data yang dirancang untuk memberikan transformasi gambar yang cepat, fleksibel dan berkualitas tinggi dalam proyek penelitian berbasis *computer vision*. Albumentations dibangun dengan fokus untuk kecepatan dan efisiensi, juga memanfaatkan optimasi pada level rendah sehingga mampu melakukan ratusan transformasi data per detik, bahkan gambar yang tergolong besar seperti MRI atau CT volumetrik. Albumentations sangatlah kompatibel dengan berbagai framework deep learning seperti PyTorch, TensorFlow dan Keras, sehingga mudah diintegrasikan ke pipeline training model segmentasi medis yang menggunakan model deep learning. Keunggulan utama dari penggunaan library Albumentations adalah pada kombinasi transformasi geometrik yang kaya, seperti misalkan rotasi, *flipping*, *scaling*, *elastic*, *brightness / contrast shift*, *gaussian noise* hingga *motion blur* sangat berguna dalam melakukan augmentasi data. Pada poengertian medis, transformasi yang dilakukan oleh library Albumentations ini sangat penting untuk mensimulasikan variasi yang nyata antar rumah sakit, mesin mri atau protokol pemindaian. Maka dari itu, melakukan augmentasi yang tepat dapat membuat model menjadi lebih ribust terhadap adanya perubahan intensitas, resolusi dan orientasi anatomi pada pasien.

Dalam konteks segmentasi medis, Albumentations menjadi sangatlah relevan karena mendukung adanya *dual-transform pipeline* yaitu transformasi yang dilakukan secara simultan pada gambar MRI dan mask. Ini memastikan citra MRI akan diterapkan secara langsung pada *ground truth mask*, menjaga adanya alignment spasial yang kritis dalam segmentasi. Fitur *dual-transform pipeline* ini biasanya digunakan pada beberapa arsitektur model deep learning seperti U-Net, 3D U-Net maupun nnU-Net. Selain itu juga Albumentations menawarkan fitur yang tidak kalah penting yaitu *probabilistic augmentation*, yaitu agar setiap transformasi yang dilakukan di eksekusi berdasarkan probabilitas tertentu. Pendekatan ini sangat membantu agar data tidak terkena overfitting dengan cara menghasilkan variasi data yang tidak monoton. Selain itu juga ada beberapa fitur seperti *Compose* untuk

menggabungkan banyak transformasi dalam satu pipeline yang efisien dan ada *randomized augmentation* untuk menghasilkan data yang lebih beragam pada setiap epoch training. Inti dari Albumentations ini adalah untuk meningkatkan variasi data dan membantu model dalam menangani heterogenitas antar pasien, kondisi pencitraan yang berbeda, hingga noise yang sering terjadi pada kasus medis.

2.3.8 PyVista

PyVista merupakan library pada Python yang mempunyai basis VTK (Visualization Toolkit) yang dibuat untuk mempermudah visualisasi dan pemrosesan pada data MRI 3D secara intuitif. PyVista sendiri menyediakan *high-level API* untuk membaca, memodifikasi dan menampilkan objek pada volumetrik maupun permukaan yang bersifat 3D, tanpa harus menangani kompleksitas rendah yang sering terjadi pada VTK. PyVista dapat melakukan rendering ilmiah yang sangat kuat karena termasuk pada *isosurface*, *extraction*, *volume rendering*, *mesh generation* serta memanipulasi objek yang berbentuk 3D secara interaktif.

Dalam konteks segmentasi medis, terutama pada data seperti MRI prostat, library PyVista mempunyai peran penting dalam melakukan proses *postprocessing* dan dalam melakukan visualisasi hasil segmentasi. Dengan menggunakan beberapa fungsi seperti `plot()`, `add_mesh()` atau `volume()`, library PyVista dapat memberikan output seperti *Volume Rendering* MRI 3D untuk melihat struktur anatomi secara holistik, *3D surface mesh* dari mask hasil segmentasi, *Overlay* pada citra asli Mri dan hasil dari prediksi model untuk memudahkan verifikasi segmentasi, dan juga memberikan hasil yang interaktif seperti rotasi, zooming, slicing 3D dan lain-lain.

Kemampuan menggunakan fitur dari library PyVista ini sangat berguna bagi radiolog dan peneliti karena pada intinya mereka ingin mengevaluasi apakah model seperti contohnya 3D nnU-Net benar-benar menangkap penyakit yang dituju dengan benar atau tidak. Dibandingkan dengan visualisasi slice dalam bentuk 2D, menggunakan visualisasi yang berbasis 3D melalui PyVista dapat memberikan pemahaman yang lebih mendalam dan komprehensif tentang bentuk, ukuran dan juga kontinuitas struktur anatomi. Selain melakukan visualisasi, PyVista juga menyediakan berbagai macam fitur yang sangat berguna bagi hasil dari segmentasi

seperti misalnya manipulasi data geometrik, *smoothing*, *decimation*, *cropping*, *thresholding*, hingga operasi dari boolean pada mesh yang memungkinkan peneliti atau radiolog membuat analisis lanjutan pada bentuk tumor. Library PyVista juga kompatibel dengan penggunaan Jupyter Notebook yang dimana mendukung rendering interaktif langsung dan dapat diekspor menjadi gambar 3D yang berkualitas tinggi untuk keperluan laporan dan publikasi ilmiah.

