

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit ginjal merupakan salah satu permasalahan kesehatan yang terus mengalami peningkatan di berbagai negara [1]. Berdasarkan data global, lebih dari 800 juta penduduk dunia mengalami berbagai gangguan ginjal, mulai dari penyakit ginjal kronis hingga kelainan seperti tumor dan kista ginjal [2]. Sebagian besar kelainan ginjal berkembang secara perlahan tanpa gejala yang jelas pada tahap awal, sehingga deteksi dini menjadi faktor penting dalam menentukan keberhasilan diagnosis dan penanganan medis [3]. Salah satu metode pencitraan medis yang banyak digunakan untuk mendeteksi kelainan ginjal adalah Computed Tomography (CT) scan karena mampu menghasilkan citra dengan resolusi tinggi dan detail anatomi yang baik [4].

Di Indonesia, berdasarkan Survei Kesehatan Indonesia (SKI) tahun 2023 [5], prevalensi Penyakit Ginjal Kronis (PGK) berdasarkan diagnosis dokter pada penduduk umur ≥ 15 tahun mencapai 0,18% atau sekitar 1,8 per 1.000 penduduk. Selain itu, proporsi hemodialisis pada penderita PGK mencapai 21,1%. Data ini menunjukkan bahwa PGK masih menjadi permasalahan kesehatan yang memerlukan perhatian, terutama dalam mendukung proses diagnosis dan pemantauan kondisi ginjal secara lebih akurat.

Dalam praktik klinis, proses analisis citra CT scan yang dilakukan secara manual oleh radiolog, sangat lama dan tidak optimal [6]. Segmentasi organ ginjal maupun lesi seperti tumor dan kista dilakukan dengan cara menandai area tertentu pada setiap irisan citra CT scan. Proses tersebut membutuhkan waktu yang cukup lama serta sangat bergantung pada pengalaman dan ketelitian tenaga medis jika dilakukan secara manual [7]. Selain itu, segmentasi manual juga berpotensi menimbulkan variasi hasil antar-pengamat (*inter-observer variability*) [8]. Seiring meningkatnya jumlah data pencitraan medis di rumah sakit, kebutuhan terhadap sistem otomatis untuk membantu analisis citra medis menjadi semakin penting.

Perkembangan teknologi kecerdasan buatan, khususnya *Deep Learning*, telah memberikan kontribusi besar dalam bidang medical image analysis. Salah satu pendekatan yang banyak digunakan adalah semantic segmentation, yaitu proses klasifikasi setiap piksel citra ke dalam kelas tertentu [9]. Pada citra CT ginjal, segmentasi bertujuan untuk memisahkan area ginjal, tumor, dan kista dari latar belakang secara otomatis [10], [11]. Hasil segmentasi yang akurat dapat membantu proses evaluasi ukuran tumor, perhitungan volume lesi, pemantauan perkembangan penyakit, hingga perencanaan tindakan medis seperti operasi maupun terapi ablasi [12].

Salah satu arsitektur Deep Learning yang paling banyak digunakan dalam segmentasi citra medis adalah U-Net [13]. Arsitektur ini diperkenalkan untuk segmentasi citra biomedis dengan struktur encoder-decoder yang simetris dan dilengkapi skip connection untuk mempertahankan informasi spasial pada citra. U-Net memiliki kemampuan yang baik dalam melakukan segmentasi meskipun jumlah data pelatihan relatif terbatas [14]. Oleh karena itu, U-Net masih menjadi dasar dari berbagai pengembangan model segmentasi medis modern.

Seiring berkembangnya penelitian, berbagai modifikasi dilakukan untuk meningkatkan performa U-Net, salah satunya dengan mengganti bagian encoder menggunakan pretrained backbone berbasis Convolutional Neural Network (CNN) [15]. Penggunaan pretrained backbone memungkinkan model mengekstraksi fitur citra secara lebih mendalam dan representatif dibandingkan encoder konvensional. Salah satu arsitektur CNN yang banyak digunakan sebagai backbone adalah DenseNet [16]. DenseNet memiliki karakteristik dense connectivity, yaitu setiap lapisan menerima masukan dari seluruh lapisan sebelumnya sehingga aliran informasi dan gradien menjadi lebih baik [17]. Struktur tersebut mampu mengurangi masalah vanishing gradient serta meningkatkan efisiensi penggunaan parameter model. DenseNet sendiri memiliki beberapa varian, seperti DenseNet121, DenseNet169, dan DenseNet201, yang memiliki kedalaman jaringan berbeda sehingga memungkinkan adanya perbedaan performa dalam proses ekstraksi fitur [18].

Dalam penelitian segmentasi ginjal, tersedia beberapa dataset publik yang dapat digunakan sebagai acuan pengembangan model. Salah satu dataset yang banyak digunakan adalah KiTS23 (Kidney Tumor Segmentation Challenge 2023) [19]. Dataset ini menyediakan citra CT abdomen beserta anotasi segmentasi multi-kelas yang mencakup ginjal, tumor, dan kista. Berbeda dengan segmentasi biner yang hanya membedakan objek dan latar belakang, segmentasi multi-kelas memiliki tingkat kompleksitas yang lebih tinggi karena model harus mampu membedakan beberapa jenis jaringan dengan karakteristik visual yang mirip [20]. Selain itu, area tumor dan kista umumnya memiliki ukuran yang lebih kecil dibandingkan area ginjal dan latar belakang sehingga menyebabkan ketidakseimbangan data (class imbalance) pada proses pelatihan model.

Sebagian besar data CT scan tersimpan dalam bentuk volume tiga dimensi (3D). Namun, penggunaan model segmentasi 3D memerlukan sumber daya komputasi yang besar serta waktu pelatihan yang lebih lama [20]. Oleh karena itu, pendekatan dua dimensi (2D) masih banyak digunakan dalam penelitian akademik karena lebih efisien dan lebih ringan dari sisi komputasi [21]. Dengan mengubah volume CT scan menjadi irisan aksial (*axial slice*), model U-Net 2D tetap mampu mempelajari karakteristik citra medis dengan baik tanpa membutuhkan spesifikasi perangkat keras yang terlalu tinggi [21].

Beberapa penelitian sebelumnya telah menerapkan U-Net untuk segmentasi ginjal pada citra CT scan, namun sebagian besar masih berfokus pada segmentasi biner atau menggunakan backbone CNN standar [22], [23]. Penelitian yang membandingkan beberapa varian DenseNet sebagai backbone U-Net pada segmentasi multi-kelas ginjal menggunakan dataset KiTS23 masih relatif terbatas. Oleh karena itu, penelitian ini dilakukan untuk mengimplementasikan arsitektur U-Net 2D dengan backbone DenseNet121, DenseNet169, dan DenseNet201 dalam segmentasi multi-kelas ginjal pada citra CT scan. Evaluasi performa model dilakukan menggunakan Mean Dice Coefficient dan Dice Coefficient pada setiap kelas segmentasi untuk mengetahui kemampuan masing-masing backbone dalam membedakan area ginjal, tumor, dan kista secara otomatis.

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem segmentasi otomatis berbasis kecerdasan buatan pada bidang radiologi, khususnya untuk analisis citra CT ginjal. Selain itu, hasil penelitian juga diharapkan dapat menjadi referensi bagi penelitian selanjutnya dalam pengembangan model segmentasi medis berbasis *Deep Learning*.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana mengimplementasikan arsitektur U-Net 2D dengan backbone DenseNet pretrained untuk segmentasi multi-class ginjal pada dataset KiTS23?
2. Bagaimana tingkat akurasi segmentasi yang dihasilkan masing-masing DenseNet berdasarkan nilai Mean Dice Coefficient dan Dice Coefficient (DC) pada setiap kelas segmentasi?
3. Bagaimana hasil evaluasi model U-Net dengan backbone DenseNet121, DenseNet169, dan DenseNet201 dalam membedakan area ginjal, tumor, dan kista secara otomatis?

1.3 Batasan Masalah

Agar penelitian ini lebih terarah dan tidak meluas, maka ditetapkan beberapa batasan masalah sebagai berikut:

1. Dataset yang digunakan dalam penelitian ini adalah dataset KiTS23.
2. Data CT scan diproses dalam bentuk citra dua dimensi (2D slice).
3. Arsitektur deep learning yang digunakan adalah 2D U-Net dengan backbone DenseNet121, DenseNet169, dan DenseNet201.
4. Segmentasi dilakukan dalam bentuk multi-kelas yang mencakup Background, Ginjal, Tumor, dan Kista.
5. Evaluasi kinerja model dilakukan menggunakan metrik Mean Dice Coefficient dan Dice Coefficient (DC) untuk setiap kelas segmentasi.

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengimplementasikan arsitektur U-Net 2D dengan backbone DenseNet121, DenseNet169, dan DenseNet201 untuk segmentasi multi-class ginjal pada citra CT scan.
2. Membandingkan performa model berdasarkan kemampuan segmentasi ginjal, tumor, dan kista.
3. Mengevaluasi performa model menggunakan metrik Mean Dice Coefficient dan Dice Coefficient dari setiap kelas segmentasi.

1.4.2 Manfaat Penelitian

Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

Manfaat Akademis

Penelitian ini diharapkan dapat menjadi referensi bagi mahasiswa dan peneliti yang mengembangkan model segmentasi citra medis berbasis deep learning, khususnya pada citra CT scan ginjal. Secara akademis, penelitian ini memberikan kontribusi melalui implementasi dan perbandingan tiga varian backbone DenseNet, yaitu DenseNet121, DenseNet169, dan DenseNet201, pada arsitektur U-Net 2D untuk segmentasi multi-class menggunakan dataset KiTS23.

Manfaat Praktis

Penelitian ini memberikan gambaran mengenai proses pengembangan model segmentasi otomatis pada citra CT scan ginjal, mulai dari konversi data CT scan 3D menjadi citra 2D, penyesuaian mask segmentasi, pelatihan model, hingga evaluasi menggunakan Dice Coefficient dan Mean Dice Coefficient. Hasil penelitian ini dapat membantu memberikan pemahaman mengenai kemampuan model U-Net 2D berbasis DenseNet dalam mengenali area ginjal, tumor, dan kista secara otomatis.

Manfaat Pengembangan

Penelitian ini diharapkan dapat mendukung pengembangan teknologi kecerdasan buatan di bidang radiologi, khususnya dalam segmentasi citra CT scan ginjal. Kontribusi teknologi dari penelitian ini terletak pada evaluasi penggunaan DenseNet121, DenseNet169, dan DenseNet201 sebagai backbone encoder pada U-Net 2D untuk mengetahui backbone yang paling sesuai dalam segmentasi multi-class ginjal. Hasil perbandingan model dapat digunakan sebagai acuan dalam pengembangan sistem segmentasi medis selanjutnya.

1.5 Sistematika Penulisan

Sistematika penulisan skripsi ini disusun sebagai berikut:

Bab I Pendahuluan

Bab ini berisi latar belakang penelitian yang menjelaskan pentingnya segmentasi ginjal pada citra CT scan serta penerapan metode deep learning dalam bidang medis. Selain itu, bab ini memuat rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan skripsi.

Bab II Tinjauan Pustaka

Bab ini membahas teori-teori dan penelitian terdahulu yang relevan dengan penelitian. Materi yang dibahas meliputi konsep dasar citra medis CT scan, anatomi ginjal dan kelainannya (tumor dan kista), *semantic segmentation*, arsitektur U-Net, konsep *Convolutional Neural Network* (CNN), serta penggunaan DenseNet121 sebagai backbone. Selain itu, dijelaskan pula metrik evaluasi segmentasi seperti Dice Coefficient dan MDC, serta gambaran umum dataset KiTS23 yang digunakan dalam penelitian.

Bab III Metodologi Penelitian

Bab ini menjelaskan tahapan penelitian yang dilakukan secara sistematis. Dimulai dari pengumpulan dan pemahaman dataset, proses preprocessing data (konversi citra 3D menjadi 2D, normalisasi, dan pelabelan multi-kelas), perancangan arsitektur U-Net 2D berbasis DenseNet121, proses pelatihan model, hingga metode evaluasi performa. Bab ini juga menjelaskan skema pembagian data, parameter pelatihan, serta alat dan perangkat lunak yang digunakan.

Bab IV Hasil dan Pembahasan

Bab ini menyajikan hasil implementasi model yang telah dilatih. Ditampilkan hasil evaluasi performa model dalam bentuk tabel dan grafik, termasuk nilai Dice Coefficient untuk setiap kelas (ginjal, tumor, dan kista). Selain itu, dilakukan analisis terhadap hasil segmentasi, perbandingan performa antar kelas, serta pembahasan kendala yang muncul selama proses pelatihan dan pengujian.

Bab V Kesimpulan dan Saran

Bab ini berisi kesimpulan dari penelitian berdasarkan hasil yang diperoleh. Selain itu, diberikan saran untuk pengembangan penelitian selanjutnya, seperti penggunaan arsitektur 3D, eksplorasi fungsi loss yang berbeda, atau pengujian pada dataset lain.

