

BAB 1 PENDAHULUAN


1.1. Latar Belakang

Kanker tulang atau yang secara medis dikenal sebagai tumor tulang adalah jenis kanker yang bermula di dalam tulang atau jaringan terkait tulang. Ada dua jenis utama kanker tulang: kanker tulang primer dan kanker tulang sekunder (metastasis) [1]. Kanker tulang primer adalah kanker yang bermula di dalam tulang itu sendiri. Sedangkan kanker tulang sekunder atau metastasis adalah kanker yang berasal dari organ tubuh lain dan kemudian menyebar ke tulang.

Salah satu cara untuk membedakan kanker tulang primer dengan metastasis adalah dengan menghitung *bone scan index* (BSI). BSI sebuah metode yang digunakan dalam pemindaian tulang untuk mengukur jumlah dan sebaran dari lesi atau kerusakan tulang [2], [3], [4]. Metode ini biasanya digunakan dalam pemantauan dan penilaian perkembangan kanker tulang atau metastasis tulang. Prinsip kerja dari BSI adalah membandingkan luas area *hotspot* kanker dengan luas area segmen tulang tertentu [2], [3]. Oleh karena itu, untuk meningkatkan akurasi perhitungan BSI, diperlukan segmentasi semantik citra sidik tulang yang akurat pula.

Segmentasi semantik citra sidik tulang adalah proses mengklasifikasikan setiap piksel dalam citra berdasarkan kategori anatomi tulang tertentu [5]. Dalam penelitian ini, segmentasi akan difokuskan pada 12 segmen utama tulang, seperti yang ditunjukkan pada Gambar 1.1. Kategori segmen yang digunakan meliputi: tengkorak (*skull*), tulang belakang leher (*cervical vertebrae*), tulang belakang dada (*thoracic vertebrae*), tulang belakang pinggang (*lumbar vertebrae*), tulang kelangkang (*sacrum*), panggul (*pelvis*), tulang rusuk (*ribs*), tulang belikat (*scapula*), tulang lengan atas (*humerus*), tulang paha (*femur*), tulang dada (*sternum*), dan tulang selangka (*clavicle*) [6].

Untuk mendapatkan akurasi segmentasi semantik yang tinggi, diperlukan sejumlah besar data pelatihan yang telah dianotasi ke dalam 12 segmen. Kelemahan proses anotasi manual yaitu memerlukan waktu yang sangat lama serta ketelitian yang tinggi untuk memastikan akurasi anotasi [7].



Gambar 1.1. Citra Sidik Tulang yang Telah Dianotasi Anterior (Kiri) dan Posterior (Kanan).

Ada beberapa solusi yang dapat digunakan untuk mengatasi masalah kekurangan data anotasi untuk pelatihan diantaranya adalah augmentasi, *transfer learning*, dan *pseudo-labeling* [8], [9], [10].

Augmentasi adalah teknik yang digunakan untuk meningkatkan jumlah dan variasi data pelatihan tanpa perlu mengumpulkan sampel baru [8]. Teknik ini dapat dilakukan pada citra medis, di mana pengumpulan dataset sulit dilakukan karena masalah privasi dan biaya pelabelan yang tinggi [8]. Augmentasi umumnya dilakukan dengan cara mentransformasi citra seperti *flipping*, *rotation*, *scaling*, *translation*, dan *shearing*. Augmentasi kurang cocok untuk penelitian ini karena proses anotasi dilakukan secara acak untuk setiap citra sidik tulang dan *mask*, sehingga menyebabkan ketidaksesuaian antara *mask* dan citra.

Transfer learning adalah konsep yang diambil dari dari penelitian kognitif yang menggunakan konsep bahwa pengetahuan dapat ditransfer antar tugas yang saling berhubungan untuk meningkatkan performa dalam tugas baru [9]. Teknik ini sangat berguna dalam situasi di mana jumlah data berlabel terbatas, seperti dalam citra medis [9]. Namun *transfer learning* tidak dapat digunakan karena belum ada *model pretrained* untuk mensegmentasikan citra sidik tulang ke dalam 12 segmen.

Maka dari itu penulis mengusulkan untuk menggunakan metode *pseudo-labeling*. Metode ini memungkinkan model untuk memanfaatkan data tidak berlabel dengan cara memprediksi label *pseudo* (sementara) untuk citra tersebut [10]. Prediksi ini kemudian digunakan sebagai data tambahan untuk melatih ulang model. Dengan demikian, data yang awalnya tidak berlabel memberikan kontribusi tambahan dalam pelatihan model.

Segmentasi semantik telah digunakan dalam berbagai penelitian, seperti pada penelitian [7] dengan menerapkan U-Net. Hasil penelitian tersebut menunjukkan bahwa U-Net memberikan performa yang baik pada *pixel accuracy*, namun belum mampu bersaing dengan model-model CNN terbaru seperti U-Net++, DeeplabV3+, Double U-Net, dan Mask R-CNN [11].

Dalam studi serupa terkait segmentasi tulang [12], model-model terbaru seperti Double U-Net, DeeplabV3+, dan Mask R-CNN menunjukkan performa yang sangat baik. Namun, pada penelitian [11] yang menggunakan dataset citra *colonoscopy*, *skin lesions*, dan *nuclei images* menunjukkan bahwa model-model tersebut memerlukan resource komputasi yang lebih tinggi dibandingkan dengan U-Net++.

Penelitian lain, yaitu penelitian [13] yang membandingkan performa U-Net++ dan Double U-Net dengan menggunakan dataset citra *polyp*, *skin lesions*, dan *nuclei images*, menunjukkan bahwa performa segmentasi U-Net++ mampu menyaingi Double U-Net. Bahkan, U-Net++ menunjukkan keunggulan dalam hal efisiensi komputasi dibandingkan Double U-Net.

Berdasarkan hasil-hasil tersebut, penelitian ini memilih U-Net++ [14] sebagai model utama untuk proses *training*, karena menawarkan keseimbangan antara performa yang kompetitif dan efisiensi *resource* komputasi.

nnU-Net merupakan salah satu metode segmentasi berbasis *deep learning* terbaru yang menunjukkan kinerja luar biasa dalam berbagai tugas segmentasi medis [15]. Keunggulan utama nnU-Net terletak pada kemampuannya untuk secara otomatis menyesuaikan diri dengan dataset baru tanpa memerlukan intervensi manual [15]. Hal ini memungkinkan nnU-Net untuk memberikan hasil segmentasi yang sangat akurat, bahkan tanpa perlu pengaturan khusus dari pengguna [15].

Meskipun nnU-Net adalah metode yang sangat canggih dan otomatis dalam mengonfigurasi *pipeline* segmentasinya, ada beberapa alasan mengapa U-Net++ dipilih dalam penelitian ini. U-Net++ menawarkan arsitektur yang lebih sederhana dan lebih mudah diatur, terutama jika peneliti ingin memiliki kontrol lebih besar atas konfigurasi model dan eksperimen. U-Net++ memiliki desain berbasis jaringan *encoder-decoder* dengan *skip connection* tambahan yang lebih dalam, memungkinkan model untuk menangani informasi spasial lebih baik dan menghasilkan segmentasi yang lebih akurat, terutama pada citra medis yang kompleks.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, masalah dalam penelitian ini dirumuskan sebagai berikut:

1. Bagaimana membangun model segmentasi semantik dengan algoritma U-Net++?
2. Bagaimana perbandingan performa model U-Net++ dengan tambahan data *pseudo-label* dan tanpa menggunakan *data pseudo-label*?

Perbandingan performa model dengan dan tanpa menggunakan data *pseudo-label* sangat penting untuk dianalisis. Tujuannya untuk menilai sejauh mana teknik *pseudo-labeling* dapat mengatasi keterbatasan data berlabel, yang

sering kali menjadi tantangan dalam penelitian, terutama pada data medis di mana proses pelabelan memerlukan biaya dan waktu yang besar.

1.3. Tujuan dan Manfaat

Tujuan dari penelitian ini adalah untuk membangun model segmentasi semantik dengan U-Net++ dan membandingkan performansi model U-Net++ yang dilatih tanpa dan dengan tambahan data *pseudo-label*. Metode *pseudo-labeling* memungkinkan penggunaan data tanpa label dengan memanfaatkan prediksi awal model sebagai label sementara (*pseudo-label*), sehingga memperbanyak dataset pelatihan tanpa perlu proses anotasi manual yang memakan waktu dan sumber daya. Dalam penelitian ini, model U-Net++ digunakan untuk membangun model segmentasi semantik, dan performa model akan dibandingkan antara kondisi dengan penggunaan data *pseudo-label* dan tanpa *pseudo-label*. Evaluasi akan mencakup analisis akurasi segmentasi dengan *dice score* dan ketepatan identifikasi segmen tulang. Dengan pendekatan ini, diharapkan penelitian ini dapat memberikan wawasan mendalam tentang manfaat *pseudo-labeling*, dalam mengatasi keterbatasan data berlabel, khususnya dalam domain citra medis yang sering terkendala oleh privasi dan ketersediaan data. Selain itu, penelitian ini juga diharapkan dapat berkontribusi pada perhitungan BSI yang lebih presisi dan andal dalam diagnosis serta pemantauan kanker tulang.

1.4. Batasan Masalah

Batasan dalam penelitian ini terletak pada penggunaan citra SPECT (*Single Photon Emission Computed Tomography*) atau sidik tulang dalam format dua dimensi. Hal ini dikarenakan, pada umumnya, citra SPECT dihasilkan dalam bentuk tiga dimensi untuk memberikan informasi yang lebih mendetail mengenai distribusi radionuklida dalam tubuh [16]. Penggunaan citra dua dimensi dalam penelitian ini dapat mempengaruhi tingkat akurasi dan kedalaman analisis yang diperoleh dibandingkan dengan citra tiga dimensi. Namun, keterbatasan ini tetap memungkinkan dilakukan evaluasi terhadap

karakteristik citra yang digunakan, meskipun dengan cakupan informasi yang lebih terbatas dibandingkan dengan citra SPECT tiga dimensi.

1.5. Metode Penelitian

Metode penelitian yang dilakukan dalam penelitian ini antara lain adalah sebagai berikut:

1. Studi Literatur

Pada tahap ini, dilakukan peninjauan terhadap berbagai penelitian, jurnal, dan literatur yang relevan dengan topik segmentasi semantik citra tulang dan metode *pseudo-labeling*. Studi literatur ini bertujuan untuk memahami metode yang telah digunakan sebelumnya, kelebihan dan kekurangannya, serta bagaimana penelitian ini dapat memberikan kontribusi baru.

2. Persiapan Data

Tahap ini mencakup pengumpulan dan anotasi dataset citra yang akan digunakan dalam pelatihan model. Dataset citra sidik tulang yang digunakan dalam penelitian ini adalah BS-80K, yang didapatkan dari 3.248 pasien dari *West China Hospital*. Sebanyak 500 citra sidik tulang tersebut dianotasi secara manual untuk dijadikan data *train*, *validation*, dan *test*.

3. Pembangunan Model

Setelah dataset siap, model segmentasi semantik mulai dibangun menggunakan algoritma U-Net++. Model ini akan dilatih dengan pendekatan *pseudo-labeling*, di mana data tanpa label akan diberikan label sementara berdasarkan prediksi model.

4. Implementasi Skenario Pengujian

Setelah model dikembangkan, dilakukan berbagai skenario pengujian untuk mengevaluasi performanya. Pengujian ini mencakup validasi model menggunakan metrik evaluasi *dice score* untuk mengukur sejauh mana model dapat mengenali struktur tulang dengan benar.

5. Analisis Hasil Pengujian

Hasil pengujian yang diperoleh dianalisis untuk memahami efektivitas *pseudo-labeling* dalam meningkatkan akurasi segmentasi. Analisis ini melibatkan perbandingan dengan model tanpa *pseudo-labeling*, guna menentukan sejauh mana peningkatan yang diberikan oleh pendekatan ini.

6. Penulisan Laporan

Terakhir, setiap kegiatan yang dilakukan pada penelitian ini akan di dokumentasikan ke dalam bentuk laporan yang dapat digunakan oleh peneliti selanjutnya agar dapat dikembangkan.

1.6. Jadwal Pelaksanaan

Tabel 1.1. Jadwal Pelaksanaan Tugas Akhir.

No.	Deskripsi Tahapan	Bulan 1	Bulan 2	Bulan 3	Bulan 4	Bulan 5	Bulan 6
1	Studi Literatur						
2	Pengumpulan Data						
3	Perancangan Model						
4	Implementasi Skenario Pengujian						
5	Analisis Hasil Pengujian						
6	Penyusunan Laporan/Buku TA						