

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

*Attention Deficit Hyperactivity Disorder* (ADHD) adalah penyakit *neuropsikiatrik* yang biasanya muncul pada masa anak-anak dan ditandai oleh hiperaktivitas, peningkatan impulsivitas, serta inatensi yang tidak sesuai dengan tahap perkembangan dengan keterdataan global diperkirakan sekitar 5–10% pada anak-anak dan 2–5% pada orang dewasa [1]. Gejala ADHD seringkali berlanjut hingga dewasa pada dua pertiga kasus jika tidak mendapatkan penanganan yang tepat, sehingga berdampak negatif pada fungsi sosial, kognitif, dan pendidikan [2]. Berdasarkan klasifikasi *Diagnostic and Statistical Manual of Mental Disorders, Edisi Kelima (DSM-5)*, ADHD dibagi menjadi tiga, yaitu dominan inatensi (*ADHD-I*) yang ditandai dengan kesulitan mengatur waktu, mengelola tugas, dan menyelesaikan pekerjaan [3], dominan hiperaktif/impulsif (*ADHD-H*) dengan gejala utama berupa perilaku hiperaktif dan impulsif, serta (*ADHD-C*) yang merupakan kombinasi dari keduanya [4].

Meskipun gejala dapat berkurang seiring waktu, dampak ADHD tetap signifikan. Gangguan ini dapat menyebabkan berbagai masalah, termasuk kesulitan ekonomi, masalah interpersonal, hambatan akademis, kenakalan, dan risiko cedera [1]. Laporan dari Organisasi Kesehatan Dunia (*WHO*) menunjukkan bahwa prevalensi ADHD pada orang dewasa rata-rata adalah 2.8% [5]. Data ini menyoroti perlunya perhatian lebih, terutama karena banyak kasus pada orang dewasa yang tidak terdiagnosis dan tidak menerima perawatan yang memadai [4]. Diagnosis dini dan akurat sangat penting untuk memastikan individu yang terkena mendapatkan dukungan yang sesuai dan meningkatkan kualitas hidup mereka [6].

Diagnosis klinis ADHD seringkali bersifat subjektif dan bervariasi tergantung pada metode yang digunakan [6]. Hal ini mendorong pencarian metode diagnostik yang lebih baik dan akurat. Salah satu pendekatan yang terpercaya adalah menggunakan pencitraan otak, seperti *Magnetic Resonance Imaging (MRI)*, untuk mengidentifikasi biomarker antara individu ADHD dan kontrol sehat [7]. MRI berfungsi sebagai metode non-invasif yang memiliki resolusi tinggi untuk

menunjukkan kelainan pada otak pasien ADHD, serta memberikan informasi yang objektif untuk evaluasi psikiatri klinis [2]

*Magnetic Resonance Imaging (MRI)* memiliki peran penting dalam penelitian dan diagnosis gangguan neuropsikiatri, termasuk *Attention Deficit Hyperactivity Disorder (ADHD)*. Sejumlah studi menunjukkan bahwa ADHD berkaitan dengan perubahan struktur otak, seperti volume materi abu-abu, ketebalan *kortikal*, serta integritas materi putih, khususnya pada area yang berhubungan dengan perhatian, kontrol impuls, dan fungsi eksekutif [8]. Dengan kemampuan pencitraan yang non-invasif dan kontras jaringan lunak yang tinggi, MRI telah menjadi alat diagnostik yang sangat andal untuk mengungkap biomarker potensial pada ADHD, meskipun masih menghadapi kendala seperti lamanya waktu akuisisi dan kebutuhan resolusi tinggi untuk akurasi diagnosis [9]. Selain pencitraan struktural, *functional MRI (fMRI)* juga banyak dimanfaatkan untuk menganalisis aktivitas otak dan konektivitas fungsional, yang terbukti relevan dalam mendeteksi pola neurobiologis [10]. Dengan demikian, MRI, baik struktural maupun fungsional, memberikan kontribusi besar dalam upaya menuju diagnosis ADHD yang lebih objektif dan berbasis biomarker.

Salah satu pendekatan yang banyak digunakan dalam analisis citra medis, termasuk MRI, adalah *Deep Learning*, yaitu cabang dari *machine learning* yang meniru cara kerja otak manusia melalui jaringan saraf tiruan (*artificial neural networks*). Teknologi ini mampu mengekstraksi pola dan fitur penting secara otomatis dari data dalam jumlah besar tanpa perlu rekayasa fitur manual. Dalam bidang citra medis, *Deep Learning* terbukti unggul dalam mengenali pola kompleks dan telah banyak diaplikasikan pada berbagai *tissue* pencitraan medis, termasuk *MRI*, untuk keperluan klasifikasi maupun Segmentasi [11]. Salah satu model *Deep Learning* yang banyak digunakan pada data medis tiga dimensi adalah *MedicalNet*, yaitu kumpulan model *3D ResNet* yang telah dilatih sebelumnya (*pre-trained*) pada berbagai dataset medis. *MedicalNet* memungkinkan proses transfer learning yang lebih efektif karena model sudah memiliki pengetahuan awal mengenai struktur anatomi dari data medis, sehingga meningkatkan akurasi dan efisiensi pelatihan pada dataset dengan ukuran terbatas [12]

Dari penelitian yang dilakukan oleh Huang dkk. mengembangkan strategi untuk meningkatkan model *Deep Learning* dalam klasifikasi penyakit *Alzheimer* (AD). Pada penelitian ini digunakan data *MRI* dari *Alzheimer's Disease Neuroimaging Initiative* (ADNI) untuk membedakan pasien AD dengan subjek kognitif normal. Salah satu model yang digunakan adalah *MedicalNet*, yaitu model berbasis *3D ResNet* yang telah dipra-latih pada dataset *Medical Decathlon* yang mencakup berbagai jenis penyakit dan *tissue* pencitraan medis. Hasil penelitian menunjukkan bahwa *fine-tuning MedicalNet* dengan data *MRI* ADNI mampu meningkatkan fokus model pada area otak yang relevan secara klinis dengan patologi AD, sehingga membantu meningkatkan interpretabilitas serta generalisasi model dalam mendeteksi biomarker *Alzheimer* [13]

Meskipun pencitraan *sMRI* (struktural *MRI*) telah digunakan secara luas, analisisnya seringkali hanya berfokus pada volume otak secara keseluruhan atau satu *tissue* tertentu [14]. Padahal, otak terdiri dari berbagai jaringan yang memiliki peran dan karakteristik unik. Materi Abu-abu (*Gray Matter/GM*) terdiri dari badan sel saraf dan sinapsis yang bertanggung jawab untuk memproses informasi. Materi Putih (*White Matter/WM*) terdiri dari akson saraf yang berfungsi sebagai jalur komunikasi antar area otak[15]. Sementara itu, Cairan Serebrospinal (*Cerebrospinal Fluid/CSF*) memiliki peran vital dalam melindungi dan mendukung otak [16].

Beberapa penelitian menunjukkan bahwa kelainan pada ADHD tidak hanya terbatas pada satu jenis jaringan[17]. Perubahan volume Materi Abu-abu di area seperti korteks *prefrontal* dikaitkan dengan fungsi eksekutif yang buruk (fungsi eksekutif adalah kemampuan mengelola dan mengendalikan perilaku)[18]. Sementara itu, kelainan pada Materi Putih dapat mengganggu konektivitas antar area otak yang vital [19]. Oleh karena itu, pendekatan *multi-tissue* yang menganalisis *GM*, *WM*, dan *CSF* secara terpisah namun bersamaan dapat memberikan gambaran yang lebih komprehensif dan akurat mengenai patologi ADHD dibandingkan dengan hanya menggunakan satu *tissue* saja. Analisis terhadap setiap *tissue* dapat mengungkap biomarker unik yang mungkin terlewatkan jika data diproses secara gabungan.

Salah satu tantangan dalam klasifikasi citra medis adalah mencapai akurasi yang tinggi dan dapat diandalkan. Model *Deep Learning* sering kali rentan terhadap kesalahan prediksi. Untuk mengatasi hal ini, pendekatan *Majority Voting* dapat diterapkan. Strategi ini menggabungkan hasil prediksi dari beberapa model *Deep Learning* yang dilatih pada *tissue* berbeda (misalnya, satu model dilatih untuk *GM*, satu untuk *WM*, dan satu untuk *CSF*). Prediksi akhir ditentukan berdasarkan mayoritas suara dari hasil setiap model. Contohnya, jika dua dari tiga model memprediksi "ADHD", maka prediksi akhir adalah "ADHD".

Pendekatan ini memiliki beberapa keuntungan. Pertama, ia dapat mengurangi bias dan error yang mungkin terjadi pada satu model. Kedua, dengan mengintegrasikan informasi dari sumber data yang berbeda (*GM*, *WM*, *CSF*), *Majority Voting* memanfaatkan keunggulan unik dari setiap *tissue*, sehingga menghasilkan keputusan klasifikasi yang lebih kuat. Strategi ini telah terbukti efektif dalam berbagai aplikasi *machine learning* dan *Deep Learning* untuk meningkatkan akurasi klasifikasi secara signifikan [20].

Penelitian terdahulu yang menggunakan *MedicalNet* telah menunjukkan keberhasilannya dalam mengidentifikasi penyakit saraf [13]. Namun, belum ada penelitian yang secara spesifik mengkombinasikan keunggulan *MedicalNet* dengan pendekatan *multi-tissue* dan *majority voting* untuk klasifikasi ADHD. Dengan demikian, penelitian ini bertujuan untuk mengembangkan model yang tidak hanya efisien dan akurat, tetapi juga memanfaatkan kekayaan informasi dari berbagai *tissue* otak (*GM*, *WM*, *CSF*). Melalui pendekatan *majority voting*, diharapkan model ini dapat mencapai akurasi yang lebih tinggi dan memberikan kontribusi signifikan dalam upaya diagnosis ADHD yang lebih objektif dan terpercaya.

## **1.2 Rumusan Masalah**

### **1.2.1. Permasalahan**

*Diagnosis Attention Deficit Hyperactivity Disorder* (ADHD) secara konvensional sangat bergantung pada observasi klinis dan wawancara. Pendekatan ini rentan terhadap subjektivitas dan berpotensi menyebabkan kesalahan diagnosis, baik berupa diagnosis yang terlewat maupun diagnosis positif palsu. Untuk mengatasi keterbatasan ini, teknologi pencitraan otak seperti *Magnetic Resonance Imaging* (MRI) menawarkan keunggulan dalam menemukan tanda-tanda biologis

(*biomarker*) yang spesifik untuk ADHD. Namun, tantangan muncul dalam analisis manual data MRI yang rumit dan bervolume besar, karena membutuhkan tenaga, waktu, serta keahlian khusus dari radiolog. Hal ini membuka risiko terjadinya kesalahan manusia (*human error*).

### 1.2.2. Solusi Permasalahan

Penelitian ini mengusulkan pengembangan *Deep Learning* untuk klasifikasi ADHD dengan memanfaatkan *transfer learning* dari arsitektur *MedicalNet* yang telah dilatih pada berbagai dataset medis. Selain itu, penelitian ini akan mengintegrasikan informasi dari berbagai *tissue* citra sMRI, yaitu materi abu-abu (*GM*), materi putih (*WM*), dan cairan *serebrospinal* (*CSF*), yang masing-masing menyimpan informasi unik mengenai patologi otak. Untuk menggabungkan hasil dari setiap *tissue*, pendekatan *Majority Voting* akan diterapkan untuk mengintegrasikan prediksi dari setiap model, sehingga diharapkan menghasilkan keputusan klasifikasi akhir yang lebih kuat.

### 1.2.3. Pertanyaan Penelitian

1. Apakah penggunaan pendekatan *multi-tissue* yang memanfaatkan Segmentasi *White Matter (WM)*, *Gray Matter (GM)*, dan *Cerebrospinal Fluid (CSF)* serta penggabungan hasil prediksi melalui *majority voting* dapat meningkatkan akurasi klasifikasi ADHD dibandingkan dengan model *MedicalNet* tunggal tanpa Segmentasi *tissue*?
2. Bagaimana perbedaan performa antara model *MedicalNet* berbasis *multi-tissue* dan model *MedicalNet* Non-Segmentasi dalam hal metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*?

## 1.3 Batasan Masalah

Terdapat batasan masalah dalam penelitian ini:

1. Metode yang digunakan adalah *transfer learning* dengan arsitektur *MedicalNet* yang dimodifikasi untuk klasifikasi.
2. Data yang digunakan dalam penelitian ini berasal dari dataset publik ADHD-200 yang dikelola oleh *International Neuroimaging Data-Sharing Initiative* (INDI) : [https://fcon\\_1000.projects.nitrc.org/indi/adhd200/](https://fcon_1000.projects.nitrc.org/indi/adhd200/)[21].

3. Data yang digunakan memiliki total 946 citra *Structural Magnetic Resonance Imaging (sMRI)* yang mencakup dua kelompok yaitu pasien dengan perkembangan normal (*Typical Development Child/TDC*) dan pasien dengan *Attention Deficit Hyperactivity Disorder (ADHD)* .
4. Setiap citra data memiliki format *NIFTI (\*.nii.gz)* dengan rata-rata resolusi  $176 \times 256$  dan 256 slice. Untuk memisahkan komponen otak, citra ini telah diSegmentasi menggunakan *SynthStrip* menjadi tiga *tissue* utama: Materi Abu-abu (*Gray Matter*), Materi Putih (*White Matter*), dan Cairan Serebrospinal (*Cerebrospinal Fluid*).
5. Teknik penggabungan prediksi dilakukan dengan *majority voting*, di mana hasil klasifikasi dari masing-masing *tissue (GM, WM, CSF)* digabung untuk menentukan hasil akhir.
6. Fokus penelitian ini pada citra *sMRI*, sehingga aspek lain seperti *fMRI, DTI*, atau data klinis (usia, IQ, skor perilaku) tidak digunakan.
7. Evaluasi kinerja model dibatasi pada metrik klasifikasi seperti akurasi, presisi, *recall*, dan *F1-score*.

## 1.4 Tujuan dan Manfaat

### 1.4.1. Tujuan

Tujuan utama dari penelitian ini adalah untuk membangun dan mengevaluasi model klasifikasi ADHD yang memanfaatkan *transfer learning* dari arsitektur *MedicalNet* pada data sMRI otak *multi-tissue*. Penelitian ini juga bertujuan untuk membandingkan performa model yang menggabungkan hasil klasifikasi akhir menggunakan metode *majority voting* dengan model yang dilatih pada citra MRI tanpa Segmentasi jaringan otak untuk membuktikan pengaruh pemisahan jaringan otak (*Gray Matter, White Matter, dan Cerebrospinal Fluid*) terhadap peningkatan akurasi sistem klasifikasi.

### 1.4.2. Manfaat

Penelitian ini memiliki manfaat sebagai berikut :

1. Menyediakan alat bantu diagnosis yang lebih objektif dan akurat untuk mendeteksi ADHD dari citra MRI, membantu tenaga medis dalam pengambilan keputusan klinis.

2. Menawarkan wawasan baru mengenai efektivitas kombinasi *transfer learning*, analisis *multi-tissue*, dan *majority voting* dalam tugas klasifikasi penyakit saraf, khususnya ADHD.
3. Menjadi referensi bagi peneliti lain yang tertarik dalam aplikasi *Deep Learning* untuk analisis citra medis, khususnya pada kasus dengan keterbatasan dataset.

### **1.5 Sistematika Penulisan**

Berikut merupakan sistematika penulisan dari proposal skripsi pada penelitian ini sebagai berikut :

## **BAB I PENDAHULUAN**

Bab ini berisi latar belakang yang menjelaskan urgensi penelitian, perumusan masalah, batasan masalah, tujuan, dan manfaat yang diharapkan, serta sistematika penulisan.

## **BAB II KAJIAN PUSTAKA**

Bab ini memuat tinjauan literatur dari penelitian-penelitian terdahulu yang relevan dan landasan teori yang mendukung metodologi penelitian, seperti teori terkait ADHD, pencitraan *MRI*, *Deep Learning*, *transfer learning*, *arsitektur MedicalNet*, dan *majority voting*.

## **BAB III METODE PENELITIAN**

Bab ini menguraikan secara sistematis dan terstruktur metode penelitian yang digunakan dalam studi ini. Pembahasan diawali dengan penjelasan mengenai sumber dan proses pengumpulan data, kemudian dilanjutkan dengan tahapan pra-pemrosesan data yang meliputi proses penyiapan dan transformasi citra sebelum dianalisis. Selanjutnya, dijelaskan perancangan arsitektur model yang diusulkan beserta mekanisme pembelajaran yang diterapkan, termasuk skema pelatihan dan strategi penggabungan hasil model. Bab ini juga memaparkan metode pengujian serta prosedur evaluasi yang digunakan untuk menilai kinerja sistem secara objektif dan terukur.

## **BAB IV HASIL DAN PEMBAHASAN**

Bab ini akan menyajikan hasil dari implementasi model serta seluruh rangkaian eksperimen yang telah dilakukan secara sistematis guna menjawab permasalahan penelitian yang telah dirumuskan. Pembahasan diawali dengan pemaparan mengenai Lingkungan Uji Coba, yang merinci konfigurasi perangkat keras (hardware) dan perangkat lunak (software) yang digunakan untuk memastikan proses komputasi serta replikasi penelitian dapat berjalan dengan standar yang baik. Selanjutnya pada bagian Hasil Uji Coba dijelaskan mendalam mengenai proses pelatihan dan validasi model yang dibagi ke dalam dua skenario utama yang meliputi Skenario 1 mengevaluasi performa model Deep Learning berbasis arsitektur MedicalNet pada jaringan otak yang terfragmentasi (White Matter, Gray Matter, dan Cerebrospinal Fluid), sementara Skenario 2 menguji performa model menggunakan citra MRI utuh (*Whole Brain*). Bab ini juga mendemonstrasikan Deployment Model ke dalam antarmuka berbasis web sebagai implementasi praktis dari sistem yang dibangun. Terakhir, dilakukan Analisis Hasil secara menyeluruh untuk membandingkan performa antar skenario berdasarkan metrik akurasi, presisi, recall, dan f1-score, serta menguji efektivitas mekanisme majority voting dalam menentukan hasil klasifikasi akhir yang paling optimal.

## **BAB V PENUTUP**

Bab ini merupakan bagian penutup yang akan menyajikan kesimpulan dari seluruh rangkaian penelitian yang telah dilaksanakan guna menjawab rumusan masalah dan tujuan penelitian yang telah ditetapkan. Bagian ini akan menguraikan hasil perbandingan performa dari 2 skenario uji coba untuk menentukan efektivitas penggunaan arsitektur MedicalNet dan strategi majority voting dalam proses klasifikasi ADHD. Selain itu, bab ini juga akan memuat saran-saran yang ditujukan bagi peneliti selanjutnya maupun pihak terkait, seperti pengembangan dataset, eksplorasi teknologi Deep Learning terbaru, serta optimalisasi metode pra-pemrosesan citra guna penyempurnaan sistem deteksi ADHD di masa mendatang.