

BAB 1

PENDAHULUAN

1.1 Latar Belakang Masalah

Otak merupakan salah satu organ paling penting dalam tubuh manusia. Sebagai pusat sistem saraf, otak bukan hanya memproses informasi dan membentuk perilaku, tetapi juga mengatur dan mengkoordinasikan banyak proses di dalam tubuh. Lewat jaringan saraf, otak menghubungkan kerja antar organ supaya fungsi tubuh tetap stabil dan tubuh bisa menyesuaikan diri dengan perubahan lingkungan maupun kondisi internal [1].

Kesehatan otak harus dijaga, apabila kesehatan otak tidak dipelihara dengan baik, maka gangguan pada otak dapat berdampak serius bagi tubuh. Berbagai gangguan otak dan sistem saraf disebut sebagai salah satu penyebab utama kematian dan kecacatan [2]. Gangguan ini juga dapat mengganggu fungsi kognitif, sensorik, dan motorik, sehingga aktivitas sehari-hari menjadi lebih sulit [3]. Secara global pada tahun 2021, gangguan sistem saraf memengaruhi sekitar 3,40 miliar orang dan menyumbang sekitar 443 juta DALYs (*Disability Adjusted Life Year*). Angka total DALYs ini juga meningkat sekitar 18,2% sejak tahun 1990 [4]. Di antara kelompok gangguan tersebut, tumor otak termasuk kondisi dengan beban klinis yang tinggi. Di Inggris, tumor otak ganas primer mencakup sekitar 3% dari total kasus kanker dengan sekitar 12.000 kasus baru per tahun [5].

Besarnya dampak tumor otak membuat deteksi dan penanganan sejak dini menjadi sangat penting. Salah satu pemeriksaan awal yang umum dilakukan adalah *imaging* menggunakan *Magnetic Resonance Imaging* atau MRI. Contoh pemakaian MRI adalah dalam melihat lesi. Lesi adalah sebuah perubahan abnormal, seperti benjolan atau luka, pada jaringan atau organ tubuh manusia yang dapat mengganggu fungsi atau struktur tubuh [6]. Pemeriksaan MRI penting karena membantu dokter melihat karakteristik lesi dengan lebih jelas, sehingga rencana penanganan bisa dibuat lebih tepat [6]. Selain untuk diagnosis awal, MRI juga dipakai untuk pemantauan lanjutan, misalnya untuk melihat perubahan pada lesi pada suatu pasien dan menilai apakah terapi yang diberikan berjalan efektif [7].

Walaupun MRI tersedia, keputusan klinis yang tepat sangat bergantung pada kemampuan radiolog dalam membaca dan memproses hasilnya. Proses ini bisa memakan waktu, ditambah jika kasus tersebut kompleks dan jumlah pemeriksaan

tinggi. Dalam sebuah kajian yang meninjau sampel acak 440 studi *imaging*, hampir setengah studi diperkirakan berpotensi menambah beban kerja radiolog, dan studi bertema AI juga berkaitan kuat dengan peningkatan beban kerja [8]. Saat beban kerja meningkat, risiko kesalahan diagnosis juga dapat meningkat. Pada studi *case control*, total 49 kesalahan diagnosis dianalisis dan beban kerja pada hari terjadinya kesalahan rata-rata mencapai 121% [9]. Dari kondisi ini, *Artificial Intelligence* atau *Deep Learning* (DL) dapat menjadi solusi yang relevan untuk membantu proses analisis.

Saat ini, DL sudah menunjukkan performa yang kuat dalam berbagai tugas *imaging* medis. Sebuah survei sistematis mengidentifikasi 11.921 studi dan memasukkan 503 studi untuk dianalisis, yang menunjukkan besarnya bukti riset DL pada diagnosis berbasis citra [10]. Di bidang medis, DL sering digunakan untuk segmentasi dan klasifikasi. Pada kasus tumor otak, DL dapat membantu menganalisis MRI, misalnya untuk segmentasi, mengenali area tumor, dan menangkap fitur yang berkaitan [11]. Namun, penerapan DL juga punya tantangan karena kebutuhan komputasi untuk melatih model dan menjalankan model bisa tinggi.

Di banyak riset, pembahasan model DL sering lebih fokus pada akurasi, sementara aspek seperti ukuran model, latensi, dan kebutuhan komputasi tidak selalu dibahas secara seimbang. Ketika model makin besar, jumlah parameter biasanya meningkat, latensi *inference* bisa bertambah, dan sumber daya untuk *training* juga makin besar. Karena itu, evaluasi sebaiknya tidak hanya menilai kualitas prediksi [12]. Dalam konteks medis, model yang terlalu berat dapat menyulitkan penerapan pada perangkat dengan komputasi terbatas atau pada situasi yang butuh respons cepat [13].

Convolutional Neural Network atau CNN adalah salah satu arsitektur *deep learning* yang banyak dipakai dalam *medical imaging* untuk tugas seperti klasifikasi dan segmentasi. CNN mampu mempelajari fitur penting dari gambar tanpa perlu rekayasa fitur manual [14]. Pada penelitian ini, model utama yang digunakan adalah MobileNetV3. MobileNetV3 dipilih karena dirancang untuk perangkat dengan memori dan daya komputasi terbatas. Pengembang MobileNetV3 melaporkan bahwa varian MobileNetV3-*Large* dapat meningkatkan akurasi dan menurunkan latensi sekitar 20% dibanding MobileNetV2 pada pengujian yang dilaporkan [15]. Untuk pembandingan yang lebih objektif, penelitian ini juga menggunakan EfficientNetV2 sebagai *baseline*, karena model ini dirancang untuk menyeimbangkan akurasi, efisiensi parameter, dan kecepatan *training*.

EfficientNetV2 dilaporkan dapat hingga 6,8 kali lebih kecil dan dapat mencapai *training* 5 hingga 11 kali lebih cepat dengan sumber daya komputasi yang sama pada evaluasi yang dilaporkan [16].

Penelitian ini melanjutkan penelitian sebelumnya yang telah mengimplementasikan EfficientNetV2B1 untuk klasifikasi tumor otak dan memperoleh performa klasifikasi yang sangat baik. Pada bagian saran, penelitian tersebut merekomendasikan pengujian arsitektur lain dari keluarga MobileNet yang secara umum dirancang untuk kebutuhan komputasi yang lebih ringan. Berdasarkan rekomendasi tersebut, penelitian ini mengimplementasikan MobileNetV3-Large untuk mengetahui kemampuan arsitektur tersebut dalam melakukan klasifikasi tumor otak dan membandingkan performa klasifikasinya dengan hasil EfficientNetV2B1 pada penelitian sebelumnya [17].

Berdasarkan permasalahan tersebut, penelitian ini berfokus pada implementasi MobileNetV3-Large untuk klasifikasi tumor otak berbasis citra MRI. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Selanjutnya, hasil terbaik MobileNetV3-Large dibandingkan dengan hasil EfficientNetV2B1 pada penelitian sebelumnya sebagai *baseline*. Melalui pendekatan tersebut, penelitian ini diharapkan dapat memberikan gambaran mengenai kemampuan MobileNetV3-Large dalam mempertahankan performa klasifikasi ketika digunakan sebagai alternatif arsitektur untuk klasifikasi tumor otak.

1.2 Rumusan Masalah

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

1. Bagaimana menghasilkan model klasifikasi tumor otak berbasis citra MRI yang mampu membedakan kelas *glioma*, *meningioma*, *pituitary*, dan *no tumor*?
2. Bagaimana pengaruh variasi rasio pembagian data terhadap performa klasifikasi MobileNetV3-Large, serta bagaimana konsistensi konfigurasi terbaik ketika diuji menggunakan beberapa nilai *seed*?
3. Bagaimana perbandingan hasil klasifikasi MobileNetV3-Large dengan hasil klasifikasi EfficientNetV2B1 yang dilaporkan dalam penelitian sebelumnya berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*?

1.3 Batasan Permasalahan

Batasan permasalahan yang ada pada penelitian ini adalah sebagai berikut:

1. Klasifikasi dibatasi pada empat kelas tumor otak, yaitu Glioma, Meningioma, Pituitary, dan *No Tumor*.
2. Dataset yang digunakan hanya berasal dari dataset publik Kaggle [18, 19, 20].
3. Eksperimen dilakukan dalam dua skenario, yaitu Skenario A sebagai rancangan utama penelitian dengan beberapa variasi pembagian data untuk memperoleh performa terbaik MobileNetV3-Large, serta Skenario B yang mengadaptasi alur penelitian sebelumnya oleh Ricario sebagai pembanding terhadap baseline EfficientNetV2B1 [17].
4. Perbandingan dengan EfficientNetV2B1 dibatasi pada hasil performa klasifikasi yang dilaporkan pada penelitian sebelumnya. Penelitian ini tidak melakukan pengukuran komparatif terhadap waktu pelatihan, latensi inferensi, ukuran model, maupun jumlah parameter pada kedua arsitektur.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut.

1. Mengimplementasikan MobileNetV3-Large untuk melakukan klasifikasi tumor otak berbasis citra MRI ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*.
2. Mengevaluasi performa klasifikasi MobileNetV3-Large menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.
3. Membandingkan hasil klasifikasi MobileNetV3-Large dengan hasil klasifikasi EfficientNetV2B1 yang dilaporkan dalam penelitian sebelumnya berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

1.5 Manfaat Penelitian

Dengan selesainya pembuatan penelitian ini, manfaat yang dapat diambil adalah sebagai berikut:

1. Menyediakan referensi kinerja MobileNetV3 untuk klasifikasi tumor otak empat kelas.
2. Memberikan hasil perbandingan klasifikasi MobileNetV3-Large dengan EfficientNetV2B1 yang telah dilaporkan dalam penelitian sebelumnya.

1.6 Sistematika Penulisan

Sistematika penulisan laporan penelitian ini disusun untuk memudahkan pemahaman alur penelitian dari awal hingga akhir. Adapun susunan penulisan adalah sebagai berikut:

1. Bab 1 PENDAHULUAN

Bab ini berisi pengantar penelitian yang mencakup latar belakang, rumusan masalah, batasan permasalahan, tujuan dan manfaat penelitian, serta sistematika penulisan. Bab ini juga menegaskan fokus penelitian pada klasifikasi tumor otak empat kelas serta alasan pemilihan MobileNetV3-Large sebagai arsitektur penelitian.

2. Bab 2 LANDASAN TEORI

Bab ini memuat landasan teori dan kajian pustaka yang mendukung penelitian, meliputi konsep tumor otak, dasar *deep learning* dan CNN, serta pengenalan MobileNetV3 sebagai model utama. Bab ini juga menjelaskan metrik evaluasi yang digunakan untuk menilai performa klasifikasi model.

3. Bab 3 METODOLOGI PENELITIAN


Bab ini menjelaskan metodologi penelitian, mulai dari sumber dataset, tahapan pra pemrosesan, pembagian data latih validasi uji, hingga konfigurasi pelatihan model. Bab ini memaparkan rancangan penelitian, konfigurasi pelatihan model, variasi pembagian data, serta metode evaluasi performa klasifikasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.

4. Bab 4 HASIL DAN DISKUSI

Bab ini menyajikan hasil dan pembahasan, mencakup performa klasifikasi, *confusion matrix*, serta perbandingan metrik *Accuracy*, *Precision*, *Recall*, dan *F1 Score*. Selain itu, bab ini membahas hasil pengujian MobileNetV3-Large pada setiap skenario penelitian serta membandingkan performa klasifikasinya dengan hasil EfficientNetV2B1 yang dilaporkan pada penelitian sebelumnya.

5. Bab 5 KESIMPULAN DAN SARAN

Bab ini memuat kesimpulan penelitian berdasarkan hasil yang diperoleh, menjawab rumusan masalah, serta pemberian saran untuk riset selanjutnya.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA