

**KLASIFIKASI TUMOR OTAK BERBASIS CITRA MRI
MENGGUNAKAN LIGHTWEIGHT CNN
ENSEMBLE MODEL**

THESIS

**Oleh :
AKBAR SIDQI
NIM. 230605210031**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI TUMOR OTAK BERBASIS CITRA MRI
MENGGUNAKAN LIGHTWEIGHT CNN
ENSEMBLE MODEL**

THESIS

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh :
AKBAR SIDQI
NIM. 230605210031**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI TUMOR OTAK BERBASIS CITRA MRI
MENGGUNAKAN LIGHTWEIGHT CNN
ENSEMBLE MODEL**

THESIS

Oleh :
AKBAR SIDQI
NIM. 230605210031

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 14 Mei 2025

Pembimbing I,

Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004

Pembimbing II,

Prof. Dr. Sri Harini, M. Si
NIP. 19731014 200112 2 002

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Drs. Cahyo Crydian, M.Cs
NIP. 19740424 200901 1 008

**KLASIFIKASI TUMOR OTAK BERBASIS CITRA MRI
 MENGGUNAKAN LIGHTWEIGHT CNN
ENSEMBLE MODEL**

THESIS

**Oleh :
AKBAR SIDQI
NIM. 230605210031**

Telah dipertahankan di Depan Dewan Pengaji Thesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk memperoleh Gelar Magister Komputer (M.Kom)

Tanggal: 14 Mei 2025

Susunan Dewan Pengaji:

Pengaji 1, : Dr. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

Pengaji 2, : Dr. M. Imamuddin, LC., MA
NIP. 19740602 200901 1 010

Pembimbing 1 : Dr. Irwan Budi Santoso, M.Kom
NIP 19770103 201101 1 004

Pembimbing 2 : Prof. Dr. Sri Harini, M. Si
NIP. 19731014 200112 2 002

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



PERNYATAAN KEASLIAN TULISAN

Yang bertanda tangan di bawah ini saya:

Nama : Akbar Sidqi
NIM : 230605210031
Program : Magister Informatika
Fakultas : Sains Dan Teknologi

Menyatakan dengan sebenarnya bahwa Thesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan Thesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 14 Mei 2025
Yang Membuat Pernyataan,



Akbar Sidqi
NIM. 230605210031

MOTTO

*“Jadilah Mata Air, Yang Jernih,
Yang Memberikan Kehidupan,
Kepada Sekitarmu”*

HALAMAN PERSEMBAHAN

Dengan mengucap syukur Alhamdulillahi rabbil alamin, Thesis ini saya persembahkan untuk :

1. Allah SWT yang memberikan rahmat, hidayah, kesehatan, rezeki, serta semua yang saya butuhkan sampai selesaiya tesis ini.
2. Rasulullah Muhammad SAW yang telah menerangi alam ini dengan nur tauhidnya. Berkat ajaran beliau melalui Al-Quran dan sunnah, membuka era ilmu pengetahuan, cahaya dan sains.
3. Seluruh keluarga tercinta (Istri Ana Rizkiya., M.Pd., M.Ag., Serta ketiga putri kami yaitu: Farhana Mumtaza Shidqi, Faradisa Misykaah Shidqiya, Nilna Mecca Mafaza Karima), yang selalu memberikan dukungan, doa dan semangat yang tiada henti.
4. Seluruh orang tua tersayang (Bapak Alm H. Rusydi HR dan Ibu Alm Hj. Titin Maysaroh HM, serta Abah H. Abdul Qodir dan Ibu Hj. Khoirul Bidayah).
5. Bapak Dr. Irwan Budi Santoso, M.Kom. dan Ibu Prof. Dr. Sri Harini, M. Si. selaku dosen pembimbing yang sudah banyak memberikan ilmu, arahan dan bimbingannya.
6. Bapak Dr. Fachrul Kurniawan, M.MT., IPU. dan Bapak Dr. M. Imamuddin, LC., MA. Selaku tim penguji tesis yang sudah banyak membantu terselesainya tesis saya.
7. Seluruh civitas akademika Universitas Islam Negeri Maulana Malik Ibrahim Malang untuk dapat menimba ilmu, Pengalaman di bidang agama serta sains dan teknologi saling melengkapi, membentuk pemahaman holistik.
8. Rekan-rekan sekalian yang tidak bisa saya sebutkan satu persatu yang telah mendukung penyelesaian tesis ini.

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Syukur alhamdulillah penulis hantarkan kehadirat Allah SWT yang telah melimpahkan Rahmat dan Hidayah-Nya. Serta sholawat dan salam selalu tercurahkan kepada Rosulullah Muhammad SAW yang telah menerangi alam ini dengan nur tauhidnya. Berkat ajaran beliau melalui Al-Quran dan sunnah, membuka era ilmu pengetahuan, cahaya dan sains. Sehingga penulis dapat menyelesaikan studi di Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang sekaligus menyelesaikan Thesis ini dengan baik, yang berjudul **“Klasifikasi Tumor Otak Berbasis Citra MRI Menggunakan Lightweight CNN Ensemble Model”**.

Selanjutnya penulis haturkan ucapan terima kasih seiring do'a dan harapan *jazakumullah ahsanal jaza'* kepada semua pihak yang telah membantu terselesaiannya Thesis ini. Ucapan terima kasih ini penulis sampaikan kepada:

1. Bapak Dr. Cahyo Crysdiyan, MCS. selaku Ketua Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Bapak Dr. Irwan Budi Santoso, M.Kom. dan Ibu Prof. Dr. Sri Harini, M. Si. Selaku dosen pembimbing yang sudah banyak memberikan ilmu, arahan dan bimbingannya.
3. Keluarga tercinta yang telah banyak memberikan doa dan dukungan kepada penulis secara moril maupun materil hingga Thesis ini dapat terselesaikan.

4. Seluruh civitas akademika Universitas Islam Negeri Maulana Malik Ibrahim Malang untuk dapat menimba ilmu, Pengalaman di bidang agama serta sains dan teknologi saling melengkapi, membentuk pemahaman holistik.
5. Semua pihak yang ikut membantu dalam menyelesaikan Thesis ini yang tidak bisa penulis sebutkan satu persatu.

Penulis menyadari bahwa dalam penyusunan Thesis ini masih terdapat kekurangan dan penulis berharap semoga Thesis ini dapat memberikan manfaat kepada para pembaca khususnya bagi penulis secara pribadi.

Amin Ya Rabbal Alamin.

Wassalamu'alaikum Wr. Wb.

Malang, 14 Mei 2025
Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	i
HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN	iii
PERNYATAAN KEASLIAN TULISAN	iv
MOTTO	v
HALAMAN PERSEMBAHAN	vi
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
ABSTRAK	xvii
ABSTRACT	xviii
الملخص	xix
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Pernyataan Masalah	4
1.3. Tujuan Penelitian	5
1.4. Manfaat Penelitian	5
1.5. Ruang Lingkup Masalah	5
BAB II STUDI PUSTAKA	6
2.1. Deteksi Tumor Otak	6
2.2. Convolutional Neural Network	10
2.3. Majority Voting	14
2.4. Weighted Average	15
2.5. Kerangka Teori	16
BAB III METODOLOGI PENELITIAN	19
3.1. Kerangka Konseptual	19
3.2. Alur Penelitian	20

3.3.	Pengumpulan Data Citra MRI	21
3.4.	Desain Sistem	22
3.5.	Resize	24
3.6.	Data Augmentasi	24
3.7.	Hiperparameter	25
3.8.	Model Convolutional Neural Network (CNN)	25
3.8.1.	Convolutional Layer	26
3.8.2.	ActivationLayer	26
3.8.3.	Pooling Layer	27
3.8.4.	Flattening	27
3.8.5.	Output (Classification) Layer	28
3.9.	Ensemble Learning	29
3.9.1.	Majority Voting	29
3.9.2.	Weighted Average	30
3.10.	Training dan Validasi dengan Ensemble	30
3.11.	Eksperimen	32
3.12.	Evaluasi	33
BAB IV LIGHTWEIGHT CNN	35
4.1.	Arsitektur Lightweight CNN untuk Klasifikasi Tumor Otak	35
4.2	Rasio Data 60:20:20	36
4.3.	Hasil Augmentasi Data	38
4.4.	Hiperparameter Model Lightweight CNN	39
4.5.	Pengujian Ukuran Kernel 3×3 Base Model CNN1	40
4.6.	Pengujian Ukuran Kernel 5×5 Base Model CNN2	41
4.7.	Pengujian Ukuran Kernel 7×7 Base Model CNN3	42
4.8.	Pengujian Filter Size terhadap Kinerja Base Model CNN	43
4.9.	Base Model 1	44
4.9.1.	Pengujian Base Model CNN1 (Adam, Kernel 3x3)	44
4.9.2	Pengujian Base Model CNN2 (Adam, Kernel 5x5)	48
4.9.3.	Pengujian Base Model CNN3 (Adam, Kernel 7x7)	51
4.9.4.	Evaluasi Base Model 1	54

4.10.	Base Model 2	54
4.10.1.	Pengujian Base Model CNN1 (AdamW, Kernel 3x3)	55
4.10.2.	Pengujian Base Model CNN2 (AdamW, Kernel 5x5)	58
4.10.3.	Pengujian Base Model CNN3 (AdamW, Kernel 7x7)	61
4.10.4.	Evaluasi Base Model 2	64
4.11.	Base Model 3	64
4.11.1.	Pengujian Base Model CNN1 (Nadam, Kernel 3x3)	65
4.11.2.	Pengujian Base Model CNN2 (Nadam, Kernel 5x5)	67
4.11.3.	Pengujian Base Model CNN3 (Nadam, Kernel 7x7)	71
4.11.4.	Evaluasi Base Model 3	74
BAB V ENSEMBLE LEARNING		75
5.1.	Ensemble Learning	75
5.2.	Majority Voting Base Model 1	76
5.3.	Weighted Average Base Model 1	79
5.4.	Majority Voting Base Model 2	81
5.5.	Weighted Average Base Model 2	83
5.6.	Majority Voting Base Model 3	85
5.7.	Weighted Average Base Model 3	87
5.8.	Evaluasi Ensemble Learning	89
BAB VI PEMBAHASAN		92
6.1.	Pengaruh Ukuran Kernel terhadap Ekstraksi Fitur	92
6.1.1.	Pengaruh Ukuran Kernel dengan Optimizer Adam	93
6.1.2.	Pengaruh Ukuran Kernel dengan Optimizer AdamW	94
6.1.3.	Pengaruh Ukuran Kernel dengan Optimizer Nadam	95
6.2.	Analisis Kinerja Lightweight CNN dengan Variasi Kernel	97
6.3.	Evaluasi Kinerja Model Lightweight CNN secara Individu	98
6.4.	Majority Voting pada Model Lightweight CNN	101
6.5.	Weighted Average pada Model Lightweight CNN	102
6.6.	Analisis Model Lightweight CNN Individu dan Ensemble	104
6.7.	Klasifikasi Tumor Otak dalam Pandangan Islam	108

BAB VII PENUTUP	112
7.1. Kesimpulan	112
7.2. Saran	114
DAFTAR PUSTAKA	115
LAMPIRAN	118

DAFTAR GAMBAR

Gambar 2.1.	Ilustrasi Arsitektur CNN	10
Gambar 2.2.	Operasi Matematis Proses Konvolusi	11
Gambar 2.3.	Aktifasi ReLu	12
Gambar 2.4.	Fully-Conected Layer	14
Gambar 2.5.	Kerangka Teori	16
Gambar 3.1.	Kerangka Konseptual	19
Gambar 3.2.	Alur Penelitian	20
Gambar 3.3.	Otak Normal dan Tumor Otak T1, T1C+, T2	22
Gambar 3.4.	Desain Sistem	23
Gambar 3.5.	Training dan Validasi Dengan Ensemble CNN	31
Gambar 4.1.	Arsitektur Base Model Lightweight CNN (Usulan)	35
Gambar 4.2.	Citra MRI, Subset Testing, Training dan Validasi	38
Gambar 4.3.	Hasil Augmentasi Data	39
Gambar 4.4.	Hasil Pelatihan, Validasi Model CNN1 (Adam, 3x3)	46
Gambar 4.5.	Confusion Matrix Base Model CNN1 (Adam, 3x3)	47
Gambar 4.6.	Hasil Pelatihan, Validasi Model CNN2 (Adam, 5x5)	49
Gambar 4.7.	Confusion Matrix Base Model CNN2 (Adam, 5x5)	50
Gambar 4.8.	Hasil Pelatihan, Validasi Model CNN3 (Adam, 7x7)	52
Gambar 4.9.	Confusion Matrix Base Model CNN3 (Adam, 7x7)	53
Gambar 4.10.	Hasil Pelatihan, Validasi Model CNN1 (AdamW, 3x3)	56
Gambar 4.11.	Confusion Matrix Base Model CNN1 (AdamW, 3x3)	57
Gambar 4.12.	Hasil Pelatihan, Validasi Model CNN2 (AdamW, 5x5)	59
Gambar 4.13.	Confusion Matrix Base Model CNN2 (AdamW, 5x5)	60
Gambar 4.14.	Hasil Pelatihan, Validasi Model CNN3 (AdamW, 7x7)	62
Gambar 4.15.	Confusion Matrix Base Model CNN3 (AdamW, 7x7)	63
Gambar 4.16.	Hasil Pelatihan, Validasi Model CNN1 (Nadam, 3x3)	66
Gambar 4.17.	Confusion Matrix Base Model CNN1 (Nadam, 3x3)	67
Gambar 4.18.	Hasil Pelatihan, Validasi Model CNN2 (Nadam, 5x5)	69

Gambar 4.19.	Confusion Matrix Base Model CNN2 (Nadam, 5x5)	70
Gambar 4.20.	Hasil Pelatihan, Validasi Model CNN3 (Nadam, 7x7)	72
Gambar 4.21.	Confusion Matrix Base Model CNN3 (Nadam, 7x7)	73
Gambar 5.1.	Ensemble Majority Voting dan Weighted Average	75
Gambar 6.1.	Pengaruh Ukuran Kernel dengan Optimizer Adam	94
Gambar 6.2.	Pengaruh Ukuran Kernel dengan Optimizer AdamW	95
Gambar 6.3.	Pengaruh Ukuran Kernel dengan Optimizer Nadam	96
Gambar 6.4.	Perbandingan Validasi Model Lightweight CNN	98
Gambar 6.5.	Evaluasi Individu Kinerja Model Lightweight CNN	100
Gambar 6.6.	Majority Voting pada Model Lightweight CNN	102
Gambar 6.7.	Weighted Average pada Model Lightweight CNN	104
Gambar 6.8.	Perbandingan Kinerja CNN Individu dan Ensemble	107

DAFTAR TABEL

Tabel 2.1.	Performa Model Penelitian pada setiap Kerangka Teori	17
Tabel 4.1.	Pembagian Data dengan Rasio 60:20:20	37
Tabel 4.2.	Pengujian Hiperparameter Model Lightweight CNN	40
Tabel 4.3.	Arsitektur Base Model CNN1 dengan Kernel Size 3×3	40
Tabel 4.4.	Arsitektur Base Model CNN2 dengan Kernel Size 5×5	41
Tabel 4.5.	Arsitektur Base Model CNN3 dengan Kernel Size 7×7	42
Tabel 4.6.	Hasil Base Model CNN1 dengan Adam dan Kernel 3×3	45
Tabel 4.7.	Hasil Base Model CNN2 dengan Adam dan Kernel 5×5	48
Tabel 4.8.	Hasil Base Model CNN3 dengan Adam dan Kernel 7×7	51
Tabel 4.9.	Evaluasi Base Model 1	54
Tabel 4.10.	Hasil Base Model CNN1 dengan AdamW dan Kernel 3×3 ...	55
Tabel 4.11.	Hasil Base Model CNN2 dengan AdamW dan Kernel 5×5 ...	58
Tabel 4.12.	Hasil Base Model CNN3 dengan AdamW dan Kernel 7×7	61
Tabel 4.13.	Evaluasi Base Model 2	64
Tabel 4.14.	Hasil Base Model CNN1 dengan Nadam dan Kernel 3×3	65
Tabel 4.15.	Hasil Base Model CNN2 dengan Nadam dan Kernel 5×5	68
Tabel 4.16.	Hasil Base Model CNN3 dengan Nadam dan Kernel 7×7	71
Tabel 4.17.	Evaluasi Base Model 3	74
Tabel 5.1.	Hasil Majority Voting pada Base Model 1	77
Tabel 5.2.	Confusion Matrix Majority Voting pada Base Model 1	78
Tabel 5.3.	Hasil Weighted Average pada Base Model 1	79
Tabel 5.4.	Confusion Matrix Weighted Average pada Base Model 1	80
Tabel 5.5.	Hasil Majority Voting pada Base Model 2	81
Tabel 5.6.	Confusion Matrix Majority Voting pada Base Model 2	82
Tabel 5.7.	Hasil Weighted Average pada Base Model 2	83
Tabel 5.8.	Confusion Matrix Weighted Average pada Base Model 2	84
Tabel 5.9.	Hasil Majority Voting pada Base Model 3	85
Tabel 5.10.	Confusion Matrix Majority Voting pada Base Model 3	86

Tabel 5.11.	Hasil Weighted Average pada Base Model 3	87
Tabel 5.12.	Confusion Matrix Weighted Average pada Base Model 3	88
Tabel 5.13.	Evaluasi Performa Ensemble Learning	89
Tabel 6.1.	Pengaruh Ukuran Kernel dengan Optimizer Adam	93
Tabel 6.2.	Pengaruh Ukuran Kernel dengan Optimizer AdamW	94
Tabel 6.3.	Pengaruh Ukuran Kernel dengan Optimizer Nadam	96
Tabel 6.4.	Perbandingan Validasi Model Lightweight CNN	97
Tabel 6.5.	Evaluasi Kinerja Lightweight CNN secara Individu	99
Tabel 6.6.	Majority Voting pada Model Lightweight CNN	101
Tabel 6.7.	Weighted Average pada Model Lightweight CNN	103
Tabel 6.8.	Perbandingan Kinerja CNN Individu dan Ensemble	104

ABSTRAK

Sidqi, Akbar. 2025. **Klasifikasi Tumor Otak Berbasis Citra MRI Menggunakan Lightweight CNN Ensemble Model.** Thesis Program Studi Magister Informatika Fakultas Sains Dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing : (I) Dr. Irwan Budi Santoso, M.Kom., (II) Prof. Dr. Sri Harini, M. Si.

Kata Kunci : Lightweight CNN, Ensemble Learning, Klasifikasi Tumor Otak, Citra MRI.

Klasifikasi tumor otak berbasis citra MRI memerlukan analisis visual yang kompleks karena adanya variasi karakteristik visual yang sangat beragam antar jenis tumor otak. Variasi ini menyebabkan model kesulitan dalam menangkap detail halus yang membedakan satu jenis tumor dengan lainnya secara akurat. Penelitian ini mengembangkan dan mengusulkan model klasifikasi untuk 17 jenis tumor otak dengan menggunakan arsitektur Lightweight Convolutional Neural Network (CNN). Model ini menggunakan variasi ukuran kernel yaitu 3×3 , 5×5 , dan 7×7 untuk menguji kemampuan ekstraksi fitur yang berbeda pada setiap konfigurasi. Sebanyak sembilan model diuji dengan konfigurasi kernel yang berbeda untuk menentukan model dengan performa terbaik. Hasil pengujian menunjukkan bahwa CNN3 dengan kernel 7×7 pada Base Model 3 memberikan hasil terbaik dengan akurasi, presisi, recall, dan F1-score sebesar 0,91. Sebaliknya, CNN2 dengan kernel 5×5 menunjukkan performa terendah dengan akurasi 0,82. Untuk meningkatkan akurasi, metode ensemble seperti Majority Voting dan Weighted Average diterapkan. Metode Weighted Average menghasilkan akurasi tertinggi sebesar 0,96 dan spesifisitas mencapai 0,99. Dari sisi optimasi, penggunaan optimizer Nadam memberikan performa paling konsisten dan mengungguli Adam dan AdamW. Kombinasi antara arsitektur CNN berkernel besar, metode ensemble Weighted Average, dan optimizer Nadam mampu meningkatkan akurasi klasifikasi tumor otak secara optimal.

ABSTRACT

Sidqi, Akbar. 2025. **MRI Based Brain Tumor Classification Using a Lightweight CNN Ensemble Model.** Master's Thesis, Informatics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Supervisors: (I) Dr. Irwan Budi Santoso, M.Kom., (II) Prof. Dr. Sri Harini, M.Si.

Keywords : Lightweight CNN, Ensemble Learning, Brain Tumor Classification, MRI Images.

Brain tumor classification based on MRI images requires complex visual analysis due to the highly diverse visual characteristics among different types of brain tumors. This variation causes difficulties for the model in accurately capturing the subtle details that distinguish one tumor type from another. This study develops and proposes a classification model for 17 types of brain tumors using a Lightweight Convolutional Neural Network (CNN) architecture. The model employs varying kernel sizes of 3×3 , 5×5 , and 7×7 to evaluate different feature extraction capabilities for each configuration. A total of nine models were tested with different kernel configurations to identify the best-performing model. The results indicate that CNN3 with a 7×7 kernel in Base Model 3 achieved the best performance, with accuracy, precision, recall, and F1-score all at 0.91. In contrast, CNN2 with a 5×5 kernel exhibited the lowest performance with an accuracy of 0.82. To enhance accuracy, ensemble methods such as Majority Voting and Weighted Average were applied. The Weighted Average method attained the highest accuracy of 0.96 and a specificity of 0.99. Regarding optimization, the use of the Nadam optimizer demonstrated the most consistent performance, outperforming both Adam and AdamW optimizers. The combination of a large-kernel CNN architecture, the Weighted Average ensemble method, and the Nadam optimizer effectively improved the accuracy of brain tumor classification.

الملخص

صدق، أكبر. ٢٠٢٥. تصنیف أورام الدماغ المستندة إلى صور الرنين المغناطيسي باستخدامة نموذج مجموعه CNN خفیفة الوزن.

رسالة الماجستير في برنامج دراسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرف (١) الدكتور عروان بودي سانتوسو الماجستير.، المشرفة (٢) الأستاذة الدكتورة سري هاريني الماجستير.

الكلمات المفتاحية: أورام الدماغ، صور الرنين المغناطيسي (Lightweight) المجموعة المركبة، CNN ، تصنیف أورام الدماغ، CITRA MRI.

يتطلب تصنیف أورام الدماغ المستند إلى التصوير بالرنين المغناطيسي تحلیلاً بصرياً معقداً بسبب الاختلاف الكبير في الخصائص البصرية بين أنواع أورام الدماغ. وجعل هذه الاختلافات من الصعب على النماذج التقاط التفاصيل الدقيقة التي تميز نوع ورم عن آخر.تطور هذه الدراسة وتقترح نموذج تصنیف لـ 17 نوعاً من أورام الدماغ باستخدام بنية الشبكة العصبية التلفيفية خفیفة الوزن (CNN). يستخدم هذا النموذج اختلافات في أحجام النواة، وهي $3 \times 3 \times 5 \times 7 \times 7$ لاختبار القدرة على استخراج ميزات مختلفة في كل تكوين. تم اختبار ما مجموعه تسعة نماذج بتكونيات نواة مختلفة لتحديد النموذج ذي الأداء الأفضل. تُظهر نتائج الاختبار أن CNN3 مع نواة 7×7 على النموذج الأساسي 3 يعطي أفضل النتائج بدقة ودقة واستدعاء ودرجة F1 تبلغ 0.91. في المقابل، يُظهر CNN2 مع نواة 5×5 أدنى أداء بدقة 0.82. لتحسين الدقة، يتم تطبيق طرق المجموعة مثل التصويت بالأغلبية والمتوسط المرجح. تنتج طريقة المتوسط المرجح أعلى دقة تبلغ 0.96 وتحصل على المخصوصية إلى 0.99. من حيث التحسين، يوفر استخدام مُحسن Nadam أداءً أكثر ثباتاً ويتفوق على Adam و AdamW. إن الجمع بين بنية CNN كبيرة النواة، وطريقة مجموعة المتوسط المرجح، ومحسن Nadam، يُحسن دقة تصنیف أورام الدماغ بشكل مثالي.

BAB I

PENDAHULUAN

1.1. Latar Belakang

Otak sebagai pengatur utama seluruh fungsi tubuh, merupakan organ paling penting dan kompleks dalam tubuh manusia. Perubahan yang tidak diinginkan pada otak, seperti pertumbuhan dan deformasi sel yang tidak terkendali, dapat menyebabkan pembentukan tumor otak. Selain itu, penyebaran sel kanker dari bagian tubuh lain juga dapat memicu munculnya tumor di otak. Menurut *World Health Organization* (WHO), sekitar 9,6 juta orang di dunia menderita tumor otak. Para ahli mengklasifikasikan tumor otak menjadi dua jenis: tumor jinak dan tumor ganas. Tumor jinak berkembang hanya di satu area tubuh dan tidak menyebar ke bagian lain, sedangkan tumor ganas menyerang jaringan sekitarnya dan menyebar ke berbagai bagian tubuh lainnya (Santoso, I. B., *et al.*, 2024). di mana keterlambatan identifikasi berdampak pada penurunan peluang kesembuhan.

Kompleksitas struktur otak dan variasi ukuran tumor menyulitkan proses diagnosis yang tepat. Oleh karena itu, diperlukan metode yang mampu mengklasifikasikan tumor otak secara akurat, terutama pada tahap awal diagnosis. Sehingga penggunaan teknologi pencitraan resonansi magnetik (MRI) menjadi solusi penting karena mampu menghasilkan citra tiga dimensi secara detail tanpa tindakan invasif (Zahid, R., *et al.*, 2024). Citra MRI ini sangat membantu para ahli radiologi dalam membedakan jaringan otak normal dan abnormal, serta

mengklasifikasikan jenis tumor yang terdeteksi (Asiri, A. A., *et al.*, 2024).

Di dalam perspektif Al-Qur'an disebutkan 2 kategori term penyakit, yaitu penyakit hati (Rohani) dan penyakit fisik (Badan). Adapun untuk klasifikasi penyakit Rohani, diantaranya secara spesifik disebutkan dalam Q.S. Al-Baqarah ayat 10.

فِي قُلُوبِهِمْ مَرَضٌ فَزَادَهُمُ اللَّهُ مَرَضًا وَلَهُمْ عَذَابٌ أَكِيمٌ بِمَا كَانُوا يَكْنِدِبُونَ (١٠)

"Dalam hati mereka ada penyakit, lalu ditambah Allah penyakitnya; dan bagi mereka siksa yang pedih, disebabkan mereka berdusta." (Q.S. Al-Baqarah : 10)

Wahbah az-Zuhaili menafsirkan ayat tersebut dalam kitabnya Al-Munir, bahwa kata **مَرْيْضٌ** adalah penyakit hati yang berupa kemunafikan. Allah mengqiyaskan kemunafikan sebagai penyakit dalam hati karena penyakit merusak fisik (Badan), sedang kemunafikan merusak hati (Rohani). (*Wahbah az-Zuhaili. Tafsir al-Munir. 2014*).

Sejalan dengan pentingnya menjaga kesehatan fisik dan rohani, deteksi penyakit secara tepat juga menjadi aspek krusial. Namun demikian, pemeriksaan citra MRI secara manual seringkali memerlukan waktu yang lama dan berisiko menimbulkan kesalahan. sehingga menghambat ketepatan diagnosis. Oleh karena itu, pengembangan metode otomatis berbasis teknologi menjadi sangat penting untuk mendukung proses diagnosis tumor otak secara lebih tepat.

Convolutional Neural Network (CNN) jaringan saraf tiruan yang umum digunakan dalam menganalisis data citra MRI, yang mampu mengidentifikasi dan mengklasifikasikan tumor otak dengan menangkap pola dan karakteristik kompleks. Sebagaimana ditunjukkan oleh penelitian sebelumnya. Penelitian

tersebut mengungkapkan bahwa penggunaan CNN dapat meningkatkan kinerja klasifikasi, bahkan ketika diterapkan hanya untuk proses ekstraksi fitur (Santoso. I. B. *et al.*, 2024). Penelitian yang dilakukan oleh Zaitoon, R., *et al.* (2023) dengan menggunakan dua arsitektur CNN, yaitu CNN dengan 5 layer dan CNN dengan 6 layer, dimana keduanya menggunakan penyetelan hiper-parameter serta proporsi pelatihan data yang berbeda. Hasil analisis menunjukkan bahwa arsitektur CNN ini mencapai akurasi sebesar 99,87% dengan gabungan adam optimizer setelah melalui evaluasi metric. Meskipun demikian, dapat disimpulkan bahwa metode ini masih memiliki keterbatasan, terutama saat diterapkan pada kumpulan data besar. Keterbatasan tersebut terutama disebabkan oleh terbatasnya sumber daya komputasi, Keterbatasan serupa juga ditemukan dalam penelitian Khan, H. A., *et al.* (2020), yang menggunakan dataset relatif kecil, terdiri dari 253 citra MRI. Selanjutnya, Penelitian Mohsen, S., *et al.* (2023) menunjukkan keterbatasan CNN dalam menjaga akurasi konsisten karena hanya menggunakan dataset terbatas pada dua jenis tumor, yaitu meningioma dan hipofisis.

Muis, A., *et al.* (2023) dengan CNN yang diusulkan, menghasilkan akurasi keseluruhan sebesar 84% dalam klasifikasi citra tumor otak. Penelitian tersebut menunjukkan bahwa variasi kompleksitas dan karakteristik citra MRI pada setiap jenis tumor otak berkontribusi pada klasifikasi. Terutama karena jenis tumor glioma dan meningioma memiliki fitur yang lebih halus (Santoso, I. B., *et al.*, 2024), dan tumpang tindih dengan jenis tumor otak lainnya (Rachmawanto, E. H., *et al.*, 2024), Hal ini membuat klasifikasi menjadi lebih sulit. Oleh karena, untuk meningkatkan performa klasifikasi tumor otak, harus melibatkan banyak/beberapa

model *Convolutional Neural Network* (CNN).

Berdasarkan kelemahan terkait data yang diolah, sehingga dibutuhkan penelitian lebih lanjut untuk menentukan model percobaan menggunakan metode deep learning. Pada penelitian ini mengusulkan klasifikasi tumor otak menggunakan beberapa model *lightweight* CNN dengan variasi ukuran filter. Ukuran filter ini dirancang untuk mengekstraksi fitur berbasis citra MRI dan menggabungkan hasil klasifikasi melalui pendekatan ensemble guna meningkatkan performa klasifikasi. Jumlah model dalam ensemble ditentukan oleh jumlah lapisan konvolusi yang digunakan. Pendekatan ini bertujuan memaksimalkan kemampuan model dalam membedakan 17 jenis tumor otak, seperti glioma dan meningioma, dengan akurasi tinggi. Kinerja ensemble akan dievaluasi melalui akurasi, presisi, recall, spesifisitas, dan confusion matrix.

1.2. Pernyataan Masalah

Berdasarkan uraian latar belakang di atas, maka pernyataan masalah pada penelitian ini adalah

1. Bagaimana pengaruh variasi ukuran filter konvolusi pada beberapa model CNN terhadap akurasi, presisi, recall, dan spesifisitas dalam klasifikasi tumor otak berbasis citra MRI ?
2. Bagaimana pengaruh ensemble terhadap akurasi, presisi, recall, dan spesifisitas klasifikasi tumor otak dengan berbagai model CNN ?

1.3. Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah

1. Menganalisis pengaruh ukuran filter konvolusi pada model CNN dalam mengklasifikasikan tumor otak berdasarkan citra MRI.
2. Mendapatkan nilai performa dari hasil klasifikasi tumor otak

1.4. Manfaat Penelitian

Penelitian ini bermanfaat sebagai alat bantu diagnosis radiologi otomatis yang mampu mengidentifikasi 17 jenis tumor otak dari citra MRI dengan akurasi yang lebih tinggi

1.5. Ruang Lingkup Masalah

Untuk memberikan batasan yang jelas dalam penelitian ini maka ruang lingkup penelitian ini hanya meliputi:

1. Data yang digunakan adalah data sekunder kuantitatif sebagai sumber data utama dari situs Kaggle, mencakup berbagai jenis tumor otak seperti glioma, meningioma, otak normal, neurocitoma, outros, dan schwannoma.
2. Ensemble diterapkan dengan menggabungkan prediksi menggunakan majority voting dan weighted average untuk meningkatkan performa klasifikasi.

BAB II

STUDI PUSTAKA

2.1. Deteksi Tumor Otak

Penelitian ini melakukan studi literatur untuk menyintesis informasi relevan dari berbagai jurnal, dengan tujuan memahami konteks dan kerangka teoritis CNN dalam klasifikasi tumor otak yang telah banyak dibahas sebelumnya.

Zaitoon, R., *et al.* (2023) Metode CNN yang diusulkan mencapai akurasi 99,87% dalam klasifikasi tumor otak, lebih efektif dibandingkan metode lain. Studi ini menunjukkan bahwa arsitektur CNN lima lapisan yang disesuaikan dengan baik memberikan performa lebih baik daripada arsitektur enam lapisan. Teknik pooling 2D Max, fungsi aktivasi ReLU, dan optimizer Adam, serta pemilihan fitur yang tepat, berperan penting dalam meningkatkan akurasi dan efektivitas klasifikasi. Selain itu, Muis, A., *et al.* (2023) menunjukkan bahwa penggunaan CNN dalam klasifikasi tumor otak dari citra MRI mencapai akurasi 84% dari 7.023 citra dalam empat kategori tumor. Meskipun akurasi sempat menurun pada beberapa iterasi, metode CNN terus meningkat seiring bertambahnya iterasi, membuktikan efektivitasnya dalam diagnosis tumor otak.

Sebagai perbandingan, metode yang diusulkan oleh Mukkapati, N., *et al.* (2022) meningkatkan akurasi metode CNN dengan mengintegrasikan U-Net untuk segmentasi, RefineNet untuk analisis pola, dan SegNet untuk klasifikasi. Metode ini mencapai akurasi 96,85% dalam klasifikasi tumor otak, lebih tinggi dibandingkan akurasi 96,13% dari CNN yang digabungkan dengan algoritma

genetika (GA). Dalam konteks peningkatan akurasi dan presisi metode CNN, Khan, H. A., *et al.* (2020) menunjukkan bahwa teknik pemrosesan citra dapat meningkatkan klasifikasi citra MRI otak menjadi kategori kanker dan non-kanker, dengan dataset 253 citra untuk pelatihan, validasi, dan pengujian.

Model yang dilatih menggunakan TensorFlow dan Keras mencapai akurasi 96% pada data pelatihan dan 89% pada data validasi, serta memberikan akurasi lebih tinggi dan waktu pelatihan lebih singkat dibandingkan model pra-terlatih seperti VGG-16, ResNet-50, dan Inception-v3. Di sisi lain, Mohsen, S., *et al.* (2023) fokus pada perbaikan hyperparameter untuk meningkatkan kinerja metode CNN yang digabungkan dengan TensorFlow dalam deteksi tumor otak. Arsitektur CNN terdiri dari 4 lapisan konvolusi, 3 lapisan max-pooling, 4 lapisan dropout, serta lapisan flatten, terhubung sepenuhnya, dan lapisan keluaran. Menggunakan citra MRI berukuran 224x224 piksel, model dilatih selama 50 epoch, mencapai akurasi pelatihan 93,6% dan akurasi pengujian 95,78%, menunjukkan efektivitas metode CNN dalam klasifikasi tumor otak otomatis dengan dua jenis tumor: meningioma dan hipofisis.

Sementara, Rachmawanto, E. H., *et al.*, (2024) Melakukan klasifikasi tumor otak menggunakan CNN berfokus pada pembedaan glioma HGG dan LGG dengan dataset BRATS 2018-2019. Dari 2048 citra MRI yang telah diproses, 80% digunakan untuk pelatihan dan 20% untuk pengujian. Model CNN sederhana dengan tiga lapisan konvolusi, dilengkapi fungsi aktivasi ReLU, normalisasi batch, dan max-pooling untuk seleksi fitur. Model ini dievaluasi menggunakan confusion matrix, dengan hasil akurasi mencapai 94,14%, yang menegaskan

efektivitas metode dalam klasifikasi tumor otak. Selain itu. Mahjoubi, M. A., *et al.* (2023) memanfaatkan keunggulan CNN dalam pengenalan citra , melakukan pengoptimalan hyperparameter melalui pencarian grid. Model CNN ini dibandingkan dengan arsitektur lain seperti AlexNet dan ResNet-50, serta diintegrasikan dengan jaringan klasifikasi untuk meningkatkan akurasi segmentasi tumor. Menggunakan lapisan Conv2D dengan 32 filter dan ukuran kernel 3x3 atau 5x5, CNN ini berhasil mengklasifikasikan tumor otak menjadi empat kelas pada citra MRI dengan akurasi 95,44% dan F1-Score 95,36%.

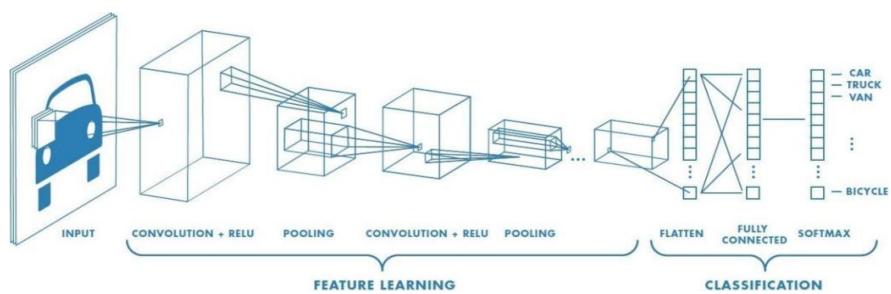
Penelitian lain selanjunya oleh Nassar, S.E. menggunakan dataset MRI T1W-CE publik yang dibagi menjadi 70% untuk pelatihan dan 30% untuk pengujian, dengan augmentasi data hanya pada set pelatihan. Lima model CNN pra-terlatih digunakan: GoogleNet dengan modul inception dan modifikasi lapisan terakhir untuk klasifikasi tumor, AlexNet dengan max-pooling tumpang tindih dan ReLU untuk citra $227 \times 227 \times 3$ piksel, ShuffleNet dengan konvolusi mendalam untuk biaya rendah, SqueezeNet dengan filter 1×1 dan 3×3 untuk efisiensi, serta NASNet-mobile yang ringan. Teknik majority voting diterapkan untuk meningkatkan akurasi klasifikasi, dengan fokus pada minimalisasi praprosesan dan penggabungan output model secara efektif, menghasilkan akurasi 99,31%. Pendekatan ini menunjukkan bahwa kombinasi hasil dari beberapa model dapat secara signifikan meningkatkan kinerja klasifikasi tumor otak berdasarkan citra MRI. Selanjutnya penelitian Alturki, N., *et al.* (2023) berfokus pada peningkatan akurasi klasifikasi tumor otak melalui model hibrida yang menggabungkan fitur CNN dengan metode voting classifier, menggabungkan dua

model: Regresi Logistik (LR) dan Stochastic Gradient Descent (SGD) yang dilatih menggunakan fitur yang diekstraksi dari CNN. Hasil penelitian menunjukkan bahwa model hibrida mencapai akurasi klasifikasi hingga 99,9%. Performa model ini dibandingkan dengan beberapa model lain, seperti NGBoost dan EfficientNet-B0, yang masing-masing menghasilkan akurasi 98,5% dan 98,8%. Dengan demikian, model hibrida yang dikembangkan terbukti lebih unggul, menunjukkan keefektifannya dalam meningkatkan klasifikasi tumor otak melalui pendekatan berbasis CNN dan voting classifier.

Selanjutnya oleh Bogacsovics, G., *et al.* (2024) menggunakan pendekatan ensemble berbasis CNN dengan memanfaatkan model seperti AlexNet, MobileNetv2, EfficientNet, dan ShuffleNet v2 untuk meningkatkan akurasi klasifikasi tumor otak pada citra MRI berbobot T1 dengan peningkatan kontras. Dengan menekankan keragaman model dalam ensemble dan menggunakan weighted average untuk menghitung kinerja model ensemble, penelitian ini berhasil meningkatkan performa klasifikasi. Hasilnya menunjukkan akurasi klasifikasi lebih dari 92%. Sementara. Vatsala, A., *et al.* (2023) Penggunaan CNN untuk klasifikasi tumor otak dengan augmentasi data meningkatkan keragaman data pelatihan. Model pembelajaran transfer seperti VGG19, EfficientNetB0, InceptionV3, dan ResNet50 diterapkan untuk mengekstraksi fitur dari citra MRI. Model ensemble weighted average yang menggabungkan fitur dari VGG19, CNN tanpa dan dengan augmentasi data mencapai kinerja dengan sensitivitas 96%, presisi 99%, dan F1-score 97%.

2.2. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah metode Deep Learning yang berkembang dari Multilayer Perceptron (MLP) dan Artificial Neural Network (ANN) untuk mengatasi kekurangan ANN dalam menyelesaikan operasi logika kompleks pada klasifikasi, pengenalan, dan prediksi. CNN sangat efektif dalam mengklasifikasikan citra kompleks, termasuk citra MRI (Zaitoon, R., et al., 2023), serta mampu memproses data berstruktur grid untuk menganalisis nilai piksel dan mengurangi noise (Asiri, A. A., et al., 2024). Proses klasifikasi dimulai dengan memperoleh citra MRI sebagai data input, baik dengan tiga channel RGB (merah, hijau, biru) atau satu channel grayscale (Khan, H. A., et al., 2020; Zaitoon, R., et al., 2023).

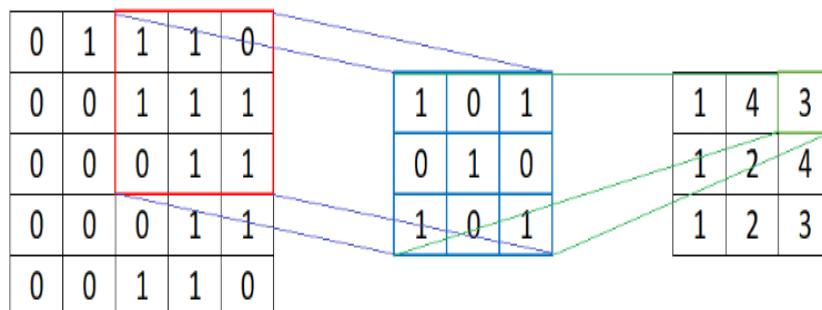


Gambar 2.1. Ilustrasi Arsitektur CNN

Pada Gambar 2.1 menunjukkan bahwa arsitektur CNN terdiri dari beberapa komponen: lapisan input, convolutional, aktivasi, dan pooling (Santoso, I. B., et al., 2024). Pada lapisan input digunakan untuk memasukkan citra MRI setelah pra-pemrosesan hingga tahap convolution layer, bergantung pada bentuk input yang dibentuk dari citra asli pada skema yang diusulkan.

a) Convolution layer

Convolution layer adalah komponen utama yang membedakan CNN dari neural network lainnya. Lapisan ini berfungsi mengekstraksi citra MRI melalui proses convolution, dilakukan pada setiap citra MRI otak yang terdapat pada lapisan sebelumnya dengan cara menggeser filter. Proses ini menghasilkan banyak peta fitur citra MRI untuk mendapatkan karakteristik citra (Santoso, I. B., *et al.*, 2024). dengan mengaplikasikan operasi matematis antara matriks citra dan filter.

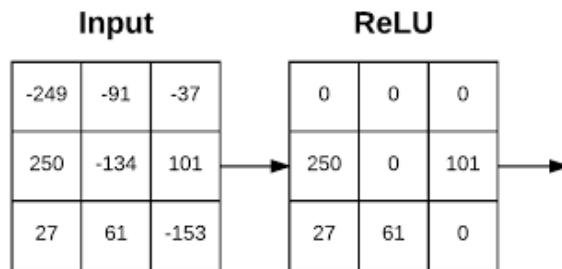


Gambar 2. 2. Operasi Matematis Proses Konvolusi
(Sumber: Mohamed Amine Mahjoubi, *et al.*, 2023)

b) Activation layer

Fungsi aktivasi berperan penting dalam CNN karena menentukan keluaran neuron dan meningkatkan sifat nonlinier dari fungsi keputusan dengan menerapkan fungsi aktivasi (Santoso, I. B., *et al.*, 2024). Memungkinkan model mempelajari hubungan kompleks antara masukan dan keluaran. Fungsi umum yang digunakan adalah ReLU, Pilihan fungsi aktivasi bergantung pada masalah spesifik yang sedang dipecahkan dan dapat berdampak signifikan pada kinerja CNN.

Penting untuk memilih fungsi aktivasi dalam CNN dengan hati-hati, karena pilihan yang salah dapat menyebabkan pelatihan dan konvergensi yang lambat, atau bahkan mencegah jaringan mempelajari pola yang diinginkan dalam data (Mahjoubi, M. A., *et al.*, 2023). Nilai keluaran neuron ditetapkan menjadi 0 jika inputnya negatif, dan jika inputnya positif, nilai keluaran neuron tersebut merupakan aktivasi input itu sendiri (Muis, A., *et al.*, 2023).



Gambar 2.3. Aktifasi ReLU
(Sumber: Rosebrock, Adrian.)

c) Pooling layer

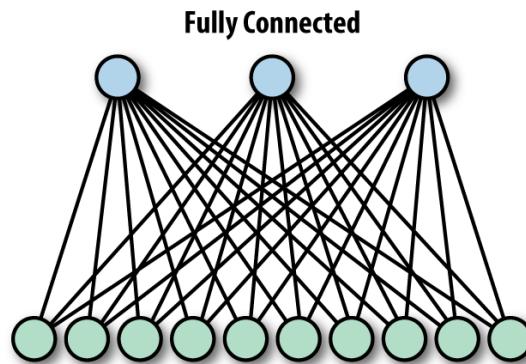
Pooling layer dalam penelitian ini digunakan untuk memasukkan citra MRI otak ke dalam neuron setelah pra-pemrosesan hingga tahap convolution (Santoso, I. B., *et al.*, 2024). Tugas lapisan ini adalah mengecilkan peta fitur, yang berarti lebih sedikit komputasi dan parameter yang diperlukan untuk mengoperasikan neuron. Oleh karena itu, dapat dikatakan bahwa ringkasan fitur merupakan keluaran dari lapisan ini. dalam hal ini, Objek peta fitur yang paling banyak dicakup oleh filter menggunakan pengumpulan maksimum (Mahjoubi, M. A., *et al.*, 2023)

d) Flattening

Flattening adalah proses mengubah matriks fitur dihasilkan dari lapisan convolution dan Max-pooling menjadi satu dimensi yang dimasukkan ke dalam lapisan fully connected (dense layer) untuk klasifikasi (Santoso, I. B., *et al.*, 2024). Dalam klasifikasi citra, setelah proses max-pooling menghasilkan matriks fitur, tahap flattening bertujuan untuk menyusun kembali data tersebut sehingga setiap fitur dapat dibandingkan dan dianalisis secara efektif (Muis, A., *et al.*, 2023).

e) Output (classification) layer

Layer klasifikasi berada di urutan terakhir dalam arsitektur CNN. Fully-Conected Layer adalah sebuah lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya sama seperti halnya dengan neural network biasa. Pada dasarnya lapisan ini biasanya digunakan pada MLP (Multi Layer Perceptron) yang mempunyai tujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linier. Perbedaan antara lapisan fully-connected dan lapisan konvolusi biasa adalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada input, sementara lapisan fully-connected memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan produk dot, sehingga fungsinya tidak begitu berbeda. Berikut ini adalah proses fully-connected :



Gambar 2. 4. Fully-Conected Layer

Pada layer klasifikasi menggunakan fungsi aktivasi "SoftMax," (Santoso, I. B., *et al.*, 2024; Mahjoubi, M. A., *et al.*, 2023). Memungkinkan model untuk mengklasifikasikan fitur yang diekstraksi dari citra masukan ke dalam kelompok terpisah. Fungsi ini mengubah keluaran dari lapisan sebelumnya menjadi probabilitas yang menjumlahkan 1, sehingga setiap kelas dapat diidentifikasi dengan jelas berdasarkan data pelatihan yang telah diberikan (Mahjoubi, M. A., et al., 2023).

2.3. Majority Voting

Majority Vote atau Suara Mayoritas adalah salah satu proses dari Bootstrap Aggregating (Bagging) yang merupakan tahapan dari metode Random Forest Classification (Cheng *et al.*, 2019; Liu *et al.*, 2021). Majority voting adalah teknik pengambilan keputusan yang umum digunakan dalam sistem klasifikasi ensemble, kinerja pengklasifikasi ensemble lebih baik (Alturki, N., et al 2023). dimana beberapa model atau classifier independen bekerja secara paralel untuk memprediksi hasil klasifikasi.

Teknik ini dapat meningkatkan akurasi minimum dengan meminimalkan dampak kesalahan prediksi dari model individual, serta memberikan kerangka pengambilan keputusan yang kuat melalui konsensus dari beberapa model yang bekerja bersama (Santoso, I. B., et al., 2024). Dengan mengurangi kesalahan klasifikasi, teknik ini memungkinkan kesalahan dari satu model dikoreksi oleh model lain, sehingga meningkatkan akurasi keseluruhan sistem. Pendekatan ini sangat bermanfaat ketika prediksi dari satu model mungkin tidak cukup akurat. Menurut (Nassar, S.E., *et al.* 2023), majority voting efektif dalam memperbaiki kelemahan masing-masing model dan meningkatkan performa sistem klasifikasi ensemble.

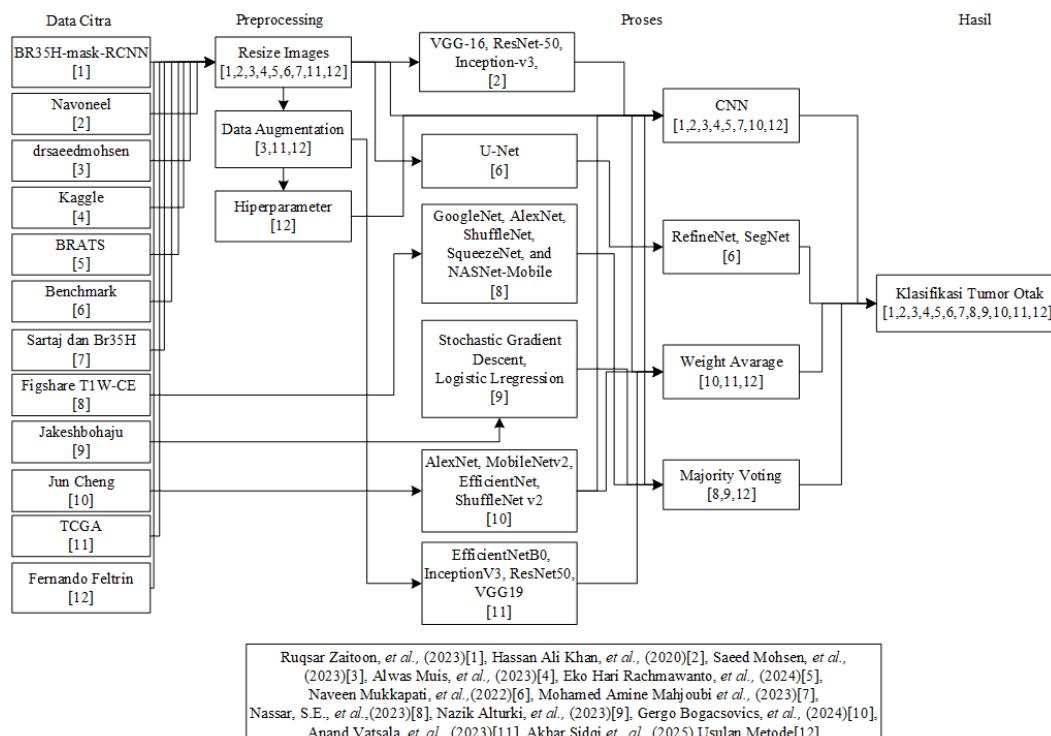
2.4. Weighted Average

Weighted average merupakan metode perhitungan rata-rata yang digunakan dalam klasifikasi ensemble untuk menggabungkan output dari beberapa model. Dalam pendekatan ini, nilai prediksi diperoleh dengan menghitung rata-rata nilai softmax dari masing-masing model, kemudian kelas dengan nilai rata-rata tertinggi dipilih sebagai hasil akhir klasifikasi (Santoso, I. B., *et al.*, 2024). Metode ini memungkinkan setiap model memberikan kontribusi yang proporsional terhadap hasil akhir berdasarkan kinerjanya. Untuk itu, dilakukan penghitungan koefisien (Bogacsovics, G., *et al.*, 2024) yang merepresentasikan tiap model, sehingga diharapkan dapat meningkatkan akurasi klasifikasi (Vatsala, A., *et al.*, 2023) dan performa keseluruhan sistem ensemble.

2.5. Kerangka Teori

Kerangka teori berfungsi sebagai landasan berpikir dalam penelitian, memberikan panduan sistematis untuk memahami, dan menjelaskan hubungan antara berbagai fakta. Menurut Nawawi (2007), kerangka teori memiliki peran penting dalam memecahkan masalah, dengan membantu peneliti dalam menganalisis dan merumuskan solusi. Sementara itu, Yusuf (2017) menambahkan bahwa teori dalam kerangka teori juga berfungsi untuk menemukan keterkaitan antara fakta secara terstruktur.

Kerangka teori dalam penelitian ini menggambarkan konsep dan pendekatan sistematis yang digunakan untuk mengklasifikasikan tumor otak, diperlihatkan pada Gambar 2.5.



Gambar 2.5. Kerangka Teori

Dalam kerangka teori studi pustaka yang ditunjukkan pada Gambar 2.4, proses klasifikasi jenis tumor otak terdiri dari beberapa langkah utama. Langkah pertama adalah pengumpulan data citra MRI, di mana sebagian besar dataset diperoleh dari situs Kaggle. Setelah pengumpulan data, tahap berikutnya adalah preprocessing, di mana Muis, A., (2023) dan Rachmawanto, E. H., (2024) melakukan normalisasi ukuran citra untuk memastikan kesesuaian dengan model klasifikasi. Setelah preprocessing, model CNN dirancang untuk mengekstraksi fitur-fitur penting dari citra MRI. Proses ekstraksi ini memanfaatkan lapisan konvolusi dan max-pooling, yang bertujuan untuk meningkatkan performa klasifikasi tumor otak, seperti yang telah dilakukan oleh Zaitoon, R., *et al* (2023).

Penelitian ini juga merujuk pada beberapa jurnal terdahulu yang telah melakukan penelitian. Daftar jurnal-jurnal terdahulu yang dijadikan acuan dapat dilihat pada Tabel 2.1, yang merangkum berbagai pendekatan dan hasil performa akurasi penelitian terkait klasifikasi tumor otak berbasis citra MRI.

Tabel 2.1. Performa Model Penelitian pada setiap Kerangka Teori

No	Peneliti	Metode	Akurasi
1	Ruqsar Zaitoon, <i>et al.</i> , (2023)	CNN, Hyper-Parameter, Multiple Layer	99,87%
2	Hassan Ali Khan, <i>et al.</i> , (2020)	VGG-16, ResNet-50, Inception-v3, CNN	95,78%
3	Saeed Mohsen, <i>et al.</i> , (2023)	CNN	95,78%
4	Alwas Muis, <i>et al.</i> , (2023)	CNN	84%
5	Eko Hari Rachmawanto, <i>et al.</i> , (2024)	CNN	94,14%
6	Naveen Mukkapati, <i>et al.</i> , (2022)	CNN, U-Net, RefineNet, SegNet	96,85%

Tabel Lanjutan 2.1. Performa Model Penelitian pada setiap Kerangka Teori

No	Peneliti	Metode	Akurasi
7	Mohamed Amine Mahjoubi <i>et al.</i> , (2023)	AlexNet, Inceptionv3, ResNet-50, VGG- 16, GoogleNet, CNN	95,44%
8	Nassar, S.E., <i>et al.</i> ,(2023)	GoogleNet, AlexNet, ShuffleNet, SqueezeNet, NASNet-Mobile Majority Voting Technique	99,31%
9	Nazik Alturki, <i>et al</i> (2023)	Stochastic Gradient Descent (SGD), Logistic Lregression (LR), Majority Voting Technique	99,9%
10	Gergo Bogacsovics, <i>et al.</i> , (2024)	AlexNet, MobileNetv2, EfficientNet, dan ShuffleNet v2, CNN, Weighted Average	90%
11	Anand Vatsala, <i>et. al.</i> , (2023)	EfficientNetB0, InceptionV3, ResNet50, VGG19,Weighted Average	98%
12	Akbar Sidqi <i>et., al.</i> (2025) Usulan Metode	CNN, Majority Voting, Weighted Average	-

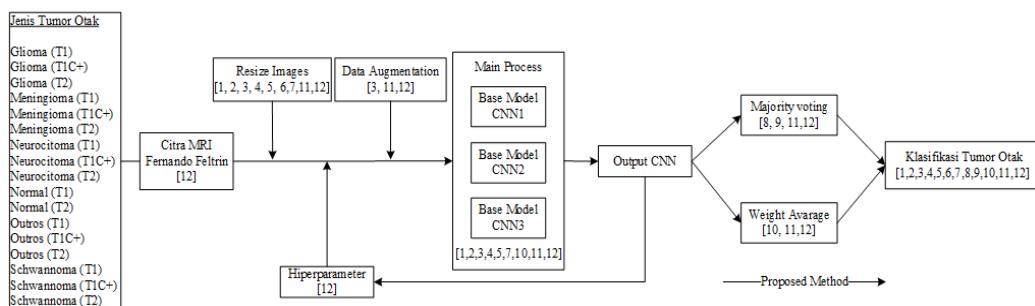
Penelitian sebelumnya yang ditampilkan dalam Tabel 2.1 menunjukkan beberapa perbedaan, terutama dalam arsitektur model CNN yang digunakan, seperti VGG19, AlexNet, MobileNetv2, EfficientNet, dan lainnya sebagaimana dilakukan oleh Khan, H. A., (2020), Naveen (2022) dan Mahjoubi, M. A., (2023), serta jenis dataset tumor dan ukuran filter yang digunakan. Seperti yang dilakukan oleh Vatsala, A., et al., (2023) dan Nassar, S. E., et al., (2024) metode ensemble learning digunakan untuk meningkatkan akurasi klasifikasi. Mengacu pada penelitian sebelumnya, penelitian ini mengusulkan untuk menggunakan beberapa model CNN lightweight dengan variasi ukuran filter berbeda serta menggabungkannya dengan metode ensemble seperti majority voting dan weighted average. Tujuan dari pendekatan untuk mengurangi kesalahan model individu dan meningkatkan performa klasifikasi tumor otak.

BAB III

METODOLOGI PENELITIAN

3.1. Kerangka Konseptual

Penelitian ini bertujuan mengembangkan metode klasifikasi tumor otak berbasis citra MRI dengan pendekatan *Convolutional Neural Network* (CNN). Beberapa model CNN *lightweight* dikombinasikan melalui metode *ensemble*, yaitu *majority voting* dan *weighted averaging*, guna meningkatkan akurasi dan performa klasifikas. Adapun kerangka konseptual penelitian ini diperlihatkan pada Gambar 3.1.



Ruqsar Zaitoon, *et al.*, (2023)[1], Hassan Ali Khan, *et al.*, (2020)[2], Saeed Mohsen, *et al.*, (2023)[3], Alwas Muis, *et al.*, (2023)[4], Eko Hari Rachmawanto, *et al.*, (2024)[5], Naveen Mukkapat, *et al.*, (2022)[6], Mohamed Amine Mahjoubi *et al.*, (2023)[7], Nassar, S.E., *et al.*, (2023)[8], Nazik Alturki, *et al.*, (2024)[9], Gergo Bogacsovics, *et al.*, (2024)[10], Anand Vatsala, *et al.*, (2023)[11], Akbar Sidqi, *et al.*, (2025)[12].

Gambar 3.1. Kerangka Konseptual

Gambar 3.1. Menggambarkan tahapan-tahapan yang dilakukan dalam proses penelitian, mulai dari input citra MRI, tahap praproses, proses utama ekstraksi dan klasifikasi fitur, hingga tahap kombinasi model untuk memperoleh hasil klasifikasi akhir.

Pada tahap awal, citra MRI yang digunakan berasal dari dataset Fernando

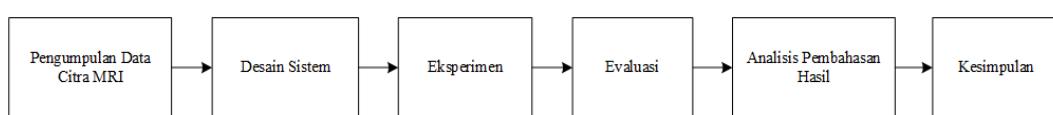
Feltrin yang terdiri dari 17 jenis tumor otak. Dataset ini kemudian melalui tahap preprocessing, yang mencakup proses resize images untuk menyeragamkan ukuran citra, dilanjutkan dengan data *augmentation* untuk memperbanyak variasi data, dan tuning hyperparameter guna mengoptimalkan kinerja model CNN.

Selanjutnya, data yang telah diproses digunakan dalam proses utama, yaitu *feature extraction* dan *classification* menggunakan arsitektur CNN. Model CNN ini digunakan untuk mengekstraksi fitur penting dari citra MRI dan melakukan klasifikasi awal terhadap jenis tumor otak. Untuk meningkatkan akurasi hasil prediksi klasifikasi, dilakukan *ensemble* dengan dua pendekatan, yaitu *majority voting* dan *weight averaging*. Hasil dari kedua pendekatan ini dikombinasikan untuk menghasilkan klasifikasi tumor otak yang lebih optimal dan akurat.

Secara keseluruhan, kerangka konseptual ini menjadi landasan dalam mengembangkan *proposed method* yang bertujuan meningkatkan performa klasifikasi citra MRI tumor otak menggunakan pendekatan kombinasi model deep learning.

3.2. Alur Penelitian

Pada penelitian klasifikasi jenis tumor otak, Gambar 3.2 menggambarkan alur penelitian yang dimulai dari tahap pengumpulan data citra MRI, kemudian dilanjutkan dengan desain sistem, eksperimen, evaluasi, analisis pembahasan hasil dan terakhir kesimpulan, yang diperlihatkan pada Gambar 3.2.

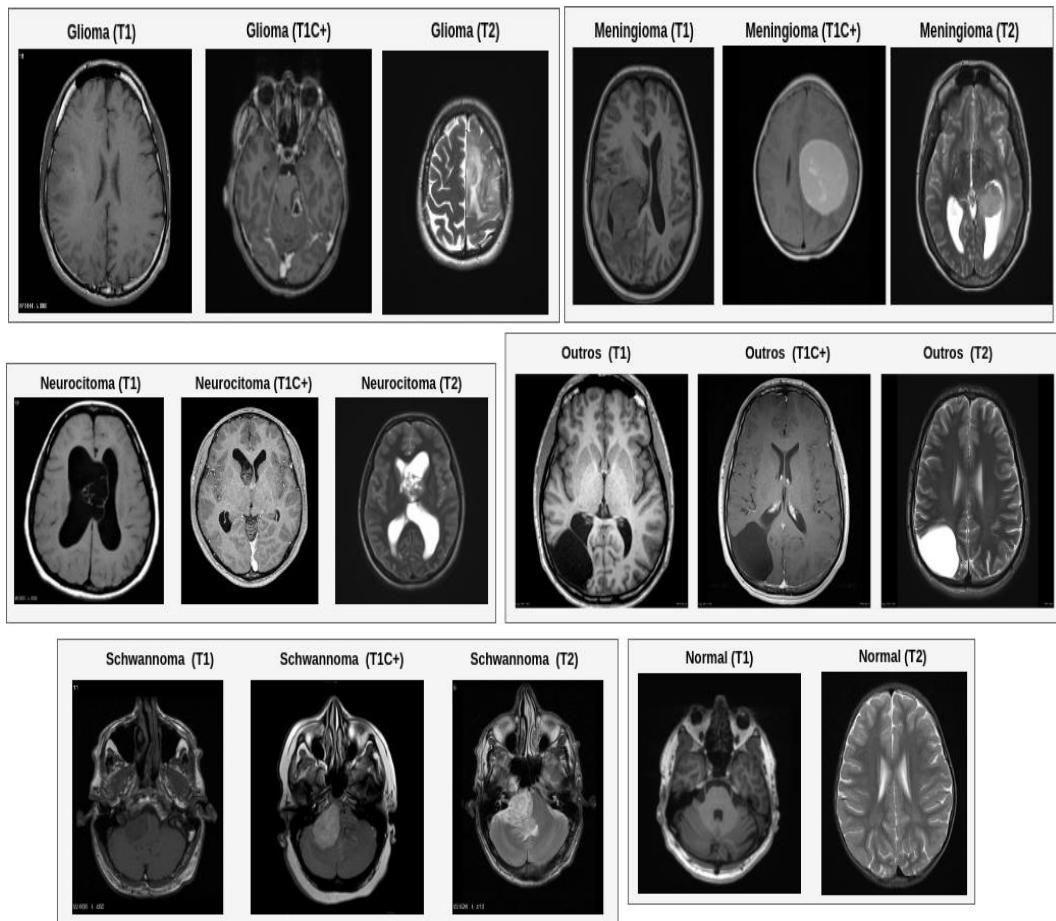


Gambar 3.2. Alur Penelitian

Gambar 3.2 memperlihatkan alur penelitian yang diawali dengan pengumpulan data citra MRI sebagai basis utama dalam pengembangan model. Tahap berikutnya adalah desain sistem yang mencakup pemilihan arsitektur serta parameter-parameter yang relevan untuk mendukung proses pembelajaran. Selanjutnya, dilakukan eksperimen sebagai proses pengujian performa model menggunakan data yang telah dikumpulkan. Hasil eksperimen kemudian dievaluasi secara komprehensif guna mengukur akurasi dan efektivitas sistem yang dikembangkan. Proses evaluasi ini dilanjutkan dengan analisis dan pembahasan hasil untuk memberikan interpretasi mendalam terhadap temuan penelitian, diakhiri dengan penyusunan kesimpulan yang merangkum hasil utama serta memberikan arahan untuk pengembangan penelitian selanjutnya.

3.3. Pengumpulan Data Citra MRI

Penelitian ini menggunakan dataset citra MRI dengan perspektif aksial pada sensitivitas T1, T1C+, dan T2, yang berasal dari Fernando Feltrin. Dataset ini berisi total 4415 citra MRI yang terbagi ke dalam 17 kelas, yaitu: glioma (T1), glioma (T1C+), glioma (T2), meningioma (T1), meningioma (T1C+), meningioma (T2), neurocitoma (T1), neurocitoma (T1C+), neurocitoma (T2), normal (T1), normal (T2), outros (T1), outros (T1C+), outros (T2), schwannoma (T1), schwannoma (T1C+), dan schwannoma (T2). Semua data ini diunduh dari situs Kaggle. Perbedaan jenis tumor otak dalam dataset tersebut dapat dilihat pada Gambar 3.3.



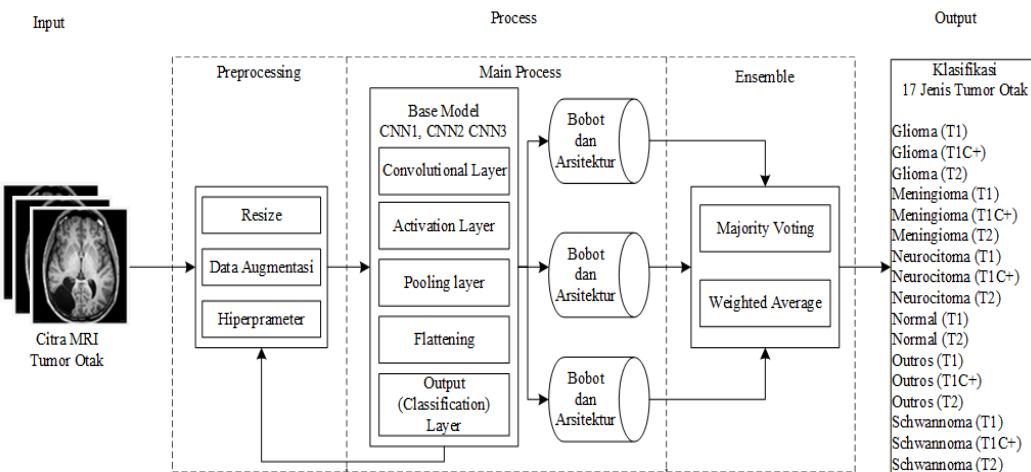
Gambar 3.3. Otak Normal dan Tumor Otak T1, T1C+, T2

3.4. Desain Sistem

Menurut Hartono (1989), analisis sistem merupakan proses evaluasi keseluruhan sistem informasi untuk mengidentifikasi dan mengevaluasi masalah, peluang, hambatan, serta kebutuhan yang diantisipasi. Tujuannya adalah memberikan saran perbaikan yang berkaitan dengan komponen sistem.

Sementara itu. Jhon Bruch dan Gary Grudnitski (Hartono, 1989), desain sistem dapat didefinisikan sebagai representasi atau pengaturan elemen-elemen individu menjadi satu unit fungsional yang terpadu. Pemilihan metode penelitian yang tepat sangat bergantung pada maksud dan tujuan penelitian tersebut.

Selain itu, menurut George M. Scott, desain sistem juga menentukan bagaimana suatu sistem akan menyelesaikan apa yang perlu diselesaikan. Hal ini menekankan pentingnya perencanaan dan pengorganisasian yang efektif dalam pengembangan sistem untuk mencapai tujuan yang diinginkan. Hasilnya, sistem dirancang secara detail berdasarkan hasil analisis yang telah dilakukan. Diperlihatkan pada Gambar 3.4.



Gambar 3.4. Desain Sistem

Gambar 3.4 menunjukkan desain sistem klasifikasi tumor otak berbasis CNN dengan pendekatan *ensemble* yang dikembangkan untuk meningkatkan akurasi identifikasi klasifikasi jenis tumor. Proses diawali dengan input citra MRI tumor otak dari sumber publik (Kaggle.com), kemudian melalui tahap *preprocessing* berupa *resize*, augmentasi, dan pengaturan hiperparameter guna menyiapkan data secara optimal.

Selanjutnya, citra yang telah diproses digunakan pada tiga base model CNN (CNN1, CNN2, CNN3) *lightweight* secara terpisah dengan dataset yang sama. Masing-masing model mengekstraksi fitur melalui lapisan konvolusi,

aktivasi, *pooling*, dan *flattening*, lalu memetakan fitur tersebut ke dalam kelas-kelas tumor otak melalui lapisan klasifikasi (*fully connected feedforward*).

Hasil prediksi dari masing-masing model digabungkan menggunakan metode *ensemble*, yaitu *majority voting* dan *weighted average*, guna meningkatkan akurasi klasifikasi.

Output dari sistem ini adalah klasifikasi 17 jenis tumor otak berdasarkan kategori yang teridentifikasi, dengan evaluasi performa melalui metrik akurasi, presisi, recall, sensitivitas, dan confusion matrix

3.5. Resize

Tahap resize dilakukan untuk menyeragamkan dimensi citra MRI menjadi ukuran 224×224 piksel. Ukuran ini dipilih karena merupakan standar input yang umum digunakan dalam arsitektur CNN modern (Zaitoon, R., *et al.*, 2023, Remzan, N., *et al.*, 2022,), sehingga model memproses data secara konsisten. Selain itu, ukuran 224×224 cukup representatif untuk mempertahankan detail penting pada citra tanpa membebani komputasi, serta kompatibel dengan berbagai arsitektur pretrained dan pengolahan batch dalam proses pelatihan model.

3.6. Data Augmentasi

Tahap augmentasi data diterapkan untuk memperkaya variasi citra latih secara artifisial, dengan tujuan meningkatkan kemampuan generalisasi model dalam menghadapi data nyata. Teknik augmentasi yang digunakan mencakup *rotation_range*, *zoom_range*, *horizontal_flip*, dan *fill_mode*. Rotasi membantu model mengenali objek meskipun terjadi perubahan sudut; *zoom* memungkinkan

model mendeteksi fitur dalam berbagai skala; pencerminan *horizontal* menambah keragaman orientasi citra; sedangkan *fill_mode* mengisi area kosong akibat transformasi dengan nilai piksel terdekat secara alami. Kombinasi teknik ini dirancang untuk mencegah overfitting serta meningkatkan ketahanan model terhadap variasi data yang tidak pernah dilihat sebelumnya.

3.7. Hiperparameter

Tunning hiperparameter ini dilakukan secara cermat untuk memastikan bahwa proses pelatihan model CNN *lightweight* berjalan optimal, baik dari segi akurasi maupun efisiensi komputasi. Tujuan utamanya adalah untuk membantu model mengenali pola dan karakteristik citra MRI secara lebih optimal, sehingga mampu mengklasifikasikan jenis tumor otak dengan tingkat akurasi yang tinggi. Pemilihan nilai yang tepat untuk *batch size*, *epoch*, *learning rate*, *optimizer*, dan *kernel size* sangat penting agar model tidak mengalami overfitting maupun underfitting.

3.8. Model Convolutional Neural Network (CNN)

Pada tahap ini, base model CNN *lightweight* dirancang untuk mengekstraksi fitur penting dari citra MRI dengan menerapkan tiga ukuran kernel konvolusi. Penerapan variasi ukuran ini memungkinkan eksplorasi pola dan fitur citra yang beragam, sehingga meningkatkan kemampuan model dalam membedakan karakteristik unik dari 17 jenis tumor otak. Dengan demikian, Pendekatan ini dirancang untuk meningkatkan akurasi klasifikasi secara menyeluruh.

3.8.1 Convolutional Layer

Dalam penelitian ini, setiap citra MRI tumor otak yang dimasukkan ke neuron diproses melalui tiga ukuran kernel konvolusi. Proses ini menghasilkan beberapa peta fitur yang membantu mengidentifikasi karakteristik citra MRI. Dapat dituliskan secara matematis sebagai berikut (Santoso, I. B., *et al.*, 2024).

$$Z_i = f(W_i X + b_i), \quad i = 1, 2, 3 \quad (1)$$

Dimana :

- Z_i : Output dari neuron ke-i.
- f : Fungsi aktivasi yang digunakan non-linearitas.
- W_i : Matriks bobot yang digunakan oleh neuron ke-i.
- X : Vektor input yang diterima oleh neuron.
- b : Bias neuron ke-i, ditambahkan untuk menggeser output dari neuron.

3.8.2. Activation Layer

Activation layer merupakan komponen penting untuk meningkatkan sifat non-linier fungsi keputusan. Peningkatan ini dicapai dengan menerapkan fungsi aktivasi yang stabil dan tidak rusak. Dalam penelitian ini, menggunakan fungsi aktivasi *Rectified Linear Unit* (ReLU) di setiap proses konvolusi. Secara matematis, hal ini dapat dituliskan sebagai berikut (Khan, H. A., *et al.*, 2020, Santoso, I. B., *et al.*, 2024,):

$$\tilde{Z}(Z_i) = \begin{cases} Z_i & \text{Jika } Z_i \geq 0 \\ 0 & \text{Jika } Z_i < 0 \end{cases}, \quad i = 1, 2, 3 \quad (2)$$

Dimana :

- $\tilde{Z}(Z_i)$: Nilai output dari fungsi aktivasi ReLU untuk input Z_i , Simbol tilde (\sim) adalah nilai keluaran setelah diterapkan fungsi aktivasi
- Z_i : Input ke fungsi aktivasi, merupakan output dari lapisan sebelumnya,
- \geq : digunakan untuk menentukan kapan output fungsi aktivasi akan sama dengan nilai input.

- 0 : Nilai hasil fungsi aktivasi ReLU jika nilai input Z_i kurang dari nol.
- < : digunakan untuk menunjukkan kondisi di mana input Z_i negatif.

3.8.3. Pooling Layer

Pooling layer digunakan untuk mengurangi ukuran representasi spasial dari hasil konvolusi. Dengan demikian, pooling layer membantu mengurangi beban komputasi dan mencegah overfitting. Terdapat beberapa teknik untuk mengumpulkan data, pada penelitian ini max-pooling dengan ukuran patch 2x2 digunakan (Mahjoubi, M. A., *et al.*, 2023, Santoso, I. B., *et al.*, 2024,). dengan persamaan matematis sebagai berikut:

$$g_i(\tilde{Z}_i) = \text{Max}\{\tilde{Z}_{ij}\}j, \quad i = 1,2,3 \quad (3)$$

Dimana:

- $g_i(\tilde{Z}_i)$: Hasil dari operasi pooling untuk neuron atau unit ke-i. Fungsi g_i menerapkan max pooling pada input \tilde{Z}_i
- \tilde{Z}_i : Himpunan input untuk neuron ke-i. berupa nilai-nilai dalam sebuah patch (sub-area) dari feature map input pada layer sebelumnya.
- $\text{Max}\{\tilde{Z}_{ij}\}j,$: Mengambil nilai maksimum dari \tilde{Z}_{ij} , di mana j mewakili indeks dari nilai area rectangular.

3.8.4. Flattening

Proses flattening dilakukan setelah max-pooling pada setiap jalur jaringan CNN, di mana fitur yang diperoleh diubah menjadi vektor. Setiap jalur jaringan mengalami proses ini sebelum fitur digabungkan dan dimasukkan ke dalam lapisan fully connected (FC). Tujuan utama flattening adalah mengubah data multidimensi, seperti gambar, menjadi format vektor agar model dapat melakukan klasifikasi berdasarkan fitur yang telah diekstraksi (Santoso, I. B., *et al.*, 2024,). dengan persamaan matematis sebagai berikut:

$$h_i = flattening(g_i), \quad i = 1, 2, 3 \quad (4)$$

Dimana:

- h_i : Nilai output setelah proses flattening untuk neuron.
- $flattening(g_i)$: Fungsi flatten mengambil output dari pooling layer berbentuk multidimensi,
- g_i : Nilai output dari langkah sebelumnya untuk neuron

3.8.5. Output (Classification) Layer

Sebelum klasifikasi, model melewati lapisan *fully connected* yang menghubungkan seluruh neuron antar lapisan. Lapisan ini menggabungkan fitur citra MRI untuk mengidentifikasi jenis tumor (Mahjoubi, M. A., *et al.*, 2023), dengan jumlah output sesuai kelas pada dataset pelatihan.

Output dari lapisan ini diteruskan ke lapisan akhir dengan fungsi aktivasi softmax untuk menentukan probabilitas dari 17 jenis tumor berdasarkan output sebelumnya (Santoso, I. B., *et al.*, 2024). Fungsi ini memungkinkan model untuk menghasilkan nilai probabilitas yang terdistribusi ke seluruh kelas, sehingga setiap input dapat diklasifikasikan ke dalam kelas dengan probabilitas tertinggi. Secara matematis, fungsi softmax dinyatakan sebagai berikut:

$$y_k(\hat{h}) = \frac{\exp(\hat{h}_k)}{\sum_{j=1}^3 \exp(\hat{h}_j)}, \quad k = 1, 2, 3 \dots 17 \quad (5)$$

Dimana:

- $y_k(\hat{h})$: Probabilitas keluaran untuk kelas ke-k berdasarkan output dari fungsi softmax. Notasi \hat{h} menggunakan output dari lapisan sebelumnya.
- $\exp(\hat{h}_k)$: Fungsi eksponensial dari keluaran neuron untuk kelas ke-k dari lapisan fully connected.
- $\sum_{j=1}^3 \exp(\hat{h}_j)$: Jumlah fungsi eksponensial dari semua keluaran neuron untuk K kelas (terdapat 17 kelas), berfungsi untuk normalisasi.

3.9. Ensemble Learning

Pada penelitian ini, pendekatan ensemble learning diterapkan untuk meningkatkan performa klasifikasi pada 17 kelas jenis tumor otak (T1, T2, ..., T17) dengan menggunakan tiga base model CNN *lightweight*, yaitu CNN1, CNN2, dan CNN3. Dua metode ensemble yang digunakan adalah *majority voting* dan *weighted average*.

3.9.1 Majority Voting

Majority voting adalah metode ensemble yang digunakan untuk memilih kelas tumor berdasarkan dari tiga model CNN. Setiap model memberikan satu prediksi untuk salah satu dari 17 kelas tumor. Sebuah suara v_{ik} di mana setiap model m_i memberikan satu prediksi T_k dengan $i \in \{1,2,3\}$ untuk salah satu dari kelas-kelas tersebut $k \in \{1, 2, 3, \dots, 17\}$, setiap model memberikan suara (1 atau 0) untuk kelas yang di prediksi. Kelas dengan suara terbanyak menjadi keputusan klasifikasi akhir (Santoso, I. B., et al., 2024). Dapat ditulis secara matematis sebagai berikut.

$$V_k = \sum_{i=1}^3 V_{ik} \quad (6)$$

Dimana :

V_k : Jumlah suara untuk kelas

3 : Jumlah total model yang digunakan untuk klasifikasi

V_{ik} : Prediksi suara dari model untuk kelas

Kelas terpilih sebagai hasil klasifikasi akhir

$$h = argmax_k(V_k) \quad h \in \{1,2,3\} \quad k \in \{1,2,3, \dots, 17\} \quad (7)$$

Dimana :

h : Kelas terpilih sebagai hasil klasifikasi akhir

$\text{argmax}_k(V_k)$: Fungsi yang memberikan nilai k yang menghasilkan nilai tertinggi untuk V_k .

3.9.2. Weighted Average

Prediksi dengan weighted average diperoleh dengan menghitung rata-rata nilai softmax dari setiap model (Santoso, I. B., et al., 2024). Hasil klasifikasi kemudian ditentukan dari kelas dengan nilai rata-rata softmax tertinggi. Secara matematis, ini dapat dinyatakan sebagai berikut.

$$h = \text{argmax}_k \sum_{i=1}^3 V_{ik}/3 \quad i \in \{1,2,3\} \quad k \in \{1, 2, 3, \dots, 17\} \quad (8)$$

Dimana:

$V_{ik}/3$: Menghitung rata-rata yang dibagi jumlah model

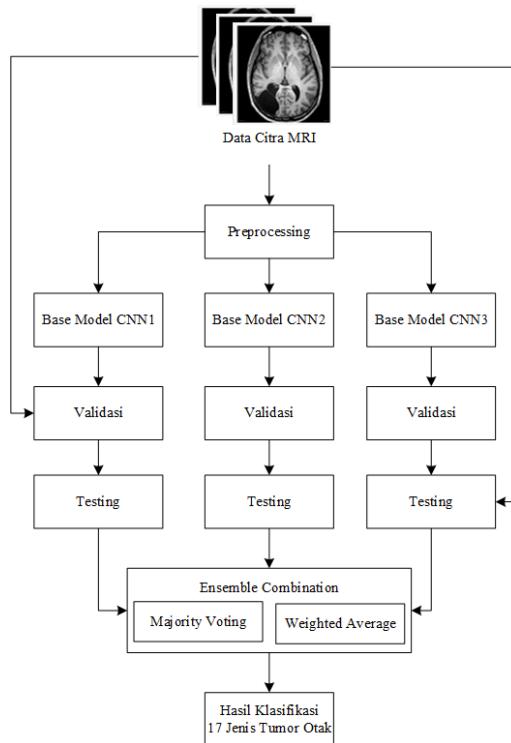
3.10. Training dan Validasi dengan Ensemble CNN

Penelitian ini membagi dataset citra MRI tumor otak ke dalam dua subset utama, yaitu data latih (*training*) dan data validasi (*validation*), dengan distribusi data kelas yang seimbang. Tujuan utama pembagian ini adalah agar model *Convolutional Neural Network* (CNN) *lightweight* dapat mempelajari representasi fitur secara optimal dan mempertahankan kemampuan generalisasi terhadap data yang belum dikenali (*Testing*).

Tahap pelatihan difokuskan pada pembelajaran fitur dan optimisasi parameter model, sedangkan data validasi digunakan untuk mengevaluasi performa secara berkala dan mendeteksi potensi *overfitting*. Evaluasi dilakukan

menggunakan data validasi dan testing untuk mengukur performa model.

Keseluruhan proses ditunjukkan pada Gambar 3.5, yang mencakup tahapan praproses citra MRI, pelatihan tiga base model *lightweight* CNN, validasi performa masing-masing model, serta penggabungan hasil klasifikasi melalui pendekatan *ensemble* menggunakan *metode majority voting* dan *weighted average* untuk memperoleh prediksi akhir klasifikasi terhadap 17 jenis tumor otak.



Gambar 3.5. Training dan Validasi dengan Ensemble CNN

Gambar 3.5 menggambarkan alur klasifikasi 17 jenis tumor otak, yang diawali dengan *preprocessing* citra MRI untuk standarisasi dimensi dan peningkatan kualitas citra MRI. Data yang telah melalui tahap praproses kemudian digunakan untuk melatih tiga arsitektur CNN *lightweight* yang berbeda, yaitu CNN1, CNN2, dan CNN3. Masing-masing model menjalani pelatihan dan

validasi guna mengevaluasi kinerja serta mencegah *overfitting*. Setelah pelatihan, hasil prediksi dari ketiga model dikombinasikan menggunakan pendekatan *ensemble* dengan dua pendekatan: *majority voting* dan *weighted average*. Pendekatan ini bertujuan meningkatkan performa akurasi klasifikasi akhir, sehingga menghasilkan prediksi yang lebih baik terhadap 17 jenis tumor otak.

Setelah pelatihan dan validasi, hasil prediksi dari ketiga model digabungkan menggunakan pendekatan *ensemble*. Dua metode digunakan dalam pendekatan ini, yaitu *majority voting* dan *weighted average*, untuk menghasilkan keputusan klasifikasi akhir yang lebih akurat. Tahapan ini menghasilkan output klasifikasi terhadap 17 jenis tumor otak secara lebih optimal.

3.11. Eksperimen

Uji eksperimen model *convolutional neural network* (CNN) dalam penelitian ini dilakukan menggunakan *Platform Google Colab*, yang menyediakan akses GPU gratis untuk mempercepat pemrosesan data tanpa membutuhkan perangkat keras lokal yang tinggi. Pemrograman menggunakan Python dengan berbagai library seperti *TensorFlow*, *Keras*, *NumPy*, dan *Pandas* sebagai kerangka utama pengujian model.

Eksperimen difokuskan pada pengujian performa CNN dengan variasi preprocessing dan parameter model untuk mendapatkan hasil klasifikasi terbaik. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score.

Selanjutnya, pendekatan *ensemble* diterapkan dengan menggabungkan prediksi beberapa model CNN melalui *majority voting* atau *weighted average* untuk meningkatkan akurasi klasifikasi tumor otak.

3.12. Evaluasi

Dalam evaluasi metode yang diusulkan, digunakan metrik evaluasi seperti akurasi, presisi, sensitivitas (recall), spesifisitas, F1-skor (Santoso, I. B., et al., 2024). Hasil evaluasi ini memberikan gambaran menyeluruh tentang keandalan model dalam mengklasifikasikan jenis tumor otak dari citra MRI. Menurut Mahjoubi, M. A., et al. (2023) Tabel yang digunakan untuk menilai kinerja model klasifikasi, membantu peneliti menganalisis kemampuan model dalam mengidentifikasi setiap kelas. Ini juga memudahkan identifikasi area yang memerlukan perbaikan. Dalam penelitian ini, terdapat 17 jenis tumor otak label pengujian, yang dihitung dari hasil klasifikasi. Misalnya,

- a) True Positive (TP): Jumlah gambar MRI meningioma yang diklasifikasikan dengan benar sebagai Meningioma;
- b) False Negative (FN): Jumlah gambar meningioma yang salah diklasifikasikan sebagai label lain;
- c) True Negative (TN): Jumlah gambar non-meningioma yang diklasifikasikan dengan benar sebagai non-meningioma;
- d) False Positive (FP): adalah jumlah gambar non-meningioma yang salah diklasifikasikan sebagai meningioma.

Perhitungan indikator-indikator ini mengikuti persamaan secara matematis (9–13), yang menjadi dasar untuk mengevaluasi performa klasifikasi tumor otak dalam penelitian ini, dengan tujuan untuk menilai tingkat akurasi, presisi, sensitivitas, dan spesifisitas model yang dikembangkan. Evaluasi ini bertujuan untuk mengetahui model mampu membedakan antara jenis tumor dengan optimal.

$$Akurasi = \frac{(tp+tn)}{(tp+fp+tn+fn)} \quad (9)$$

$$Presisi = \frac{tp}{(tp+fp)} \quad (10)$$

$$Recall (Sensitivitas) = \frac{tp}{(tp+fn)} \quad (11)$$

$$Spesifitas = \frac{tn}{(tn+fp)} \quad (12)$$

$$F - Score = \frac{2x svt x prs}{(svt+prs)} \quad (13)$$

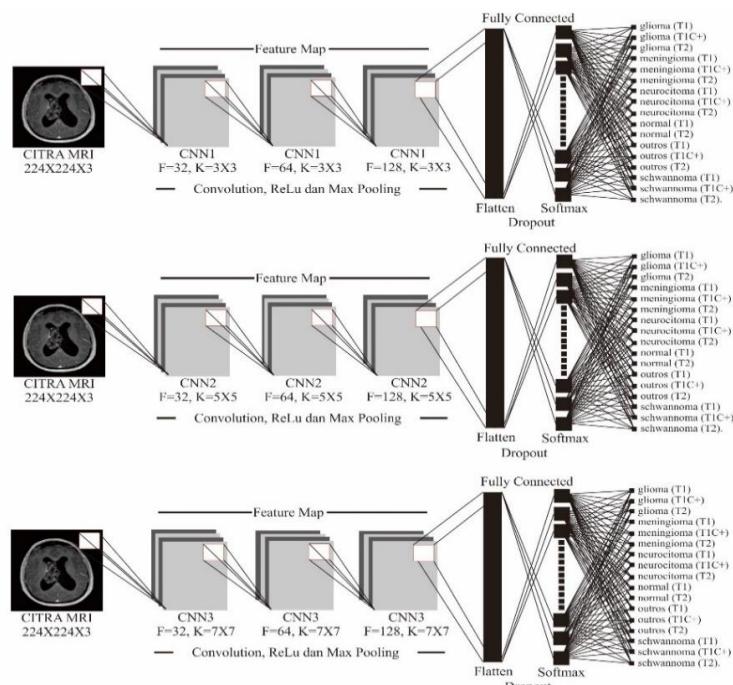
fBAB IV

LIGHTWEIGHT CNN

Analisis dilakukan terhadap model *Convolutional Neural Network* (CNN) yang dirancang khusus untuk mengklasifikasikan 17 jenis tumor otak. Evaluasi dilakukan secara komprehensif untuk mengidentifikasi model dengan performa terbaik dan paling optimal dalam klasifikasi tumor otak.

4.1. Arsitektur Lightweight CNN untuk Klasifikasi Tumor Otak

Penelitian ini mengusulkan tiga arsitektur *lightweight CNN*, yaitu model dengan jumlah parameter dan kompleksitas komputasi yang lebih rendah dibandingkan arsitektur CNN *high capacity* atau *full scale* yang umum digunakan. Bertujuan menghasilkan model yang optimal tanpa menurunkan performa klasifikasi 17 jenis tumor otak pada citra MRI, ditampilkan pada Gambar 4.1.



Gambar 4.1. Arsitektur Base Model Lightweight CNN (Usulan)

Gambar 4.1 memperlihatkan tiga model CNN dengan konfigurasi lapisan serupa, yang hanya berbeda pada ukuran kernel. Variasi ukuran kernel ini bertujuan untuk mengevaluasi pengaruhnya terhadap kemampuan model dalam mengenali kompleksitas dan variasi visual tumor. Semua model dilatih dan diuji menggunakan dataset yang sama guna memperoleh hasil performa yang optimal. CNN1 menggunakan kernel kecil (3×3) untuk mengekstrak fitur lokal seperti tepi dan tekstur halus, CNN2 memakai kernel sedang (5×5) untuk menangkap pola spasial lebih luas, dan CNN3 menggunakan kernel besar (7×7) untuk menjangkau fitur global dan struktur kompleks. Meskipun jumlah lapisan konvolusi sama, perbedaan ukuran kernel memengaruhi kedalaman perceptual serta cakupan informasi yang ditangkap tiap model. Pengembangan ketiga model ini merupakan tahap awal dalam proses *ensemble* yang akan diterapkan pada tahap berikutnya guna meningkatkan akurasi klasifikasi.

4.2. Rasio Data 60:20:20

Dataset citra MRI dibagi menjadi 60:20:20 dengan *random_state* = 42 agar pembagian data konsisten. Tujuannya mengevaluasi pengaruh proporsi data dan filter terhadap performa model. Model diuji menggunakan optimizer Adam, AdamW, dan Nadam dengan metrik akurasi, presisi, recall, spesifisitas, dan F1-Score. Potongan kode pembagian data diperlihatkan sebagai berikut.

```
X_train, X_test, y_train, y_test = train_test_split(images, labels,
test_size=test_size, random_state=42, stratify=labels)
X_train, X_val, y_train, y_val = train_test_split(X_train, y_train,
test_size=validation_split, random_state=42, stratify=y_train)
```

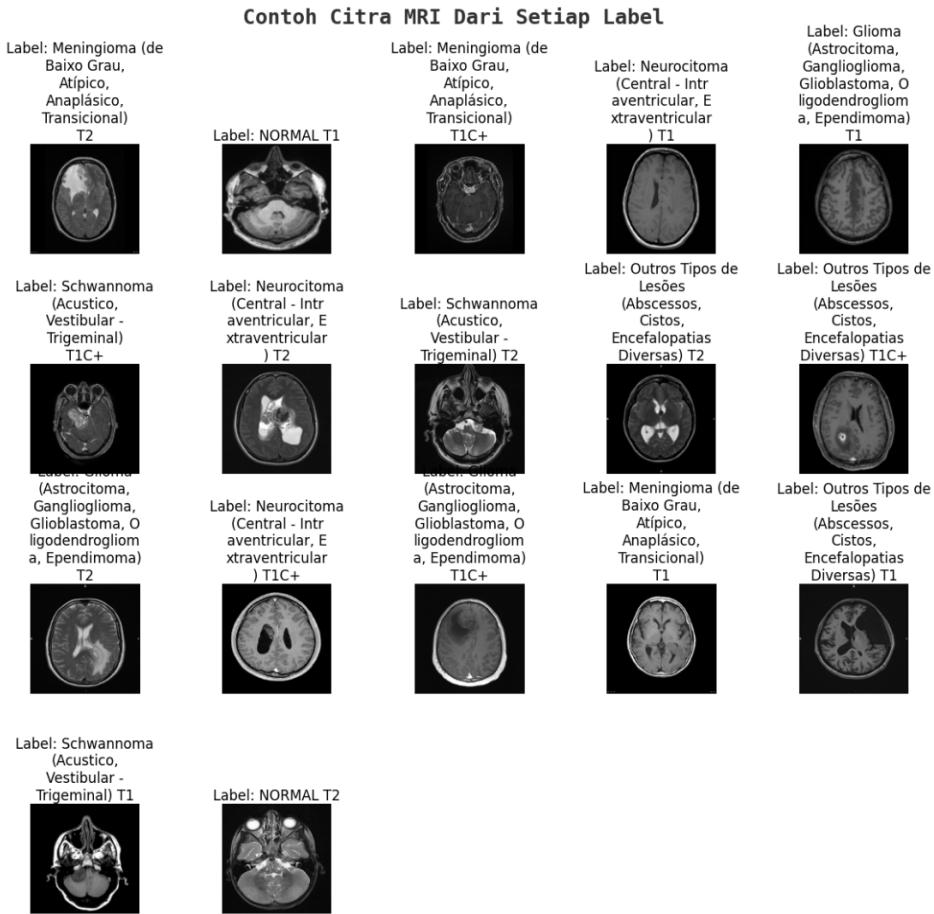
Potongan kode diatas menggunakan pustaka scikit-learn untuk membagi data dengan rasio 60:20:20 (60% pelatihan, 20% pengujian, dan 20% validasi).

Tabel 4.1 menunjukkan hasil pembagian data.

Tabel 4.1. Pembagian Data dengan Rasio 60:20:20

Index	Daftar Kelas Tumor Otak	Training	Testing	Validasi
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	208	69	69
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	91	31	30
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	92	31	30
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	375	125	125
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	101	34	34
5	NORMAL T1	163	54	55
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	207	69	69
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	116	39	39
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	258	86	86
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	74	24	25
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	305	101	102
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	34	11	12
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	29	10	9
13	NORMAL T2	175	58	58
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	67	23	22
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	197	66	66
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	157	52	52
Total		2649	883	883

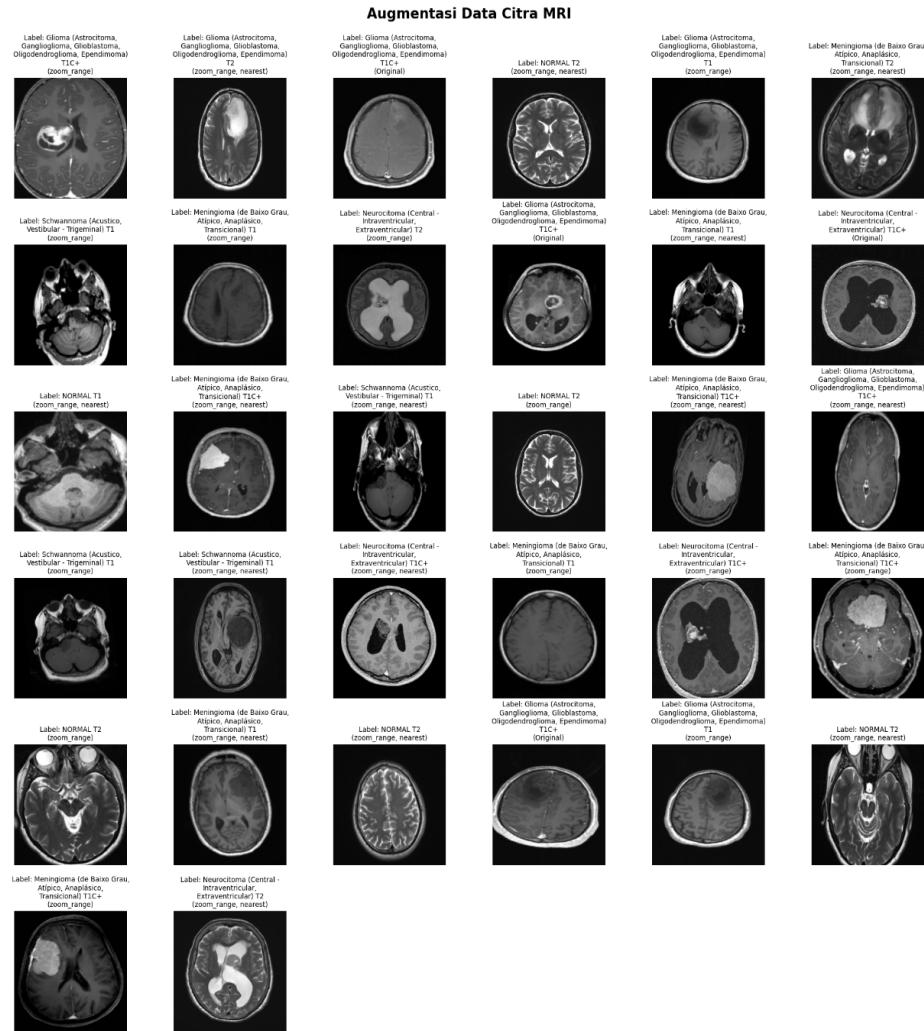
Sebagai bagian dari visualisasi, berikut ditampilkan contoh citra MRI yang telah diolah, mewakili data pelatihan, testing, dan validasi. Diperlihatkan pada Gambar 4.2.



Gambar 4.2. Citra MRI, Subset Testing, Training dan Validasi

4.3. Hasil Augmentasi Data

Penelitian ini juga menerapkan augmentasi data citra untuk meningkatkan kualitas dataset, memungkinkan model mempelajari pola yang lebih beragam. Teknik augmentasi pada tiga base model CNN terdiri dari *rotation_range* = 10, *zoom_range* = 0.2, *horizontal_flip* = True dan *fill_mode* = 'nearest', yang diperlihatkan pada Gambar 4.3.



Gambar 4.3. Hasil Augmentasi Data

4.4. Hiperparameter Model Lightweight CNN

Pada tahap pengujian, tiga base model CNN (CNN1, CNN2, dan CNN3) dikembangkan dan diuji dengan berbagai kombinasi hiperparameter utama, seperti *batch size*, *epoch*, *learning rate*, *optimizer*, dan ukuran kernel. Masing-masing konfigurasi dioptimalkan untuk klasifikasi citra MRI tumor otak. Model hasil tuning CNN1, CNN2, dan CNN3 dikelompokkan dalam Base Model Set, yaitu Base Model 1, Base Model 2, dan Base Model 3, untuk dianalisis lebih lanjut. Rincian hiperparameter ditampilkan pada Tabel 4.2.

Tabel 4.2. Pengujian Hiperparameter Model Lightweight CNN

Base Model	Base Model Set	Batch Size	Learning Rate	Epoch	Kernel Size	Optimizer	Filter Size
CNN1	Base Model 1	32	0.001	50	3x3	Adam	32, 64, 128
CNN2					5x5		
CNN3					7x7		
CNN1	Base Model 2	32	0.001	50	3x3	AdamW	32, 64, 128
CNN2					5x5		
CNN3					7x7		
CNN1	Base Model 3	32	0.001	50	3x3	Nadam	32, 64, 128
CNN2					5x5		
CNN3					7x7		

4.5. Pengujian Ukuran Kernel 3×3 Base Model CNN1

Penelitian ini menguji pengaruh kernel size 3×3 terhadap performa base model CNN1. Model diuji terdiri dari satu hingga tiga blok Conv2D, diikuti max pooling untuk mereduksi dimensi tanpa kehilangan informasi penting. Output dari layer konvolusi terakhir diratakan (*flatten*) dan dilanjutkan ke dua dense layer, dengan satu layer menggunakan dropout guna mengurangi risiko overfitting. Detail arsitektur dan parameter model dapat dilihat pada Tabel 4.3

Tabel 4.3. Arsitektur Base Model CNN1 dengan Kernel Size 3×3

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d (MaxPooling2D)	(None, 111, 111, 32)	0
conv2d_1 (Conv2D)	(None, 109, 109, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 64)	0
conv2d_2 (Conv2D)	(None, 52, 52, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 128)	0
flatten (Flatten)	(None, 86528)	0
dense (Dense)	(None, 128)	11,075,712
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 17)	2,193

Total params: 11,171,153 (42.61 MB)

Trainable params: 11,171,153 (42.61 MB)

Non-trainable params: 0 (0.00 B)

Tabel 4.3 menunjukkan base model CNN1 yang digunakan, dengan total 11.171.153 parameter yang seluruhnya dapat dilatih. Sebagian besar parameter lebih dari 11.171.153 juta berasal dari dense layer pertama, yang menerima input sebesar 86.528 node dari hasil flatten layer konvolusi terakhir. Hal ini menunjukkan bahwa semakin kompleks struktur konvolusi, semakin besar pula dimensi fitur dan jumlah parameter pada tahap klasifikasi. Analisis ini bertujuan mengevaluasi kontribusi arsitektur terhadap kompleksitas dan performa model, khususnya pengaruh kernel size 3×3 terhadap akurasi klasifikasi citra tumor otak.

4.6. Pengujian Ukuran Kernel 5×5 Base Model CNN2

Penelitian ini menguji pengaruh kernel size 5×5 terhadap performa base model CNN2. Model terdiri dari satu hingga tiga blok Conv2D dengan max pooling. Output dari layer terakhir diratakan dan dihubungkan ke dua dense layer, salah satunya menggunakan dropout untuk mengurangi overfitting. Rincian arsitektur dan parameter diperlihatkan pada Tabel 4.4.

Tabel 4.4. Arsitektur Base Model CNN2 dengan Kernel Size 5×5

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 220, 220, 32)	2,432
max_pooling2d (MaxPooling2D)	(None, 110, 110, 32)	0
conv2d_1 (Conv2D)	(None, 106, 106, 64)	51,264
max_pooling2d_1 (MaxPooling2D)	(None, 53, 53, 64)	0
conv2d_2 (Conv2D)	(None, 49, 49, 128)	204,928
max_pooling2d_2 (MaxPooling2D)	(None, 24, 24, 128)	0
flatten (Flatten)	(None, 73728)	0
dense (Dense)	(None, 128)	9,437,312
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 17)	2,193

Total params: 9,698,129 (37.00 MB)
 Trainable params: 9,698,129 (37.00 MB)
 Non-trainable params: 0 (0.00 B)

Tabel 4.4 menunjukkan arsitektur base model CNN2 dengan total 9.698.129 parameter yang dapat dilatih (trainable), di mana sekitar 97% atau lebih dari 9.437.312 parameter berasal dari layer pertama setelah proses flattening terhadap 73.728 node hasil ekstraksi fitur. Mengindikasikan bahwa semakin kompleks struktur konvolusi, semakin besar pula dimensi fitur dan jumlah parameter pada tahap klasifikasi. Analisis ini bertujuan untuk menilai kontribusi arsitektur terhadap kompleksitas dan kinerja model, khususnya dampak kernel size 5×5 terhadap akurasi klasifikasi citra tumor otak.

4.7. Pengujian Ukuran Kernel 7×7 Base Model CNN3

Penelitian ini menguji pengaruh kernel size 7×7 terhadap performa base model CNN3. Model terdiri dari satu hingga tiga blok Conv2D dengan max pooling, diikuti flatten dan dua dense layer, salah satunya dengan dropout. Rincian arsitektur dan parameter ditampilkan pada Tabel 4.5.

Tabel 4.5. Arsitektur Base Model CNN3 dengan Kernel Size 7×7

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 218, 218, 32)	4,736
max_pooling2d (MaxPooling2D)	(None, 109, 109, 32)	0
conv2d_1 (Conv2D)	(None, 103, 103, 64)	100,416
max_pooling2d_1 (MaxPooling2D)	(None, 51, 51, 64)	0
conv2d_2 (Conv2D)	(None, 45, 45, 128)	401,536
max_pooling2d_2 (MaxPooling2D)	(None, 22, 22, 128)	0
flatten (Flatten)	(None, 61952)	0
dense (Dense)	(None, 128)	7,929,984
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 17)	2,193

Total params: 8,438,865 (32.19 MB)
 Trainable params: 8,438,865 (32.19 MB)
 Non-trainable params: 0 (0.00 B)

Tabel 4.5 menunjukkan arsitektur base model CNN3 dengan 8.438.865 parameter yang seluruhnya dapat dilatih, di mana lebih dari 93% (7.929.984 parameter) berasal dari dense layer pertama yang menerima input sebesar 61.952 node dari flatten layer. Hal ini menunjukkan bahwa semakin besar keluaran fitur dari proses konvolusi, semakin tinggi pula beban komputasi pada tahap klasifikasi. Analisis ini mengevaluasi kontribusi struktur kernel size 7×7 terhadap kompleksitas model dan akurasi klasifikasi citra tumor otak.

4.8. Pengujian Filter Size terhadap Kinerja Base Model CNN

Penelitian ini menggunakan ukuran filter 32, 64, dan 128 dalam model *Convolutional Neural Network* (CNN) dimaksudkan untuk mengoptimalkan proses ekstraksi fitur dari citra secara bertahap dan hierarkis. Filter berukuran 32 digunakan pada lapisan awal untuk menangkap fitur-fitur dasar seperti garis, tepi, dan pola tekstur sederhana. Selanjutnya, peningkatan jumlah filter menjadi 64 dan 128 pada lapisan berikutnya memungkinkan model mengenali pola yang lebih kompleks dan abstrak, seiring bertambahnya kedalaman representasi spasial.

Strategi ini bertujuan memperkaya informasi fitur untuk meningkatkan akurasi klasifikasi. Namun, penggunaan banyak filter meningkatkan dimensi output, jumlah node pada flatten layer, dan parameter pada dense layer, yang berdampak pada kompleksitas arsitektur dan kebutuhan komputasi.

Dengan demikian, pemilihan kombinasi filter 32, 64, dan 128 dalam penelitian ini bertujuan untuk mencapai keseimbangan antara kedalaman representasi fitur dan efisiensi komputasi, guna mendukung kinerja optimal dalam klasifikasi citra tumor otak.

4.9. Base Model 1

Base model 1 terdiri dari tiga base model CNN, yaitu CNN1, CNN2, dan CNN3, yang dibedakan berdasarkan ukuran kernel masing-masing, yaitu 3×3 , 5×5 , dan 7×7 . Ketiga model menggunakan optimizer Adam, batch size 32, learning rate 0.001, dan 50 epoch untuk proses pelatihan.

Pengujian dilakukan dengan variasi parameter dan preprocessing data untuk mengukur dampaknya terhadap performa model. Tujuan utama dari pengujian ini adalah untuk mengevaluasi setiap konfigurasi kernel dalam mengekstraksi fitur pada citra tumor otak serta menentukan kombinasi parameter yang menghasilkan klasifikasi paling optimal.

Pendekatan ini juga bertujuan untuk memahami bagaimana perubahan ukuran kernel memengaruhi kemampuan model dalam menangkap pola dan detail pada citra MRI yang kompleks. Dengan demikian, dapat diperoleh model CNN yang terbaik dalam mengenali dan mengklasifikasikan jenis tumor otak berdasarkan citra MRI.

4.9.1. Pengujian Base Model CNN1 (Adam, Kernel 3×3)

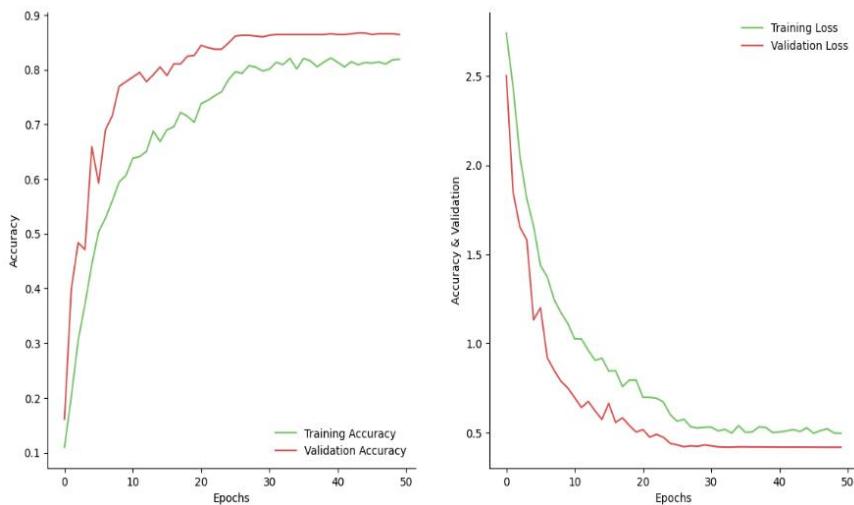
Pengujian ini bertujuan untuk mengevaluasi kinerja model Convolutional Neural Network (CNN) yang menggunakan optimizer Adam dan kernel berukuran 3×3 , guna menilai pengaruh ukuran kernel terhadap akurasi klasifikasi citra MRI tumor otak. Fokus utama dari pengujian ini adalah untuk mengidentifikasi sejauh mana konfigurasi kernel 3×3 mampu mengekstraksi fitur penting yang relevan untuk meningkatkan akurasi dan kemampuan generalisasi model. Hasil pengujian ditunjukkan secara rinci pada Tabel 4.6.

Tabel 4.6. Hasil Base Model CNN1 dengan Adam dan Kernel 3x3

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.97	0.78	0.88	0.98	0.83
1	0.99	0.88	0.68	1.00	0.77
2	0.99	0.96	0.91	1.00	0.93
3	0.98	0.81	0.97	0.98	0.88
4	0.98	0.91	0.91	0.99	0.91
5	0.99	0.85	0.88	1.00	0.86
6	0.97	0.80	0.80	0.98	0.80
7	0.97	0.92	0.88	0.99	0.90
8	0.99	0.96	0.87	1.00	0.91
9	0.99	0.67	0.18	1.00	0.28
10	0.99	0.83	0.94	0.99	0.88
11	1.00	1.00	0.60	1.00	0.75
12	0.96	0.75	0.80	0.98	0.77
13	0.99	0.94	0.96	1.00	0.95
14	0.99	0.88	0.90	0.99	0.89
15	0.97	0.88	0.85	0.99	0.86
16	0.99	0.91	0.88	1.00	0.89

Tabel 4.6 menunjukkan bahwa optimizer Adam dengan kernel 3x3 memiliki akurasi tinggi $\geq 96\%$ dan kinerja stabil dalam klasifikasi tumor otak pada citra MRI. Precision dan recall yang seimbang menunjukkan performa yang baik, meskipun recall menurun pada kelas 9 dan 11. Specificity mendekati 1.00 menandakan rendahnya kesalahan negatif, sehingga model ini memiliki performa yang baik. Gambar 4.4 menampilkan proses pelatihan dan validasi untuk menggambarkan stabilitas dan konvergensi model.

Gambar 4.4 menunjukkan kurva akurasi dan loss selama 50 epoch pelatihan untuk data training dan validasi. Grafik kiri memperlihatkan tren peningkatan akurasi seiring bertambahnya epoch, sedangkan grafik kanan menunjukkan penurunan nilai loss secara bertahap. Visualisasi ini bertujuan untuk mengevaluasi proses pembelajaran serta mengidentifikasi potensi overfitting atau underfitting.



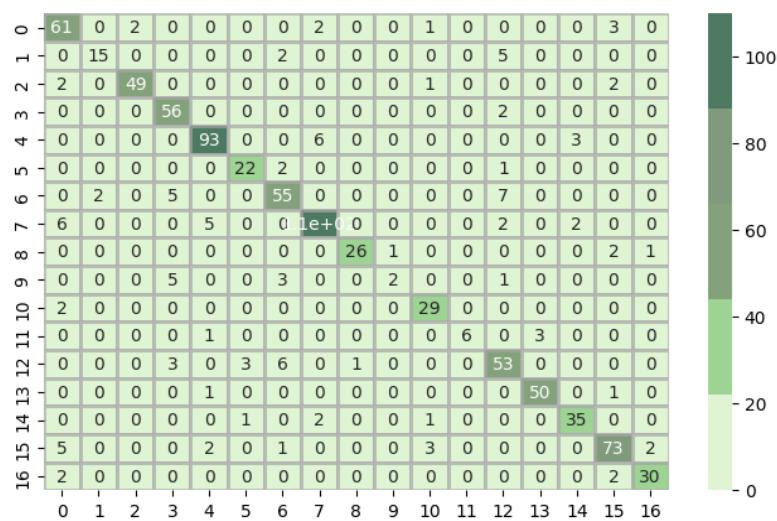
Gambar 4.4. Hasil Pelatihan, Validasi Model CNN1 (Adam, Kernel 3x3)

Pada grafik akurasi (kiri), terlihat bahwa akurasi training meningkat secara konsisten hingga sekitar 82%, sementara akurasi validasi mencapai sekitar 87% dan cenderung stabil setelah epoch ke-25. Hal ini menunjukkan bahwa model mampu belajar dengan baik dari data training dan memiliki generalisasi yang cukup baik terhadap data validasi.

Pada grafik loss (kanan), terjadi penurunan signifikan pada loss training dan validasi, dengan loss validasi menurun lebih cepat dan stabil di sekitar 0.44. Tidak terdapat indikasi overfitting yang jelas, karena kurva validasi tidak menunjukkan kenaikan signifikan meskipun loss training terus menurun. Model menunjukkan performa stabil dengan generalisasi baik tanpa indikasi overfitting, menandakan konfigurasi arsitektur dan parameter pelatihan sudah optimal untuk model ini.

Untuk melengkapi hasil yang diperoleh, dilakukan analisis menggunakan *confusion matrix* guna mengevaluasi kemampuan model dalam membedakan masing-masing jenis tumor otak secara lebih spesifik. Analisis ini penting karena

akurasi keseluruhan tidak selalu mencerminkan kinerja model dalam mengklasifikasikan tiap kelas secara individual. Dengan memerhatikan distribusi prediksi benar dan salah pada setiap kelas, *confusion matrix* memberikan gambaran menyeluruh mengenai pola klasifikasi, memperlihatkan kecenderungan kesalahan model, serta membantu mengidentifikasi kelas-kelas yang sulit dibedakan.



Gambar 4.5. Confusion Matrix Base Model CNN1 (Adam, Kernel 3x3)

Gambar 4.5 *heatmap confusion matrix* di atas menunjukkan kinerja model dalam mengklasifikasikan 17 kelas yang berbeda. Nilai diagonal pada matriks menunjukkan jumlah prediksi yang benar, sedangkan nilai di luar diagonal merepresentasikan kesalahan klasifikasi. Secara umum, model menunjukkan performa yang baik, ditunjukkan oleh dominasi nilai tinggi pada diagonal utama. Kelas ke 3 memiliki jumlah prediksi benar tertinggi 93 sampel, diikuti oleh kelas ke 0 dan ke 7 yang juga menunjukkan akurasi tinggi, termasuk akurasi sempurna pada kelas ke 7. Sebaliknya, beberapa kelas seperti kelas ke 6 dan ke 16 menunjukkan adanya prediksi yang salah ke kelas lain, yang mengindikasikan

kemungkinan adanya kemiripan fitur atau ketidakseimbangan distribusi data.

Sebaran kesalahan yang relatif kecil dan merata menunjukkan bahwa model tidak mengalami bias sistematis terhadap kelas tertentu. Berdasarkan hasil evaluasi ini, model dapat dikategorikan memiliki kemampuan klasifikasi yang optimal.

4.9.2. Pengujian Base Model CNN2 (Adam, Kernel 5x5)

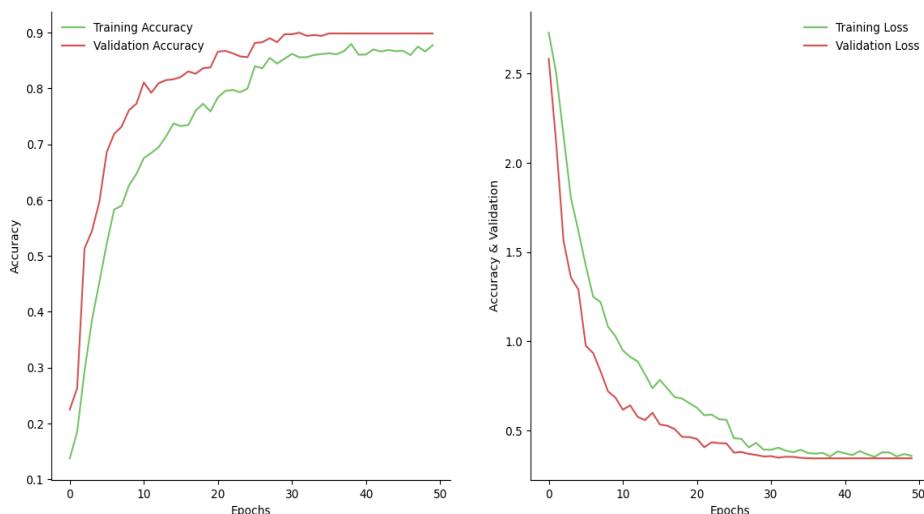
Selanjutnya, dilakukan pengujian dengan kernel size 5x5, diharapkan dapat menangkap fitur yang lebih luas dan meningkatkan akurasi. Perbandingan ini bertujuan untuk mengevaluasi pengaruh ukuran kernel terhadap performa model dalam klasifikasi tumor otak. Hasil pengujian diperlihatkan pada Tabel 4.7.

Tabel 4.7. Hasil Base Model CNN2 dengan Adam dan Kernel 5x5

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.89	0.97	0.99	0.93
1	0.99	0.82	0.82	1.00	0.82
2	0.99	1.00	0.91	1.00	0.95
3	0.99	0.85	0.97	0.99	0.91
4	0.98	0.90	0.93	0.99	0.91
5	1.00	0.96	0.88	1.00	0.92
6	0.96	0.74	0.84	0.98	0.79
7	0.98	0.94	0.88	0.99	0.91
8	1.00	1.00	0.87	1.00	0.93
9	0.99	0.56	0.45	1.00	0.50
10	0.99	0.75	0.97	0.99	0.85
11	1.00	1.00	0.80	1.00	0.89
12	0.97	0.88	0.74	0.99	0.80
13	0.99	0.94	0.96	1.00	0.95
14	0.99	0.90	0.95	1.00	0.92
15	0.98	0.91	0.83	0.99	0.87
16	0.99	0.86	0.94	0.99	0.90

Tabel 4.7 menunjukkan bahwa model CNN dengan kernel 5×5 mampu mencapai akurasi $\geq 96\%$ dan tingkat kesalahan yang rendah. Performa klasifikasi

terbaik ditunjukkan pada kelas 5, 8, 11, dan 13 yang terklasifikasi secara konsisten dan akurat. Namun, kelas 9 masih menunjukkan hasil yang kurang optimal, mengindikasikan perlunya peningkatan dalam representasi fitur spesifik pada kelas tersebut. Penggunaan kernel 5×5 memungkinkan model menangkap informasi spasial yang lebih luas, tetapi juga memerlukan strategi tambahan untuk meningkatkan generalisasi. Selanjutnya, Gambar 4.6 menggambarkan stabilitas proses pelatihan dan konvergensi model, yang ditandai dengan peningkatan akurasi dan penurunan loss secara konsisten pada data training dan validasi.



Gambar 4.6. Hasil Pelatihan, Validasi Model CNN2 (Adam, Kernel 5x5)

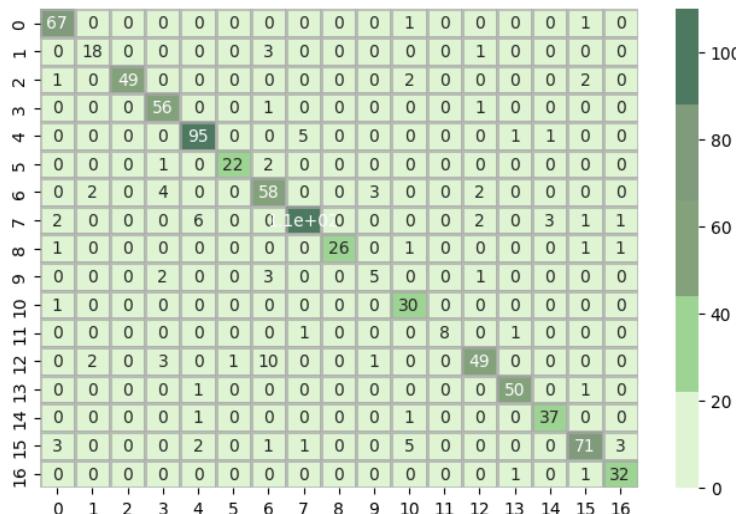
Gambar 4.6 menunjukkan grafik akurasi dan loss selama proses pelatihan dan validasi menggunakan optimizer Adam dengan ukuran kernel 5×5 .

Kurva akurasi (kiri) menunjukkan peningkatan signifikan pada fase awal pelatihan. Akurasi validasi mencapai sekitar 87%, sedikit lebih tinggi dibandingkan akurasi training yang berkisar di 82%, dan keduanya menunjukkan tren stabil setelah epoch ke 30. Menunjukkan kemampuan generalisasi yang baik.

Kurva loss (kanan) mengalami penurunan tajam pada awal pelatihan, lalu melandai mendekati nilai minimum tanpa fluktuasi berarti. Loss validasi cenderung lebih rendah dibandingkan loss training, menandakan tidak terjadi overfitting.

Model dengan optimizer Adam dan kernel 5x5 menunjukkan kinerja pelatihan yang stabil, serta memiliki kemampuan generalisasi yang baik terhadap data validasi. Konfigurasi ini menunjukkan performa yang optimal.

Sebagai pelengkap hasil yang diperoleh, dilakukan analisis *confusion matrix* untuk mengevaluasi kemampuan model dalam membedakan masing-masing jenis tumor otak secara lebih mendalam. Analisis ini menjadi penting mengingat akurasi keseluruhan tidak selalu merepresentasikan performa klasifikasi pada setiap kelas. Diperlihatkan pada Gambar 4.7.



Gambar 4.7. Confusion Matrix Base Model CNN2 (Adam, Kernel 5x5)

Gambar 4.7 menunjukkan confusion matrix untuk klasifikasi 17 jenis tumor otak. Mayoritas prediksi berada pada diagonal utama, menandakan akurasi model yang baik. Kelas ke-4 dan ke-15 menunjukkan hasil sangat akurat dengan masing-

masing 95 dan 71 prediksi benar. Namun, misclassifikasi masih terjadi, terutama pada kelas ke-12 dan ke-13 akibat kemiripan fitur. Meskipun performa model tergolong baik, perbaikan diperlukan pada kelas dengan tingkat kesalahan tinggi untuk meningkatkan akurasi keseluruhan.

4.9.3. Pengujian Base Model CNN3 (Adam, Kernel 7x7)

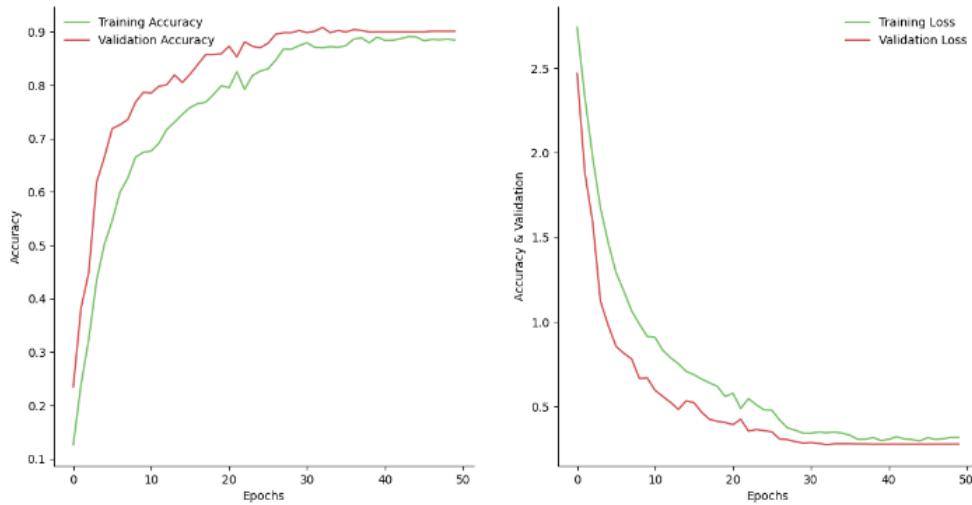
Pengujian dengan kernel size 7x7 dilakukan untuk mengeksplorasi pengaruh ukuran kernel yang lebih besar terhadap kinerja model dalam klasifikasi citra MRI. Hasil pengujian diperlihatkan pada Tabel 4.8.

Tabel 4.8. Hasil Base Model CNN3 dengan Adam dan Kernel 7x7

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.88	0.94	0.99	0.91
1	0.99	0.81	0.77	1.00	0.79
2	0.99	0.95	0.96	1.00	0.95
3	0.99	0.87	0.93	0.99	0.90
4	0.98	0.88	0.96	0.98	0.92
5	0.99	0.90	0.76	1.00	0.82
6	0.97	0.78	0.83	0.98	0.80
7	0.98	0.96	0.91	0.99	0.93
8	0.99	1.00	0.83	1.00	0.91
9	0.99	1.00	0.55	1.00	0.71
10	0.99	0.81	0.97	0.99	0.88
11	1.00	1.00	0.70	1.00	0.82
12	0.98	0.85	0.85	0.99	0.85
13	0.99	0.94	0.92	1.00	0.93
14	0.99	0.95	0.92	1.00	0.93
15	0.97	0.89	0.83	0.99	0.86
16	0.99	0.86	0.91	0.99	0.88

Pada Tabel 4.8 menunjukkan kinerja yang optimal dengan akurasi tinggi 98-99% serta specificity mendekati 1.00, menandakan model mampu membedakan sampel dengan sangat baik. Meskipun recall pada beberapa kelas masih perlu

dingkatkan, model secara keseluruhan telah memberikan hasil yang optimal dalam klasifikasi. Gambar 4.8. menunjukkan stabilitas dan konvergensi model.



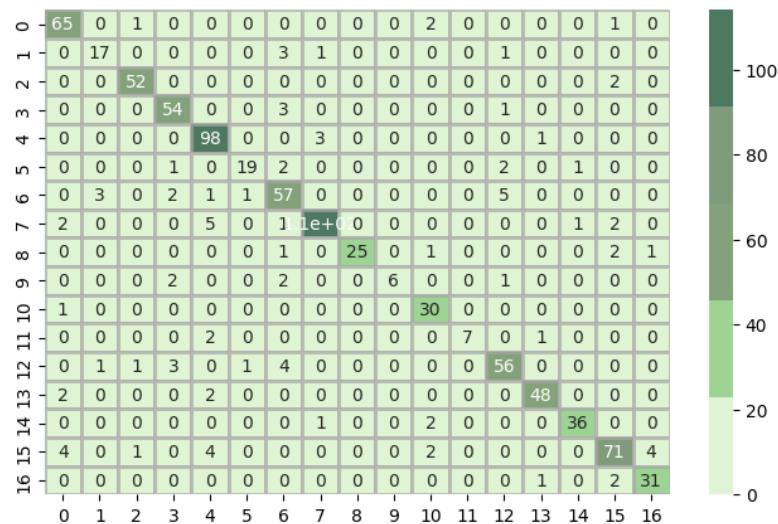
Gambar 4.8. Hasil Pelatihan, Validasi Model CNN3 (Adam, Kernel 7x7)

Gambar 4.8 menunjukkan grafik perbandingan antara akurasi dan loss pada data pelatihan dan validasi selama 50 epoch. Grafik kiri memperlihatkan bahwa akurasi pelatihan dan validasi meningkat secara konsisten seiring bertambahnya epoch, dengan nilai akurasi akhir mendekati 0,9 untuk keduanya. Hal ini mengindikasikan bahwa model belajar secara optimal dan mampu mengenali pola pada data dengan baik.

Sementara itu, grafik kanan memperlihatkan penurunan nilai loss secara signifikan pada awal pelatihan, kemudian stabil mendekati nilai minimum. Penurunan yang seimbang antara training loss dan validation loss menunjukkan bahwa model tidak mengalami overfitting, karena performa pada data validasi tetap stabil dan tidak memburuk meskipun epoch terus bertambah.

Secara keseluruhan, model menunjukkan proses pelatihan yang baik,

dengan konvergensi yang stabil, generalisasi yang optimal, dan minim overfitting. Hal ini memperlihatkan bahwa arsitektur dan parameter pelatihan yang digunakan sudah cukup optimal. Analisis *confusion matrix* digunakan untuk mengevaluasi kemampuan model membedakan setiap jenis tumor secara rinci. Ini penting karena akurasi keseluruhan tidak selalu mencerminkan performa per kelas. Gambar 4.9 menampilkan distribusi prediksi benar dan salah, serta pola kesalahan klasifikasi.



Gambar 4.9. Confusion Matrix Base Model CNN3 (Adam, Kernel 7x7)

Gambar 4.9 menunjukkan *confusion matrix* menunjukkan kinerja klasifikasi model terhadap 17 kelas tumor otak. Mayoritas prediksi benar berada pada diagonal utama, yang menandakan model mampu mengenali sebagian besar kelas dengan baik. Beberapa kelas seperti kelas ke 4 (indeks 4) dan kelas ke 15 (indeks 15) menunjukkan performa yang sangat tinggi dengan masing-masing 98 dan 71 prediksi benar. Namun, terdapat misclassifikasi ringan pada beberapa kelas, seperti kelas ke 5, ke 8, dan ke 16 yang menunjukkan prediksi menyebar ke kelas lain. Mengindikasikan kemiripan fitur antar kelas menyebabkan kesalahan prediksi.

Model menunjukkan performa optimal dengan akurasi tinggi pada sebagian besar dari 17 jenis tumor otak. Meski terdapat beberapa kesalahan, distribusi prediksi menunjukkan kemampuan klasifikasi yang baik. Perbaikan pada kelas dengan error diperlukan untuk meningkatkan stabilitas dan generalisasi.

4.9.4. Evaluasi Base Model 1

Evaluasi terhadap base model 1 dilakukan untuk mengetahui performa model sebelum diterapkan optimasi lebih lanjut, sebagai baseline perbandingan dengan pengujian berikutnya. Diperlihatkan pada Tabel 4.9.

Tabel 4.9. Evaluasi Base Model 1

Base Model 1 dengan Optimizer Adam						
Base Model	Kernel Size	Accuracy	Precision	Recall	Specificity	F1-Score
CNN1	3x3	0.87	0.87	0.87	0.99	0.86
CNN2	5x5	0.89	0.89	0.89	0.99	0.89
CNN3	7x7	0.89	0.89	0.89	0.99	0.89

Pada Tabel 4.9 hasil nilai rata-rata evaluasi 17 jenis tumor. Menunjukkan model dengan kernel 5×5 dan 7×7 memiliki performa terbaik Accuracy, Precision, Recall, F1-Score = 0.89%, sementara kernel 3×3 sedikit lebih rendah Accuracy = 0.87%. Seluruh model memiliki Specificity tinggi 0.99%, menunjukkan deteksi negatif yang sangat baik. Perbedaan kecil dalam Recall dan F1-Score mengindikasikan bahwa semua kernel sudah optimal dalam klasifikasi jenis tumor.

4.10. Base Model 2

Base Model 2 terdiri dari tiga model CNN, yaitu CNN1, CNN2, dan CNN3, yang masing-masing dibedakan berdasarkan ukuran kernel: 3×3 , 5×5 , dan 7×7 .

Ketiga model ini dilatih menggunakan optimizer AdamW, yaitu varian dari Adam yang memisahkan weight decay dari pembaruan gradien. Proses pelatihan dilakukan selama 50 epoch dengan batch size 32 dan learning rate sebesar 0,001. Setiap model menggunakan filter berukuran 32, 64, dan 128 pada lapisan konvolusionalnya.

4.10.1. Pengujian Base Model CNN1 (AdamW, Kernel 3x3)

Pada pengujian ini, dilakukan penerapan optimizer AdamW dengan kernel size 3x3 untuk menilai pengaruhnya terhadap akurasi dalam klasifikasi tumor otak pada citra MRI. Hasil pengujian diperlihatkan pada Tabel 4.10.

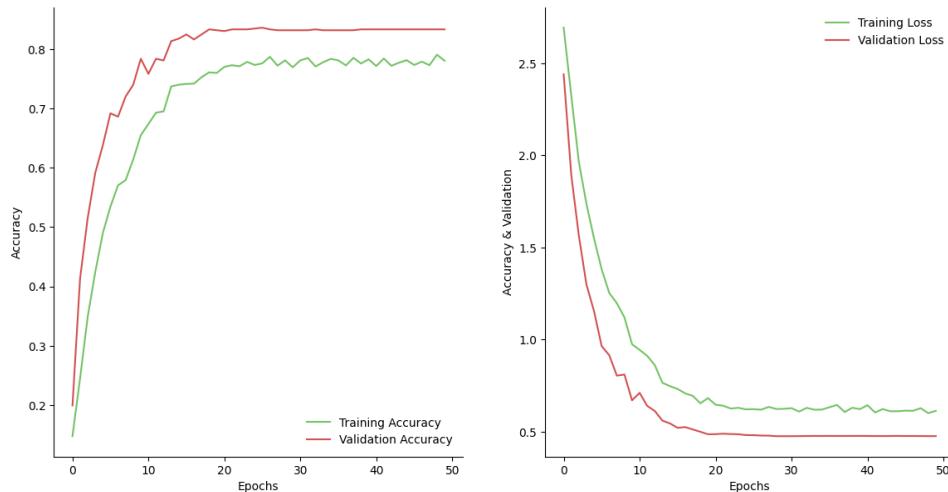
Tabel 4.10. Hasil Base Model CNN1 dengan AdamW dan Kernel 3x3

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.96	0.68	0.84	0.97	0.75
1	0.99	0.82	0.82	1.00	0.82
2	0.99	0.88	0.94	0.99	0.91
3	0.99	0.83	0.98	0.99	0.90
4	0.98	0.90	0.92	0.99	0.91
5	0.99	0.86	0.76	1.00	0.81
6	0.97	0.83	0.75	0.99	0.79
7	0.96	0.90	0.81	0.99	0.85
8	1.00	1.00	0.87	1.00	0.93
9	0.99	1.00	0.45	1.00	0.62
10	0.99	0.80	0.90	0.99	0.85
11	0.99	1.00	0.50	1.00	0.67
12	0.97	0.77	0.80	0.98	0.78
13	0.99	0.91	0.94	0.99	0.92
14	0.99	0.90	0.90	1.00	0.90
15	0.96	0.84	0.77	0.98	0.80
16	0.99	0.83	0.88	0.99	0.85

Tabel 4.10 menunjukkan model memiliki akurasi $\geq 96\%$ dan minim kesalahan. Kelas 8, optimal, sementara kelas 9, 11 masih kurang optimal. Secara

keseluruhan model dapat menangkap fitur lebih luas namun butuh perbaikan.

Gambar 4.10. Menunjukkan stabilitas dan konvergensi model.

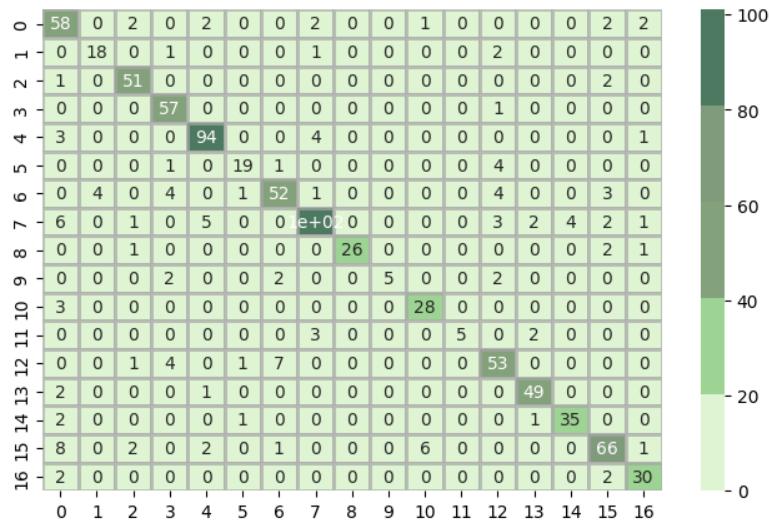


Gambar 4.10. Hasil Pelatihan, Validasi Model CNN1 (AdamW, Kernel 3x3)

Gambar 4.10 memperlihatkan performa akurasi dan loss pada proses pelatihan model selama 50 epoch. Pada grafik kiri, akurasi pelatihan (training accuracy) meningkat hingga sekitar 0,77, sedangkan akurasi validasi mencapai nilai lebih tinggi, sekitar 0,83, dan stabil setelah epoch ke-20. Hal ini mengindikasikan bahwa model mampu melakukan generalisasi dengan baik pada data validasi.

Pada grafik kanan, training loss dan validation loss menunjukkan penurunan signifikan sejak awal pelatihan. Validation loss turun lebih cepat dan mencapai nilai lebih rendah dibandingkan training loss, lalu stabil mendekati 0,45 tanpa menunjukkan gejala overfitting. Secara keseluruhan, performa model sangat stabil dan optimal. Model berhasil mempelajari pola data dengan baik tanpa overfitting, ditunjukkan oleh stabilitas akurasi dan loss pada data validasi yang lebih baik dibandingkan data pelatihan.

Sebagai pelengkap hasil evaluasi, dilakukan analisis *confusion matrix* untuk menilai kemampuan model dalam membedakan masing-masing jenis tumor otak secara detail. Analisis ini penting karena akurasi keseluruhan tidak selalu mencerminkan performa pada setiap kelas secara spesifik. *Confusion matrix* memberikan gambaran komprehensif mengenai pola klasifikasi, menunjukkan kecenderungan kesalahan model, serta membantu mengidentifikasi kelas-kelas yang sulit dipisahkan. Hasil analisis ini ditampilkan pada Gambar 4.11.



Gambar 4.11. Confusion Matrix Base Model CNN1 (AdamW, Kernel 3x3)

Gambar 4.11 menunjukkan *confusion matrix* yang mengindikasikan bahwa model secara umum memiliki performa klasifikasi yang cukup baik. Hal ini ditunjukkan oleh nilai-nilai tinggi pada diagonal utama, seperti pada kelas ke 4 (94 prediksi benar), kelas ke 2 (51), dan kelas ke 15 (66), yang menandakan bahwa sebagian besar kelas berhasil dikenali dengan tepat.

Meskipun demikian, masih ditemukan beberapa kesalahan klasifikasi, terutama pada kelas ke 0, ke 5, dan ke 6, yang menunjukkan sebaran prediksi ke

berbagai kelas lain. Hal ini mengindikasikan bahwa model mengalami kesulitan dalam membedakan fitur pada kelas-kelas dengan karakteristik yang serupa, sehingga berdampak pada penurunan presisi dan sensitivitas di kelas tersebut.

Model menunjukkan performa klasifikasi yang optimal, namun masih perlu dioptimalkan pada kelas dengan akurasi rendah untuk meningkatkan stabilitas dan representativitas sistem.

4.10.2. Pengujian Base Model CNN2 (AdamW, Kernel 5x5)

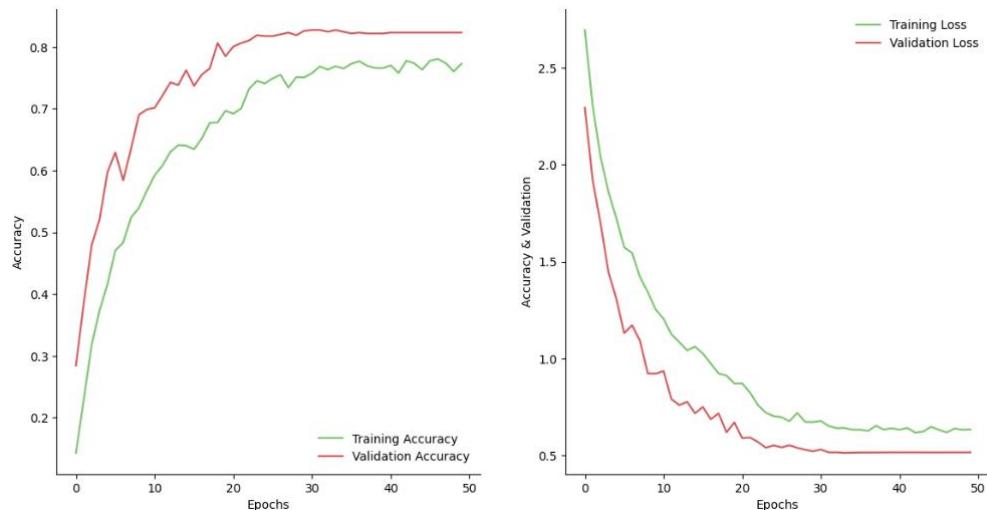
Pengujian selanjutnya menggunakan kernel size 5x5 untuk mengevaluasi apakah ukuran kernel yang lebih besar dapat meningkatkan performa model dalam klasifikasi. Diperlihatkan pada Tabel 4.11.

Tabel 4.11. Hasil Base Model CNN2 dengan AdamW dan Kernel 5x5

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.96	0.71	0.83	0.97	0.77
1	0.99	0.80	0.73	1.00	0.76
2	0.99	0.89	0.89	0.99	0.89
3	0.98	0.76	0.91	0.98	0.83
4	0.97	0.82	0.91	0.97	0.86
5	0.99	0.85	0.88	1.00	0.86
6	0.96	0.71	0.80	0.97	0.75
7	0.96	0.90	0.84	0.98	0.87
8	0.99	1.00	0.83	1.00	0.91
9	0.99	0.60	0.27	1.00	0.37
10	0.99	0.88	0.90	1.00	0.89
11	0.99	0.86	0.60	1.00	0.71
12	0.95	0.70	0.64	0.98	0.67
13	0.99	0.94	0.92	1.00	0.93
14	0.99	0.97	0.85	1.00	0.91
15	0.96	0.84	0.79	0.98	0.81
16	0.99	0.87	0.76	1.00	0.81

Tabel 4.11 menunjukkan performa optimal dengan Accuracy ≥ 0.95 pada sebagian besar kelas. Kelas 8, 2, 13, dan 14 menunjukkan hasil optimal, sementara

kelas 9 memiliki Precision 0.60 dan Recall 0.27 yang rendah, sehingga F1-Score juga rendah 0.37. Perbaikan pada kelas 9 diperlukan untuk meningkatkan klasifikasi dan keseimbangan antara metrik. Gambar 4.12 menunjukkan stabilitas dan konvergensi model.

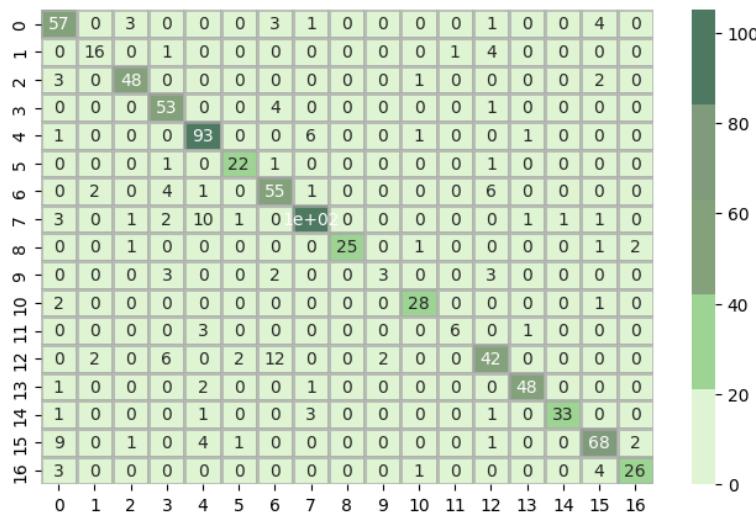


Gambar 4.12. Hasil Pelatihan, Validasi Model CNN2 (AdamW, Kernel 5x5)

Gambar 4.12 menunjukkan perkembangan akurasi dan loss pada data pelatihan dan validasi selama 50 epoch. Grafik kiri menggambarkan bahwa akurasi validasi meningkat secara konsisten hingga mencapai sekitar 0,83, sedangkan akurasi pelatihan mencapai sekitar 0,76. Pola ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, dengan performa lebih tinggi pada data validasi dibandingkan data pelatihan. Grafik kanan menunjukkan penurunan yang konsisten pada nilai loss untuk pelatihan dan validasi. Validation loss menurun secara tajam hingga mencapai nilai mendekati 0,5 dan kemudian stabil, menunjukkan bahwa proses pelatihan berlangsung secara baik tanpa indikasi overfitting. Perbedaan antara training loss dan validation loss tetap relatif kecil di

akhir pelatihan. Secara keseluruhan, model menunjukkan performa yang stabil, dengan hasil validasi yang lebih baik dari pelatihan, yang mengindikasikan model tidak mengalami overfitting dan berhasil belajar secara optimal dari data.

Sebagai pelengkap hasil yang diperoleh, Analisis confusion matrix dilakukan untuk mengevaluasi kemampuan model membedakan tiap jenis tumor otak secara detail. Karena akurasi keseluruhan tidak selalu mencerminkan performa per kelas, confusion matrix menunjukkan pola klasifikasi, kesalahan model, dan kelas yang sulit dibedakan. Hasilnya ditampilkan pada Gambar 4.13.



Gambar 4.13. Confusion Matrix Base Model CNN2 (AdamW, Kernel 5x5)

Gambar 4.13 menampilkan confusion matrix yang menunjukkan performa klasifikasi model terhadap 17 kelas. Secara umum, model menunjukkan kinerja yang cukup baik, terlihat dari nilai prediksi benar yang tinggi pada diagonal utama, khususnya pada kelas ke 4 (93), kelas ke 3 (53), dan kelas ke 15 (68). Hal ini mengindikasikan bahwa model mampu mengenali sebagian besar kelas dengan akurasi tinggi. Namun, masih terdapat misclassifikasi pada beberapa kelas, seperti

kelas ke 0 dan ke 6, yang menunjukkan sebaran prediksi ke beberapa kelas lain. Misclassifikasi ini mengindikasikan adanya kemiripan fitur antar kelas yang belum sepenuhnya dapat dibedakan oleh model.

Model secara keseluruhan sudah cukup andal, tetapi akurasi pada beberapa kelas masih perlu ditingkatkan. Oleh karena itu, perbaikan dapat difokuskan pada peningkatan pemisahan fitur antar kelas yang sering tertukar.

4.10.3. Pengujian Base Model CNN3 (AdamW, Kernel 7x7)

Pada pengujian ini, kernel size 7x7 diterapkan untuk menguji dampaknya terhadap kemampuan model dalam menangkap fitur yang lebih luas pada citra MRI. Hasil pengujian diperlihatkan pada Tabel 4.12.

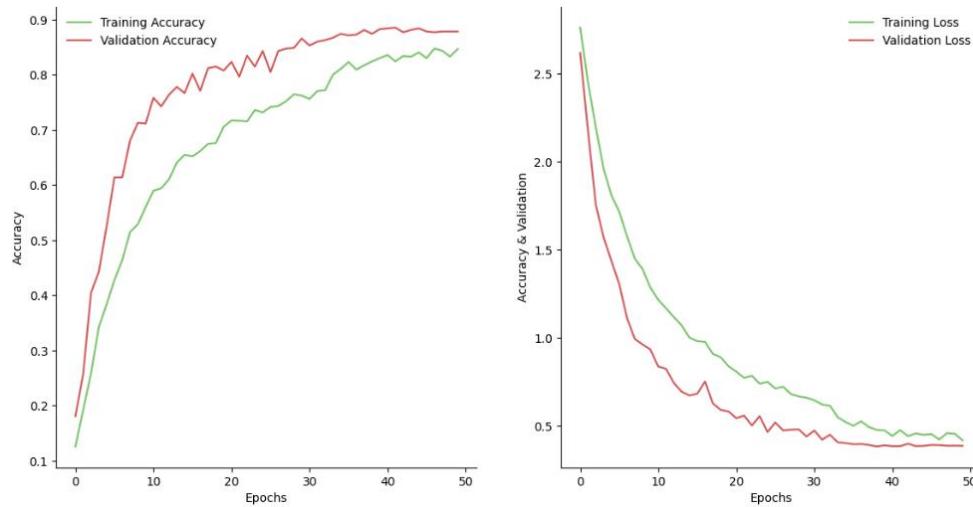
Tabel 4.12. Hasil Base Model CNN3 dengan AdamW dan Kernel 7x7

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.97	0.79	0.84	0.98	0.81
1	0.99	0.85	0.77	1.00	0.81
2	0.99	0.96	0.91	1.00	0.93
3	0.98	0.85	0.90	0.99	0.87
4	0.98	0.86	0.93	0.98	0.89
5	1.00	1.00	0.96	1.00	0.98
6	0.97	0.80	0.83	0.98	0.81
7	0.97	0.88	0.91	0.98	0.89
8	0.99	0.93	0.90	1.00	0.91
9	0.99	0.83	0.45	1.00	0.58
10	0.99	0.83	0.97	0.99	0.89
11	0.99	1.00	0.50	1.00	0.67
12	0.97	0.79	0.82	0.98	0.80
13	0.99	0.98	0.90	1.00	0.94
14	0.99	0.92	0.90	1.00	0.91
15	0.97	0.89	0.79	0.99	0.84
16	0.99	0.86	0.94	0.99	0.90

Tabel 4.12 menunjukkan model memiliki akurasi $\geq 97\%$ dan minim kesalahan. Kelas 5, optimal, sementara kelas 9, 11 masih kurang optimal. Secara

keseluruhan model dapat menangkap fitur lebih luas namun butuh perbaikan.

Gambar 4.14 memperlihatkan stabilitas dan konvergensi model.

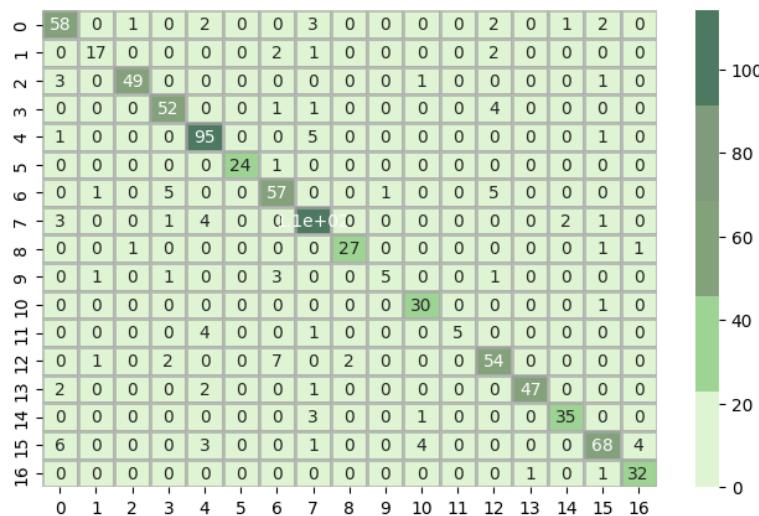


Gambar 4.14. Hasil Pelatihan, Validasi Model CNN3 (AdamW, Kernel 7x7)

Gambar 4.14 menunjukkan performa model selama 50 epoch melalui grafik akurasi dan loss. Grafik kiri menampilkan peningkatan akurasi pelatihan dan validasi secara konsisten, dengan akurasi validasi mencapai 0,89 dan pelatihan 0,85, menandakan model belajar dengan baik dan mampu melakukan generalisasi. Grafik kanan menunjukkan penurunan loss yang stabil pada kedua data, dengan validation loss berada di bawah training loss dan mencapai 0,35, mengindikasikan tidak terjadi overfitting.

Secara keseluruhan, model menunjukkan pelatihan yang optimal dengan akurasi meningkat dan loss menurun secara konsisten. Untuk melengkapi analisis, dilakukan evaluasi menggunakan confusion matrix Gambar 4.15 guna menilai performa klasifikasi per kelas. Analisis ini penting karena akurasi keseluruhan belum tentu mencerminkan kemampuan model membedakan setiap jenis tumor.

Confusion matrix memberikan gambaran rinci tentang pola klasifikasi dan kesalahan, serta membantu mengidentifikasi kelas yang sulit dibedakan.



Gambar 4.15. Confusion Matrix Base Model CNN3 (AdamW, Kernel 7x7)

Gambar 4.15 *confusion matrix* di atas menunjukkan performa model klasifikasi terhadap 17 kelas jenis tumor otak. Secara umum, diagonal utama mendominasi dengan nilai prediksi yang tinggi, mengindikasikan tingkat akurasi model yang baik. Misalnya, kelas ke 5, ke 6, dan ke 15 menunjukkan akurasi prediksi yang sangat tinggi dengan nilai masing-masing 95, 57, dan 68 prediksi benar. Namun, masih terdapat sejumlah kesalahan klasifikasi (misclassification), seperti pada kelas 0 yang diprediksi sebagai kelas 3, 6, dan 16, serta kelas 2 yang memiliki prediksi ke kelas 0 dan 4. Hal ini menunjukkan adanya kemiripan fitur antar kelas tertentu yang mungkin perlu ditinjau kembali.

Secara keseluruhan, model mampu mengenali pola mayoritas kelas dengan baik, tetapi perlu peningkatan pada kelas-kelas minor yang memiliki distribusi data rendah atau mudah tertukar.

4.10.4. Evaluasi Base Model 2

Evaluasi base model 2 dilakukan untuk memperoleh gambaran mengenai kinerja model sebelum dilakukan optimasi lebih lanjut, yang akan menjadi dasar perbandingan hasil pengujian berikutnya. Diperlihatkan pada Tabel 4.13.

Tabel 4.13. Evaluasi Base Model 2

Base Model 2 dengan Optimizer AdamW						
Base Model	Kernel Size	Accuracy	Precision	Recall	Specificity	F1-Score
CNN1	3x3	0.85	0.85	0.85	0.99	0.84
CNN2	5x5	0.82	0.83	0.82	0.99	0.82
CNN3	7x7	0.87	0.87	0.87	0.99	0.87

Hasil evaluasi nilai rata-rata 17 jenis tumor pada Tabel 4.13. Optimizer AdamW menunjukkan Kernel 7x7 memberikan performa terbaik dengan Accuracy, Precision, Recall, dan F1-Score masing-masing 0.87, Specificity (0.99). Kernel 3x3 sedikit lebih baik dibandingkan Kernel 5x5, namun keduanya memiliki kinerja lebih rendah dibandingkan Kernel 7x7. Secara keseluruhan, Kernel 7x7 mempunyai keseimbangan terbaik antara Precision dan Recall.

4.11. Base Model 3

Base Model 3 terdiri dari tiga model CNN, yaitu CNN1, CNN2, dan CNN3, yang masing-masing dibedakan berdasarkan ukuran kernel: 3×3 , 5×5 , dan 7×7 . Ketiga model ini dilatih menggunakan optimizer Nadam, yang merupakan kombinasi antara Adam dan Nesterov accelerated gradient. Proses pelatihan dilakukan selama 50 epoch dengan batch size 32 dan learning rate sebesar 0,001. Dengan menggunakan ukuran filter 32, 64, dan 128 pada lapisan konvolusi.

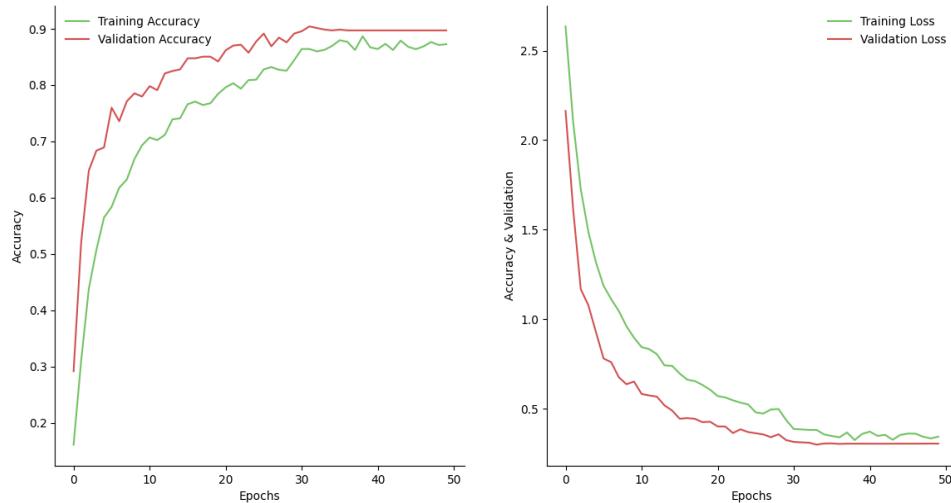
4.11.1. Pengujian Base Model CNN1 (Nadam, Kernel 3x3)

Pada pengujian ini, optimizer Nadam digunakan dengan kernel size 3x3 untuk mengevaluasi kinerjanya dalam klasifikasi tumor otak pada citra MRI, dengan fokus pada pengaruh ukuran kernel yang lebih kecil terhadap hasil model. Hasil pengujian diperlihatkan pada Tabel 4.14.

Tabel 4.14. Hasil Base Model CNN1 dengan Nadam dan Kernel 3x3

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.98	0.81	0.94	0.98	0.87
1	0.99	0.84	0.73	1.00	0.78
2	0.99	0.96	0.91	1.00	0.93
3	0.99	0.88	0.98	0.99	0.93
4	0.99	0.93	0.95	0.99	0.94
5	1.00	0.96	0.88	1.00	0.92
6	0.99	0.91	0.90	0.99	0.90
7	0.98	0.93	0.90	0.99	0.91
8	1.00	0.96	0.90	1.00	0.93
9	0.99	1.00	0.45	1.00	0.62
10	0.99	0.81	0.97	0.99	0.88
11	1.00	1.00	0.70	1.00	0.82
12	0.98	0.82	0.88	0.98	0.85
13	0.99	0.96	0.92	1.00	0.94
14	0.99	0.90	0.95	1.00	0.92
15	0.98	0.93	0.81	0.99	0.87
16	0.99	0.87	0.97	0.99	0.92

Tabel 4.14 menunjukkan kinerja sangat baik dengan Accuracy ≥ 0.98 pada sebagian besar kelas. Kelas 5 dan Kelas 8 memiliki performa terbaik. Kelas 9 memiliki Precision tinggi 1.00 tetapi Recall rendah 0.45, menghasilkan F1-Score rendah 0.62. Secara keseluruhan, model efektif meskipun beberapa kelas perlu perbaikan. Gambar 4.16 menunjukkan stabilitas dan konvergensi model.

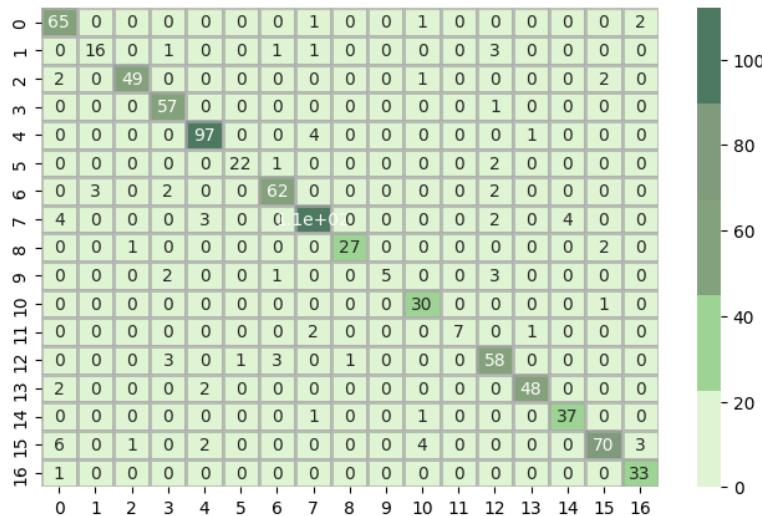


Gambar 4.16. Hasil Pelatihan, Validasi Model CNN1 (Nadam, Kernel 3x3)

Gambar 4.16 menunjukkan perkembangan akurasi dan loss selama 50 epoch pelatihan. Pada grafik kiri, baik akurasi pelatihan maupun validasi mengalami peningkatan signifikan pada awal epoch dan kemudian stabil mendekati angka 90%. Hal ini mengindikasikan model berhasil belajar dengan baik dan memiliki performa klasifikasi yang tinggi.

Grafik kanan menunjukkan penurunan loss yang konsisten pada data pelatihan dan validasi, menandakan proses pembelajaran berlangsung baik tanpa gejala overfitting yang mencolok. Perbedaan antara training dan validation loss tergolong kecil, yang menunjukkan generalisasi model tergolong optimal.

Sebagai pelengkap hasil evaluasi, dilakukan analisis *confusion matrix* untuk menilai kemampuan model dalam membedakan setiap jenis tumor otak secara detail. Analisis ini penting karena akurasi keseluruhan tidak selalu mencerminkan performa pada masing-masing kelas. *Confusion matrix* menggambarkan secara komprehensif mengenai pola klasifikasi, diperlihatkan pada Gambar 4.17.



Gambar 4.17. Confusion Matrix Base Model CNN1 (Nadam, Kernel 3x3)

Gambar 4.17 menunjukkan *heatmap confusion matrix* hasil klasifikasi terhadap 17 kelas tumor otak. Mayoritas nilai diagonal memiliki intensitas warna tertinggi, yang menunjukkan bahwa sebagian besar prediksi model sesuai dengan label sebenarnya. Contohnya, kelas ke-5, ke-6, dan ke-15 menunjukkan performa klasifikasi sangat baik dengan nilai prediksi benar berturut-turut 97, 62, dan 70.

Namun, masih terdapat sejumlah kecil kesalahan klasifikasi yang tersebar pada beberapa kelas. Misalnya, kelas ke-1 dan ke-2 memperlihatkan prediksi yang tersebar ke beberapa kelas lain, yang menandakan masih adanya tumpang tindih fitur antar kelas tersebut. Meskipun demikian, kesalahan klasifikasi secara umum relatif kecil dan tidak terpusat pada satu kelas tertentu. Secara keseluruhan, model menunjukkan kinerja klasifikasi yang optimal dengan tingkat kesalahan yang rendah, dengan kemampuan yang baik dalam membedakan kelas tumor otak.

4.11.2. Pengujian Base Model CNN2 (Nadam, Kernel 5x5)

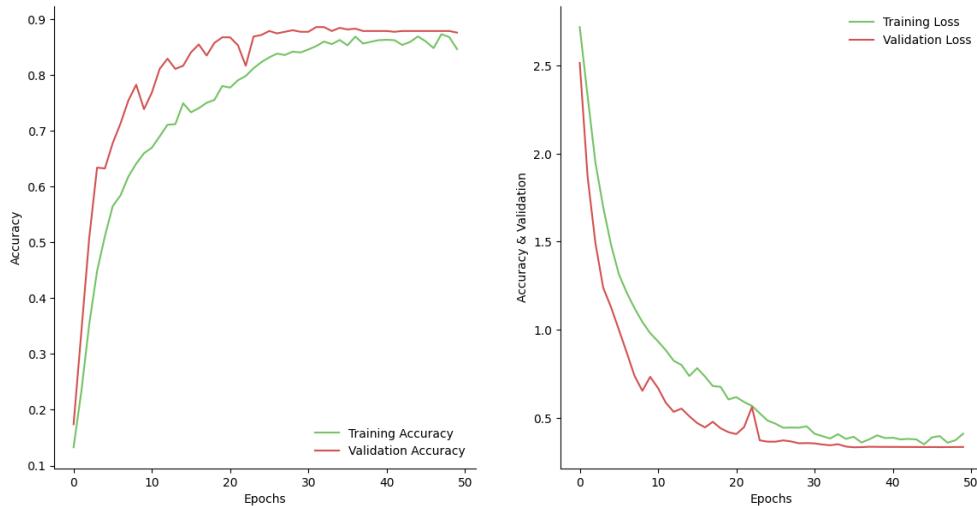
Pengujian selanjutnya menggunakan kernel size 5x5 untuk menilai apakah

ukuran kernel yang lebih besar dapat memberikan peningkatan akurasi dalam klasifikasi fitur pada citra MRI. Hasil pengujian diperlihatkan pada Tabel 4.15.

Tabel 4.15. Hasil Base Model CNN2 dengan Nadam dan Kernel 5x5

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.98	0.83	0.94	0.98	0.88
1	0.99	0.90	0.82	1.00	0.86
2	1.00	1.00	0.94	1.00	0.97
3	0.99	0.90	0.93	0.99	0.91
4	0.99	0.94	0.99	0.99	0.96
5	1.00	0.96	0.88	1.00	0.92
6	0.97	0.77	0.86	0.98	0.81
7	0.98	0.96	0.90	0.99	0.93
8	1.00	1.00	0.90	1.00	0.95
9	0.99	0.70	0.64	1.00	0.67
10	0.99	0.93	0.90	1.00	0.91
11	1.00	1.00	0.90	1.00	0.95
12	0.97	0.84	0.80	0.99	0.82
13	1.00	1.00	0.94	1.00	0.97
14	1.00	0.93	0.97	1.00	0.95
15	0.97	0.90	0.83	0.99	0.86
16	0.99	0.85	1.00	0.99	0.92

Berdasarkan Tabel 4.15, mayoritas kelas menunjukkan nilai akurasi $\geq 0,97$, yang memperlihatkan kinerja model yang sangat baik dalam melakukan klasifikasi. Kelas 2, 5, dan 8 merupakan kelas dengan performa paling optimal, ditunjukkan oleh tingginya nilai akurasi serta metrik evaluasi lainnya. Sebaliknya, Kelas 9 menunjukkan performa terendah dengan nilai F1-Score sebesar 0,67, disebabkan oleh rendahnya nilai Precision (0,70) dan Recall (0,64), yang mengindikasikan adanya tantangan dalam mengenali kelas tersebut secara konsisten. Secara umum, model menunjukkan klasifikasi yang optimal. Diperlihatkan pada Gambar 4.18.

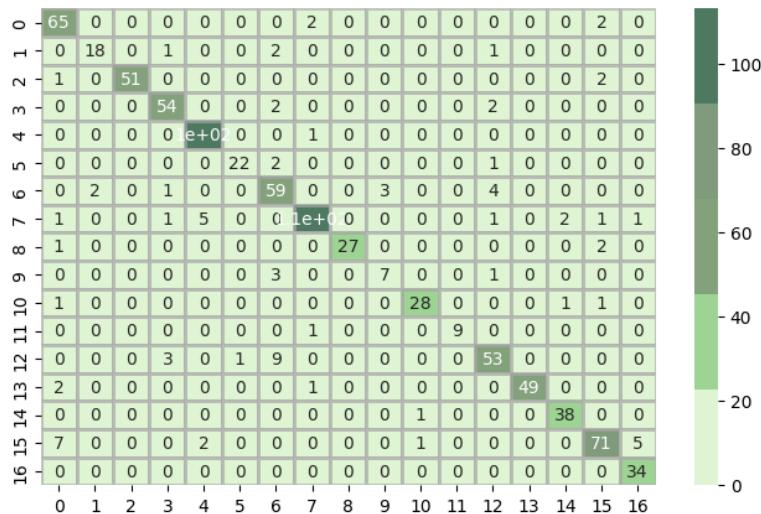


Gambar 4.18. Hasil Pelatihan, Validasi Model CNN2 (Nadam, Kernel 5x5)

Gambar 4.18 menunjukkan grafik performa model selama proses pelatihan selama 50 epoch. Grafik kiri memperlihatkan bahwa akurasi pelatihan dan validasi meningkat pesat pada awal epoch, lalu cenderung stabil di atas 85% setelah epoch ke 30, menunjukkan bahwa model mampu belajar secara efektif dan generalisasi berjalan baik.

Pada grafik kanan, baik training loss maupun validation loss mengalami penurunan tajam di awal, kemudian melandai dan stabil mendekati angka 0,3. Selisih antara training dan validation loss relatif kecil, yang mengindikasikan tidak terjadinya overfitting signifikan. Secara keseluruhan, kurva menunjukkan model memiliki stabilitas yang baik, konvergen dengan cepat, dan mampu mencapai performa tinggi secara konsisten pada data pelatihan dan validasi.

Untuk melengkapi hasil yang diperoleh, dilakukan analisis *confusion matrix* guna mengevaluasi kemampuan model dalam membedakan tiap jenis tumor otak. Analisis ini penting karena memberikan gambaran menyeluruh performa per kelas, mengidentifikasi pola kesalahan klasifikasi, ditunjukkan pada Gambar 4.19.



Gambar 4.19. Confusion Matrix Base Model CNN2 (Nadam, Kernel 5x5)

Gambar 4.19 *confusion matrix* menunjukkan performa model dalam mengklasifikasikan 17 kelas. Mayoritas nilai prediksi berada pada diagonal utama, yang menunjukkan tingkat akurasi klasifikasi yang baik. Sebagian besar kelas memiliki jumlah prediksi benar yang tinggi, misalnya kelas ke 4 (indeks 4) dengan 100 prediksi benar dan kelas ke 15 (indeks 15) dengan 71 prediksi benar.

Namun, terdapat beberapa kelas dengan misclassifikasi, seperti kelas ke 1 (indeks 1) dan kelas ke 13 (indeks 13), yang menunjukkan adanya distribusi prediksi ke kelas lain. Hal ini mengindikasikan bahwa beberapa kelas memiliki kemiripan fitur yang tinggi, sehingga lebih sulit dibedakan oleh model.

Confusion matrix menunjukkan model memiliki performa klasifikasi yang baik dengan prediksi benar tinggi pada sebagian besar kelas. Namun, beberapa kelas masih sering tertukar, menandakan perlu peningkatan kemampuan diskriminasi pada kelas dengan karakteristik serupa. Oleh karena itu. Diperlukan optimasi penyesuaian arsitektur atau augmentasi data untuk meningkatkan akurasi.

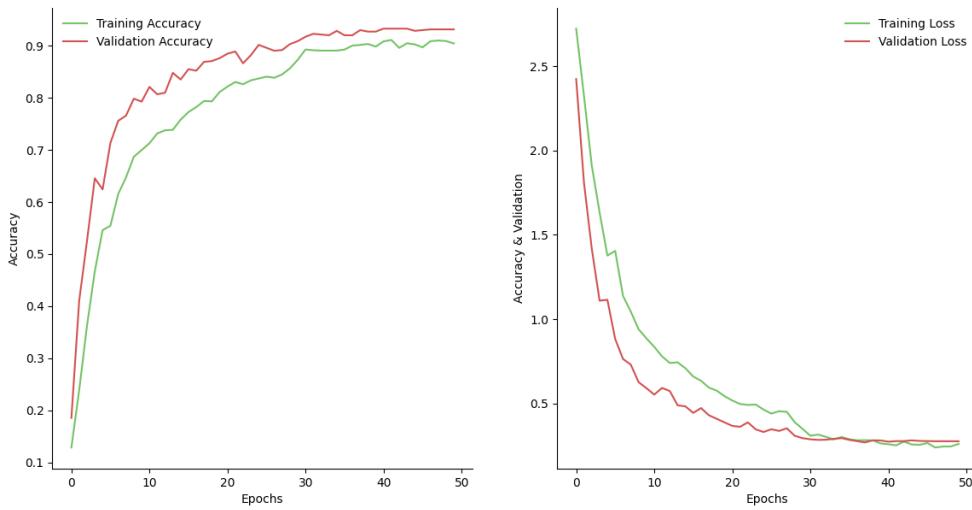
4.11.3. Pengujian Base Model CNN3 (Nadam, Kernel 7x7)

Dalam pengujian ini, kernel size 7x7 diterapkan untuk menguji apakah penggunaan ukuran kernel yang lebih besar dapat membantu model dalam menangkap fitur yang lebih kompleks dalam citra MRI. Hasil pengujian diperlihatkan pada Tabel 4.16.

Tabel 4.16. Hasil Base Model CNN3 dengan Nadam dan Kernel 7x7

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.98	0.89	0.91	0.99	0.90
1	0.99	0.94	0.68	1.00	0.79
2	1.00	1.00	0.94	1.00	0.97
3	0.99	0.90	0.93	0.99	0.91
4	0.98	0.89	0.96	0.98	0.92
5	0.99	0.88	0.88	1.00	0.88
6	0.98	0.83	0.90	0.98	0.86
7	0.99	0.98	0.94	1.00	0.96
8	1.00	1.00	0.90	1.00	0.95
9	0.99	0.86	0.55	1.00	0.67
10	0.99	0.82	0.90	0.99	0.86
11	1.00	1.00	0.90	1.00	0.95
12	0.98	0.83	0.89	0.99	0.86
13	1.00	0.98	0.94	1.00	0.96
14	0.99	0.92	0.92	1.00	0.92
15	0.98	0.88	0.87	0.99	0.87
16	0.99	0.94	0.91	1.00	0.92

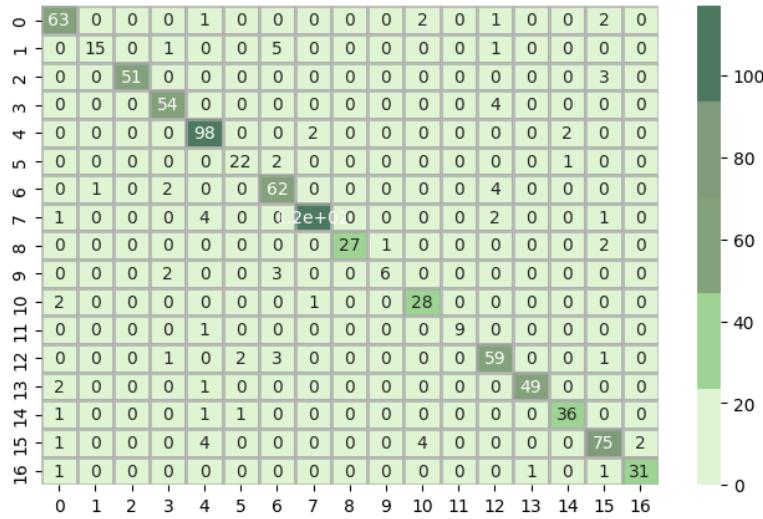
Tabel 16 memperlihatkan kinerja model yang optimal dengan nilai akurasi $\geq 0,98$ pada sebagian besar kelas. Namun, Kelas 9 tercatat memiliki F1-Score terendah sebesar 0,67, yang terutama disebabkan oleh rendahnya nilai Recall, menunjukkan bahwa model kurang efektif dalam mendeteksi kelas tersebut. Secara keseluruhan, model menunjukkan performa yang baik dan optimal, meskipun beberapa kelas masih memerlukan perbaikan untuk meningkatkan akurasi dan ketepatan klasifikasi. Diperlihatkan Gambar 4.20.



Gambar 4.20. Hasil Pelatihan, Validasi Model CNN3 (Nadam, Kernel 7x7)

Pada Gambar 4.20 di atas menunjukkan perkembangan akurasi dan *loss* selama 50 *epoch* pelatihan. Pada grafik kiri, akurasi pelatihan dan validasi meningkat secara stabil hingga mendekati 0,93, dengan kurva validasi sedikit lebih tinggi dari pelatihan. Pola ini mengindikasikan kemampuan generalisasi model yang baik tanpa adanya *overfitting* yang signifikan. Sementara itu, grafik kanan memperlihatkan penurunan tajam *loss* pada 10 *epoch* pertama, kemudian stabil di bawah 0,3. Selisih *loss* antara pelatihan dan validasi sangat kecil, menandakan bahwa model tidak mengalami *underfitting* maupun *overfitting*. Secara keseluruhan, grafik ini mencerminkan kinerja pelatihan yang optimal, dengan konvergensi stabil dan akurasi tinggi pada kedua data.

Untuk melengkapi hasil yang diperoleh, dilakukan analisis *confusion matrix* guna mengevaluasi kemampuan model dalam membedakan tiap jenis tumor otak. Analisis ini penting karena memberikan gambaran menyeluruh performa per kelas, menunjukkan pola kesalahan klasifikasi, seperti ditunjukkan pada Gambar 4.21.



Gambar 4.21. Confusion Matrix Base Model CNN3 (Nadam, Kernel 7x7)

Gambar 4.21 *confusion matrix* di atas menggambarkan performa model dalam mengklasifikasikan 17 kelas (label 0 - 16). Secara keseluruhan, model menunjukkan kinerja yang sangat baik, ditandai dengan dominasi nilai tinggi pada diagonal utama, yang mencerminkan prediksi yang tepat. Hal ini menunjukkan bahwa model mampu mengenali pola fitur utama dari sebagian besar kelas dengan akurat.

Beberapa kelas menunjukkan tingkat akurasi yang sangat tinggi, seperti kelas 5 (98 prediksi benar), kelas 6 (62), kelas 10 (28), kelas 11 (59), dan kelas 15 (75), yang menandakan adanya presisi dan sensitivitas yang baik dalam mengidentifikasi kategori-kategori tersebut. Di sisi lain, terdapat beberapa kelas yang mengalami kesalahan klasifikasi (confusion), seperti kelas 1 yang hanya terkласifikasi benar sebanyak 15 kali, dan selebihnya salah diprediksi sebagai kelas 3, 5, dan 8. Kelas 0 pun mengalami kekeliruan klasifikasi ke beberapa kelas seperti 3, 6, dan 15, meskipun sebagian besar (63) sudah diprediksi dengan tepat.

Temuan ini mengindikasikan bahwa, meskipun performa model secara umum sudah cukup baik, masih terdapat tumpang tindih fitur antar beberapa kelas tertentu. Oleh karena itu, diperlukan strategi perbaikan seperti augmentasi data, penyeimbangan jumlah sampel per kelas, atau fine-tuning arsitektur.

4.11.4. Evaluasi Base Model 3

Evaluasi terhadap base model CNN3 dilakukan untuk memahami kinerjanya sebelum penerapan optimasi lebih lanjut, yang akan digunakan sebagai dasar untuk membandingkan hasil pengujian selanjutnya. Hasil pengujian diperlihatkan pada Tabel 4.17.

Tabel 4.17. Evaluasi Base Model 3

Base Model 3 dengan Optimizer Nadam						
Base Model	Kernel Size	Accuracy	Precision	Recall	Specificity	F1-Score
CNN1	3x3	0.90	0.90	0.90	0.99	0.90
CNN2	5x5	0.90	0.91	0.90	0.99	0.91
CNN3	7x7	0.91	0.91	0.91	0.99	0.91

Hasil evaluasi nilai rata-rata 17 jenis tumor pada Tabel 4.17. Optimizer Nadam menunjukkan bahwa Kernel 7x7 memberikan performa terbaik dengan Accuracy, Precision, Recall, dan F1-Score tertinggi 0.91. Kernel 3x3 dan Kernel 5x5 juga menunjukkan hasil yang sangat baik, dengan sedikit perbedaan pada Precision dan Recall. Semua kernel memiliki Specificity tinggi 0.99, menunjukkan kinerja optimal dalam mendeteksi kelas negatif. Secara keseluruhan, Kernel 7x7 memberikan keseimbangan terbaik antara Precision dan Recall.

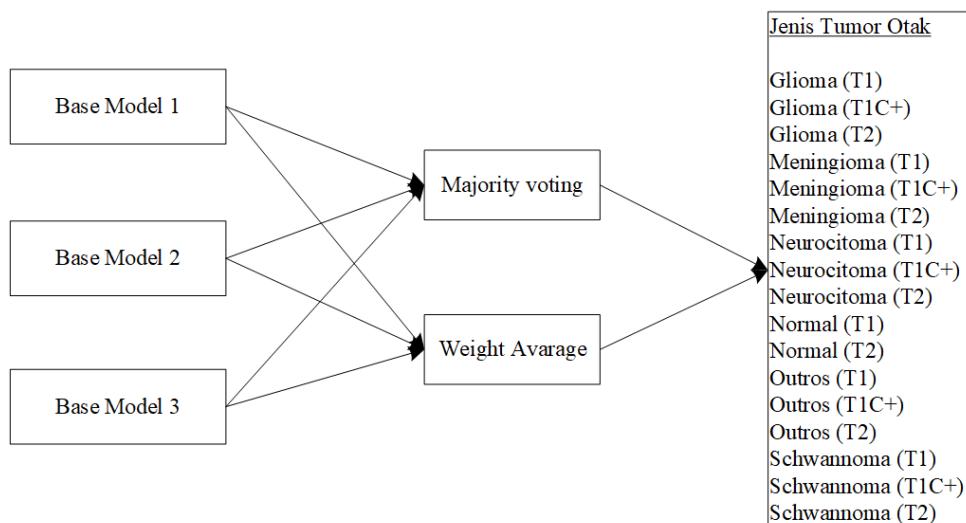
BAB V

ENSEMBLE LEARNING

Penelitian ini menerapkan pendekatan *ensemble learning* dengan mengintegrasikan beberapa *base model* CNN *lightweight* untuk klasifikasi citra tumor otak. Pendekatan ini bertujuan mengurangi tingkat kesalahan prediksi sekaligus meningkatkan akurasi dan performa model secara keseluruhan.

5.1. Ensemble Learning

Penerapan metode *ensemble learning* bertujuan meningkatkan akurasi dan stabilitas performa klasifikasi pada model *Convolutional Neural Network* (CNN). Metode yang digunakan yaitu *majority voting* (MV) dan *weighted average* (WA), yang dirancang untuk mengintegrasikan keunggulan beberapa base model CNN agar menghasilkan klasifikasi tumor otak yang lebih optimal, diperlihatkan pada Gambar 5.1.



Gambar 5.1. Ensemble Majority Voting dan Weighted Average

Gambar 5.1 menunjukkan desain metode *ensemble* learning yang digunakan dalam penelitian ini. terdapat tiga kelompok model utama: base model 1, base model 2, dan base model 3. Perbedaan utama di antara ketiganya terletak pada variasi ukuran kernel yang digunakan, yang bertujuan untuk menangkap fitur citra dari berbagai skala. Selain itu, setiap model dalam kelompok tersebut dilatih menggunakan algoritma optimisasi berbeda, yaitu Adam, AdamW, dan Nadam, untuk meningkatkan keberagaman proses pelatihan. Ketiga base model ini kemudian berperan sebagai *base learners* dalam sistem *ensemble learning*.

Setiap base model menghasilkan prediksi klasifikasi terhadap 17 kelas citra tumor otak berdasarkan jenis dan modalitas MRI (T1, T1C+, T2). Hasil prediksi dari ketiga model ini kemudian digabungkan menggunakan dua pendekatan, yaitu *majority voting* dan *weighted average*. Dalam *majority voting*, kelas yang memperoleh suara terbanyak dari ketiga model dipilih sebagai hasil akhir klasifikasi. Sementara itu, *weighted average* menghitung rata-rata nilai softmax dari setiap model, dan kelas dengan nilai rata-rata tertinggi dijadikan hasil akhir Penggabungan model-model dasar dengan variasi ukuran kernel ini bertujuan untuk meningkatkan akurasi dan menghasilkan performa klasifikasi tumor otak yang lebih optimal.

5.2. Majority Voting Base Model 1

Base Model 1 merupakan hasil ensemble dari tiga arsitektur CNN *lightweight* yang dirancang dengan variasi ukuran kernel 3×3 , 5×5 , dan 7×7 . Masing-masing model dilatih secara terpisah menggunakan algoritma optimasi Adam, dengan tujuan membangun keragaman struktural yang dapat meningkatkan

generalisasi dan akurasi klasifikasi terhadap citra MRI tumor otak. Hasil performa ditampilkan pada Tabel 5.1.

Tabel 5.1. Hasil Majority Voting pada Base Model 1

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.91	0.98	0.99	0.94
1	0.99	0.92	0.91	0.99	0.92
2	0.99	0.98	0.96	0.99	0.97
3	0.99	0.90	0.98	0.99	0.94
4	0.99	0.94	0.97	0.99	0.96
5	0.99	0.93	0.93	0.99	0.93
6	0.98	0.91	0.89	0.99	0.90
7	0.99	0.97	0.95	0.99	0.96
8	0.99	0.99	0.92	0.99	0.95
9	0.99	1.00	0.68	1.00	0.81
10	0.99	0.93	0.96	0.99	0.94
11	0.99	1.00	0.93	1.00	0.96
12	0.98	0.90	0.91	0.99	0.90
13	0.99	0.98	0.96	0.99	0.97
14	0.99	0.98	0.97	0.99	0.98
15	0.99	0.96	0.94	0.99	0.95
16	0.99	0.96	0.97	0.99	0.96

Tabel 5.1 menunjukkan hasil *majority voting* pada base model 1, dengan akurasi hampir 1.00 untuk semua kelas, menunjukkan kinerja optimal. Precision dan specificity yang tinggi mengindikasikan kemampuan model dalam mengidentifikasi kelas yang benar dan meminimalkan kesalahan. Meskipun recall bervariasi, terutama pada kelas 9 (0.68), model ini secara keseluruhan optimal mengurangi kesalahan klasifikasi. F1-Score yang tinggi menunjukkan keseimbangan baik antara precision dan recall, menjadikan model ini akurat dan konsisten dalam klasifikasi tumor otak.

Untuk memperkuat hasil evaluasi, gabungan prediksi dari ketiga model dianalisis menggunakan confusion matrix melalui pendekatan majority voting,

guna mengukur akurasi klasifikasi pada masing-masing kelas tumor otak secara lebih menyeluruh. Analisis ini bertujuan untuk mengevaluasi secara rinci kemampuan model dalam mengklasifikasikan setiap jenis tumor otak. Pendekatan ini memberikan gambaran lebih mendalam tentang performa klasifikasi sekaligus memperkuat penilaian keseluruhan terhadap efektivitas metode ensemble majority voting yang diterapkan. Diperlihatkan pada Tabel 5.2.

Tabel 5.2. Confusion Matrix Majority Voting pada Base Model 1

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	339	0	0	0	0	0	0	1	0	0	3	0	0	0	0	2	0
1	0	103	0	0	0	0	4	0	0	0	0	5	0	0	0	0	0
2	6	0	263	0	0	0	0	0	0	0	1	0	0	0	0	2	0
3	0	0	0	287	0	0	2	0	0	0	0	0	2	0	0	0	0
4	0	0	0	0	497	0	0	8	0	0	0	0	0	3	0	0	0
5	0	0	0	2	0	115	3	0	0	0	0	3	0	0	0	0	0
6	0	6	0	10	0	2	311	0	0	0	0	17	0	0	0	0	0
7	6	0	0	1	16	0	1	596	0	0	0	2	0	2	1	0	0
8	2	0	1	0	0	0	0	0	141	0	2	0	0	0	3	3	0
9	0	0	0	5	0	0	10	0	0	39	0	0	3	0	0	0	0
10	3	0	0	0	0	0	0	0	0	148	0	0	0	0	1	1	1
11	0	0	0	0	2	0	0	0	0	0	45	0	1	0	0	0	0
12	0	2	1	12	0	4	9	1	0	0	0	300	0	0	0	0	0
13	2	0	0	0	4	0	0	1	1	0	0	0	252	0	1	0	0
14	0	0	0	0	1	1	0	2	0	0	1	0	0	0	189	0	0
15	12	0	1	0	5	1	1	0	0	0	3	0	0	0	0	405	2
16	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	3	164

Tabel 5.2 menunjukkan bahwa Base Model 1 telah mencapai performa klasifikasi yang optimal pada sebagian besar kelas, khususnya kelas 0, 3, 4, 7, dan 15, dengan jumlah prediksi benar yang tinggi. Hal ini mencerminkan kemampuan model dalam mengenali fitur visual secara tepat.

Meskipun demikian, masih terdapat misklasifikasi pada kelas 6, 9, dan 12, yang mengindikasikan adanya kemiripan fitur antar kelas serta tantangan dalam pemisahan representasi data. Kondisi ini dapat diatasi melalui peningkatan kualitas data, penyeimbangan distribusi kelas, dan penguatan strategi pelatihan. Secara keseluruhan, confusion matrix telah menunjukkan performa klasifikasi optimal.

5.3. Weighted Average Base Model 1

Base Model CNN1 merupakan hasil ensemble dari tiga arsitektur CNN *lightweight* yang dirancang dengan variasi ukuran kernel 3×3 , 5×5 , dan 7×7 . Masing-masing model dilatih secara terpisah menggunakan algoritma optimasi Adam, diterapkan metode *weighted average* untuk menggabungkan prediksi berdasarkan rata-rata softmax yang dibagi jumlah model. Pendekatan ini menghasilkan klasifikasi yang lebih akurat dengan memperhitungkan tingkat kepercayaan setiap model. Hasil pengujian dapat dilihat pada Tabel 5.3.

Tabel 5.3. Hasil Weighted Average pada Base Model 1

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.93	0.97	0.99	0.95
1	0.99	0.92	0.89	0.99	0.90
2	0.99	0.99	0.97	0.99	0.98
3	0.99	0.93	0.98	0.99	0.96
4	0.99	0.95	0.97	0.99	0.96
5	0.99	0.96	0.91	0.99	0.94
6	0.98	0.90	0.92	0.99	0.91
7	0.99	0.98	0.95	0.99	0.96
8	0.99	1.00	0.92	1.00	0.96
9	0.99	0.95	0.71	0.99	0.82
10	0.99	0.92	0.96	0.99	0.94
11	0.99	1.00	0.91	1.00	0.95
12	0.98	0.91	0.92	0.99	0.91
13	0.99	0.96	0.98	0.99	0.97
14	0.99	0.98	0.97	0.99	0.98
15	0.99	0.97	0.95	0.99	0.96
16	0.99	0.96	0.97	0.99	0.96

Tabel 5.3 menunjukkan hasil evaluasi weighted average pada Base Model CNN1, dengan akurasi mendekati 1.00 untuk sebagian besar kelas. Precision dan specificity yang tinggi menunjukkan kemampuan model mengidentifikasi kelas dengan tepat, sementara recall yang sangat baik mencerminkan pengurangan

kesalahan klasifikasi. Meskipun kelas 9 memiliki recall terendah (0.71) dan F1-Score (0.82), model ini secara keseluruhan sudah optimal.

Untuk memperkuat validasi hasil evaluasi, dilakukan analisis confusion matrix terhadap Base Model 1, yang merupakan gabungan tiga base model CNN *lightweight* dengan metode weighted average. Analisis ini mengkaji akurasi klasifikasi per kategori tumor otak dan memberikan bukti empiris efektivitas pendekatan ensemble. Rincian hasil performa ditampilkan pada Tabel 5.4.

Tabel 5.4. Confusion Matrix Weighted Average pada Base Model 1

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	324	0	2	0	1	0	0	3	1	0	5	0	0	0	0	9	0
1	0	88	0	0	0	0	4	0	0	0	0	20	0	0	0	0	0
2	4	0	262	0	0	0	0	0	0	1	0	0	0	0	0	5	0
3	0	0	0	287	0	2	0	0	0	0	0	2	0	0	0	0	0
4	0	0	0	0	487	0	0	13	0	0	0	0	3	5	0	0	0
5	0	0	0	1	0	107	5	0	0	0	0	10	0	0	0	0	0
6	0	9	0	10	0	4	275	1	0	0	0	47	0	0	0	0	0
7	12	0	0	0	20	0	1	583	0	0	0	3	0	6	0	0	0
8	2	0	2	0	0	0	0	0	138	1	1	0	0	0	5	3	0
9	0	1	0	7	0	0	18	0	0	25	0	0	6	0	0	0	0
10	5	0	0	0	0	0	0	0	0	146	0	0	0	1	1	0	0
11	0	0	0	0	8	0	0	0	0	0	36	0	4	0	0	0	0
12	0	2	0	12	0	9	20	1	1	0	0	284	0	0	0	0	0
13	0	0	0	0	7	0	0	3	0	0	0	0	249	0	2	0	0
14	0	0	0	0	0	1	0	7	0	0	2	0	0	0	184	0	0
15	13	0	2	0	5	0	1	0	0	0	7	0	0	0	0	396	6
16	3	0	0	0	0	0	0	0	1	0	0	1	0	4	160	0	0

Tabel 5.4 confusion matrix hasil klasifikasi 17 kelas tumor otak, dengan baris menunjukkan label aktual dan kolom prediksi model. Nilai tinggi pada diagonal utama mencerminkan prediksi yang akurat, terutama pada kelas ke-0 (324), kelas ke-3 (287), kelas ke-5 (487), kelas ke-7 (583), dan kelas ke-12 (284). Sebaliknya, kelas ke-15 dan ke-16 menunjukkan tingkat kesalahan prediksi yang cukup tinggi. Hal ini dapat disebabkan oleh ketidakseimbangan distribusi data atau kemiripan fitur visual antar kelas. Oleh karena itu, diperlukan evaluasi tambahan melalui metrik akurasi, presisi, recall, dan F1-score per kelas.

5.4. Majority Voting Base Model 2

Base Model CNN2 merupakan kombinasi ensemble dari tiga arsitektur CNN *lightweight* dengan variasi ukuran kernel 3×3 , 5×5 , dan 7×7 , yang masing-masing dilatih secara independen menggunakan algoritma optimasi AdamW. Metode majority voting diterapkan untuk menentukan kelas akhir berdasarkan prediksi mayoritas dari ketiga model tersebut. Pendekatan ini bertujuan untuk mengurangi variabilitas prediksi sekaligus meningkatkan performa klasifikasi. Hasil evaluasi performa model ditampilkan pada Tabel 5.5.

Tabel 5.5. Hasil Majority Voting pada Base Model 2

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.98	0.82	0.95	0.98	0.88
1	0.99	0.85	0.84	0.99	0.85
2	0.99	0.95	0.95	0.99	0.95
3	0.98	0.87	0.98	0.98	0.92
4	0.98	0.91	0.95	0.98	0.93
5	0.99	0.92	0.86	0.99	0.89
6	0.97	0.87	0.85	0.98	0.86
7	0.98	0.95	0.93	0.99	0.94
8	0.99	1.00	0.92	1.00	0.95
9	0.99	1.00	0.56	1.00	0.71
10	0.99	0.90	0.94	0.99	0.92
11	0.99	1.00	0.75	1.00	0.85
12	0.97	0.85	0.85	0.98	0.85
13	0.99	0.97	0.93	0.99	0.95
14	0.99	0.95	0.95	0.99	0.95
15	0.98	0.9	0.90	0.99	0.93
16	0.99	0.94	0.92	0.99	0.93

Tabel 5.5 menunjukkan hasil majority voting pada Base Model 2, dengan akurasi yang tinggi di sebagian besar kelas. Precision dan specificity yang baik mengindikasikan kemampuan model dalam mengidentifikasi kelas dengan tepat. Meskipun recall pada kelas 9 rendah (0.56), secara keseluruhan, model ini

menunjukkan performa stabil dengan F1-Score yang seimbang antara precision dan recall.

Untuk memperkuat validasi hasil evaluasi, dilakukan analisis confusion matrix pada Base Model 2, yang merupakan hasil gabungan tiga model CNN lightweight menggunakan metode majority voting. Analisis ini bertujuan mengukur akurasi klasifikasi setiap kategori tumor otak serta memberikan bukti empiris terkait efektivitas pendekatan ensemble. Rincian hasil performa diperlihatkan pada Tabel 5.6.

Tabel 5.6. Confusion Matrix Majority Voting pada Base Model 2

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	330	0	4	0	1	0	0	3	0	0	4	0	0	0	0	2	1
1	0	95	0	1	0	0	3	1	0	0	0	0	12	0	0	0	0
2	8	0	261	0	0	0	0	0	0	0	1	0	0	0	0	2	0
3	0	0	0	287	0	0	3	0	0	0	0	0	1	0	0	0	0
4	4	0	1	0	483	0	0	15	0	0	0	0	0	1	2	2	0
5	0	0	0	3	1	106	1	0	0	0	0	0	12	0	0	0	0
6	0	11	0	15	1	0	297	0	0	0	1	0	20	0	0	1	0
7	12	0	1	2	16	0	0	587	0	0	0	0	0	1	5	1	0
8	1	0	3	0	0	0	0	1	140	0	0	0	0	0	0	3	4
9	0	3	1	5	0	0	12	0	0	32	0	0	4	0	0	0	0
10	9	0	0	0	0	0	0	0	0	0	144	0	0	0	0	0	0
11	0	0	0	0	9	0	0	2	0	0	0	36	0	1	0	0	0
12	1	2	1	16	0	6	22	0	0	0	0	0	280	0	1	0	0
13	6	0	0	0	8	0	0	3	0	0	0	0	0	244	0	0	0
14	2	0	0	0	1	2	0	2	0	0	1	0	0	0	186	0	0
15	18	0	1	0	8	1	1	1	0	0	9	0	0	0	0	387	4
16	7	0	0	0	0	0	0	0	0	0	0	0	2	0	3	157	

Tabel 5.6 menunjukkan confusion matrix hasil klasifikasi 17 kelas tumor otak menggunakan metode *majority voting*. Mayoritas nilai diagonal memiliki jumlah prediksi benar yang besar, menandakan akurasi klasifikasi yang baik. Beberapa kelas, seperti kelas 0, 3, 6, dan 7, menunjukkan prediksi yang sangat tepat. Namun, terdapat kesalahan klasifikasi yang menonjol antara kelas tertentu, seperti kelas 13 yang sering diklasifikasikan sebagai kelas 14, serta kelas 10 dan 12, yang menunjukkan kemungkinan kemiripan karakteristik.

Secara umum, model menunjukkan performa yang baik dan stabil. Metode *majority voting* terbukti efektif dalam meningkatkan performa akurasi keseluruhan dari model-model dasar. Meski demikian, evaluasi lebih lanjut diperlukan pada kelas dengan tingkat kekeliruan tinggi untuk mengoptimalkan kinerja klasifikasi secara menyeluruh.

5.5. Weighted Average Base Model 2

Metode weighted average diterapkan pada Base Model 2, yaitu ensemble dari tiga CNN *lightweight* dengan kernel 3×3 , 5×5 , dan 7×7 , yang dilatih secara independen menggunakan AdamW. Hasil klasifikasi digabungkan berdasarkan rata-rata softmax untuk meningkatkan akurasi. Hasil pengujian ditampilkan pada Tabel 5.7.

Tabel 5.7. Hasil Weighted Average pada Base Model 2

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.98	0.86	0.95	0.98	0.90
1	0.99	0.91	0.83	0.99	0.87
2	0.99	0.96	0.96	0.99	0.96
3	0.99	0.92	0.98	0.99	0.95
4	0.98	0.92	0.95	0.98	0.93
5	0.99	0.95	0.85	0.99	0.90
6	0.98	0.88	0.89	0.98	0.88
7	0.98	0.95	0.94	0.99	0.95
8	0.99	1.00	0.92	1.00	0.95
9	0.99	1.00	0.71	1.00	0.83
10	0.99	0.91	0.95	0.99	0.93
11	0.99	1.00	0.83	1.00	0.90
12	0.97	0.85	0.87	0.98	0.86
13	0.99	0.97	0.94	0.99	0.95
14	0.99	0.94	0.98	0.99	0.96
15	0.98	0.96	0.90	0.99	0.93
16	0.99	0.94	0.94	0.99	0.94

Tabel 5.7 menunjukkan hasil evaluasi Weighted Average pada Base Model CNN2, dengan akurasi tinggi di hampir semua kelas. Precision dan specificity yang baik mencerminkan kemampuan model mengidentifikasi kelas dengan tepat. Meskipun recall kelas 9 lebih rendah (0.71), dengan F1-Score yang seimbang antara precision dan recall.

Sebagai upaya memperkuat validitas hasil evaluasi model, dilakukan analisis *confusion matrix* terhadap Base Model 2, yang dibentuk melalui penggabungan tiga arsitektur CNN *lightweight* dengan pendekatan *Weighted Average*. Analisis ini bertujuan untuk menilai tingkat ketepatan klasifikasi pada masing-masing kategori tumor otak serta memberikan dasar empiris atas efektivitas metode *ensemble* yang diterapkan. Hasil performa klasifikasi secara rinci diperlihatkan pada Tabel 5.8.

Tabel 5.8. Confusion Matrix Weighted Average pada Base Model 2

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	329	0	2	0	1	0	0	4	0	0	3	0	2	0	1	2	1
1	0	94	0	1	0	0	7	1	0	0	0	0	9	0	0	0	0
2	6	0	263	0	0	0	0	0	0	0	1	0	0	0	0	2	0
3	0	0	0	288	0	0	1	0	0	0	0	0	2	0	0	0	0
4	2	0	1	0	483	0	0	13	0	0	0	0	0	2	4	3	0
5	0	0	0	3	0	105	2	0	0	0	0	0	13	0	0	0	0
6	0	7	0	9	0	0	310	1	0	0	1	0	17	0	0	1	0
7	8	0	1	0	16	0	0	590	0	0	0	0	2	1	6	1	0
8	0	0	3	0	0	0	0	0	140	0	1	0	0	0	0	4	4
9	0	2	0	3	0	0	7	0	0	41	0	0	4	0	0	0	0
10	7	0	0	0	0	0	0	0	0	0	146	0	0	0	0	0	0
11	0	0	0	0	5	0	0	1	0	0	40	0	2	0	0	0	0
12	0	0	1	9	0	5	25	0	0	0	0	0	288	0	1	0	0
13	2	0	0	0	9	0	0	3	0	0	0	0	0	246	0	0	1
14	1	0	0	0	0	0	0	2	0	0	0	0	0	0	191	0	0
15	18	0	1	0	9	0	0	1	0	0	7	0	1	0	0	390	3
16	6	0	0	0	0	0	0	0	0	0	0	0	0	2	0	2	159

Tabel 5.8 memperlihatkan confusion matrix klasifikasi 17 kelas tumor otak menggunakan ensemble Weighted Average pada Base Model 2. Baris menunjukkan label aktual, kolom adalah prediksi model. Nilai tinggi pada diagonal

utama menandakan akurasi klasifikasi yang baik. Kinerja terbaik terlihat pada kelas 0 (329 benar), 3 (288), 6 (310), 7 (590), dan 15 (390). Kesalahan pada kelas 10 dan 13 tersebar secara acak tanpa pola ambiguitas signifikan, yang menunjukkan bahwa pendekatan ensemble weighted average telah berhasil meningkatkan performa akurasi secara optimal.

5.6. Majority Voting Base Model 3

Metode majority voting diterapkan pada Base Model 3, yaitu ensemble tiga CNN *lightweight* dengan kernel 3×3 , 5×5 , dan 7×7 yang dilatih independen menggunakan Nadam. Pendekatan ini meningkatkan stabilitas prediksi dan mengurangi kesalahan, sehingga memperbaiki performa akurasi klasifikasi tumor otak. Hasil pengujian diperlihatkan pada Tabel 5.9.

Tabel 5.9. Hasil Majority Voting pada Base Model 3

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.91	0.98	0.99	0.95
1	0.99	0.92	0.91	0.99	0.91
2	0.99	0.99	0.97	0.99	0.98
3	0.99	0.93	0.98	0.99	0.96
4	0.99	0.97	0.98	0.99	0.97
5	0.99	0.98	0.91	0.99	0.94
6	0.99	0.93	0.93	0.99	0.93
7	0.99	0.98	0.97	0.99	0.98
8	0.99	1.00	0.93	1.00	0.96
9	0.99	0.97	0.80	0.99	0.88
10	0.99	0.96	0.98	0.99	0.97
11	0.99	1.00	0.97	1.00	0.98
12	0.98	0.91	0.93	0.99	0.92
13	0.99	0.99	0.98	0.99	0.98
14	0.99	0.98	0.98	0.99	0.98
15	0.99	0.97	0.94	0.99	0.95
16	0.99	0.96	0.97	0.99	0.97

Tabel 5.9 menunjukkan hasil evaluasi Majority Voting pada Base Model CNN3, dengan akurasi hampir 1.00 di semua kelas. Precision, specificity, dan recall umumnya tinggi, kecuali kelas 9 dengan recall terendah (0.80), yang mempengaruhi F1-Score (0.88). Secara keseluruhan, model ini menunjukkan keseimbangan antara precision, recall, dan F1-Score dengan performa stabil.

Untuk memperkuat validitas evaluasi, dilakukan analisis confusion matrix pada Base Model 3, yang merupakan ensemble tiga CNN *lightweight* dengan majority voting. Analisis ini mengevaluasi akurasi klasifikasi per kelas tumor otak sekaligus menguatkan efektivitas metode ensemble. Hasil rinci diperlihatkan pada Tabel 5.10.

Tabel 5.10. Confusion Matrix Majority Voting pada Base Model 3

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	341	0	1	0	0	0	0	0	0	0	1	0	0	0	0	2	0
1	0	102	0	1	0	0	3	0	0	0	0	0	6	0	0	0	0
2	3	0	266	0	0	0	0	0	0	0	0	0	0	0	0	3	0
3	0	0	0	287	0	0	1	0	0	0	0	0	3	0	0	0	0
4	1	0	0	0	500	0	0	5	0	0	0	0	0	1	0	1	0
5	0	1	0	3	0	113	2	0	0	0	0	0	4	0	0	0	0
6	0	6	0	5	0	0	323	0	0	0	0	0	12	0	0	0	0
7	3	0	0	0	8	0	0	608	0	0	0	0	3	0	2	0	1
8	5	0	0	0	0	0	0	0	142	1	0	0	0	0	4	0	0
9	0	0	0	2	0	0	7	0	0	46	0	0	2	0	0	0	0
10	3	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0
11	0	0	0	0	0	0	0	1	0	0	0	47	0	0	0	0	0
12	1	1	0	8	0	2	8	0	0	0	0	0	308	0	1	0	0
13	2	0	0	0	3	0	0	0	0	0	0	0	0	256	0	0	0
14	1	0	0	0	0	0	0	1	0	0	0	0	0	0	192	0	0
15	9	0	0	0	4	0	0	0	0	0	5	0	0	0	0	407	5
16	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	165

Tabel 5.10 menunjukkan *confusion matrix* klasifikasi 17 kelas tumor otak menggunakan metode *ensemble* Majority Voting pada Base Model 3. Nilai-nilai tinggi pada diagonal utama, seperti 341 (kelas 0), 266 (kelas 2), 287 (kelas 3), dan 608 (kelas 7), menunjukkan performa akurasi tinggi pada kelas-kelas tersebut. Sebaliknya, nilai signifikan di luar diagonal, seperti 323 (sel 6,7) dan 608 (sel 7,6),

mengindikasikan ambiguitas antar kelas yang menyebabkan kesalahan klasifikasi. Secara keseluruhan, performa model dapat dikategorikan baik dan cukup optimal dalam mengenali sebagian besar kelas, meskipun masih terdapat ruang untuk peningkatan, khususnya pada kelas-kelas yang tumpang tindih. Matriks ini menjadi dasar evaluasi yang penting untuk pengembangan model lebih lanjut.

5.7. Weighted Average Base Model 3

Metode weighted average diterapkan pada Base Model 3, merupakan ensemble dari tiga arsitektur CNN *lightweight* dengan ukuran kernel 3×3 , 5×5 , dan 7×7 yang dilatih secara independen menggunakan optimizer Nadam. Prediksi akhir diperoleh melalui rata-rata keluaran softmax yang dibagi jumlah model. Hasil performa diperlihatkan pada Tabel 5.11.

Tabel 5.11. Hasil Weighted Average pada Base Model 3

Class	Accuracy	Precision	Recall	Specificity	F1-Score
0	0.99	0.94	0.99	0.99	0.96
1	0.99	0.96	0.93	0.99	0.95
2	0.99	0.99	0.97	0.99	0.98
3	0.99	0.95	0.97	0.99	0.96
4	0.99	0.97	0.99	0.99	0.98
5	0.99	0.97	0.92	0.99	0.95
6	0.99	0.94	0.95	0.99	0.95
7	0.99	0.98	0.97	0.99	0.98
8	0.99	1.00	0.94	1.00	0.97
9	0.99	0.95	0.82	0.99	0.88
10	0.99	0.94	0.98	0.99	0.96
11	0.99	1.00	0.97	1.00	0.98
12	0.99	0.93	0.95	0.99	0.94
13	0.99	0.99	0.98	0.99	0.98
14	0.99	0.97	0.98	0.99	0.98
15	0.99	0.97	0.94	0.99	0.95
16	0.99	0.95	0.98	0.99	0.97

Tabel 5.11 menunjukkan hasil evaluasi Weighted Average pada Base Model CNN3, dengan akurasi mendekati 1.00 di hampir semua kelas, menunjukkan performa yang sangat baik. Precision dan specificity yang tinggi mencerminkan kemampuan model yang sangat baik dalam mengidentifikasi kelas yang benar dan meminimalkan kesalahan klasifikasi. Recall juga tinggi di sebagian besar kelas, meskipun kelas 9 menunjukkan recall terendah (0.82), yang mempengaruhi F1-Score (0.88) pada kelas tersebut. Secara keseluruhan, model ini menunjukkan keseimbangan yang baik antara precision, recall, dan F1-Score, serta performa stabil di hampir semua kelas.

Untuk meningkatkan validitas evaluasi, dilakukan analisis *confusion matrix* terhadap Base Model 3, yakni *ensemble* tiga CNN *lightweight* dengan metode *Weighted Average*. Analisis ini menilai akurasi klasifikasi pada masing-masing kelas tumor otak serta mengkonfirmasi efektivitas pendekatan *ensemble* yang digunakan. Hasil detail ditampilkan pada Tabel 5.12.

Tabel 5.12. Confusion Matrix Weighted Average pada Base Model 3

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
0	342	0	0	0	0	0	0	0	0	0	2	0	0	0	0	1	0
1	0	105	0	1	0	0	4	0	0	0	0	0	2	0	0	0	0
2	2	0	266	0	0	0	0	0	0	0	0	0	0	0	0	4	0
3	0	0	0	285	0	0	3	0	0	0	0	0	3	0	0	0	0
4	0	0	0	0	503	0	0	3	0	0	0	0	0	1	0	1	0
5	0	0	0	2	0	114	1	0	0	0	0	0	5	0	1	0	0
6	0	4	0	3	0	0	332	0	0	0	0	0	7	0	0	0	0
7	4	0	0	0	7	0	0	608	0	0	0	0	3	0	2	0	1
8	2	0	0	0	0	0	0	0	144	2	0	0	0	0	0	4	0
9	0	0	0	2	0	0	6	0	0	47	0	0	2	0	0	0	0
10	2	0	0	0	0	0	0	0	0	0	151	0	0	0	0	0	0
11	0	0	0	0	0	0	0	1	0	0	0	47	0	0	0	0	0
12	0	0	0	6	0	3	6	0	0	0	0	0	313	0	1	0	0
13	2	0	0	0	2	0	0	1	0	0	0	0	0	256	0	0	0
14	0	0	0	0	0	0	0	2	0	0	0	0	0	0	192	0	0
15	8	0	1	0	3	0	0	0	0	0	5	0	0	0	0	407	6
16	1	0	0	0	0	0	0	0	0	1	0	0	0	0	1	166	

Tabel 5.12 menampilkan *confusion matrix* klasifikasi 17 kelas tumor otak menggunakan metode *Weighted Average* pada Base Model 3. Nilai-nilai tinggi pada diagonal utama, seperti 342 (kelas 0), 266 (kelas 2), 285 (kelas 3), 503 (kelas 5), dan 608 (kelas 7), menunjukkan bahwa model memiliki akurasi tinggi dalam mengklasifikasikan sebagian besar kelas. Selain itu, penurunan signifikan pada nilai non-diagonal, seperti kesalahan klasifikasi antara kelas 6 dan 7, menandakan peningkatan presisi dibandingkan metode sebelumnya. Hasil ini mengindikasikan bahwa pendekatan *ensemble* dengan *Weighted Average* memberikan performa klasifikasi yang lebih optimal dan representatif, serta memperkuat efektivitas model dalam membedakan antar kelas tumor secara lebih akurat.

5.8. Evaluasi Ensemble Learning

Evaluasi terhadap metode ensemble dilakukan untuk mengukur performa dalam meningkatkan akurasi dan stabilitas klasifikasi melalui penggabungan prediksi dari beberapa base model CNN *lightweight*. Hasil evaluasi performa ditampilkan pada Tabel 5.13

Tabel 5.13. Evaluasi Performa Ensemble

Base Model site	Ensemble	Accuracy	Precision	Recall	Specificity	F1-Score
Base Model 1	MV	0.94	0.95	0.94	0.99	0.94
	WA	0.95	0.95	0.95	0.99	0.95
Base Model 2	MV	0.91	0.92	0.91	0.99	0.91
	WA	0.92	0.93	0.92	0.99	0.92
Base Model3	MV	0.96	0.96	0.96	0.99	0.96
	WA	0.96	0.96	0.96	0.99	0.96

Tabel 5.13 menunjukkan hasil evaluasi performa tiga Base Model CNN *lightweight* yang dikombinasikan dengan dua metode ensemble, yaitu Majority Voting (MV) dan Weighted Average (WA), untuk klasifikasi 17 kelas tumor otak. Evaluasi mencakup lima metrik utama: Accuracy, Precision, Recall, Specificity, dan F1-Score. Tujuan dari penggunaan metode ensemble adalah untuk meningkatkan akurasi dan stabilitas model melalui penggabungan prediksi dari beberapa arsitektur yang dilatih secara independen.

Pada Base Model 1, penerapan WA menunjukkan peningkatan performa di seluruh metrik dibanding MV. Accuracy meningkat dari 0,94 menjadi 0,95, Precision dan Recall masing-masing naik dari 0,95 dan 0,94 menjadi 0,95. F1-Score juga naik dari 0,94 menjadi 0,95. Hal ini menunjukkan bahwa WA mampu mengurangi kesalahan klasifikasi dan meningkatkan keseimbangan antara presisi dan sensitivitas model.

Demikian pula pada Base Model 2, metode WA menunjukkan peningkatan seragam dibanding MV. Accuracy meningkat dari 0,91 menjadi 0,92, Precision dari 0,92 menjadi 0,93, serta Recall dan F1-Score masing-masing dari 0,91 menjadi 0,92. Meskipun peningkatan ini relatif kecil, hal tersebut menunjukkan bahwa WA lebih efektif dalam mengatasi ketidakseimbangan prediksi antar kelas pada model dengan performa awal yang masih moderat.

Sementara itu, pada Base Model 3, kedua metode ensemble menghasilkan performa yang identik di seluruh metrik, dengan nilai Accuracy, Precision, Recall, dan F1-Score sebesar 0,96, serta Specificity sebesar 0,99. Hal ini mengindikasikan bahwa Base Model 3 telah mencapai performa optimal dan sangat stabil, sehingga

metode agregasi yang digunakan (MV atau WA) tidak memberikan dampak signifikan terhadap hasil akhir. Model ini menunjukkan kapabilitas tinggi dalam mengenali pola data yang kompleks dengan tingkat kesalahan yang sangat rendah.

Secara keseluruhan, penerapan metode ensemble, khususnya Weighted Average (WA), menunjukkan kontribusi signifikan dalam meningkatkan performa model klasifikasi, terutama pada Base Model 1 dan 2. Dibandingkan dengan Majority Voting (MV), WA menunjukkan keunggulan dalam aspek akurasi, presisi, serta konsistensi antar kelas, yang menunjukkan kemampuan model dalam mengurangi kesalahan prediksi. Sementara itu, Base Model 3 menunjukkan performa yang sangat baik dan stabil pada seluruh metrik evaluasi, mengindikasikan bahwa arsitektur model dan strategi pelatihannya telah optimal. Dengan demikian, integrasi arsitektur CNN lightweight dan metode ensemble Weighted Average terbukti mampu meningkatkan performa kualitas klasifikasi tumor otak dengan banyak kelas secara optimal dan representatif.

BAB VI

PEMBAHASAN

Pembahasan ini berfokus pada analisis implementasi arsitektur *lightweight Convolutional Neural Network* (CNN) dengan variasi ukuran kernel (3×3 , 5×5 , dan 7×7), serta penerapan metode *ensemble learning* (Majority Voting dan Weighted Average) dalam klasifikasi 17 jenis tumor otak berdasarkan citra MRI. Evaluasi mencakup akurasi dan perbandingan kinerja masing-masing pendekatan untuk mengukur pengaruh arsitektur dan metode *ensemble* terhadap kualitas klasifikasi. Pendekatan ini diharapkan memberikan gambaran komprehensif mengenai performa kombinasi model dalam mendukung diagnosis citra medis yang memerlukan presisi tinggi.

6.1. Pengaruh Ukuran Kernel Terhadap Ekstraksi Fitur

Variasi ukuran kernel dalam arsitektur Lightweight CNN berperan penting dalam menentukan kapasitas jaringan dalam mengekstraksi fitur spasial dari citra masukan. Kernel berukuran kecil, seperti 3×3 , cenderung fokus pada detail lokal dan tekstur halus, sedangkan kernel berukuran lebih besar, seperti 5×5 dan 7×7 , memiliki area reseptif yang lebih luas sehingga mampu menangkap pola spasial yang lebih kompleks. Ukuran kernel secara langsung memengaruhi kualitas representasi fitur di setiap lapisan konvolusional, yang berdampak pada akurasi klasifikasi tumor otak berbasis citra MRI. Semakin tinggi nilai val accuracy dan AUC serta semakin rendah val loss, semakin baik kemampuan kernel dalam mengekstraksi fitur relevan untuk klasifikasi tumor otak.

6.1.1. Pengaruh Ukuran Kernel dengan Optimizer Adam

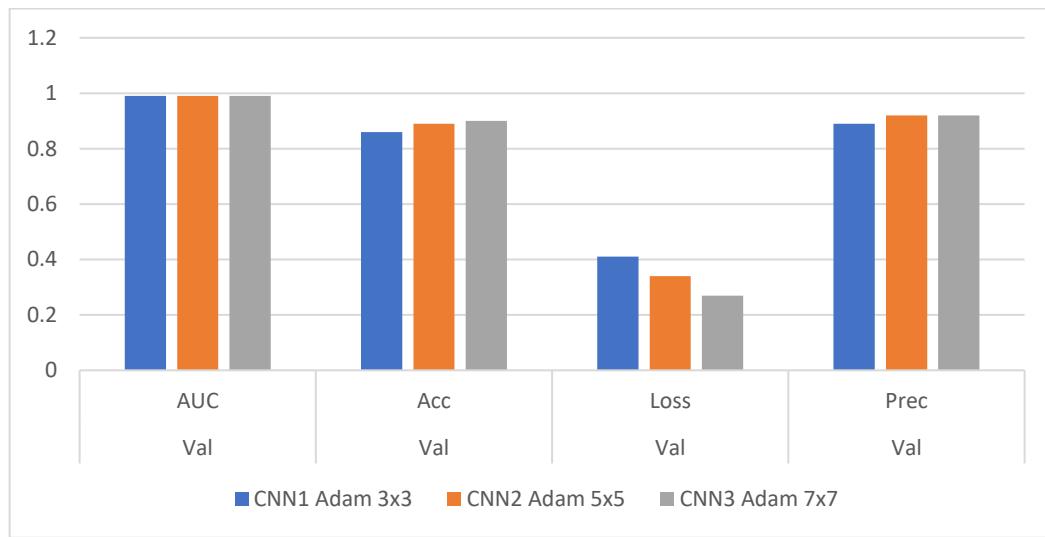
Hasil evaluasi performa model Lightweight CNN dengan variasi ukuran kernel (3x3, 5x5, dan 7x7) menggunakan optimizer Adam ditampilkan pada Tabel 6.1. Setiap konfigurasi diuji berdasarkan AUC, akurasi, loss, presisi, dan recall pada data validasi untuk menilai kemampuan model dalam mengekstraksi fitur spasial pada klasifikasi citra MRI.

Tabel 6.1. Pengaruh Ukuran Kernel dengan Optimizer Adam

Base Model	Optimizer	Kernel Size	Val AUC	Val Acc	Val Loss	Val Prec	Val Rec
CNN1	Adam	3x3	0.99	0.86	0.41	0.89	0.84
CNN2	Adam	5x5	0.99	0.89	0.34	0.92	0.86
CNN3	Adam	7x7	0.99	0.90	0.27	0.92	0.89

Tabel 6.1 menunjukkan bahwa variasi ukuran kernel memberikan dampak terhadap performa model Lightweight CNN dengan optimizer Adam. Meskipun AUC tetap konstan pada 0,99, terdapat peningkatan akurasi dari 0,86 (3x3) menjadi 0,90 (7x7), serta penurunan loss dari 0,41 menjadi 0,27, yang mencerminkan peningkatan kemampuan generalisasi model. Presisi dan recall juga meningkat, masing-masing dari 0,89 ke 0,92 dan 0,84 ke 0,89, menunjukkan bahwa kernel yang lebih besar memungkinkan model mengenali pola spasial dengan lebih baik. Secara keseluruhan, kernel 7x7 memberikan performa paling optimal.

Gambar 6.1 memperlihatkan peningkatan akurasi, presisi, dan recall serta penurunan loss seiring bertambahnya ukuran kernel, memperkuat hasil Tabel 6.1 bahwa kernel lebih besar meningkatkan performa klasifikasi citra MRI oleh Lightweight CNN dengan optimizer Adam.



Gambar 6.1. Pengaruh Ukuran Kernel dengan Optimizer Adam

6.1.2. Pengaruh Ukuran Kernel dengan Optimizer AdamW

Untuk mengetahui pengaruh variasi ukuran kernel terhadap performa model Lightweight CNN dengan optimizer AdamW, dilakukan evaluasi menggunakan kernel berukuran 3x3, 5x5, dan 7x7. Evaluasi ini mencakup metrik AUC, akurasi, loss, presisi, dan recall pada data validasi guna menilai kemampuan model dalam mengekstraksi fitur spasial pada klasifikasi citra MRI. Hasil lengkap dari pengujian tersebut ditampilkan pada Tabel 6.2

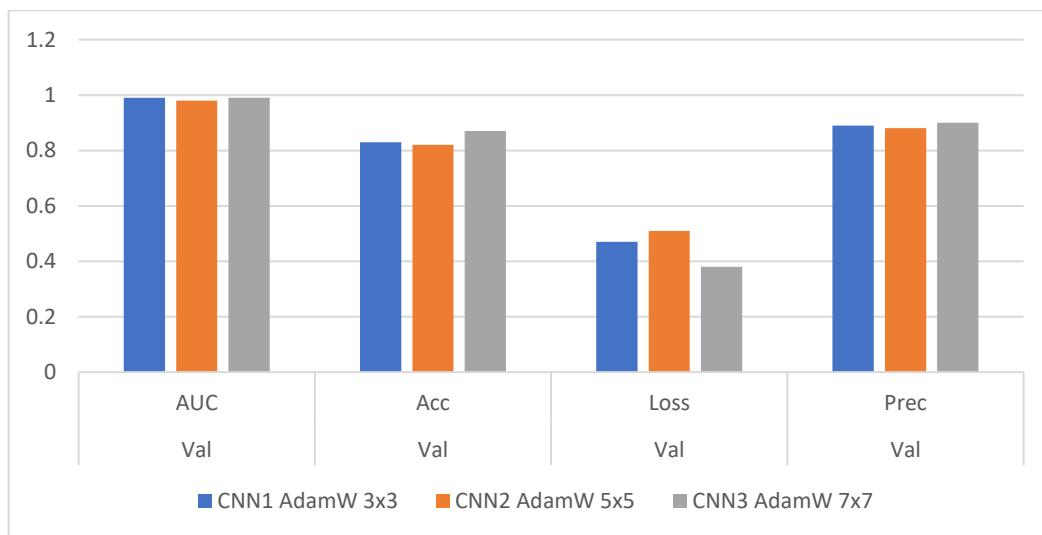
Tabel 6.2. Pengaruh Ukuran Kernel Dengan Optimizer AdamW

Base Model	Optimizer	Kernel Size	Val AUC	Val Acc	Val Loss	Val Prec	Val Rec
CNN1	AdamW	3x3	0.99	0.83	0.47	0.89	0.79
CNN2	AdamW	5x5	0.98	0.82	0.51	0.88	0.78
CNN3	AdamW	7x7	0.99	0.87	0.38	0.90	0.86

Tabel 6.2 menunjukkan bahwa ukuran kernel 7x7 dengan optimizer AdamW menghasilkan performa terbaik pada model Lightweight CNN, ditandai

dengan akurasi dan recall tertinggi (0,87 dan 0,86), serta loss terendah (0,38). AUC dan presisi relatif stabil di semua ukuran kernel, menunjukkan konsistensi kemampuan klasifikasi citra MRI.

Gambar 6.2 menunjukkan pola peningkatan akurasi, presisi, dan recall serta penurunan loss seiring bertambahnya ukuran kernel, yang memperkuat hasil analisis pada Tabel 6.2 bahwa penggunaan kernel lebih besar meningkatkan performa klasifikasi citra MRI oleh model Lightweight CNN dengan optimizer AdamW.



Gambar 6.2. Pengaruh Ukuran Kernel Dengan Optimizer AdamW

6.1.3. Pengaruh Ukuran Kernel dengan Optimizer Nadam

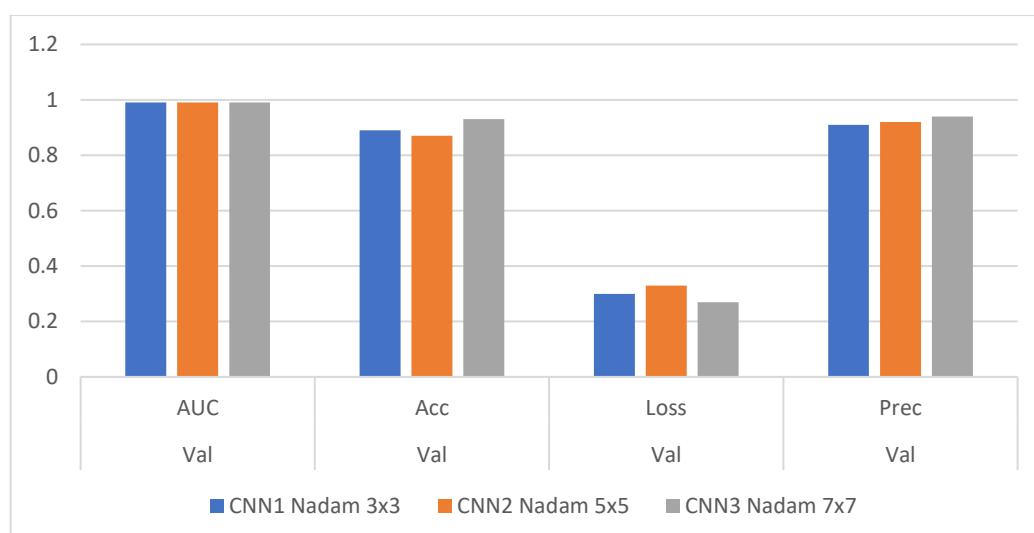
Pengaruh variasi ukuran kernel terhadap performa model Lightweight CNN dengan optimzer Nadam dianalisis melalui evaluasi menggunakan kernel 3x3, 5x5, dan 7x7. Penilaian dilakukan berdasarkan metrik AUC, akurasi, loss, presisi, dan recall pada data validasi untuk mengukur kemampuan model dalam mengekstraksi fitur spasial pada klasifikasi citra MRI. Hasil diperlihatkan pada Tabel 6.3.

Tabel 6.3. Pengaruh Ukuran Kernel dengan Optimizer Nadam

Base Model	Optimizer	Kernel Size	Val AUC	Val Acc	Val Loss	Val Prec	Val Rec
CNN1	Nadam	3x3	0.99	0.89	0.30	0.91	0.87
CNN2	Nadam	5x5	0.99	0.87	0.33	0.92	0.87
CNN3	Nadam	7x7	0.99	0.93	0.27	0.94	0.91

Tabel 6.3. menunjukkan performa model Lightweight CNN dengan optimizer Nadam pada variasi ukuran kernel 3x3, 5x5, dan 7x7. AUC konsisten tinggi di 0,99, menandakan kemampuan pemisahan kelas yang sangat baik. Akurasi tertinggi dicapai pada kernel 7x7 (0,93), dengan penurunan loss terendah (0,27), serta presisi (0,94) dan recall (0,91) terbaik. Hasil ini mengindikasikan bahwa peningkatan ukuran kernel secara signifikan meningkatkan kemampuan ekstraksi fitur spasial dan kinerja klasifikasi citra MRI.

Gambar 6.3 memperkuat hasil Tabel 6.3 bahwa peningkatan ukuran kernel meningkatkan akurasi, presisi, dan recall serta menurunkan loss pada klasifikasi citra MRI oleh model Lightweight CNN dengan optimizer Nadam.

**Gambar 6.3.** Pengaruh Ukuran Kernel dengan Optimizer Nadam

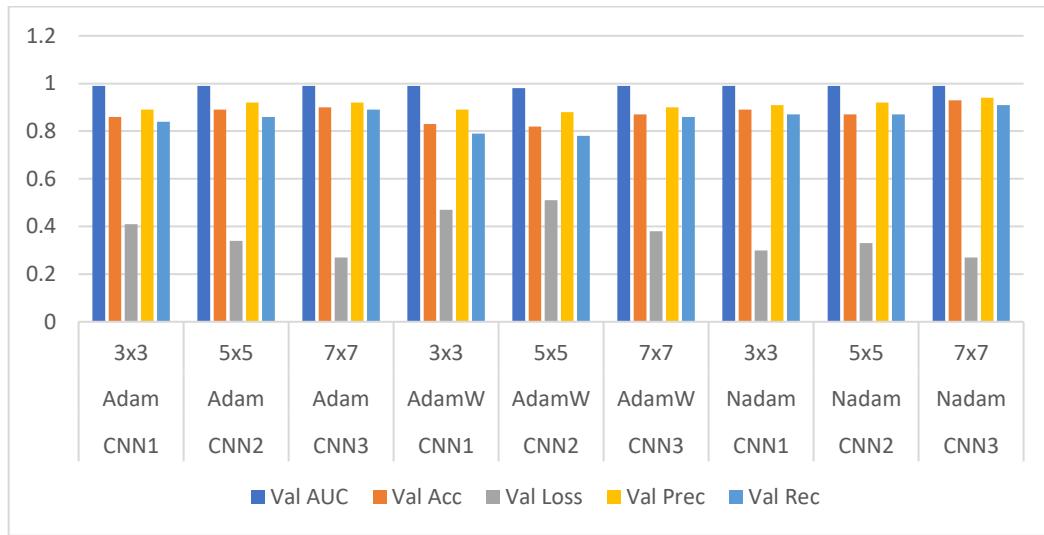
6.2. Analisis Kinerja Lightweight CNN dengan Variasi Kernel

Analisis ini membahas performa arsitektur *lightweight* CNN dengan tiga variasi ukuran kernel (3×3 , 5×5 , dan 7×7) yang masing-masing dikombinasikan dengan tiga jenis optimizer: Adam, AdamW, dan Nadam. Kombinasi tersebut menghasilkan sembilan model yang dikelompokkan ke dalam tiga base model site, berdasarkan jenis optimizernya. Fokus analisis terletak pada pengaruh variasi kernel dan jenis optimizer terhadap performa klasifikasi, ditinjau melalui metrik Val AUC, Val Accuracy, Val Loss, Val Precision dan Val Recall. Hasil evaluasi kinerja model ditampilkan secara terperinci pada Tabel 6.4 untuk memudahkan perbandingan antar model. Analisis ini memberikan gambaran yang jelas mengenai pengaruh parameter terhadap klasifikasi tumor otak pada citra MRI.

Tabel 6.4. Perbandingan Validasi Model Lightweight CNN

Base Model	Optimizer	Kernel Size	Val AUC	Val Acc	Val Loss	Val Prec	Val Rec
CNN1	Adam	3×3	0.99	0.86	0.41	0.89	0.84
CNN2	Adam	5×5	0.99	0.89	0.34	0.92	0.86
CNN3	Adam	7×7	0.99	0.90	0.27	0.92	0.89
CNN1	AdamW	3×3	0.99	0.83	0.47	0.89	0.79
CNN2	AdamW	5×5	0.98	0.82	0.51	0.88	0.78
CNN3	AdamW	7×7	0.99	0.87	0.38	0.90	0.86
CNN1	Nadam	3×3	0.99	0.89	0.30	0.91	0.87
CNN2	Nadam	5×5	0.99	0.87	0.33	0.92	0.87
CNN3	Nadam	7×7	0.99	0.93	0.27	0.94	0.91

Tabel 6.4 menunjukkan bahwa seluruh model memiliki AUC tinggi dan konsisten (0.98 – 0.99), mencerminkan kemampuan klasifikasi yang baik. CNN3 dengan kernel 7×7 dan optimizer Nadam menunjukkan performa validasi terbaik, dengan val accuracy 0.93, val loss 0.27, precision 0.94, dan recall 0.91. Sebagaimana tergambar dari perbedaan nilai validasi pada Gambar 6.4.



Gambar 6.4. Perbandingan Validasi Model Lightweight CNN

Secara keseluruhan, model dengan kernel lebih besar 7×7 menunjukkan performa lebih tinggi dibandingkan kernel 3×3 dan 5×5 , terutama saat dioptimasi menggunakan Nadam. Sementara itu, penggunaan AdamW cenderung menghasilkan val accuracy dan recall yang lebih rendah dibanding Adam dan Nadam, menunjukkan bahwa jenis optimizer memberikan pengaruh signifikan terhadap kualitas pelatihan.

Dengan demikian, kombinasi kernel 7×7 dan optimizer Nadam menunjukkan kapabilitas terbaik dalam meningkatkan akurasi validasi dan konsistensi model terhadap data yang belum pernah dilihat sebelumnya

6.3. Evaluasi Kinerja Model Lightweight CNN secara Individu

Evaluasi kinerja masing-masing model Lightweight Convolutional Neural Network (CNN) dilakukan melalui metrik evaluasi, seperti akurasi, presisi, specificity, recall, dan F1-score. Metrik ini memberikan gambaran menyeluruh mengenai kemampuan model dalam mengklasifikasikan data secara tepat, termasuk

dalam mengidentifikasi tingkat kesalahan klasifikasi yang terjadi pada setiap kelas. Dengan melakukan evaluasi secara individual, performa setiap model dapat dianalisis secara objektif guna mengetahui kelayakan dalam penerapan metode ensemble pada tahap berikutnya. Hasil evaluasi tersebut ditampilkan secara lengkap pada Tabel 6.5.

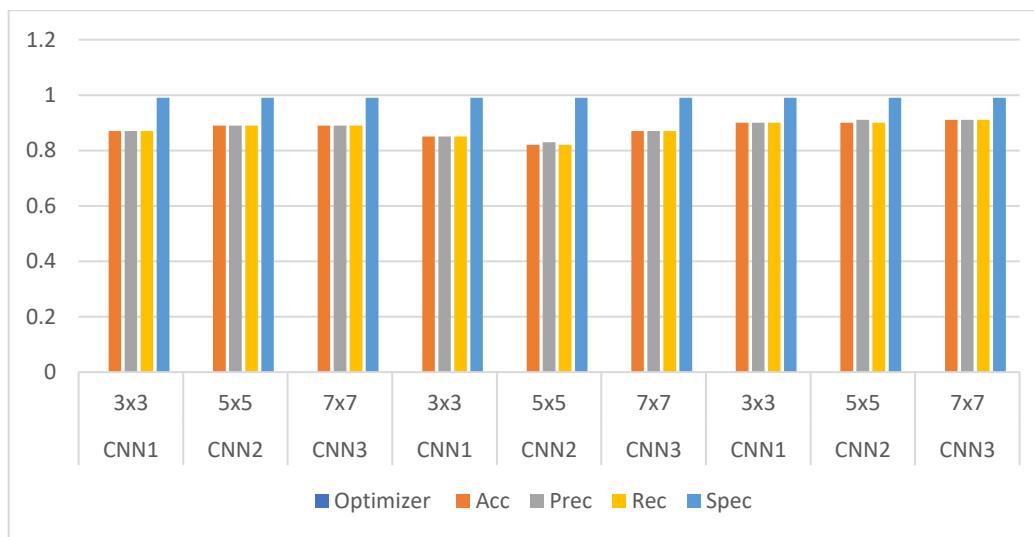
Tabel 6.5. Evaluasi Kinerja Lightweight CNN secara Individu

Base Model	Kernel Size	Optimizer	Acc	Prec	Rec	Spec	F1-Score
CNN1	3x3	Adam	0.87	0.87	0.87	0.99	0.86
CNN2	5x5		0.89	0.89	0.89	0.99	0.89
CNN3	7x7		0.89	0.89	0.89	0.99	0.89
CNN1	3x3	AdamW	0.85	0.85	0.85	0.99	0.84
CNN2	5x5		0.82	0.83	0.82	0.99	0.82
CNN3	7x7		0.87	0.87	0.87	0.99	0.87
CNN1	3x3	Nadam	0.90	0.90	0.90	0.99	0.90
CNN2	5x5		0.90	0.91	0.90	0.99	0.91
CNN3	7x7		0.91	0.91	0.91	0.99	0.91

Tabel 6.5 menunjukkan evaluasi kinerja masing-masing model Lightweight CNN (CNN1, CNN2, dan CNN3) yang menggunakan tiga jenis kernel (3x3, 5x5, dan 7x7) serta dioptimasi dengan tiga jenis optimizer, yaitu Adam, AdamW, dan Nadam. Setiap model dievaluasi menggunakan lima metrik utama: akurasi, presisi, recall, specificity, dan F1-score. Untuk memperoleh pemahaman yang lebih komprehensif terhadap kontribusi setiap optimizer terhadap kinerja model, dilakukan perhitungan nilai rata-rata dari setiap metrik evaluasi berdasarkan jenis optimizer yang digunakan.

Berdasarkan rata-rata metrik evaluasi, model Lightweight CNN dengan optimizer Nadam menunjukkan performa paling stabil dalam klasifikasi, dengan

akurasi 0.90, diikuti Adam (0.88) dan AdamW (0.85). Pola serupa terlihat pada presisi dan recall, di mana Nadam mencatatkan nilai 0.91 dan 0.90, lebih tinggi dibandingkan Adam (0.88) dan AdamW (0.85). Nilai F1-score juga mendukung kecenderungan ini, dengan rata-rata 0.91 untuk Nadam, 0.88 untuk Adam, dan 0.84 untuk AdamW. Sementara itu, seluruh model menunjukkan specificity konstan sebesar 0.99, yang mencerminkan konsistensi dalam mengenali kelas negatif. Perbedaan performa rata-rata ini divisualisasikan pada Gambar 6.5 untuk memperkuat hasil evaluasi.



Gambar 6.5. Evaluasi Individu Kinerja Model Lightweight CNN

Secara keseluruhan, temuan ini menunjukkan bahwa penggunaan optimizer Nadam memberikan pengaruh terhadap performa klasifikasi model Lightweight CNN jika dibandingkan dengan Adam dan AdamW. Hal ini dapat dikaitkan dengan mekanisme adaptif Nadam yang menggabungkan RMSprop dan momentum, sehingga mampu mempercepat konvergensi dan meningkatkan generalisasi model dalam proses klasifikasi citra tumor otak.

6.4. Majority Voting pada Model Lightweight CNN

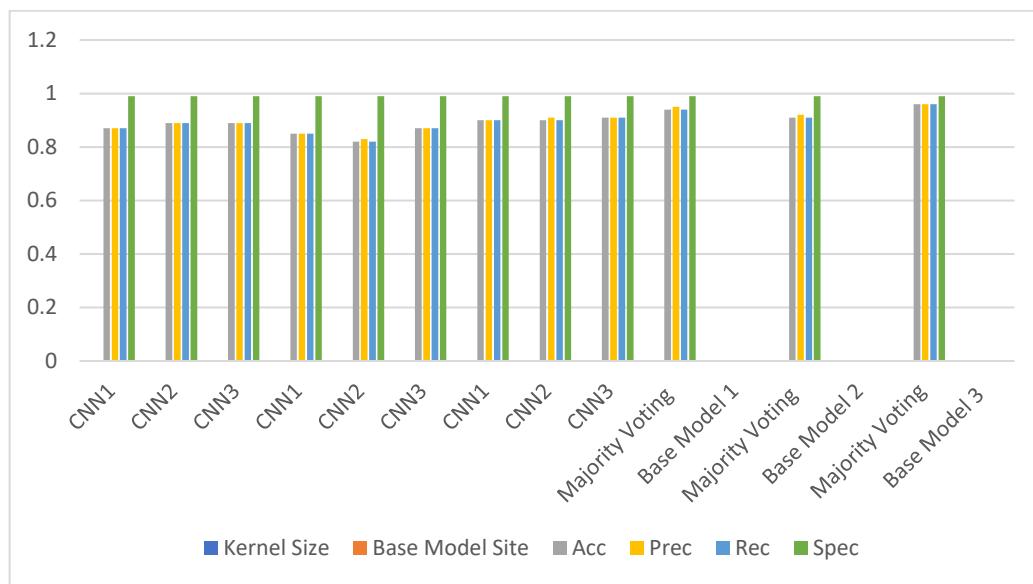
Pada bagian ini, dibahas penerapan metode majority voting sebagai pendekatan *ensemble* untuk mengintegrasikan prediksi dari beberapa model Lightweight CNN. Metode majority voting bertujuan meningkatkan stabilitas dan akurasi klasifikasi dengan menentukan keputusan akhir berdasarkan suara mayoritas dari model-model individu. Analisis difokuskan pada pengaruh metode ini terhadap performa klasifikasi tumor otak pada citra MRI, khususnya dalam hal reliabilitas dan presisi hasil prediksi. Diperlihatkan pada Tabel 6.6.

Tabel 6.6. Majority Voting pada Model Lightweight CNN

Base Model	Kernel Size	Base Model Site	Acc	Prec	Rec	Spec	F1-Score
CNN1	3x3	Base Model 1	0.87	0.87	0.87	0.99	0.86
CNN2	5x5		0.89	0.89	0.89	0.99	0.89
CNN3	7x7		0.89	0.89	0.89	0.99	0.89
CNN1	3x3	Base Model 2	0.85	0.85	0.85	0.99	0.84
CNN2	5x5		0.82	0.83	0.82	0.99	0.82
CNN3	7x7		0.87	0.87	0.87	0.99	0.87
CNN1	3x3	Base Model 3	0.90	0.90	0.90	0.99	0.90
CNN2	5x5		0.90	0.91	0.90	0.99	0.91
CNN3	7x7		0.91	0.91	0.91	0.99	0.91
Majority Voting Base Model 1			0.94	0.95	0.94	0.99	0.94
Majority Voting Base Model 2			0.91	0.92	0.91	0.99	0.91
Majority Voting Base Model 3			0.96	0.96	0.96	0.99	0.96

Berdasarkan hasil evaluasi pada Tabel 6.6, model Lightweigh CNN individual menunjukkan performa yang cukup baik dengan rata-rata akurasi berkisar antara 0.82 hingga 0.91, dan specificity tetap tinggi pada angka 0.99 di seluruh konfigurasi. Model dengan kernel 7x7 secara konsisten mencatat hasil

tertinggi di setiap konfigurasi. Penerapan metode majority voting pada masing-masing base model menghasilkan peningkatan signifikan pada semua metrik, dengan akurasi tertinggi sebesar 0.96 pada kombinasi Base Model 3. Hal ini menunjukkan bahwa ensemble melalui majority voting mampu mengoptimalkan kinerja klasifikasi dibandingkan model individual. Perbedaan hasil evaluasi tersebut divisualisasikan pada Gambar 6.6 untuk memperkuat interpretasi terhadap performa masing-masing pendekatan.



Gambar 6.6. Majority Voting pada Model Lightweight CNN

6.5. Weighted Average pada Model Lightweight CNN

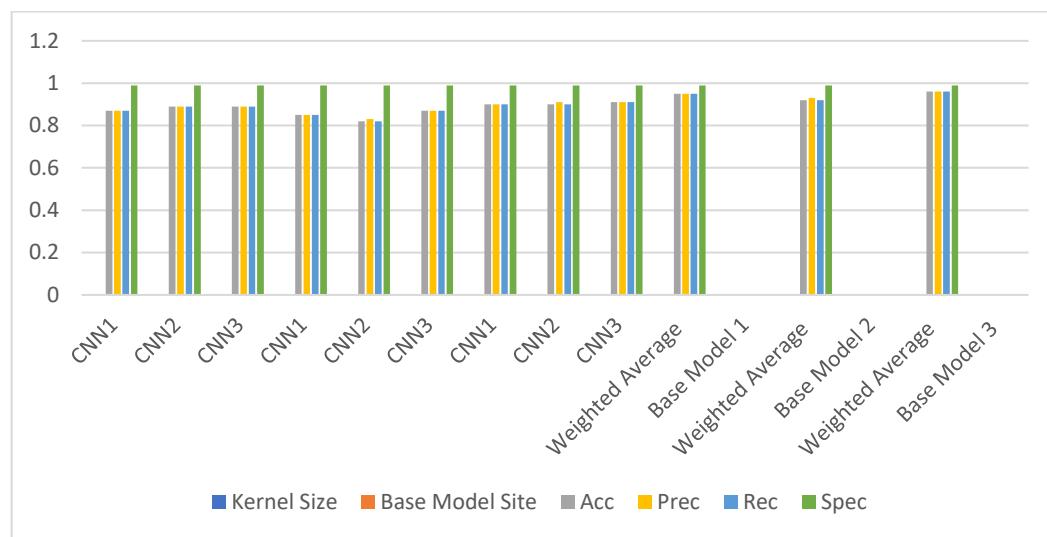
Weighted average digunakan sebagai pendekatan *ensemble* dengan menghitung rata-rata nilai softmax dari masing-masing model Lightweight CNN, lalu memilih kelas dengan nilai rata-rata tertinggi sebagai hasil akhir klasifikasi. Pendekatan ini bertujuan mengutamakan kontribusi model dengan kinerja terbaik guna meningkatkan akurasi dan sensitivitas, khususnya terhadap kelas tumor yang

sulit dikenali. Evaluasi difokuskan pada pengaruh strategi pembobotan terhadap kualitas klasifikasi citra MRI. Diperlihatkan pada Tabel 6.7.

Tabel 6.7. Weighted Average pada Model Lightweight CNN

Base Model	Kernel Size	Base Model Site	Acc	Prec	Rec	Spec	F1-Score
CNN1	3x3	Base Model 1	0.87	0.87	0.87	0.99	0.86
CNN2	5x5		0.89	0.89	0.89	0.99	0.89
CNN3	7x7		0.89	0.89	0.89	0.99	0.89
CNN1	3x3	Base Model 2	0.85	0.85	0.85	0.99	0.84
CNN2	5x5		0.82	0.83	0.82	0.99	0.82
CNN3	7x7		0.87	0.87	0.87	0.99	0.87
CNN1	3x3	Base Model 3	0.90	0.90	0.90	0.99	0.90
CNN2	5x5		0.90	0.91	0.90	0.99	0.91
CNN3	7x7		0.91	0.91	0.91	0.99	0.91
Weighted Average Base Model 1			0.95	0.95	0.95	0.99	0.95
Weighted Average Base Model 2			0.92	0.93	0.92	0.99	0.92
Weighted Average Base Model 3			0.96	0.96	0.96	0.99	0.96

Berdasarkan hasil evaluasi pada Tabel 6.7, penerapan metode weighted average pada masing-masing base model Lightweight CNN menunjukkan peningkatan performa secara menyeluruh dibandingkan model individual. Rata-rata akurasi meningkat menjadi 0.95 (Base Model 1), 0.92 (Base Model 2), dan 0.96 (Base Model 3). Seluruh metrik lain seperti presisi, recall, dan F1-score juga mengalami peningkatan serupa, sementara nilai specificity tetap tinggi pada angka 0.99. Menunjukkan bahwa metode weighted average mampu mengoptimalkan integrasi prediksi antar model sehingga menghasilkan klasifikasi yang lebih akurat dan seimbang. Perbedaan hasil evaluasi divisualisasikan pada Gambar 6.7 untuk memperkuat interpretasi terhadap performa masing-masing pendekatan.



Gambar 6.7. Weighted Average Pada Model Lightweight CNN

6.6. Analisis Model Lightweight CNN Individu dan Ensemble

Perbandingan kinerja antara model CNN individu dan hasil kombinasi melalui metode ensemble majority voting serta weighted average Diperlihatkan secara komprehensif. Analisis difokuskan pada evaluasi akurasi, stabilitas prediksi, dan kemampuan generalisasi masing-masing pendekatan, guna mengidentifikasi strategi klasifikasi citra MRI tumor otak yang paling optimal. Diperlihatkan pada Tabel 6.8.

Tabel 6.8. Perbandingan Kinerja CNN Individu dan Ensemble

Base Model	Kernel Size	Base Model Site	Accuracy	Precision	Recall	Specificity	F1-Score
CNN1	3x3	Base Model 1	0.87	0.87	0.87	0.99	0.86
CNN2	5x5		0.89	0.89	0.89	0.99	0.89
CNN3	7x7		0.89	0.89	0.89	0.99	0.89
CNN1	3x3	Base Model 2	0.85	0.85	0.85	0.99	0.84
CNN2	5x5		0.82	0.83	0.82	0.99	0.82
CNN3	7x7		0.87	0.87	0.87	0.99	0.87
CNN1	3x3	Base Model 3	0.90	0.90	0.90	0.99	0.90
CNN2	5x5		0.90	0.91	0.90	0.99	0.91
CNN3	7x7		0.91	0.91	0.91	0.99	0.91

Tabel Lanjutan 6.8. Perbandingan Kinerja CNN Individu dan Ensemble

Base Model	Kernel Size	Base Model Site	Accuracy	Precision	Recall	Specificity	F1-Score
Majority Voting Base Model 1			0.94	0.95	0.94	0.99	0.94
Majority Voting Base Model 2			0.91	0.92	0.91	0.99	0.91
Majority Voting Base Model 3			0.96	0.96	0.96	0.99	0.96
Weighted Average Base Model 1			0.95	0.95	0.95	0.99	0.95
Weighted Average Base Model 2			0.92	0.93	0.92	0.99	0.92
Weighted Average Base Model 3			0.96	0.96	0.96	0.99	0.96

Tabel 6.8 menunjukkan perbandingan kinerja antara model Lightweight CNN individu dan metode ensemble (*majority voting* dan *weighted average*) menggunakan beberapa metrik evaluasi utama: *accuracy*, *precision*, *recall*, *specificity*, dan F1-score. Analisis menunjukkan bahwa performa model individu sangat dipengaruhi oleh variasi ukuran kernel dan konfigurasi arsitektur dasar.

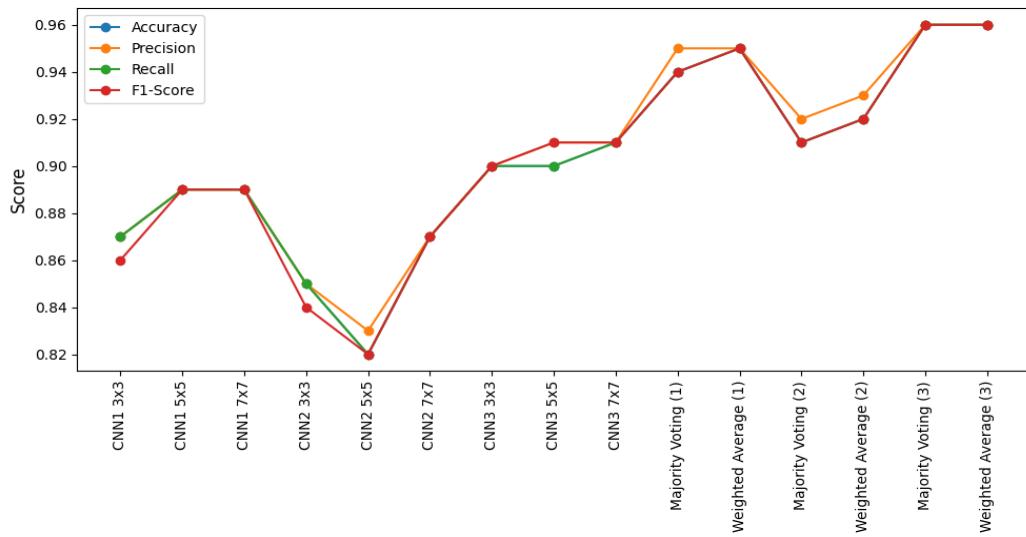
Pada model individu, CNN dengan kernel 7×7 (CNN3) secara konsisten memberikan hasil yang lebih unggul dibandingkan kernel 3×3 (CNN1) dan 5×5 (CNN2). Hal ini terlihat pada semua struktur arsitektur (Base Model 1, 2, dan 3), di mana CNN3 mencapai akurasi dan metrik evaluasi lain yang lebih tinggi, misalnya pada Base Model 3 dengan akurasi 0.91 dan F1-score 0.91. Sebaliknya, performa terendah diperoleh dari CNN2 di Base Model 2, yang mengindikasikan bahwa kernel 5×5 pada konfigurasi tersebut kurang optimal dibandingkan konfigurasi lain.

Metode ensemble, baik majority voting maupun weighted average, secara konsisten menunjukkan peningkatan kinerja yang signifikan dibandingkan model

CNN individu. Pada ketiga arsitektur dasar yang diuji, ensemble berhasil menggabungkan prediksi model-model dasar sehingga menghasilkan akurasi tertinggi, yakni hingga 0.96 pada Base Model 3. Majority voting dan weighted average memberikan hasil yang hampir serupa pada semua metrik evaluasi, dengan nilai precision, recall, dan F1-score yang meningkat secara proporsional, mencerminkan peningkatan dalam keseimbangan antara sensitivitas dan presisi prediksi.

Hal ini mengindikasikan bahwa ensemble mampu mengurangi kesalahan klasifikasi yang mungkin terjadi pada model tunggal, dengan mengintegrasikan kekuatan masing-masing model dasar. Peningkatan performa ensemble juga menunjukkan kemampuan adaptasi yang lebih baik terhadap variasi data dan kompleksitas klasifikasi, terutama terlihat pada Base Model 3, di mana akurasi dan F1-score mencapai nilai tertinggi 0.96. Nilai specificity tetap stabil tinggi (0.99), menandakan bahwa peningkatan performa ensemble tidak mengorbankan kemampuan model dalam mengidentifikasi kelas negatif secara tepat.

Perbandingan kinerja antara model Lightweight CNN individu dan metode ensemble divisualisasikan secara menyeluruh pada Gambar 6.8 untuk memperkuat pemahaman terhadap performa masing-masing pendekatan. Visualisasi ini berfungsi sebagai pelengkap dari data kuantitatif yang ditampilkan dalam Tabel 6.8, serta membantu menggambarkan secara lebih intuitif perbedaan kinerja antar model yang diuji. Dengan menampilkan metrik evaluasi utama seperti *accuracy*, *precision*, *recall*, *F1-score*, dan *specificity*, Gambar 6.8 memberikan informasi yang jelas mengenai masing-masing model dalam berbagai konfigurasi dasar CNN.



Gambar 6.8. Perbandingan Kinerja CNN Individu dan Ensemble

Gambar 6.8 menunjukkan perbandingan kinerja model Lightweight CNN individu dan metode ensemble dalam klasifikasi tumor otak berbasis citra MRI. Bawa model dengan kernel 7×7 (CNN3) secara konsisten unggul dibandingkan kernel 3×3 (CNN1) dan 5×5 (CNN2), terutama pada Base Model 3. Pendekatan ensemble majority voting maupun weighted average menunjukkan peningkatan performa pada seluruh metrik evaluasi, dengan weighted average (3) mencapai nilai tertinggi hingga 0.96. Visualisasi ini memperkuat bahwa penggabungan model mampu meningkatkan performa akurasi.

Dengan demikian, visualisasi pada Gambar 6.8 berfungsi untuk memperjelas temuan numerik, tetapi juga memperkuat interpretasi metode ensemble dapat meningkatkan performa klasifikasi. Selain itu, pendekatan ini dapat meminimalkan overfitting. Integrasi antara visualisasi grafis dan data kuantitatif memperkuat temuan bahwa pendekatan ensemble memberikan hasil yang lebih optimal dalam analisis citra MRI.

6.7. Klasifikasi Tumor Otak dalam Pandangan Islam

Tumor otak merupakan pertumbuhan sel abnormal di dalam atau di sekitar jaringan otak. Secara medis, tumor otak diklasifikasikan menjadi dua jenis utama berdasarkan sifat dan tingkat keganasannya, yaitu tumor jinak (benign) dan tumor ganas (malignant). Tumor jinak cenderung tumbuh lambat dan tidak menyebar ke jaringan sekitarnya, sedangkan tumor ganas bersifat invasif dan dapat menyebar ke bagian lain dari sistem saraf pusat. Selain itu, tumor otak juga dibedakan menjadi tumor primer, yang berasal dari jaringan otak itu sendiri, dan tumor sekunder (metastatik), yang merupakan hasil penyebaran kanker dari organ tubuh lainnya ke otak.

Untuk mendeteksi dan mengklasifikasikan tumor otak, teknologi pencitraan seperti *Magnetic Resonance Imaging* (MRI) digunakan secara luas. Citra MRI memberikan gambaran detail struktur otak, memungkinkan identifikasi lokasi, ukuran, serta jenis tumor dengan tingkat akurasi tinggi. Melalui analisis citra MRI, para ahli radiologi dapat membedakan berbagai jenis tumor otak seperti glioma, meningioma, otak normal, neurocitoma, outros, dan schwannoma, yang memiliki ciri khas tersendiri dalam bentuk, batas tepi, intensitas sinyal, dan pola penyebaran.

Namun demikian, dalam perspektif Islam, penyakit bukan hanya dilihat dari sisi medis atau teknologi. Penyakit, termasuk tumor otak, dipandang sebagai bagian dari ujian hidup yang Allah SWT berikan kepada hamba-Nya. Ujian ini sarat makna, mengandung hikmah, dan menjadi jalan untuk meningkatkan derajat keimanan, kesabaran, serta ketergantungan manusia kepada Sang Pencipta. Hal ini ditegaskan dalam Surat Al-Baqarah ayat 155–156:

وَلَنَبْلُو نَّكْمٌ بِشَيْءٍ مِّنَ الْحُزْفِ وَالْجُوعِ وَنَقْصٌ مِّنَ الْأَمْوَالِ وَالْأَنْفُسِ وَالثَّمَرَاتِ وَبَيْتُرِ
الصَّابِرِينَ (١٥٥) الَّذِينَ إِذَا أَصَابَتْهُمْ مُصِيبَةٌ قَالُوا إِنَّا لِلَّهِ وَإِنَّا إِلَيْهِ رَاجِعُونَ (١٥٦)

“Dan Kami pasti akan menguji kamu dengan sedikit ketakutan, kelaparan, kekurangan harta, jiwa, dan buah-buahan. Dan sampaikanlah kabar gembira kepada orang-orang yang sabar (155), (yaitu) orang-orang yang apabila ditimpa musibah, mereka berkata “Innā lillāhi wa innā ilaihi rāji‘ūn” (sesungguhnya kami milik Allah dan kepada-Nya lah kami kembali) (156).” (Al-Baqarah: 155-156)

Tafsir Wajiz Al Baqarah 155-156 menjelaskan bahwa surat ini berisi tentang kehidupan manusia yang penuh cobaan. Allah menguji manusia untuk mengetahui kualitas keimanan seseorang melalui ketakutan, kelaparan, kekurangan harta, jiwa, dan buah-buahan. Ketika dilanda ujian, umat Islam harus bersabar dengan mengucapkan *“Innā lillāhi wa innā ilaihi rāji‘ūn”* (sesungguhnya kami milik Allah dan kepada-Nya lah kami kembali). Kalimat tersebut memperlihatkan kepasrahan hamba pada Allah SWT. Mereka yang melakukan hal tersebut akan diberi ampunan dan petunjuk kebenaran. (Az-Zuhaili Wahbah) pakar fiqh dan tafsir.

Ayat tersebut mengingatkan bahwa segala bentuk musibah, termasuk penyakit seperti tumor otak, merupakan bagian dari sunnatullah (ketetapan Allah) yang mendidik manusia untuk bersabar dan berserah diri kepada-Nya. Islam memandang penyakit bukan sebagai hukuman semata, melainkan sebagai ujian kehidupan yang sarat hikmah sarana untuk menghapus dosa, meningkatkan derajat keimanan, dan memperkuat hubungan antara hamba dan Tuhannya.

Dalam konteks ini, klasifikasi tumor otak melalui citra *Magnetic Resonance Imaging* (MRI) tidak hanya menjadi sarana diagnosis dan pengobatan secara medis, tetapi juga menjadi momentum refleksi spiritual. Pemahaman terhadap penyakit seperti tumor otak harus diiringi dengan kesadaran akan keterbatasan manusia,

pentingnya ikhtiar, kesabaran, serta doa sebagai bentuk ketawakalan kepada Allah dalam menghadapi setiap ujian hidup.

Setiap individu dianjurkan untuk berusaha secara maksimal, termasuk memanfaatkan kemajuan teknologi dan pengobatan modern, sebagai bagian dari ikhtiar yang sejalan dengan nilai-nilai Islam. Namun demikian, Al-Qur'an mengingatkan bahwa kesembuhan dan kehidupan sepenuhnya berada dalam kuasa Allah SWT. Hal ini ditegaskan dalam firman-Nya (Q.S. Asy-Syu'ara: 80-81):

وَدَا مَرْضٌ فَهُوَ يَشْفِيْنِ (٨٠) وَاللَّذِيْنِ يُمِتُّنِيْنِ ثُمَّ يُحْيِيْنِ (٨١)

"dan apabila aku sakit, Dialah yang menyembuhkan aku (80) dan Yang akan mematikan aku, kemudian akan menghidupkan aku (kembali)(81)." (Q.S. Asy-Syu'ara: 80-81)

Dalam *Tafsir al-Wajiz*. Az-Zuhaili Wahbah pakar fiqih dan tafsir menjelaskan bahwa Q.S. Asy-Syu'ara ayat 80, dijelaskan bahwa salah satu sifat Allah adalah sebagai pemberi kesembuhan. Jika aku sakit, Allah adalah Dzat yang menyembuhkanku dari penyakit setelah aku menerima beberapa sebab (kesembuhan) seperti obat. Selanjutnya, pada ayat 81 disebutkan sifat Allah sebagai Dzat yang mematikan dan menghidupkan, yaitu yang akan mematikan manusia di akhir ajalnya dan membangkitkannya kembali di akhirat.

Dalam konteks penelitian ini, klasifikasi tumor otak berbasis citra MRI merupakan upaya teknologi untuk mendukung proses diagnosis dengan pendekatan kecerdasan buatan. Salah satu metode yang digunakan Convolutional Neural Network (CNN), yaitu model deep learning yang dapat menganalisis citra dan mengekstraksi fitur penting. CNN mampu mengenali pola visual dalam citra MRI otak untuk membedakan berbagai jenis tumor.

Untuk meningkatkan akurasi dan stabilitas sistem klasifikasi, digunakan pendekatan ensemble CNN, yaitu penggabungan beberapa base mode Lightweight CNN melalui pendekatan majority voting atau weighted average. Pendekatan ini memanfaatkan kelebihan masing-masing model untuk menghasilkan keputusan klasifikasi yang lebih optimal.

Meski berbasis teknologi, penelitian ini tetap berpijak pada nilai-nilai spiritual dalam Islam. Penyakit, termasuk tumor otak, dipandang sebagai bagian dari ujian kehidupan yang mengandung hikmah. Islam mengajarkan bahwa setiap ujian merupakan bentuk kasih sayang dan cara Allah untuk meningkatkan keimanan serta membersihkan dosa. Oleh karena itu, pengembangan sistem klasifikasi ini tidak hanya merupakan bentuk ikhtiar ilmiah, tetapi juga bentuk pengabdian kepada Allah melalui ilmu dan teknologi.

Dengan mengintegrasikan kecanggihan CNN dan pendekatan ensemble dengan kesadaran spiritual Islam, penelitian ini merepresentasikan harmoni antara ilmu pengetahuan dan iman. Hal ini menegaskan bahwa di balik setiap algoritma dan inovasi, manusia tetap membutuhkan bimbingan Ilahi dalam menjalani hidup dan menghadapi segala ujian, termasuk penyakit yang kompleks seperti tumor otak.

BAB VII

PENUTUP

7.1. Kesimpulan

Hasil pengujian menunjukkan bahwa variasi ukuran kernel dan konfigurasi arsitektur dasar sangat berpengaruh pada performa *model Convolutional Neural Network* (CNN) dalam klasifikasi tumor otak. Dari sembilan model CNN Lightweight yang diuji, model dengan kernel 7×7 (CNN3) menunjukkan hasil terbaik, terutama pada Base Model 3, di mana akurasi, presisi, recall, dan F1-score mencapai nilai 0,91. Hal ini mengindikasikan bahwa kernel yang lebih besar memiliki kemampuan lebih baik dalam menangkap pola-pola kompleks pada citra MRI dibandingkan kernel 3×3 dan 5×5 . Sebaliknya, CNN2 dengan kernel 5×5 memperlihatkan performa terendah di Base Model 2 dengan akurasi hanya 0,82, yang mengindikasikan keterbatasan dalam mengekstraksi fitur representatif dari data citra MRI.

Selanjutnya, penerapan metode *ensemble*, yaitu *Majority Voting* (MV) dan *Weighted Average* (WA), dapat meningkatkan kinerja model secara optimal. Pada Base Model 1, nilai akurasi meningkat dari 0,89 menjadi 0,94 dengan MV, dan menjadi 0,95 dengan WA. Pada Base Model 2, akurasi naik dari 0,87 menjadi 0,91 dan 0,92 secara berurutan dengan MV dan WA. Sementara itu, Base Model 3 mencapai performa optimal dengan kedua metode ensemble, yaitu akurasi 0,96, presisi 0,96, recall 0,96, dan F1-score 0,96, serta spesifitas yang sangat tinggi di 0,99. Data ini menunjukkan bahwa *Weighted Average* memberikan peningkatan

performa yang lebih stabil dibandingkan Majority Voting, terutama pada model yang belum mencapai performa maksimal, Hal ini karena Weighted Average menggabungkan nilai probabilitas (softmax) dari masing-masing model berdasarkan bobotnya, sehingga keputusan akhir mempertimbangkan kontribusi relatif setiap model terhadap kemungkinan masing-masing kelas. Dengan pendekatan ini, Weighted Average dapat menghasilkan prediksi yang optimal.

Dari segi optimizer, analisis nilai rata-rata performa menunjukkan bahwa optimizer Nadam memberikan hasil paling stabil dan optimal dibanding Adam dan AdamW. Optimizer Nadam berhasil mencapai akurasi rata-rata 0,90 dengan nilai presisi dan recall masing-masing 0,91 dan 0,90, serta F1-score sebesar 0,91. Sebaliknya, Adam dan AdamW menunjukkan performa yang sedikit lebih rendah dengan akurasi rata-rata masing-masing 0,88 dan 0,85. Spesifisitas yang stabil tinggi di 0,99 pada semua optimizer menunjukkan bahwa model mampu secara optimal mengenali kelas negatif tanpa banyak kesalahan. Keunggulan Nadam ini kemungkinan karena adaptasi learning rate yang lebih baik, sehingga proses pembelajaran lebih efisien dan model lebih mampu menggeneralisasi data.

Keseluruhan hasil tersebut mengindikasikan bahwa kombinasi arsitektur CNN dengan kernel besar (7×7), penggunaan optimizer Nadam, dan penggabungan prediksi melalui metode Weighted Average memberikan pendekatan paling optimal untuk klasifikasi 17 kelas (multi-kelas) tumor otak berbasis citra MRI. Pendekatan ini tidak hanya meningkatkan akurasi dan stabilitas, tetapi juga memperkuat kemampuan model dalam mengatasi pola data kompleks dan ketidakseimbangan kelas yang menyulitkan interpretasi citra MRI.

7.2. Saran

Penelitian ini telah menunjukkan bahwa penggunaan model *Lightweight CNN* dengan variasi ukuran kernel dan metode ensemble mampu secara optimal meningkatkan performa klasifikasi pada citra MRI. Namun, penelitian selanjutnya masih perlu menangani berbagai permasalahan, khususnya kompleksitas struktur dan karakteristik data citra MRI yang dapat memengaruhi akurasi klasifikasi.

Salah satu tantangan utama dalam klasifikasi citra MRI adalah adanya area tumpang tindih antar jenis tumor yang memiliki kemiripan visual. Oleh karena itu, penelitian selanjutnya disarankan untuk mengimplementasikan mekanisme attention, seperti CBAM atau Squeeze-and-Excitation (SE), guna membantu model memusatkan perhatian pada bagian citra yang paling relevan. Pendekatan ini berpotensi meningkatkan akurasi klasifikasi, khususnya pada kasus citra dengan perbedaan antar kelas yang sulit dikenali.

Selain itu, penerapan transfer learning menggunakan model pralatih *Lightweight* seperti *MobileNetV3* atau *EfficientNet-lite* dapat mempertahankan efisiensi komputasi sekaligus meningkatkan kemampuan model dalam mengekstraksi pola-pola kompleks. Cara ini sangat relevan untuk diterapkan pada dataset yang terbatas. Namun, untuk meningkatkan performa pada kelas minoritas yang jumlah datanya lebih sedikit, diperlukan pendekatan khusus seperti focal loss, augmentasi generatif, atau oversampling adaptif guna mengatasi ketidakseimbangan kelas.

DAFTAR PUSTAKA

- Asiri, A. A., Soomro, T. A., Shah, A. A., & others. (2024). Optimized brain tumor detection: A dual-module approach for MRI image enhancement and tumor classification. *IEEE Access*, 12, 42868–42887.
- Alturki, N., Ume, M., Ishaq, A., & others. (2023). Combining CNN features with voting classifiers for optimizing performance of brain tumor classification. *Cancers*, 15, 1767. <https://doi.org/10.3390/cancers15061767>.
- Bogacsovics, G., Harangi, B., & Hajdu, A. (2024). Developing diverse ensemble architectures for automatic brain tumor classification. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-19657-z>.
- Feltrin, F. (n.d.). *Brain tumor MRI images 17 classes* [Dataset]. Kaggle. <https://www.kaggle.com/datasets/fernando2rad/brain-tumor-mri-images-17-classes>.
- Glassner, A. (2021). *Deep learning: A visual approach*. No Starch Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hafeez, H. A., Elmagzoub, M. A., Abdullah, N. A. B., & others. (2023). A CNN-model to classify low-grade and high-grade glioma from MRI images. *IEEE Access*, 11, 46283–46296. <https://doi.org/10.1109/ACCESS.2023.3273487>.
- Khan, H. A., Jue, W., Mushtaq, M. U., & others. (2020). Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*, 17(5), 6203–6216. <https://doi.org/10.3934/mbe.2020328>.
- Mukkapati, N., & Anbarasi, M. S. (2022). Brain tumor classification based on enhanced CNN model. *Revue d'Intelligence Artificielle*, 36(1), 125–130. <https://doi.org/10.18280/ria.360114>.
- Mahjoubi, M. A., Hamida, S., El Gannour, O., & others. (2023). Improved multiclass brain tumor detection using convolutional neural networks and magnetic resonance imaging. *International Journal of Advanced Computer Science and Applications*, 14(3), 406–414. <https://doi.org/10.14569/IJACSA.2023.0140346>.
- Muis, A., Sunardi, & Yudhana, A. (2023). Medical image classification of brain tumor using convolutional neural network algorithm. *Jurnal Infotel*, 15(3), 227–232. <https://doi.org/10.20895/infotel.v15i3.964>.
- Muis, A., Sunardi, S., & Yudhana, A. (2024). CNN-based approach for enhancing brain tumor image classification accuracy. *International Journal of*

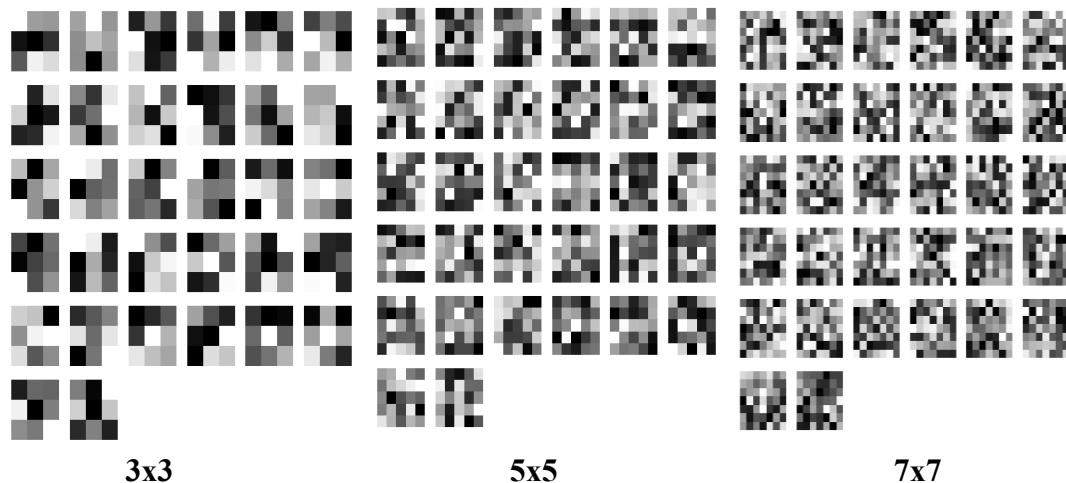
- Engineering*, 37(5), 984–996. <https://doi.org/10.5829/ije.2024.37.05b.15>.
- Mohsen, S., Fawaz, W. M., Abdel-Rehim, A., & others. (2023). Convolutional neural network for automatic brain tumor detection. *Proceedings of Engineering and Technology Innovation*, 24, 15–21. <https://doi.org/10.46604/peti.2023.10307>.
- Nassar, S. E., Yasser, I., Amer, H. M., & Mohamed, M. A. (2023). A robust MRI-based brain tumor classification via a hybrid deep learning technique. *Journal of Supercomputing*, 80, 2403–2427. <https://doi.org/10.1007/s11227-023-05549-w>.
- Namatēvs, I. (2017). Deep convolutional neural networks: Structure, feature extraction and training. *Information Technology and Management Science*, 20, 40–47. <https://doi.org/10.1515/itms-2017-0007>.
- Nag, A., Mondal, H., Hassan, M. M., & others. (2024). TumorGANet: A transfer learning and generative adversarial network-based data augmentation model for brain tumor classification. *IEEE Access*, 12, 103060–103081. <https://doi.org/10.1109/ACCESS.2024.3429633>.
- Rachmawanto, E. H., Sari, C. A., & Isinkaye, F. O. (2024). A good result of brain tumor classification based on simple convolutional neural network architecture. *Telecommunication Computing Electronics and Control*, 22(3), 711–719. <https://doi.org/10.12928/TELKOMNIKA.v22i3.25863>.
- Remzan, N., Tahiry, K., & Farchi, A. (2022). Brain tumor classification in magnetic resonance imaging images using convolutional neural network. *International Journal of Electrical and Computer Engineering*, 12(6), 6664–6674. <https://doi.org/10.11591/ijece.v12i6.pp6664-6674>.
- Santoso, I. B., Utama, S. N., & Supriyono. (2024). A new voting of convolutional neural networks for brain tumor detection based on MRI images. *International Journal of Intelligent Engineering and Systems*, 17(1), 212–227. <https://doi.org/10.22266/ijies2024.0229.2>.
- Santoso, I. B., Supriyono, & Utama, S. N. (2024). Multi-model of convolutional neural networks for brain tumor classification in magnetic resonance imaging images. *International Journal of Intelligent Engineering and Systems*, 17(5), 741–758. <https://doi.org/10.22266/ijies2024.1031.56>.
- Vatsala, A., Gupta, S., Gupta, D., & others. (2023). Weighted average ensemble deep learning model for stratification of brain tumor in MRI images. *Diagnostics*. <https://doi.org/10.3390/diagnostics13071320>.
- Wahbah az-Zuhaili. (2014). *Tafsir al-Munir (Aqidah, Syari'ah, Manhaj)* (Jilid 8, hlm. 89–90). Gema Insani.

- Zahid, R., Ma, Y., Inam, U., & others. (2024). Integrating convolutional neural networks with attention mechanisms for magnetic resonance imaging-based classification of brain tumors. *Bioengineering*, 11(7), 701. <https://doi.org/10.3390/bioengineering11070701>.
- Zaitoon, R., & Syed, H. (2023). Enhanced brain tumor detection and classification in MRI scans using convolutional neural networks. *International Journal of Advanced Computer Science and Applications*, 14(9). <https://doi.org/10.14569/IJACSA.2023.0140929>.

LAMPIRAN

Lampiran 1

Convolutional Neural Network (CNN) memanfaatkan filter (kernel) untuk mengekstraksi fitur dari citra MRI (input). Sebelum pelatihan, filter masih berupa bobot awal acak (initial weights). Visualisasi ini bertujuan untuk memahami perbedaan karakteristik dan cakupan area dari filter berukuran 3×3 , 5×5 , dan 7×7 pada lapisan awal CNN.



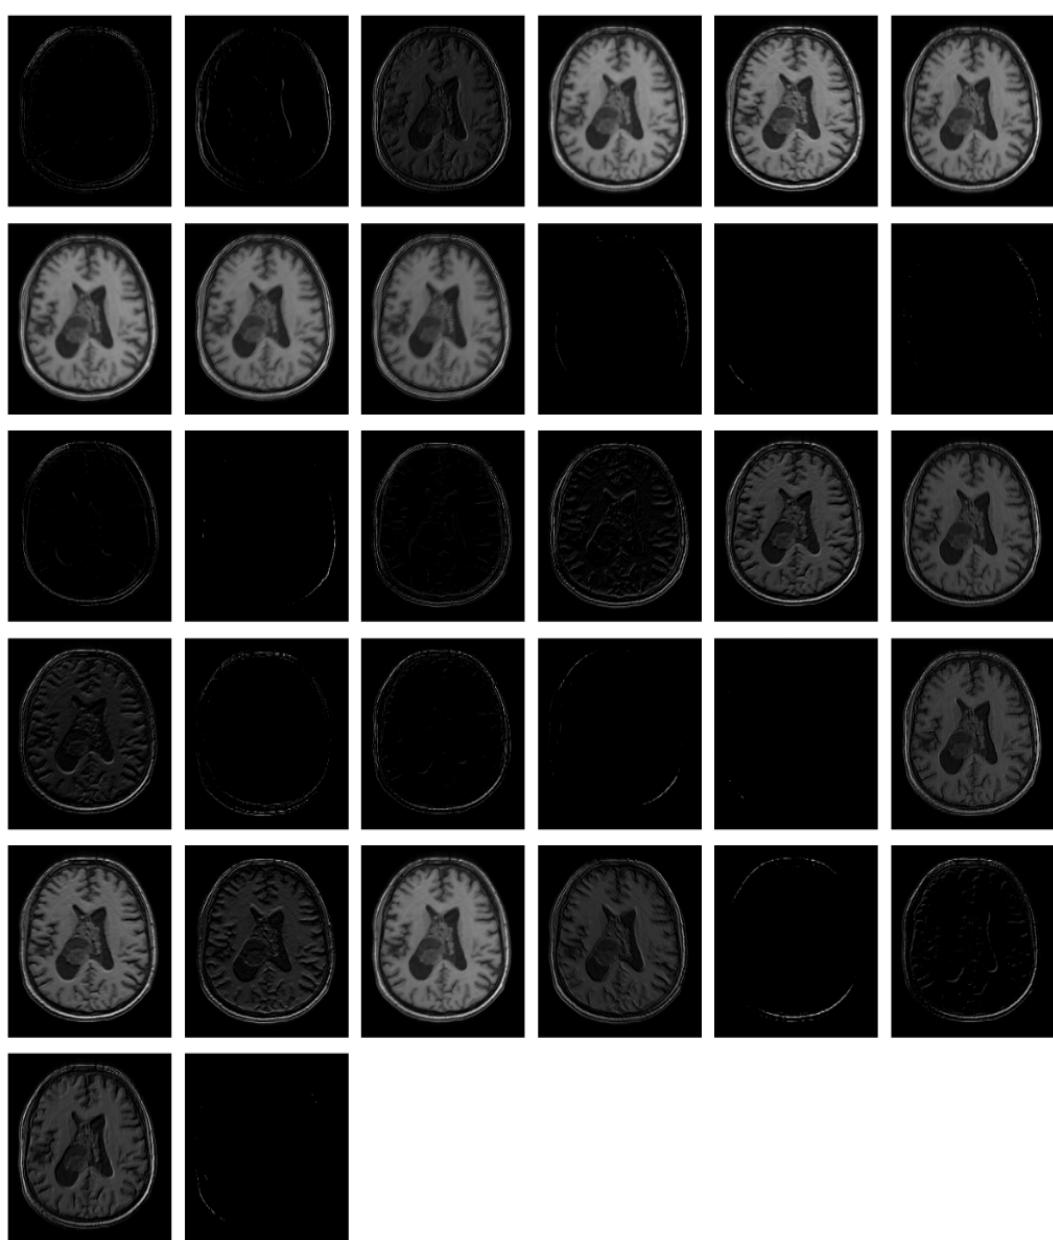
Tujuan

- Menunjukkan bentuk awal filter sebelum pelatihan.
- Membandingkan tingkat kompleksitas pola berdasarkan ukuran filter.
- Menganalisis efek ukuran filter terhadap cakupan informasi spasial.

Visualisasi ini memperlihatkan bahwa semakin besar ukuran filter, semakin kompleks pola yang terbentuk dan semakin luas area yang dianalisis.

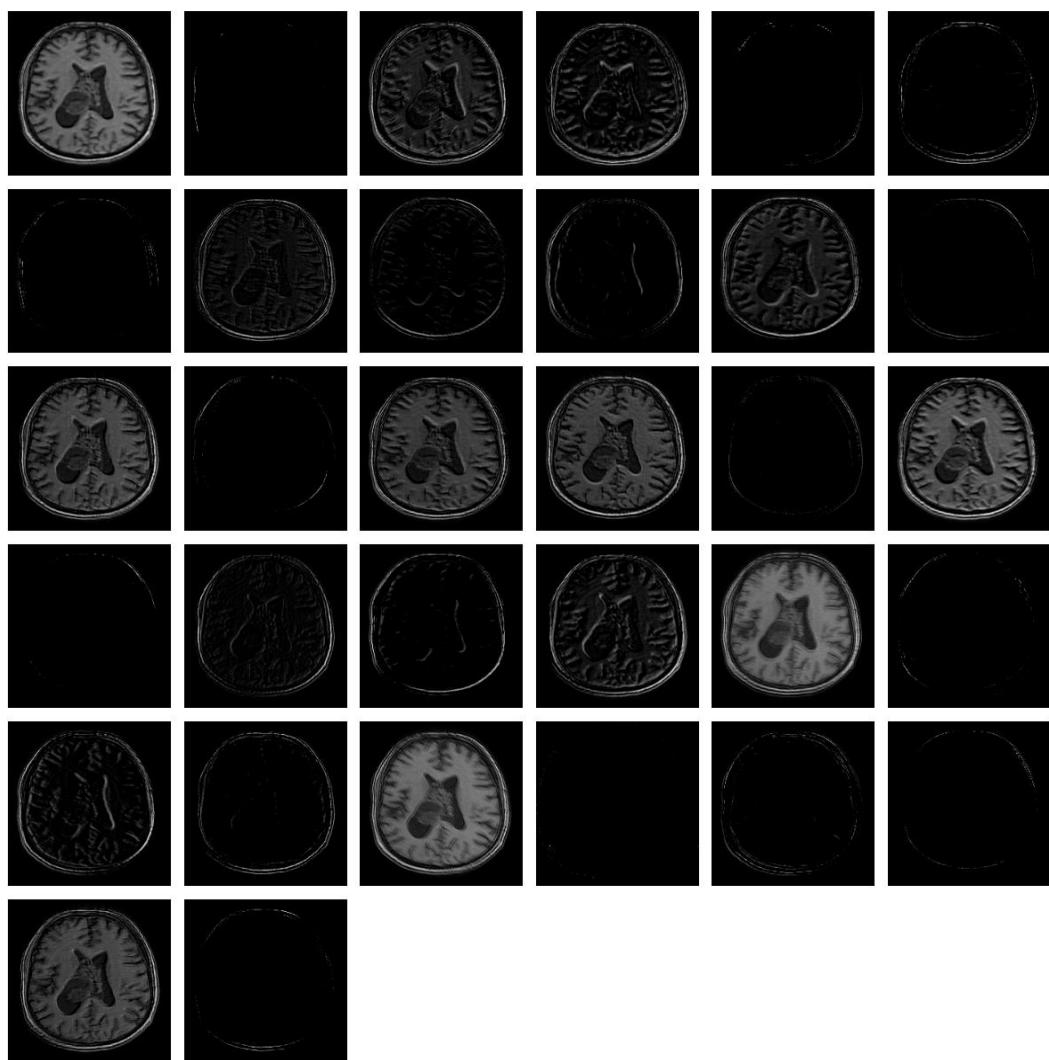
Lampiran 2

Gambar di bawah menunjukkan visualisasi aktivasi fitur dari lapisan konvolusi model CNN dengan kernel 3×3 pada citra MRI otak. Setiap kotak merepresentasikan output dari satu filter. Terlihat beberapa filter berhasil menyoroti struktur anatomi penting seperti ventrikel otak, sementara lainnya menunjukkan respons minimal. Visualisasi ini bertujuan untuk menilai kemampuan model dalam mengekstraksi fitur relevan yang mendukung klasifikasi tumor otak secara akurat.



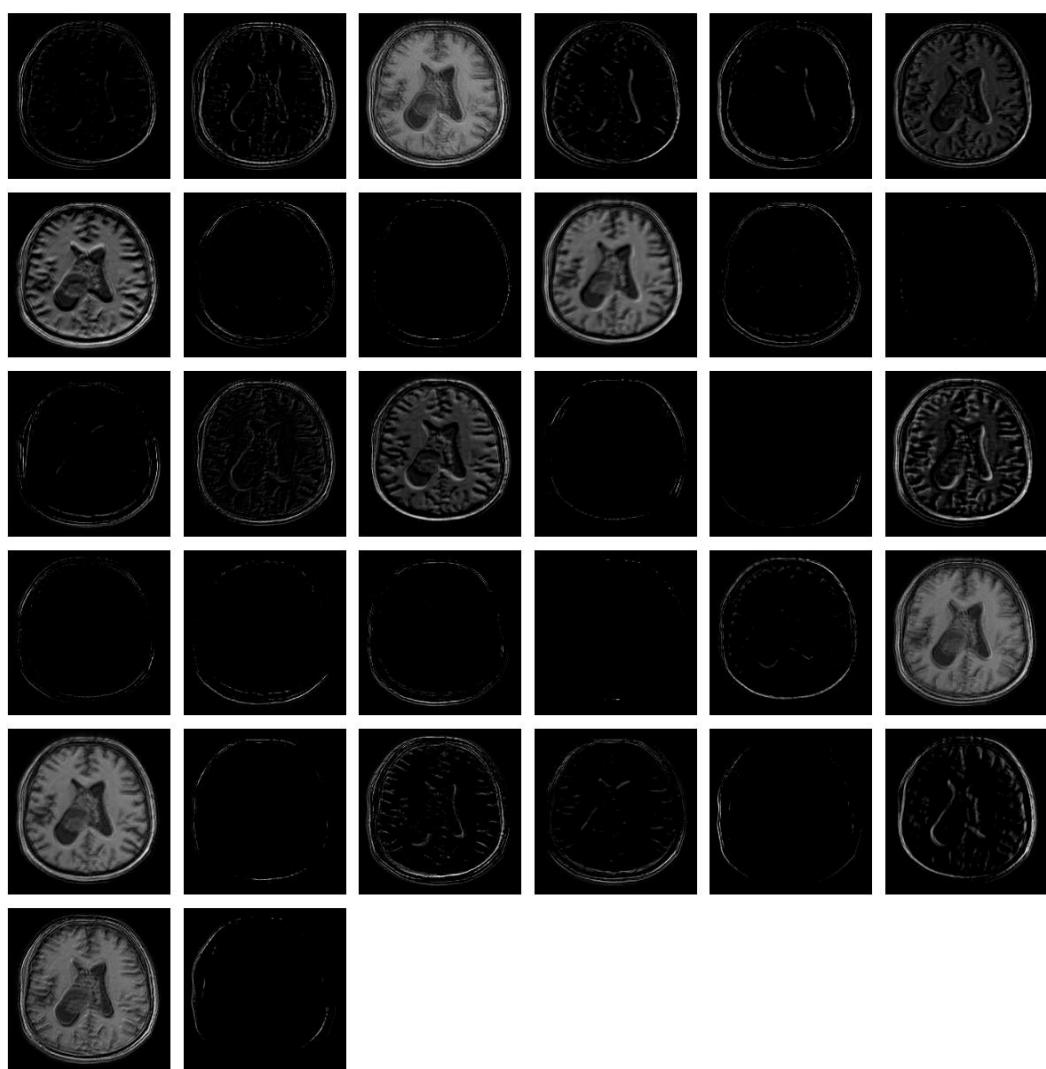
Lampiran 3

Gambar berikut menampilkan hasil aktivasi fitur dari salah satu lapisan konvolusi model CNN dengan kernel 5×5 terhadap citra MRI otak. Setiap kotak menunjukkan feature map dari satu filter. Beberapa filter tampak mampu menyoroti struktur anatomi otak secara jelas, seperti ventrikel dan kontur jaringan, menandakan keberhasilan dalam mengekstraksi pola spasial yang relevan. Sebaliknya, sejumlah filter menunjukkan aktivasi minim atau tidak aktif, yang dapat mengindikasikan selektivitas filter terhadap fitur tertentu. Visualisasi ini berperan penting dalam mengevaluasi performa representasi fitur model, khususnya dalam mendukung tugas klasifikasi tumor otak secara lebih presisi.



Lampiran 4

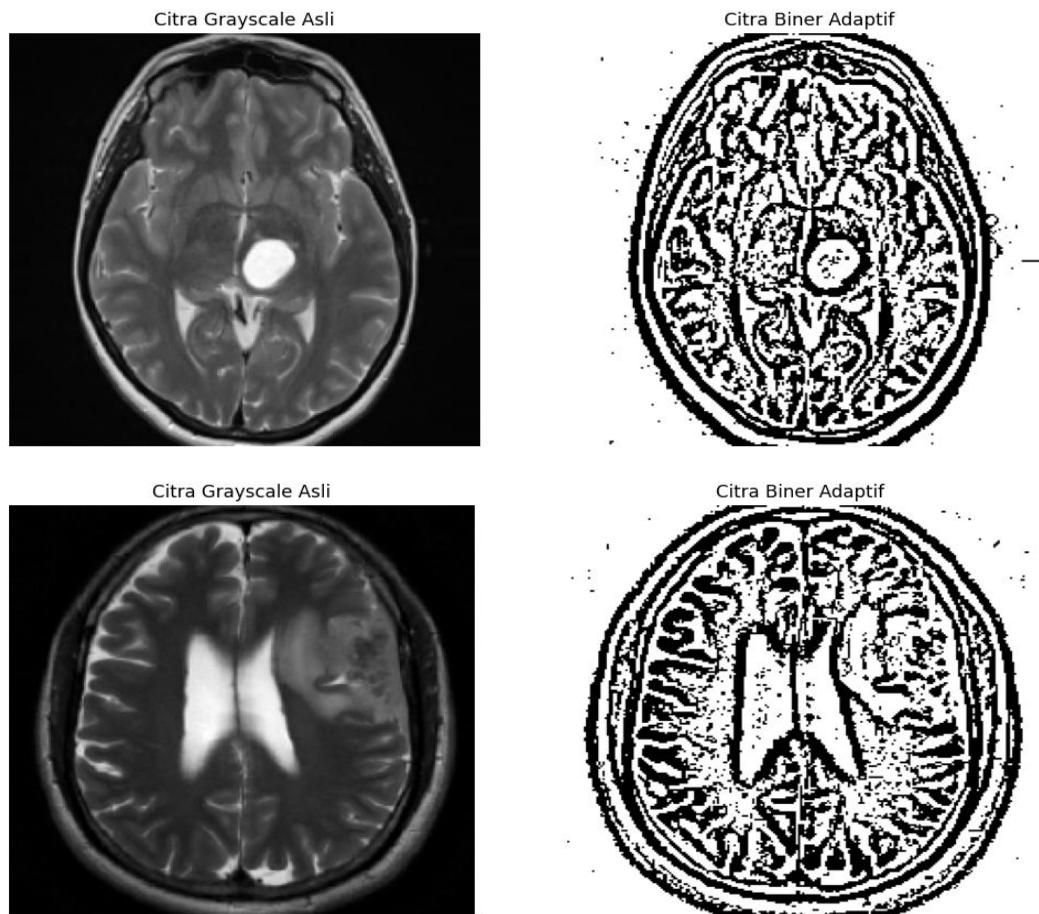
Gambar dibawah menunjukkan hasil aktivasi fitur dari salah satu lapisan konvolusi model CNN dengan kernel 7×7 terhadap citra MRI otak. Setiap feature map mewakili respon dari satu filter. Dengan ukuran kernel yang lebih besar, aktivasi tampak mampu menangkap pola spasial yang lebih luas, seperti kontur ventrikel dan jaringan sekitar. Beberapa filter menunjukkan aktivasi kuat terhadap area struktural penting, sementara sebagian lainnya tetap pasif. Visualisasi ini mengindikasikan bahwa penggunaan kernel 7×7 mendukung ekstraksi fitur global yang lebih komprehensif, sehingga memperkuat kontribusi model dalam proses klasifikasi citra medis.



Lampiran 5

Gambar kiri merupakan citra grayscale asli yang menunjukkan data intensitas piksel secara utuh, sehingga seluruh tekstur, kontras, dan pola spasial otak dapat dianalisis secara menyeluruh oleh model klasifikasi. Gambar kanan adalah hasil konversi biner adaptif, yaitu transformasi citra menjadi bentuk hitam-putih berbasis nilai ambang lokal. Proses ini menyederhanakan informasi visual dan menekankan kontur serta tepi struktur, sehingga membantu menyoroti pola-pola tekstur atau batasan morfologi yang relevan untuk proses klasifikasi otomatis.

Tujuan utama perbedaan ini adalah untuk mengevaluasi pengaruh representasi citra terhadap performa model CNN dalam mengidentifikasi kelas tumor otak. Citra asli mempertahankan informasi lengkap, sedangkan citra biner adaptif memberikan penyederhanaan untuk menonjolkan fitur struktural.



Lampiran 6

Perbandingan Accuracy Base Model 1 Dengan Optimizer Adam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Accuracy	Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.97	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.98	0.98	0.98
5	NORMAL T1	0.99	1.00	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.97	0.96	0.97
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.97	0.98	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	1.00	0.99
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.96	0.97	0.98
13	NORMAL T2	0.99	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.97	0.98	0.97
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99	0.99

Lampiran 7

Perbandingan Precision Base Model 1 Dengan Optimizer Adam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Precision	Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.78	0.89	0.88
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.88	0.82	0.81
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.96	1.00	0.95
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.81	0.85	0.87
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.91	0.90	0.88
5	NORMAL T1	0.85	0.96	0.90
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.80	0.74	0.78
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.92	0.94	0.96
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.96	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.67	0.56	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.83	0.75	0.81
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.75	0.88	0.85
13	NORMAL T2	0.94	0.94	0.94
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.88	0.90	0.95
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.88	0.91	0.89
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.91	0.86	0.86

Lampiran 8

Perbandingan Recall Base Model 1 Dengan Optimizer Adam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Recall	Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.88	0.97	0.94
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.68	0.82	0.77
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.91	0.91	0.96
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.97	0.97	0.93
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.91	0.93	0.96
5	NORMAL T1	0.88	0.88	0.76
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.80	0.84	0.83
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.88	0.88	0.91
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.87	0.87	0.83
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.18	0.45	0.55
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.94	0.97	0.97
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.60	0.80	0.70
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.80	0.74	0.85
13	NORMAL T2	0.96	0.96	0.92
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.90	0.95	0.92
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.85	0.83	0.83
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.88	0.94	0.91

Lampiran 9

Perbandingan Specificity Base Model 1 Dengan Optimizer Adam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Specificity	Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	1.00	1.00	1.00
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	1.00	1.00	1.00
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99	0.98
5	NORMAL T1	1.00	1.00	1.00
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.98	0.98	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	1.00	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.99	0.99
13	NORMAL T2	1.00	1.00	1.00
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	1.00	1.00
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	1.00	0.99	0.99

Lampiran 10

Perbandingan F1-Score Base Model 1 Dengan Optimizer Adam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		F1-Score	F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.83	0.93	0.91
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.77	0.82	0.79
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.93	0.95	0.95
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.88	0.91	0.90
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.91	0.91	0.92
5	NORMAL T1	0.86	0.92	0.82
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.80	0.79	0.80
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.90	0.91	0.93
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.91	0.93	0.91
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.28	0.50	0.71
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.88	0.85	0.88
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.75	0.89	0.82
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.77	0.80	0.85
13	NORMAL T2	0.95	0.95	0.93
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.89	0.92	0.93
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.86	0.87	0.86
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.89	0.90	0.88

Lampiran 11

Perbandingan Accuracy Base Model 2 Dengan Optimizer AdamW

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Accuracy	Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.96	0.96	0.97
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.98	0.98
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.98	0.97	0.98
5	NORMAL T1	0.99	0.99	1.00
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.97	0.96	0.97
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.96	0.96	0.97
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	0.99	0.99
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.99	0.99	0.99
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.97	0.95	0.97
13	NORMAL T2	0.99	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.96	0.96	0.97
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99	0.99

Lampiran 12

Perbandingan Precision Base Model 2 Dengan Optimizer AdamW

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Precision	Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.68	0.71	0.79
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.82	0.80	0.85
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.88	0.89	0.96
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.83	0.76	0.85
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.90	0.82	0.86
5	NORMAL T1	0.86	0.85	1.00
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.83	0.71	0.80
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.90	0.90	0.88
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00	0.93
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	0.60	0.83
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.80	0.88	0.83
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	0.86	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.77	0.70	0.79
13	NORMAL T2	0.91	0.94	0.98
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.90	0.97	0.92
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.84	0.84	0.89
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.83	0.87	0.86

Lampiran 13

Perbandingan Recall Base Model 2 Dengan Optimizer AdamW

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Recall	Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.84	0.83	0.84
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.82	0.73	0.77
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.94	0.89	0.91
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.91	0.90
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.92	0.91	0.93
5	NORMAL T1	0.76	0.88	0.96
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.75	0.80	0.83
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.81	0.84	0.91
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.87	0.83	0.90
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.45	0.27	0.45
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.90	0.90	0.97
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.50	0.60	0.50
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.80	0.64	0.82
13	NORMAL T2	0.94	0.92	0.90
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.90	0.85	0.90
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.77	0.79	0.79
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.88	0.76	0.94

Lampiran 14

Perbandingan Specificity Base Model 2 Dengan Optimizer AdamW

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Specificity	Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.97	0.97	0.98
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	1.00	1.00	1.00
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99	1.00
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.98	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.97	0.98
5	NORMAL T1	1.00	1.00	1.00
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.97	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.98	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	1.00	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	1.00	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.98	0.98
13	NORMAL T2	0.99	1.00	1.00
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	1.00	1.00	1.00
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.98	0.98	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	1.00	0.99

Lampiran 15

Perbandingan F1-Score Base Model 2 Dengan Optimizer AdamW

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		F1-Score	F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.75	0.77	0.81
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.82	0.76	0.81
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.91	0.89	0.93
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.90	0.83	0.87
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.91	0.86	0.89
5	NORMAL T1	0.81	0.86	0.98
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.79	0.75	0.81
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.85	0.87	0.89
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.93	0.91	0.91
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.62	0.37	0.58
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.85	0.89	0.89
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.67	0.71	0.67
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.78	0.67	0.80
13	NORMAL T2	0.92	0.93	0.94
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.90	0.91	0.91
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.80	0.81	0.84
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.85	0.81	0.90

Lampiran 16

Perbandingan Accuracy Base Model 3 Dengan Optimizer Nadam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Accuracy	Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.98	0.98
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	1.00	1.00
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99	0.98
5	NORMAL T1	1.00	1.00	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.97	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.98	0.98	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.97	0.98
13	NORMAL T2	0.99	1.00	1.00
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	1.00	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.98	0.97	0.98
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99	0.99

Lampiran 17

Perbandingan Precision Base Model 3 Dengan Optimizer Nadam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Precision	Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.81	0.83	0.89
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.84	0.90	0.94
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.96	1.00	1.00
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.88	0.90	0.90
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.93	0.94	0.89
5	NORMAL T1	0.96	0.96	0.88
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.91	0.77	0.83
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.93	0.96	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.96	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	0.70	0.86
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.81	0.93	0.82
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.82	0.84	0.83
13	NORMAL T2	0.96	1.00	0.98
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.90	0.93	0.92
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.93	0.90	0.88
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.87	0.85	0.94

Lampiran 18

Perbandingan Recall Base Model 3 Dengan Optimizer Nadam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Recall	Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.94	0.94	0.91
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.73	0.82	0.68
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.91	0.94	0.94
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.93	0.93
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.95	0.99	0.96
5	NORMAL T1	0.88	0.88	0.88
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.90	0.86	0.90
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.90	0.90	0.94
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.90	0.90	0.90
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.45	0.64	0.55
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.97	0.90	0.90
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.70	0.90	0.90
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.88	0.80	0.89
13	NORMAL T2	0.92	0.94	0.94
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.95	0.97	0.92
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.81	0.83	0.87
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.97	1.00	0.91

Lampiran 19

Perbandingan Specificity Base Model 3 Dengan Optimizer Nadam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		Specificity	Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.98	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	1.00	1.00	1.00
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	1.00	1.00	1.00
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99	0.98
5	NORMAL T1	1.00	1.00	1.00
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.98	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99	1.00
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	1.00	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	1.00	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.99	0.99
13	NORMAL T2	1.00	1.00	1.00
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	1.00	1.00	1.00
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99	1.00

Lampiran 20

Perbandingan F1-Score Base Model 3 Dengan Optimizer Nadam

Index	Daftar Kelas Tumor Otak	Base Model CNN1 (3x3)	Base Model CNN2 (5x5)	Base Model CNN3 (7x7)
		F1-Score	F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.87	0.88	0.90
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.78	0.86	0.79
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.93	0.97	0.97
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.93	0.91	0.91
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.94	0.96	0.92
5	NORMAL T1	0.92	0.92	0.88
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.90	0.81	0.86
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.91	0.93	0.96
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.93	0.95	0.95
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.62	0.67	0.67
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.88	0.91	0.86
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.82	0.95	0.95
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.85	0.82	0.86
13	NORMAL T2	0.94	0.97	0.96
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.92	0.95	0.92
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.87	0.86	0.87
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.92	0.92	0.92

Lampiran 21

Analisis Prediksi Base Model 1 (Majority Voting dan Weighted Average)

Distribusi hasil prediksi Base Model 1, yang terdiri atas tiga model CNN dengan kernel 3×3 , 5×5 , dan 7×7 serta dioptimasi menggunakan Adam, menunjukkan pola klasifikasi yang stabil dan konsisten. Majority voting dan weighted average diterapkan untuk meningkatkan robustness dan akurasi. Kelas 7 mendominasi prediksi (611 – 613), menandakan model lebih mampu mengenali pola visual pada kelas tersebut. Sebaliknya, kelas 9 dan 10 mencatat prediksi terendah (26 – 43), kemungkinan akibat keterbatasan data atau kompleksitas fitur. Konsistensi antar model dengan deviasi minimal menunjukkan kontribusi majority voting dan weighted average dalam menghasilkan klasifikasi yang optimal.

```
unique, counts = np.unique(y_pred1_labels, return_counts=True)
print("Distribusi Model 1:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred2_labels, return_counts=True)
print("Distribusi Model 2:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred3_labels, return_counts=True)
print("Distribusi Model 3:", dict(zip(unique, counts)))
```

Distribusi Model 1: {0: 363, 1: 100, 2: 268, 3: 317, 4: 528, 5: 123, 6: 324, 7: 611, 8: 140, 9: 26, 10: 163, 11: 36, 12: 372, 13: 257, 14: 196, 15: 422, 16: 169}
Distribusi Model 2: {0: 360, 1: 98, 2: 266, 3: 316, 4: 516, 5: 117, 6: 384, 7: 613, 8: 145, 9: 43, 10: 157, 11: 44, 12: 307, 13: 257, 14: 196, 15: 420, 16: 176}
Distribusi Model 3: {0: 361, 1: 112, 2: 272, 3: 310, 4: 528, 5: 121, 6: 345, 7: 612, 8: 142, 9: 43, 10: 157, 11: 44, 12: 328, 13: 260, 14: 192, 15: 418, 16: 170}

Distribusi Model 1:

{0: 363, 1: 100, 2: 268, 3: 317, 4: 528, 5: 123, 6: 324, 7: 611, 8: 140, 9: 26, 10: 163, 11: 36, 12: 372, 13: 257, 14: 196, 15: 422, 16: 169}

Distribusi Model 2:

{0: 360, 1: 98, 2: 266, 3: 316, 4: 516, 5: 117, 6: 384, 7: 613, 8: 145, 9: 43, 10: 157, 11: 44, 12: 307, 13: 257, 14: 196, 15: 420, 16: 176}

Distribusi Model 3:

{0: 361, 1: 112, 2: 272, 3: 310, 4: 528, 5: 121, 6: 345, 7: 612, 8: 142, 9: 43, 10: 157, 11: 44, 12: 328, 13: 260, 14: 192, 15: 418, 16: 170}

Lampiran 22

Analisis Perbandingan Accuracy Base Model 1 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.98	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	0.99
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.99	0.99
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.98
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 23

Analisis Perbandingan Precision Base Model 1 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.91	0.93
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.92	0.92
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.98	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.90	0.93
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.94	0.95
5	NORMAL T1	0.93	0.96
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.91	0.90
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.97	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	0.95
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.93	0.92
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.90	0.91
13	NORMAL T2	0.98	0.96
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.98	0.98
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.96	0.97
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.96	0.96

Lampiran 24

Analisis Perbandingan Recall Base Model 1 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.97
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.91	0.89
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.96	0.97
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.98
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.97	0.97
5	NORMAL T1	0.93	0.91
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.89	0.92
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.95	0.95
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.92	0.92
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.68	0.71
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.96	0.96
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.93	0.91
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.91	0.92
13	NORMAL T2	0.96	0.98
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.97	0.97
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.94	0.95
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.97	0.97

Lampiran 25

Analisis Perbandingan Specificity Base Model 1 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.99
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.99	0.99
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 26

Analisis Perbandingan F1-Score Base Model 1 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.94	0.95
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.92	0.90
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.97	0.98
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.94	0.96
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.96	0.96
5	NORMAL T1	0.93	0.94
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.90	0.91
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.96	0.96
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.95	0.96
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.81	0.82
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.94	0.94
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.96	0.95
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.90	0.91
13	NORMAL T2	0.97	0.97
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.98	0.98
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.95	0.96
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.96	0.96

Lampiran 27

Analisis Prediksi Base Model 2 (Majority Voting dan Weighted Average)

Distribusi prediksi Base Model 2, yang terdiri dari tiga CNN1, CNN2 dan CNN3 dengan kernel 3×3 , 5×5 , dan 7×7 serta dioptimasi menggunakan AdamW, menunjukkan klasifikasi yang stabil dan konsisten. Penerapan *majority voting* dan *weighted average* meningkatkan robustness dan akurasi model.

Kelas 4 dan 7 mendominasi prediksi dengan frekuensi tertinggi (514 – 530 dan 604 – 633), menunjukkan model mampu mengenali pola visualnya dengan baik. Sebaliknya, kelas 9 dan 11 menunjukkan prediksi terendah (27 – 47 dan 33 – 42), kemungkinan akibat keterbatasan data atau kompleksitas fitur.

Deviasi rendah antar model menegaskan kontribusi metode ensemble dalam menghasilkan klasifikasi yang optimal dan generalisasi yang baik.

```
unique, counts = np.unique(y_pred1_labels, return_counts=True)
print("Distribusi Model 1:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred2_labels, return_counts=True)
print("Distribusi Model 2:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred3_labels, return_counts=True)
print("Distribusi Model 3:", dict(zip(unique, counts)))

Distribusi Model 1: {0: 389, 1: 108, 2: 286, 3: 324, 4: 520, 5: 111, 6: 317, 7: 604, 8: 135, 9: 28, 10: 165, 11: 33, 12: 366, 13: 257, 14: 196, 15: 402, 16: 174}
Distribusi Model 2: {0: 364, 1: 106, 2: 264, 3: 330, 4: 530, 5: 116, 6: 338, 7: 633, 8: 138, 9: 27, 10: 158, 11: 39, 12: 345, 13: 251, 14: 194, 15: 424, 16: 158}
Distribusi Model 3: {0: 374, 1: 103, 2: 268, 3: 309, 4: 514, 5: 108, 6: 373, 7: 621, 8: 145, 9: 47, 10: 161, 11: 42, 12: 315, 13: 250, 14: 198, 15: 410, 16: 177}
```

Distribusi Model 1:

{0: 389, 1: 108, 2: 286, 3: 324, 4: 520, 5: 111, 6: 317, 7: 604, 8: 135, 9: 28, 10: 165, 11: 33, 12: 366, 13: 257, 14: 196, 15: 402, 16: 174}

Distribusi Model 2:

{0: 364, 1: 106, 2: 264, 3: 330, 4: 530, 5: 116, 6: 338, 7: 633, 8: 138, 9: 27, 10: 158, 11: 39, 12: 345, 13: 251, 14: 194, 15: 424, 16: 158}

Distribusi Model 3:

{0: 374, 1: 103, 2: 268, 3: 309, 4: 514, 5: 108, 6: 373, 7: 621, 8: 145, 9: 47, 10: 161, 11: 42, 12: 315, 13: 250, 14: 198, 15: 410, 16: 177}

Lampiran 28

Analisis Perbandingan Accuracy Base Model 2 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.98
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.98	0.98
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.97	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.98	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	0.99
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.99	0.99
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.97	0.97
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.98	0.98
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 29

Analisis Perbandingan Precision Base Model 2 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.82	0.86
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.85	0.91
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.95	0.96
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.87	0.92
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.91	0.92
5	NORMAL T1	0.92	0.95
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.87	0.88
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.95	0.95
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.90	0.91
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.85	0.85
13	NORMAL T2	0.97	0.97
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.95	0.94
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.9	0.96
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.94	0.94

Lampiran 30

Analisis Perbandingan Recall Base Model 2 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.95	0.95
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.84	0.83
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.95	0.96
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.98
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.95	0.95
5	NORMAL T1	0.86	0.85
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.85	0.89
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.93	0.94
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.92	0.92
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.56	0.71
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.94	0.95
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.75	0.83
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.85	0.87
13	NORMAL T2	0.93	0.94
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.95	0.98
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.90	0.90
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.92	0.94

Lampiran 31

Analisis Perbandingan Specificity Base Model 2 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.98
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.98	0.98
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.98	0.98
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	1.00	1.00
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.98
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 32

Analisis Perbandingan F1-Score Base Model 2 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.88	0.90
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.85	0.87
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.95	0.96
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.92	0.95
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.93	0.93
5	NORMAL T1	0.89	0.90
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.86	0.88
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.94	0.95
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.95	0.95
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.71	0.83
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.92	0.93
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.85	0.90
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.85	0.86
13	NORMAL T2	0.95	0.95
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.95	0.96
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.93	0.93
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.93	0.94

Lampiran 33

Analisis Prediksi Base Model 3 (Majority Voting dan Weighted Average)

Distribusi prediksi pada Base Model 3, yang terdiri atas tiga arsitektur CNN (CNN1, CNN2, dan CNN3) dengan kernel 3×3 , 5×5 , dan 7×7 serta dioptimalkan menggunakan algoritma Nadam, menunjukkan klasifikasi yang akurat. Majority voting dan weighted average terbukti meningkatkan robustness model. Prediksi tertinggi tercatat pada kelas 7 (618 – 621) dan kelas 4 (301 – 314), menunjukkan kemampuan model mengenali fitur visual secara optimal. Sebaliknya, kelas 9 (43 – 51) dan 11 (40 – 48) memiliki prediksi terendah, diduga akibat data terbatas atau kompleksitas fitur. Deviasi rendah antar model menegaskan efektivitas ensemble dalam meningkatkan performa dan generalisasi.

```
unique, counts = np.unique(y_pred1_labels, return_counts=True)
print("Distribusi Model 1:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred2_labels, return_counts=True)
print("Distribusi Model 2:", dict(zip(unique, counts)))

unique, counts = np.unique(y_pred3_labels, return_counts=True)
print("Distribusi Model 3:", dict(zip(unique, counts)))

Distribusi Model 1: {0: 361, 1: 100, 2: 267, 3: 311, 4: 515, 5: 109, 6: 354, 7: 621, 8: 143, 9: 43, 10: 161, 11: 40, 12: 340, 13: 257, 14: 197, 15: 421, 16: 175}
Distribusi Model 2: {0: 357, 1: 104, 2: 269, 3: 303, 4: 524, 5: 111, 6: 360, 7: 612, 8: 141, 9: 49, 10: 151, 11: 48, 12: 337, 13: 253, 14: 197, 15: 417, 16: 182}
Distribusi Model 3: {0: 360, 1: 108, 2: 270, 3: 301, 4: 512, 5: 118, 6: 348, 7: 618, 8: 144, 9: 51, 10: 161, 11: 47, 12: 333, 13: 260, 14: 194, 15: 424, 16: 166}
```

Distribusi Model 1:

```
{0: 361, 1: 100, 2: 267, 3: 311, 4: 515, 5: 109, 6: 354, 7: 621, 8: 143, 9: 43, 10: 161, 11: 40, 12: 340, 13: 257, 14: 197, 15: 421, 16: 175}
```

Distribusi Model 2:

```
{0: 357, 1: 104, 2: 269, 3: 303, 4: 524, 5: 111, 6: 360, 7: 612, 8: 141, 9: 49, 10: 151, 11: 48, 12: 337, 13: 253, 14: 197, 15: 417, 16: 182}
```

Distribusi Model 3:

```
{0: 360, 1: 108, 2: 270, 3: 301, 4: 512, 5: 118, 6: 348, 7: 618, 8: 144, 9: 51, 10: 161, 11: 47, 12: 333, 13: 260, 14: 194, 15: 424, 16: 166}
```

Lampiran 34

Analisis Perbandingan Accuracy Base Model 3 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Accuracy	Accuracy
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.99
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.99	0.99
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.99	0.99
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.98	0.99
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 35

Analisis Perbandingan Precision Base Model 3 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Precision	Precision
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.91	0.94
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.92	0.96
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.93	0.95
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.97	0.97
5	NORMAL T1	0.98	0.97
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.93	0.94
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.98	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.97	0.95
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.96	0.94
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.91	0.93
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.98	0.97
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.97	0.97
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.96	0.95

Lampiran 36

Analisis Perbandingan Recall Base Model 3 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Recall	Recall
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.98	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.91	0.93
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.97	0.97
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.98	0.97
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.98	0.99
5	NORMAL T1	0.91	0.92
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.93	0.95
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.97	0.97
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.93	0.94
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.80	0.82
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.98	0.98
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.97	0.97
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.93	0.95
13	NORMAL T2	0.98	0.98
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.98	0.98
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.94	0.94
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.97	0.98

Lampiran 37

Analisis Perbandingan Specificity Base Model 3 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		Specificity	Specificity
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.99	0.99
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.99	0.99
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.99	0.99
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.99	0.99
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.99	0.99
5	NORMAL T1	0.99	0.99
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.99	0.99
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.99	0.99
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	1.00	1.00
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.99	0.99
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.99	0.99
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	1.00	1.00
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.99	0.99
13	NORMAL T2	0.99	0.99
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.99	0.99
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.99	0.99
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.99	0.99

Lampiran 38

Analisis Perbandingan F1-Score Base Model 3 Antara Majority Voting dan Weighted Average

Index	Daftar Kelas Tumor Otak	Majority Voting	Weighted Average
		F1-Score	F1-Score
0	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T2	0.95	0.96
1	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1	0.91	0.95
2	Schwannoma (Acustico, Vestibular - Trigeminal) T1	0.98	0.98
3	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1C+	0.96	0.96
4	Neurocitoma (Central - Intraventricular, Extraventricular) T1	0.97	0.98
5	NORMAL T1	0.94	0.95
6	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T1	0.93	0.95
7	Schwannoma (Acustico, Vestibular - Trigeminal) T1C+	0.98	0.98
8	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1	0.96	0.97
9	Schwannoma (Acustico, Vestibular - Trigeminal) T2	0.88	0.88
10	Glioma (Astrocitoma, Ganglioglioma, Glioblastoma, Oligodendrogioma, Ependimoma) T1C+	0.97	0.96
11	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T2	0.98	0.98
12	Outros Tipos de Lesões (Abscessos, Cistos, Encefalopatias Diversas) T1C+	0.92	0.94
13	NORMAL T2	0.98	0.98
14	Neurocitoma (Central - Intraventricular, Extraventricular) T2	0.98	0.98
15	Meningioma (de Baixo Grau, Atípico, Anaplásico, Transicional) T2	0.95	0.95
16	Neurocitoma (Central - Intraventricular, Extraventricular) T1C+	0.97	0.97

Lampiran 39

Lightweight CNN Source Code Kernel Size 3x3

```
target_size = (224, 224)
test_size = 0.20
validation_split = 0.20
epochs = 50
batch_size = 32

train_datagen = ImageDataGenerator(
    rotation_range=10,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator()
train_generator = train_datagen.flow(X_train, y_train,
batch_size=batch_size)
val_generator = val_datagen.flow(X_val, y_val, batch_size=batch_size)

def base_model_cnn(target_size, num_classes):
    model = models.Sequential([
        layers.Conv2D(filters=32, kernel_size=(3,3), activation='relu',
input_shape=target_size + (3,)),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=64, kernel_size=(3,3), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=128, kernel_size=(3,3), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Flatten(),
        layers.Dense(128, activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(num_classes, activation='softmax')
    ])
    return model
```

Lampiran 40

Lightweight CNN Source Code Kernel Size 5x5

```
target_size = (224, 224)
test_size = 0.20
validation_split = 0.20
epochs = 50
batch_size = 32

train_datagen = ImageDataGenerator(
    rotation_range=10,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator()
train_generator = train_datagen.flow(X_train, y_train,
batch_size=batch_size)
val_generator = val_datagen.flow(X_val, y_val, batch_size=batch_size)

def base_model_cnn(target_size, num_classes):
    model = models.Sequential([
        layers.Conv2D(filters=32, kernel_size=(5,5), activation='relu',
input_shape=target_size + (3,)),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=64, kernel_size=(5,5), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=128, kernel_size=(5,5), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Flatten(),
        layers.Dense(128, activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(num_classes, activation='softmax')
    ])
    return model
```

Lampiran 41

Lightweight CNN Source Code Kernel Size 7x7

```
target_size = (224, 224)
test_size = 0.20
validation_split = 0.20
epochs = 50
batch_size = 32

train_datagen = ImageDataGenerator(
    rotation_range=10,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator()
train_generator = train_datagen.flow(X_train, y_train,
batch_size=batch_size)
val_generator = val_datagen.flow(X_val, y_val, batch_size=batch_size)

def base_model_cnn(target_size, num_classes):
    model = models.Sequential([
        layers.Conv2D(filters=32, kernel_size=(7,7), activation='relu',
input_shape=target_size + (3,)),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=64, kernel_size=(7,7), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Conv2D(filters=128, kernel_size=(7,7), activation='relu'),
        layers.MaxPooling2D(pool_size=(2, 2)),
        layers.Flatten(),
        layers.Dense(128, activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(num_classes, activation='softmax')
    ])
    return model
```

Lampiran 42

Ensembel Learning Source Code

Weighted Average

```
model1_softmax = y_pred1
model2_softmax = y_pred2
model3_softmax = y_pred3

weighted_softmax_average = np.zeros_like(y_pred1)

for i in range(len(y_pred1)):
    weighted_softmax_average[i] = (model1_softmax[i] + model2_softmax[i]
+ model3_softmax[i]) / 3

print("\nEvaluasi rata-rata untuk tiap kelas:")
for i in range(17):
    print(f"Kelas {i}: {weighted_softmax_average[:, i]}")

y_weighted_avg_labels = np.argmax(weighted_softmax_average, axis=1)
```

Majority Voting

```
ensemble_predictions = np.array([y_pred1_labels, y_pred2_labels,
y_pred3_labels,])
y_majority_vote = np.apply_along_axis(lambda x: np.bincount(x).argmax(),
axis=0, arr=ensemble_predictions)
```