

Klasifikasi Penyakit Alzheimer menggunakan CNN dengan pretrained VGG19 dan SMOTE berdasarkan Citra MRI Otak

Ramanda md¹, Ery Hartati²

¹Program Studi Infotmatika, Universitas Multi Data Palembang, Palembang, Indonesia

²Program Studi Magister Teknologi Informasi, Universitas Multi Data Palembang, Palembang, Indonesia

Email : ramandamd@mhs.mdp.ac.id, ery_hartati@mdp.ac.id

Article Information

Article history

Received 12 October 2025

Revised 27 November 2025

Accepted 18 December 2025

Available 30 December 2025

Keywords

Alzheimer

CNN

Classification

SMOTE

VGG19

Abstract

Early detection of Alzheimer's disease is crucial for effective treatment, and the use of brain MRI images has become a common method for diagnosis. However, many previous studies have faced challenges in addressing class imbalance in their datasets, leading to lower accuracy for minority classes. This study aims to address this issue by using a pretrained CNN architecture, VGG19, combined with the SMOTE method to address class integration and improve classification accuracy. This study contributes by introducing SMOTE to the Alzheimer's MRI image dataset to achieve a more balanced class distribution, which has not been fully explored in previous studies. The evaluation results show that the classification accuracy reaches 95%, higher than previous studies using VGG-19 with an accuracy of 77.66%. These results confirm that the use of VGG19 with SMOTE produces better performance, especially in addressing class representation, which is a key contribution of this study. This research has the potential to be applied in more efficient and accurate automated image-based detection systems, especially for the early diagnosis of Alzheimer's disease.

Keywords : Alzheimer, CNN, Classification, SMOTE, VGG19

Corresponding Author:

Ramanda md,
Universitas Multi Data Palembang,
Email:
ramandamd@mhs.mdp.ac.id

Abstrak

Deteksi dini penyakit Alzheimer sangat penting untuk pengobatan yang efektif, dan penggunaan citra MRI otak telah menjadi metode umum untuk diagnosis. Namun, banyak penelitian sebelumnya menghadapi tantangan dalam menangani ketidakseimbangan kelas dalam dataset mereka, yang menyebabkan akurasi yang lebih rendah untuk kelas minoritas. Penelitian ini bertujuan untuk menyelesaikan masalah ini dengan menggunakan arsitektur CNN pretrained VGG19 yang dikombinasikan dengan metode SMOTE untuk mengatasi ketidakseimbangan kelas dan meningkatkan akurasi klasifikasi. Penelitian ini berkontribusi dengan memperkenalkan SMOTE ke dataset citra MRI Alzheimer untuk mencapai distribusi kelas yang lebih seimbang, yang belum sepenuhnya dieksplorasi dalam penelitian sebelumnya. Hasil evaluasi menunjukkan bahwa akurasi klasifikasi mencapai 95%, yang lebih tinggi daripada penelitian sebelumnya yang menggunakan VGG-19 dengan akurasi 77,66%. Hasil ini menegaskan bahwa penggunaan VGG19 dengan SMOTE menghasilkan kinerja yang lebih baik, terutama dalam menangani ketidakseimbangan kelas, yang merupakan kontribusi utama dari penelitian ini. Penelitian ini berpotensi untuk diterapkan dalam sistem deteksi berbasis citra otomatis yang lebih efisien dan akurat, terutama untuk diagnosis dini penyakit Alzheimer.

Kata Kunci : Alzheimer, CNN, Klasifikasi, SMOTE, VGG19

Copyright@2025 Ramanda md, Ery Hartati
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Penyakit *Alzheimer* mengakibatkan penyusutan volume otak sehingga memengaruhi fungsi kognitif secara signifikan (Krismantoro, 2021). Penyakit *Alzheimer* menyebabkan kehilangan *neuron* dan kesulitan bagi penderita untuk melakukan aktivitas sehari-hari karena kebingungan, ingatan yang tidak terorganisir, dan hilangnya kemampuan untuk mengingat(Breijyeh & Karaman, 2020). Penyebab penyakit ini adalah akumulasi abnormal protein *beta-amyloid* di jaringan otak membentuk plak yang merusak koneksi saraf, menjadi pemicu utama *Alzheimer*(Sianturi, 2021).

Secara medis, penyakit dibagi menjadi empat tahap, yaitu demensia sangat ringan, demensia ringan, demensia sedang, dan demensia berat(Fu'Adah et al., 2021). Jumlah kasus penyakit *Alzheimer* di Indonesia mencapai 1,2 juta pada tahun 2015. Angka ini diperkirakan akan terus meningkat hingga 1.894.000 kasus pada tahun 2030 dan terus meningkat hingga 3.980.000 kasus pada tahun 2050(Prabu Aji & Anantanyu, 2022). Penyebab utama yang memengaruhi perkembangan penyakit *Alzheimer* yaitu usia, yang umumnya didiagnosis pada orang berusia 65 tahun ke atas. Namun, tidak menutup kemungkinan bahwa penyakit *Alzheimer* juga dapat terjadi pada orang yang lebih muda. Faktor genetik juga dapat meningkatkan risiko terkena penyakit ini, serta cedera otak traumatis yang parah(Prasetya & Machfud, 2022).

Cara yang mudah untuk mendiagnosis penyakit *Alzheimer* adalah dengan menggunakan pencitraan medis(Alghamedy et al., 2022). Tenaga medis menggunakan citra medis, gambar dua dimensi yang menunjukkan bagian-bagian tubuh manusia, untuk mendeteksi dan menganalisis berbagai penyakit. *Magnetic Resonance Imaging (MRI)* merupakan salah satu teknik yang dapat digunakan untuk menghasilkan citra medis(Wijaya Kusuma & Kusumadewi, 2020). Untuk Diagnosis Penyakit *Alzheimer*, MRI telah menjadi teknologi diagnostic yang sangat penting(Yamanakkanavar et al., 2020). Meskipun meningkatkan keakuratan diagnosis penyakit *Alzheimer*, interpretasi manual gambar *MRI* oleh tenaga medis memiliki beberapa keterbatasan.

Proses manual memakan waktu dan bergantung pada keterampilan dan pengalaman individu. Kesalahan manusia juga meningkatkan kemungkinan terjadinya kesalahan diagnosis(Wirya, 2023). Sebab itu, Diperlukan metode yang dapat melakukan proses klasifikasi pada penyakit *Alzheimer* berdasarkan Citra *MRI*. Untuk pengenalan pola gambar, jaringan saraf konvolusional (CNN) merupakan salah satu metode pembelajaran mendalam yang paling populer. CNN dapat dengan jelas membedakan gambar dengan karakteristik yang serupa dan sulit dikenali saat digunakan untuk klasifikasi gambar skala besar secara otomatis dan efisien. Inilah alasan mengapa metode CNN sangat baik untuk digunakan dalam pembelajaran mendalam(Septipalan et al., 2024). CNN salah satu model deep learning yang memiliki beragam variasi arsitektur, termasuk di antaranya adalah VGG-19. Arsitektur VGG-19 ini dibangun dengan total 19 lapisan, yang terbagi menjadi beberapa komponen utama: 16 lapisan konvolusi untuk

ekstraksi fitur, 4 lapisan max pooling untuk reduksi dimensi, 2 lapisan fully connected untuk klasifikasi, serta 1 lapisan softmax sebagai output akhir. Spesifikasi teknisnya meliputi ukuran input standar sebesar 224x224 piksel, yang telah dioptimalkan untuk pemrosesan gambar. Arsitektur ini telah melalui proses pelatihan intensif menggunakan dataset besar ImageNet yang mencakup lebih dari 1 juta gambar. Dari segi konfigurasi, VGG-19 menerapkan kernel konvolusi berukuran 3x3 secara konsisten di seluruh lapisan konvolusinya. Struktur jaringan ini terorganisir dalam 5 blok utama, dimana setiap blok mengandung beberapa lapisan konvolusi dengan kedalaman yang bervariasi, dan diakhiri dengan lapisan max pooling yang berfungsi sebagai pembatas antar blok sekaligus mengurangi dimensi spasial fitur. Pendekatan arsitektural ini memungkinkan ekstraksi fitur hierarkis yang efektif, mulai dari fitur tingkat rendah hingga tinggi.(Marcella et al., 2022).

Penelitian yang dilakukan (Ajagbe et al., 2021) untuk mengklasifikasikan penyakit Alzheimer menggunakan gambar MRI dengan metode *Deep Convolutional Neural Networks* (DCNN) menggunakan tiga model arsitektur, yaitu CNN, VGG-16, dan VGG-19. Dalam pengujian yang dilakukan, VGG-19 memberikan hasil akurasi tertinggi yaitu 77,66%, diikuti oleh VGG-16 dengan 77,04%, dan CNN dasar dengan 71,02%. Selain akurasi, VGG-19 juga menunjukkan performa dengan AUC sebesar 81,55% dan precision 58,48%, sedangkan VGG-16 memiliki AUC 80,67% dan precision 57,43%. Salah satu keterbatasan dari penelitian ini adalah adanya ketidakseimbangan dalam jumlah data antar kelas, yang dapat memengaruhi hasil klasifikasi. Selain itu, metode augmentasi yang digunakan dalam penelitian ini cukup sederhana, sehingga mungkin tidak cukup efektif dalam menangani variasi kompleks yang ada dalam data MRI.

Penelitian yang telah dilakukan sebelumnya (Austin et al., 2024) untuk klasifikasi Alzheimer menggunakan Convnext menunjukkan Model menghasilkan akurasi 75%, Tetapi *dataset* tidak seimbang antar kelas sehingga akurasi yang dimiliki oleh data kelas minoritas memiliki Tingkat akurasi rendah dengan f1 score 0.15 dan hasil confusion matrix yaitu 1 prediksi benar dan 11 prediksi salah. Berdasarkan penjelasan bahwa pretrained VGG19 memiliki kinerja yang lebih baik dalam hal Tingkat akurasi. Oleh karena itu tujuan penelitian ini yaitu untuk menerapkan arsitektur pretrained VGG19 pada klasifikasi penyakit *Alzheimer* berdasarkan Citra *MRI* dengan menggunakan SMOTE untuk mengatasi ketidakseimbangan *dataset* pada kelas.

Dalam konteks diagnosis dan pemantauan AD, *magnetic resonance imaging* (MRI) banyak digunakan karena mampu menggambarkan perubahan struktur otak yang berkaitan dengan neurodegenerasi. Namun, interpretasi citra MRI secara manual membutuhkan keahlian tinggi, memakan waktu, dan rentan terhadap variasi antar penilai—sehingga pendekatan komputasional yang konsisten dan terukur menjadi relevan untuk mendukung proses skrining dan analisis. Sejalan dengan kemajuan

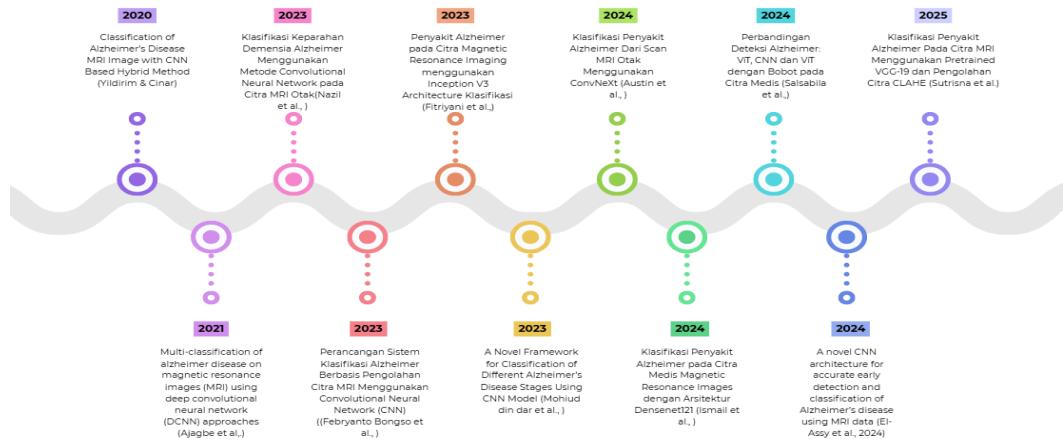
computer vision, metode *deep learning* (khususnya *convolutional neural network/CNN*) telah menunjukkan potensi kuat dalam ekstraksi fitur otomatis dari citra medis, termasuk untuk tugas deteksi/klasifikasi terkait AD. Tinjauan dan survei pada bidang ini melaporkan bahwa CNN mampu menangkap pola kompleks pada citra neuroimaging, meskipun performa sangat dipengaruhi oleh kualitas data, strategi pelatihan, dan skema evaluasi (Khojaste-Sarakhsy, M., et al., 2022).

Meskipun demikian, tantangan praktis yang sering muncul pada klasifikasi citra MRI AD adalah keterbatasan data berlabel dan ketidakseimbangan kelas (misalnya distribusi kelas normal lebih dominan dibanding kelas stadium tertentu). Kondisi ini dapat menyebabkan model bias terhadap kelas mayoritas dan menghasilkan metrik yang tampak tinggi namun tidak merepresentasikan kemampuan model dalam mengenali kelas minoritas—masalah yang banyak dibahas pada literatur pengolahan data medis tidak seimbang. Karena itu, strategi penanganan imbalance (misalnya *oversampling* berbasis SMOTE) perlu dipertimbangkan secara tepat dalam pipeline pelatihan, disertai evaluasi yang menekankan metrik yang sensitif terhadap imbalance agar interpretasi kinerja lebih adil (Wang, S., et al., 2021).

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada klasifikasi citra MRI otak untuk membedakan kategori kondisi terkait Alzheimer dengan memanfaatkan CNN berbasis transfer learning menggunakan model pretrained VGG19, serta menerapkan SMOTE untuk membantu menyeimbangkan distribusi kelas pada data latih. Pendekatan transfer learning dipilih karena efektif ketika jumlah data berlabel terbatas dan telah banyak digunakan pada tugas klasifikasi MRI AD (Raza, N., et al., 2023). Secara ringkas, kontribusi penelitian ini adalah merancang pipeline klasifikasi MRI berbasis pretrained VGG19, mengintegrasikan strategi penyeimbangan kelas untuk mengurangi bias terhadap kelas minoritas, dan menyajikan evaluasi kinerja yang lebih informatif melalui metrik klasifikasi yang relevan pada skenario data tidak seimbang.

2. Kajian Terdahulu

Pada Kajian Terdahulu untuk mempermudah penjelasan proses yang telah dilakukan, disusun sebuah roadmap penelitian alzheimer pada Gambar 1.



Gambar 1. Roadmap Penelitian Alzheimer

Penelitian yang dilakukan sebelumnya oleh (Sutrisna et al., 2025), yang menggunakan CNN dengan arsitektur VGG19 dan pengolahan citra CLAHE, model tersebut menghasilkan akurasi yang sangat baik dengan nilai F1 sebesar 93,91%. Namun, meskipun hasilnya cukup baik, penelitian tersebut tidak mengatasi ketidakseimbangan kelas pada dataset yang digunakan, yang merupakan masalah dalam klasifikasi penyakit Alzheimer. Oleh karena itu, penelitian ini menggunakan metode SMOTE untuk mengatasi masalah ketidakseimbangan antar kelas dan meningkatkan hasil klasifikasi kelas yang jumlahnya sedikit.

Penelitian yang dilakukan(Austin et al., 2024) menggunakan ConvNeXt juga berkonsentrasi pada klasifikasi Alzheimer dengan dataset MRI; meskipun mereka tidak menggunakan teknik SMOTE, akurasi model pada kelas minoritas sangat rendah, dengan skor F1 hanya 0,15. Akurasi total model hanya 75%, menunjukkan bahwa metode SMOTE dapat memainkan peran yang signifikan dalam meningkatkan akurasi model.

Penelitian sebelumnya yang dilakukan oleh (Ajagbe et al., 2021) dalam mengklasifikasikan penyakit Alzheimer menggunakan gambar MRI dengan metode Deep Convolutional Neural Networks menggunakan tiga jenis model arsitektur, yaitu CNN, VGG-16, dan VGG-19. Dari hasil pengujian yang dilakukan, model VGG-19 memberikan akurasi terbaik dengan angka 77,66%, kemudian diikuti oleh VGG-16 dengan 77,04%, dan CNN dasar dengan 71,02%. Selain akurasi, VGG-19 juga menunjukkan nilai AUC sebesar 81,55% dan precision 58,48%, sedangkan VGG-16 memiliki AUC 80,67% dan precision 57,43%. Meskipun hasil yang diperoleh cukup memuaskan, penelitian tersebut tidak berhasil mengatasi masalah ketidakseimbangan kelas dalam dataset, yang bisa memengaruhi hasil klasifikasi. Oleh karena itu, penelitian

ini akan menggunakan metode SMOTE untuk mengatasi masalah ketidakseimbangan kelas.

Alzheimer

Alzheimer adalah penyakit yang menyerang orang tua dan menyebabkan penurunan daya ingat. Penyakit ini mempengaruhi sistem saraf otak, menyebabkan kerusakan pada sel-sel neuron dan mengakibatkan kesulitan dalam menjalani aktivitas sehari-hari, seperti kebingungan dalam memahami pertanyaan, gangguan memori, dan akhirnya kehilangan kemampuan untuk mengingat. (Dewi et al., 2025).

Akumulasi plak protein *beta-amyloid* mengganggu komunikasi antara sel otak, yang merupakan penyebab utama penyakit *Alzheimer*(Sianturi, 2021). Meskipun interpretasi manual citra medis seringkali memakan waktu dan rawan kesalahan manusia, diagnosis dini dan akurat sangat penting untuk penanganan yang lebih efektif(Wirya, 2023).

Oleh Sebab itu diperlukan untuk Mengidentifikasi penyakit *Alzheimer* dengan berdasarkan Tingkat keparahan yaitu Demensia sedang(*Moderate Demented*), Demensia ringan(*Mild Demented*), Demensia Sangat Ringan(*Very Mild Demented*), dan Tanpa Demensia(*Non Demented*).

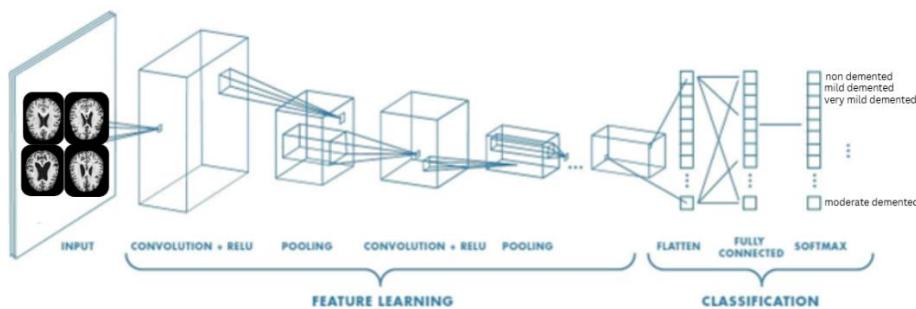
Deep Learning

Deep learning merupakan aspek dari machine learning yang menggunakan jaringan saraf buatan dengan banyak layer untuk memproses, mengevaluasi, dan memahami data yang kompleks(Huang et al., 2020). Model ini dirancang untuk meniru cara otak manusia dalam memproses informasi, menganalisis keterkaitan, dan mengidentifikasi pola(Saptadi et al., 2025). *Deep learning* mampu melebihi metode pembelajaran konvensional saat mengolah data tidak terstruktur seperti teks, gambar, dan suara(Hafidzah et al., 2024). *Deep learning* saat ini menjadi teknologi inti dalam revolusi kecerdasan buatan berkat kemajuan dalam komputasi, munculnya big data, dan algoritma yang efisien.

Convolutional Neural Network (CNN)

CNN adalah salah satu model deep learning yang populer dalam tugas klasifikasi dan pengenalan gambar. Secara umum, arsitektur CNN terbagi menjadi tiga bagian utama, yaitu lapisan konvolusi, lapisan *pooling*, dan lapisan *fully connected*(Dewi et al., 2025). Dalam prosesnya, CNN bekerja melalui dua tahap kunci: ekstraksi fitur dan klasifikasi. Pada tahap ekstraksi fitur, jaringan melakukan operasi konvolusi, diikuti oleh fungsi aktivasi ReLU dan *pooling*. Proses ini berulang melalui beberapa lapisan, bahkan bisa mencapai ratusan lapisan. Selanjutnya, tahap klasifikasi menggunakan lapisan *fully connected* untuk menghasilkan vektor berdimensi-K, di mana K menunjukkan jumlah

kelas prediksi yang dapat dikenali oleh model (Wardani & Leonardi, 2023). Arsitektur dapat dilihat pada gambar 1.



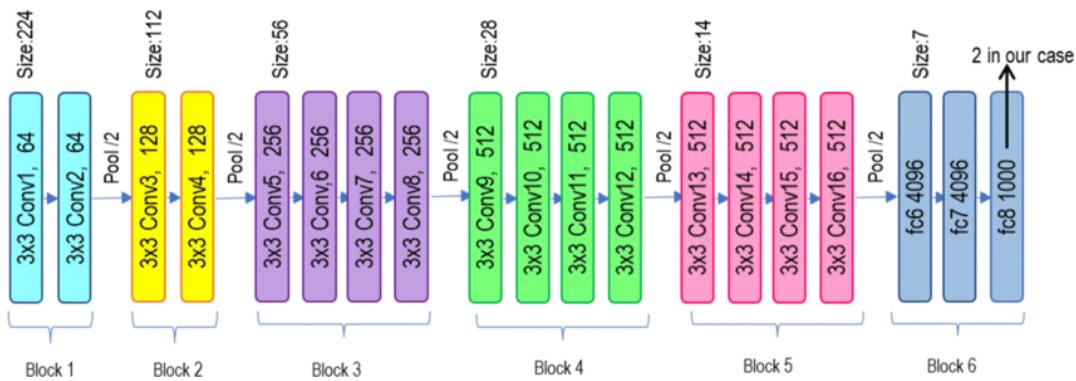
Gambar 2. Arsitektur CNN
Sumber:(Wardani & Leonardi, 2023)

VGG19

Visual Geometry Group (VGG) di *University of Oxford* mengembangkan model jaringan saraf konvolusional (CNN) bernama VGG19. Model ini diperkenalkan dalam publikasi oleh Simonyan dan Zisserman pada tahun 2014 dan terdiri dari 19 lapisan yang dapat dilatih, termasuk 16 lapisan konvolusi dan 3 lapisan *fully connected*. Karena struktur dan performa yang bagus, VGG19 dianggap sebagai salah satu arsitektur terbaik dalam tugas klasifikasi gambar.

Model ini menggunakan *filter* berukuran 3x3 di setiap lapisan konvolusi, sehingga lebih mudah dipahami dan digunakan. Salah satu keunggulan VGG19 adalah kemampuan *transfer learning*, yaitu belajar dari dataset besar seperti *ImageNet*. Kemampuan ini memungkinkan model digunakan kembali untuk berbagai masalah klasifikasi gambar, termasuk dalam bidang medis seperti klasifikasi penyakit *Alzheimer*. VGG19, yang memiliki 19 lapisan, cukup dalam untuk menangkap dan mengenali elemen visual yang kompleks. Ini memungkinkan model mengenali perbedaan kecil pada gambar dengan lebih akurat(Sutrisna et al., 2025).

Gambar 2 menunjukkan struktur *Convolutional Neural Network* (CNN) yang terdiri dari banyak blok konvolusi dan pooling. Setiap blok bertujuan mengekstrak fitur gambar secara bertahap. Pada lapisan konvolusi pertama, model mengenali fitur dasar seperti garis atau tepi. Dengan lapisan konvolusi yang lebih dalam, model mulai mengenali fitur yang lebih kompleks, seperti tekstur, bentuk, dan objek yang lebih spesifik. Setelah diproses, gambar diratakan (*flattened*), yaitu proses mengubah gambar dari bentuk dua dimensi menjadi satu dimensi agar bisa diproses lebih lanjut. Proses ini dilanjutkan dengan lapisan *fully connected* (FC), yang bertugas menggabungkan semua fitur yang telah dipelajari dan membuat keputusan akhir mengenai klasifikasi gambar tersebut. Pada akhirnya, model CNN ini akan menghasilkan prediksi kelas gambar. Ini dapat digunakan untuk mengklasifikasikan tingkat keparahan penyakit *Alzheimer* dengan menggunakan karakteristik yang diekstrak dan dipelajari selama proses pelatihan.



Gambar 3. Arsitektur VGG19

Sumber:(Sutrisna et al., 2025)

SMOTE

SMOTE adalah Teknik yang digunakan untuk mengatasi masalah ketidakseimbangan kelas dalam *dataset* dengan menciptakan contoh baru secara sintetis untuk kelas yang sedikit(Wang et al., 2021). Metode ini menggunakan proyeksi titik data minoritas ke dalam ruang fitur yang ada dan contoh baru di antara titik data yang ada(Praskatama et al., 2024). SMOTE biasanya digunakan untuk data tabular, tetapi juga dapat diterapkan untuk *dataset* gambar dengan memperlakukan gambar sebagai vektor fitur. Dalam hal ini, SMOTE menghasilkan sampel sintetis yang didasarkan pada nilai piksel atau fitur yang mengelilingi gambar, yang dapat membantu menyeimbangkan distribusi kelas bahkan dalam *dataset* yang terdiri dari gambar.

$$X_{new} = X_i + \lambda * (X_i^{neighbor} - X_i) \quad (1)$$

Keterangan:

X_{new} : Data Sintetis yang baru dibuat

X_i : Titik data minoritas yang sudah ada

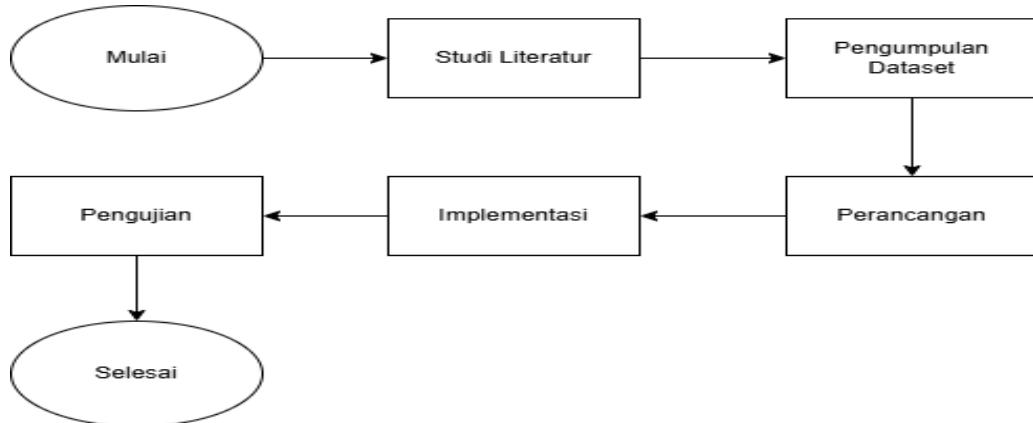
λ : parameter acak yang memiliki rentang distribusi mulai dari 0 hingga 1

$X_i^{neighbor}$: Tetangga terdekat dari X_i

Rumus matematis untuk SMOTE saat menghasilkan data baru disajikan dalam Persamaan 1. Dengan cara ini, SMOTE meningkatkan jumlah data yang ada dalam kelas minoritas dan membantu model mempelajari pola yang lebih representatif di seluruh *dataset*.

3. Metodologi Penelitian

Dalam Penelitian ini, membahas tentang langkah-langkah perancangan metodologi penelitian yang dimulai dari studi literatur sampai dengan selesai. Berikut Tahapan metodologi penlitian pada gambar 3.



Gambar 4. Tahapan Metodologi Penelitian

1. Studi Literatur

Studi Literatur ini dilakukan untuk mendapatkan pemahaman yang lebih baik tentang subjek penelitian, termasuk identifikasi penyakit *Alzheimer*, pemrosesan gambar *MRI*, metode klasifikasi gambar berbasis *deep learning*, Penerapan SMOTE untuk mengatasi Ketidakseimbangan data pada kelas dan penerapan *transfer learning* menggunakan arsitektur VGG19. Sumber literatur yang digunakan termasuk buku, jurnal ilmiah, dan publikasi online yang berkaitan dengan klasifikasi gambar medis dan penggunaan model yang diprogram untuk diagnosis.

2. Pengumpulan Dataset



Penelitian ini menggunakan menggunakan *Dataset* citra *MRI* Otak yang bersifat public atau sekunder dan diperoleh dari situs Kaggle dengan format gambar *JPG* ukuran 176 x 208 dengan jumlah dataset 6400.


Tabel 1. Informasi Dataset Alzheimer

<i>Dataset</i>	Sumber	Lisensi	Format	Ukuran	Jumlah <i>Dataset</i>
Alzheimer	Kaggle	Original <i>Dataset</i>	JPG	176 x 208	6.400

Pada Tabel 2. menunjukkan jumlah gambar pada *dataset* awal sebelum teknik SMOTE. *Dataset* yang digunakan dalam penelitian ini terdiri dari empat kelas yang mengkategorikan tingkat keparahan penyakit Alzheimer berdasarkan gambar MRI otak pasien. Kelas dengan gambar paling sedikit memiliki jumlah gambar yang berbeda, yang menyebabkan ketidakseimbangan yang jelas. Untuk menyelesaikan masalah ini, menggunakan pendekatan SMOTE untuk oversampling kelas minoritas dan menyeimbangkan *dataset*.

Tabel 2. Informasi Jumlah Dataset yang digunakan

Kelas	<i>Jumlah Dataset</i>	<i>Gambar</i>
Non Demented	3200	
VeryMild Demented	2240	

Mild Demented	896		
Moderate Demented	64		

Pada Tabel 3. menunjukkan distribusi *dataset* setelah penerapan SMOTE. ini memprioritaskan pembangkitan sampel untuk kelas minoritas dan menghilangkan pembangkitan contoh sintetis untuk kelas mayoritas. Jumlah gambar total meningkat menjadi 12.800. Setelah oversampling, *dataset* setiap kelas sekarang terdiri dari 3.200 gambar, Karena SMOTE menghasilkan sampel sintetis untuk kelas minoritas, jumlah data per kelas menjadi seimbang dengan kelas mayoritas. Teknik ini menginterpolasi dan menambah titik data di kelas minoritas untuk memastikan distribusi kelas setara, yang mengurangi masalah ketidakseimbangan kelas yang dapat memengaruhi kinerja model

Tabel 3. Jumlah Citra dataset setelah SMOTE

Kelas	<i>Dataset</i>
Non Demented	3200
VeryMild Demented	3200
Mild Demented	3200
Moderate Demented	3200
Total	12.800

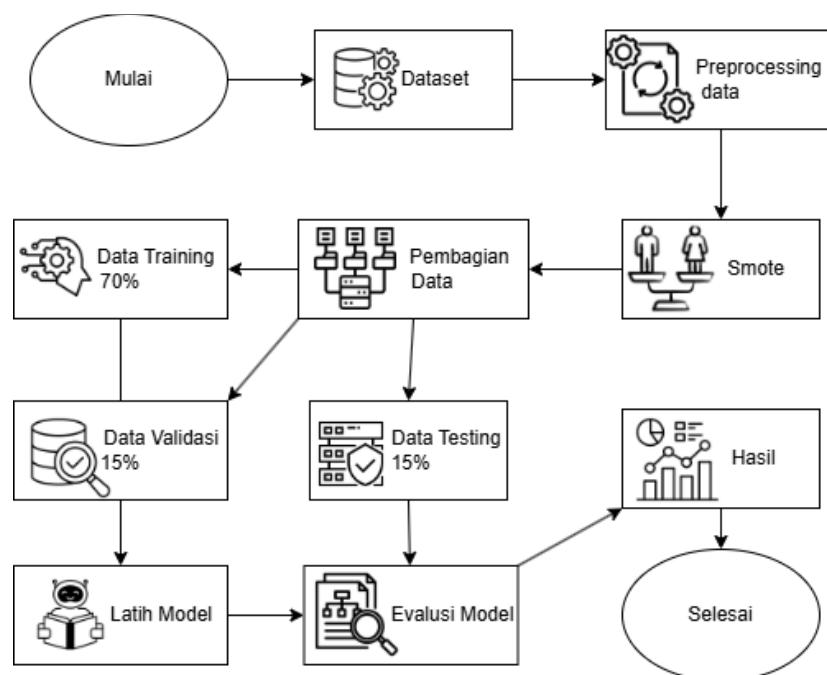
Setelah penerapan SMOTE, *dataset* dibagi 70% data latih 15% data validasi dan 15% data testing, ini dilakukan untuk memastikan bahwa model dilatih dan diuji dengan benar, dan agar hasil evaluasi model menunjukkan kemampuan model untuk mengklasifikasikan data. Hal ini ditunjukkan dalam tabel 4.

Tabel 4. Informasi Pembagian Data

No	Pembagian Dataset		
	Data Training	Data Validasi	Data Testing
1	70%	15%	15%
2	8960	1920	1920

3. Perancangan

Tahap Perancangan akan dijelaskan mengenai *Dataset* diolah sampai tahap Pelatihan Model hingga terbentuknya model yang siap untuk dievaluasi. Berikut gambar perancangan dapat dilihat pada Gambar 5.



Gambar 5. Skema Perancangan

Pada tahap awal, 6.400 gambar *MRI* otak diunggah dan dimasukkan ke dalam empat folder yang berbeda berdasarkan tingkat keparahan mereka *NonDemented*, *VeryMildDemented*, *MildDemented*, dan *ModerateDemented*. Setelah itu, set data melewati proses preprocessing. Ini termasuk mengubah ukuran gambar yang sebelumnya 176 x 208 piksel menjadi 224 x 224 piksel untuk menyesuaikannya dengan input standar model VGG19. Selain itu, skala gambar diubah menjadi skala normalisasi [0, 1], yang dimaksudkan untuk mempercepat konvergensi selama pelatihan. Untuk mengatasi masalah ketidakseimbangan kelas, teknik SMOTE diterapkan pada *dataset*. Ini merupakan langkah penting lainnya.

Dengan menggunakan parameter *K-nearest neighbors*, SMOTE menginterpolasi titik data yang ada dalam ruang fitur untuk menghasilkan citra sintetis dengan cara mengubah gambar yang 2D menjadi 1D. Metode ini meningkatkan jumlah sampel di kelas minoritas, sehingga meningkatkan keseimbangan distribusi kelas. Setelah SMOTE digunakan, *dataset* dibagi menjadi tiga bagian: 75% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data uji. Ini dilakukan untuk memastikan bahwa model dapat dilatih, diverifikasi, dan diuji secara adil.

Untuk tahap pelatihan model, arsitektur VGG19, yang telah dilatih dengan *dataset ImageNet*, dipilih karena kemampuan untuk mengekstraksi fitur dari gambar dan kinerjanya yang luar biasa dalam klasifikasi citra medis. Selama pelatihan, model ini dilatih selama 150 *epoch*, dengan setiap epoch mencakup seluruh *dataset* yang digunakan untuk memperbarui bobot model. Selama pelatihan, categorical crossentropy digunakan sebagai loss function untuk mengukur perbedaan antara prediksi model dan nilai target pada masalah klasifikasi multi-kelas. Berdasarkan jurnal (Sutrisna et al., 2025) *learning rate* 0.001 merupakan nilai yang paling tinggi akurasi diantara learning rate lainnya sehingga ditetapkan nilai 0.001 sebagai learning rate. Optimizer Adamax digunakan untuk mengoptimalkan pembaruan bobot model. Ini telah terbukti efektif dalam menjaga kestabilan pelatihan pada *dataset* yang besar.

Selain itu, ukuran *batch* yang digunakan adalah 32. Ini mengatur berapa banyak gambar yang diproses sebelum pembaruan bobot. Dengan pengaturan ini, model dilatih dengan baik untuk mencapai konvergensi terbaik. Regularisasi *L2* diterapkan pada lapisan Dense untuk mengurangi risiko overfitting karena model yang terlalu kompleks. Ini mencegah model untuk bergantung terlalu banyak pada fitur tertentu. *Dropout* juga digunakan pada lapisan *Dense*. Ini dilakukan untuk mengurangi ketergantungan model pada neuron tertentu dan mencegah model menjadi terlalu spesifik pada data pelatihan. Langkah-langkah

ini meningkatkan kemampuan untuk generalisasi pada data baru dan mencegah model belajar terlalu banyak pada data pelatihan.

Setelah pelatihan, untuk evaluasi model menggunakan confusion matrix yang mana dapat dilakukan untuk menilai kinerja model dalam mengklasifikasikan setiap kelas menggunakan metrik akurasi, *precision*, *recall*, dan *F1 Score*. Untuk analisis yang lebih mendalam, *confusion matrix* digunakan untuk menunjukkan kesalahan klasifikasi dan mengevaluasi distribusi kesalahan antara berbagai kelas. Evaluasi ini memberikan gambaran yang lebih lengkap tentang efektivitas model dalam menangani *dataset* yang tidak seimbang.

4. Implementasi

Tahapan implementasi ini adalah membuat penelitian ini menjadi kenyataan agar bisa mengklasifikasikan jenis keparahan penyakit *Alzheimer* dengan menggunakan CNN dengan model pretrained VGG19 dan SMOTE berdasarkan Citra *MRI* Otak.

5. Pengujian

Setelah tahap evaluasi model, hasil evaluasi model akan dihitung dengan menggunakan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, *f1 score*, dan *accuracy* yang dapat dilihat pada persamaan (2),(3),(4), dan (5).

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

Keterangan:

TP:Jumlah data *positif* yang diklasifikasikan dengan benar oleh sistem

TN:Jumlah data *negatif* yang diklasifikasikan dengan benar oleh sistem

FN:Jumlah data *negatif* yang diklasifikasikan dengan salah oleh sistem

FP: Jumlah data *positif* yang diklasifikasikan dengan salah oleh sistem

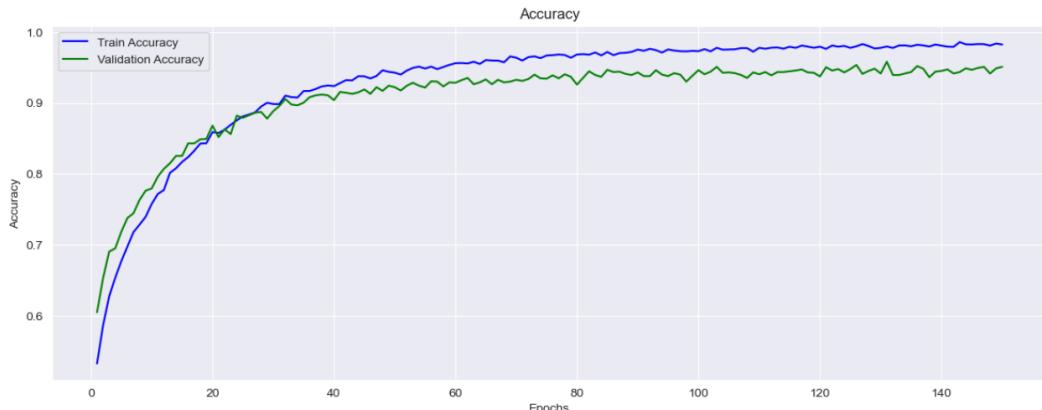
4. Hasil dan Pembahasan

Pada bagian ini dijelaskan hasil penelitian dan sekaligus diberikan pembahasan yang komprehensif mengenai penerapan SMOTE untuk menyeimbangkan kelas dataset


yang tidak seimbang kedalam arsitektur VGG19 untuk klasifikasikan penyakit Alzheimer dengan Tingkat keparahan berdasarkan Citra MRI Otak menggunakan Optimizer Adamax, Dropout, Learning rate, dan Epoch.

4.1. SMOTE

Penelitian berfokus untuk menyeimbangkan kelas pada dataset yang tidak seimbang dengan menggunakan SMOTE. Hasil yang didapat menggunakan SMOTE dapat dilihat pada tabel 5 dan gambar 6, 7, 8 dan 9.



Gambar 6. Tampilan Hasil Grafik Akurasi Training Model VGG19



Gambar 7. Tampilan Hasil Grafik Loss Training Model VGG19

Grafik akurasi dan loss pada Gambar 6 dan 7 menggambarkan performa pelatihan model yang sangat optimal ketika menggunakan teknik SMOTE. Terlihat bahwa nilai akurasi dan loss pada setiap epoch antara data pelatihan dan validasi memiliki keselarasan yang tinggi, tanpa adanya jarak yang mencolok. Hal ini menunjukkan bahwa model VGG19 yang dikombinasikan dengan SMOTE berhasil menghindari masalah underfitting maupun overfitting. Dengan demikian, dapat disimpulkan bahwa model

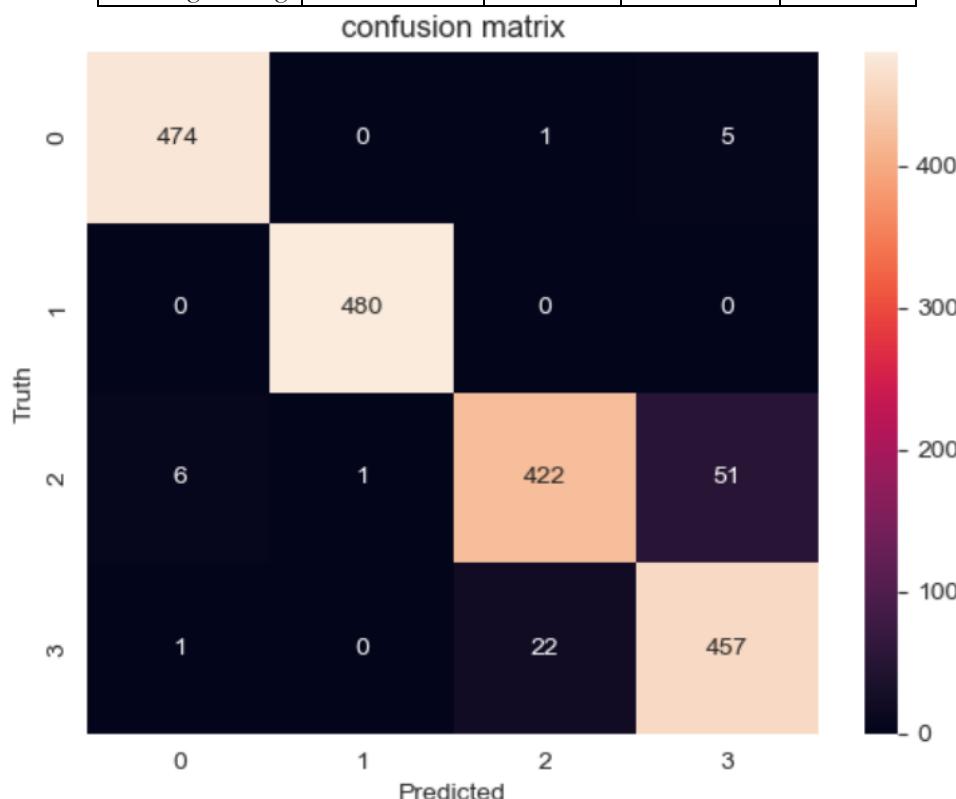
tersebut telah mencapai tingkat pemahaman yang mendalam terhadap data, sebagaimana tercermin dari konsistensi hasil pada kedua set data (pelatihan dan validasi).

```
model.evaluate(test_imgs,test_labels)
60/60 [0.259782612323761, 0.9546874761581421]
127s 2s/step - accuracy: 0.9532 - loss: 0.2366
```

Gambar 8. Hasil Evaluasi Model VGG19

Tabel 5. *Classification Report*

	Precision	Recall	F1 score	Support
0	0.99	0.99	0.99	480
1	1.00	1.00	1.00	480
2	0.95	0.88	0.91	480
3	0.89	0.95	0.92	480
Accuracy			0.95	1920
Macro avg	0.96	0.95	0.95	1920
Weighted avg	0.96	0.95	0.95	1920



Gambar 9. Confusion Matrix

Dengan berdasarkan hasil *confusion matriks* tersebut kelas *MildDemented*(0) mendapatkan 474 prediksi benar dan 6 prediksi salah. Kelas *ModerateDemented*(1) mendapatkan 480 prediksi benar dan 0 prediksi salah. Kelas *NonDemented*(2) mendapatkan 422 Prediksi benar dan 58 prediksi salah. Kelas *Verymilddemented*(3) mendapatkan 457 Prediksi Benar dan 23 Prediksi Salah.

Dengan demikian SMOTE membantu mengatasi ketidakseimbangan data pada kelas dalam mengklasifikasikan penyakit Alzheimer dengan sangat baik dan menghasilkan akurasi yang cukup tinggi sebesar 95%.

4.2. Perbandingan Penelitian Terdahulu

Setelah mencapai hasil tertinggi sebesar 95% dalam penelitian ini dengan memanfaatkan VGG19 dan SMOTE, penulis akan membandingkan hasil tersebut dengan penelitian referensi yang telah ditentukan. Tabel 6 menunjukkan peningkatan akurasi studi ini (0,9546) dibanding akurasi yang dilaporkan oleh penelitian Ajagbe (0,7102–0,7766 pada beberapa arsitektur).

Meskipun demikian, perbandingan ini harus disertai klarifikasi kesetaraan protokol (dataset yang sama, skema split yang sama, penggunaan augmentasi dan metrik yang sama). Tanpa kontrol tersebut, perbandingan raw accuracy berpotensi tidak merefleksikan keunggulan metode secara adil. Hasil perbandingan tersebut dapat dilihat pada tabel 6.

Tabel 6. Perbandingan Hasil

Metode	Arsitektur	Augmentasi	SMOTE	Jumlah Dataset	Akurasi
1.Jurnal Ajagbe	CNN, VGG16, VGG19	Menggunakan	Tidak Menggunakan	6400	0.7102, 0.7704, 0.7766
2.Jurnal Penulis	VGG19	Tidak Menggunakan	Menggunakan	6400	0.9546

Meskipun Tabel 6 menunjukkan bahwa pendekatan yang diusulkan memiliki kinerja lebih tinggi dibanding penelitian pembanding, perbandingan kinerja antar-studi perlu ditafsirkan secara hati-hati karena sangat dipengaruhi oleh dataset, protokol pembagian data, dan unit pemisahan. Pada klasifikasi Alzheimer berbasis MRI 2D-slice, Yagis et al. (2021) menegaskan bahwa pemisahan data pada level irisan (slice-level split) dapat memicu data leakage, yaitu irisan dari subjek yang sama berpotensi muncul di data latih dan data uji sehingga performa tampak meningkat secara artifisial. Karena itu, klaim “unggul” antar-studi sebaiknya selalu disertai klarifikasi apakah evaluasi dilakukan pada level subjek (subject-level split) dan apakah terdapat langkah mitigasi kebocoran data,

sebagaimana juga ditekankan dalam telaah metodologis tentang rigor evaluasi pada diagnosis Alzheimer berbasis deep learning (Young et al., 2025).

Selain isu protokol, ketidakseimbangan kelas pada dataset medis menuntut pelaporan metrik yang lebih informatif daripada akurasi saja. Studi tinjauan pada dataset medis tidak seimbang menekankan bahwa akurasi dapat “menutupi” kegagalan model pada kelas minoritas; karena itu, evaluasi sebaiknya melaporkan metrik seperti macro-F1, balanced accuracy, serta metrik per-kelas (misalnya recall/sensitivitas per kelas) agar performa pada kelas minoritas terukur secara adil (Salmi et al., 2024). Pada konteks medical imaging AI, pemilihan metrik juga harus selaras dengan tujuan klinis dan risiko kesalahan, sehingga interpretasi hasil sebaiknya tidak hanya bertumpu pada satu metrik agregat (Kocak et al., 2025).

penelitian ini menggunakan SMOTE untuk meningkatkan representasi kelas minoritas, sehingga penerapannya pada data citra perlu dijelaskan dengan ketat dan diterapkan hanya pada data latih agar tidak mengkontaminasi evaluasi. Untuk memperkuat klaim bahwa SMOTE benar-benar berkontribusi pada peningkatan performa (bukan efek samping rancangan evaluasi), bagian ini akan lebih kuat jika dilengkapi studi ablation: (i) VGG19 tanpa SMOTE dan (ii) VGG19 + SMOTE (dengan protokol split yang ketat), lalu dibandingkan menggunakan metrik yang sensitif terhadap kelas minoritas seperti macro-F1 dan recall per kelas, sebagaimana direkomendasikan pada kajian dataset medis imbalanced (Salmi et al., 2024).

4.3 Keterbatasan Penelitian

Meskipun penelitian ini menunjukkan kinerja klasifikasi yang tinggi, terdapat beberapa keterbatasan yang perlu disampaikan untuk menjaga transparansi dan meningkatkan kredibilitas interpretasi hasil. Pertama, performa model deep learning pada citra MRI sangat dipengaruhi oleh konfigurasi pelatihan, sehingga stabilitas kinerja masih bergantung pada penyetelan hyperparameter (misalnya learning rate, jumlah epoch, batch size, regularisasi, dan dropout). Oleh karena itu, hasil yang diperoleh pada penelitian ini masih berpotensi berubah ketika dilakukan pengaturan hyperparameter yang berbeda, sehingga diperlukan strategi optimasi yang lebih sistematis pada penelitian lanjutan untuk memastikan performa yang konsisten.

Kedua, meskipun penelitian ini telah mengklasifikasikan beberapa kategori kondisi/tingkat keparahan, evaluasi lebih lanjut masih diperlukan untuk memperluas cakupan klasifikasi tingkat keparahan Alzheimer dengan penambahan lebih banyak kelas, sehingga model dapat merepresentasikan variasi kondisi klinis secara lebih rinci. Perluasan kelas ini juga penting agar model memiliki kemampuan diskriminasi yang lebih baik pada kategori yang cenderung saling berdekatan secara karakteristik visual.

Ketiga, keterbatasan juga terkait dengan rancangan evaluasi dan interpretasi kinerja pada data citra MRI. Protokol pembagian data (split) perlu dipastikan dilakukan

secara ketat agar tidak menimbulkan bias evaluasi, terutama pada skenario citra MRI 2D-slice yang berpotensi menimbulkan data leakage jika pemisahan data tidak merepresentasikan unit subjek/pasien secara benar. Selain itu, meskipun metrik agregat telah disajikan, pelaporan hasil akan lebih kuat jika dilengkapi analisis kinerja per kelas (misalnya per-class recall dan per-class F1-score) untuk menilai konsistensi model dalam mengenali kelas yang lebih sulit.

4.4. Rekomendasi Penelitian lanjutan

Berdasarkan keterbatasan tersebut, penelitian lanjutan disarankan untuk melakukan optimasi hyperparameter secara terstruktur, perluasan jumlah kelas untuk klasifikasi tingkat keparahan Alzheimer, serta penguatan protokol evaluasi dan pelaporan metrik per kelas agar generalisasi model dapat dinilai lebih robust.

5. Kesimpulan

Kesimpulan Penelitian ini menunjukkan bahwa penggunaan arsitektur VGG19 yang digabungkan dengan teknik SMOTE untuk menangani ketidakseimbangan kelas pada dataset berhasil mencapai tingkat akurasi yang tinggi, yaitu 95% dalam klasifikasi penyakit *Alzheimer*. Hasil ini menunjukkan perbaikan signifikan jika dibandingkan dengan penelitian sebelumnya yang menggunakan CNN, VGG16, VGG19 dengan akurasi 71%, 77% dan 77%. Keunggulan model ini terletak pada kemampuannya mengatasi ketidakseimbangan kelas melalui SMOTE. Serta kelebihan Arsitektur VGG19 dalam mengekstraksi fitur-fitur gambar yang kompleks, yang memungkinkan deteksi lebih akurat pada Citra MRI Otak.

Meskipun hasil yang diperoleh cukup memuaskan, penelitian ini memiliki beberapa keterbatasan, seperti kebutuhan untuk penyesuaian hyperparameter yang lebih tepat guna mempertahankan stabilitas performa model, serta perlunya evaluasi lebih lanjut terkait tingkat keparahan penyakit *Alzheimer* dengan penambahan lebih banyak kelas. Secara umum, Temuan ini memberi kesempatan untuk membuat sistem pemantauan otomatis menggunakan gambar medis yang lebih cepat dan tepat, khususnya untuk penggunaan dalam mendeteksi penyakit Alzheimer lebih awal.

6. Ucapan Terima Kasih

Kami menyampaikan rasa terima kasih kepada Tuhan Yang Maha Esa serta mengucapkan banyak terima kasih kepada semua pihak, khususnya kepada co-author dan Universitas Multi Data Palembang, yang telah memberikan bantuan dan dukungan selama penelitian ini berlangsung.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Ajagbe, S. A., Amuda, K. A., Oladipupo, M. A., & Afe, O. F. (2021). *Multi-classification of alzheimer disease on magnetic resonance images (MRI) using deep convolutional neural network (DCNN) approaches*. *Multi-classification of alzheimer disease on magnetic resonance images (MRI) using deep convolutional neural network (DCNN) approaches*. April. <https://doi.org/10.19101/IJACR.2021.1152001>
- Alghamedy, F. H., Shafiq, M., Liu, L., Yasin, A., Khan, R. A., & Mohammed, H. S. (2022). Machine Learning-Based Multimodel Computing for Medical Imaging for Classification and Detection of Alzheimer Disease. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/9211477>
- Austin, Y. S., Irfano, H., Christopher, J. Y., Sukma, L. C., Putra, O. P., Ardhanto, R. I., & Yudistira, N. (2024). *Klasifikasi penyakit Alzheimer dari scan MRI Otak menggunakan Convnet Classification of Alzheimer's Disease from brain MRI Scans using*. 11(6), 1223–1232. <https://doi.org/10.25126/jtiik.2024118117>
- Breijeh, Z., & Karaman, R. (2020). Comprehensive Review on Alzheimer's Disease: Causes and Treatment. *Molecules*, 25(24). <https://doi.org/10.3390/MOLECULES25245789>
- Dewi, B., Muflikhah, L., & Setiawan, B. D. (2025). *Klasifikasi Penyakit Alzheimer Berdasarkan Citra MRI Otak*. 9(6), 1–10.
- Fu'Adah, Y. N., Wijayanto, I., Pratiwi, N. K. C., Taliningsih, F. F., Rizal, S., & Pramudito, M. A. (2021). Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture. *Journal of Physics: Conference Series*, 1844(1). <https://doi.org/10.1088/1742-6596/1844/1/012020>
- Hafidzah, P., Maryani, S., Ihsani, B. Y., Erwin, E., & Niswariyana, A. K. (2024). Penerapan Deep Learning dalam Menganalisis Sentimen di Media Sosial. *Seminar Nasional Paedagoria*, 4, 328–339.
- Huang, J., Chai, J., & Cho, S. (2020). Deep Learning In Finance and Banking. *Frontiers of Business Research in China*, 14(1).

- Khojaste-Sarakhs, M., Haghghi, S. S., Ghomi, S. M. T. F., & Marchiori, E. (2022). Deep learning for Alzheimer's disease diagnosis: A survey. *Artificial intelligence in medicine*, 130, 102332. <https://doi.org/10.1016/j.artmed.2022.102332>
- Kocak, B., Klontzas, M. E., Stanzione, A., Meddeb, A., Demircioğlu, A., Bluethgen, C., Bressem, K. K., Ugga, L., Mercaldo, N., Díaz, O., & Cuocolo, R. (2025). Evaluation metrics in medical imaging AI: Fundamentals, pitfalls, misapplications, and recommendations. *European Journal of Radiology Artificial Intelligence*, 3, 100030. <https://doi.org/10.1016/j.ejrai.2025.100030>
- Krismantoro, E. (2021). *Klasifikasi Objek Alzheimer Citra Otak Magnetic Resonance Image (MRI) Dengan Metode Backpropagation Neural Network Berdasarkan Clinical Dementia Rating (CDR)*.
- Marcella, D., Yohannes, & Devella, S. (2022). *Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19*. 3(1), 60–70.
- Prabu Aji, S., & Anantanyu, S. (2022). Alzheimer Dan Gejala Sistem Saraf (Neurologis) Akibat Pestisida. *Public Health and Safety International Journal*, 2(01), 99–102. <https://doi.org/10.55642/phasij.v2i01.167>
- Prasetya, O., & Machfud, S. (2022). Analisis Prediksi Penyakit Demensia Alzheimer Menggunakan Metode Decision Tree C4.5 Dan Naive Bayes. *Jurnal Informatika Utama*, 14–25.
- Praskatama, V., Shidik, G. F., & Ningrum, A. P. (2024). Comparative Study: Flower Classification using Deep Learning, SMOTE and Fine-Tuning. *Journal of Applied Informatics and Computing*, 8(2), 557–568. <https://doi.org/10.30871/jaic.v8i2.8730>
- Raza, N., Naseer, A., Tamoor, M., & Zafar, K. (2023). Alzheimer Disease Classification through Transfer Learning Approach. *Diagnostics*, 13(4), 801. <https://doi.org/10.3390/diagnostics13040801>
- Saptadi, N. T. S., Kristiawan, H., Nugroho, A. Y., Rahayu, N., Suwarmiyati, Waseso, B., Intan, I., Khairunnas, Martono, Saputra, P. Y., Sutriawan, Soekarman, Mahatma, K., Yunianto, I., Soleh, O., Sutoyo, M. N., Siswoyo, B., & Aliyah. (2025). *Deep Learning Teori, Algoritma, dan Aplikasi* (Issue March).
- Salmi, M., Atif, D., Oliva, D., Abraham, A., & Ventura, S. (2024). Handling imbalanced medical datasets: Review of a decade of research. *Artificial Intelligence Review*, 57, 273. <https://doi.org/10.1007/s10462-024-10884-2>
- Septipalan, M. L., Hibritzi, M. S., Latifah, N., Lina, R., & Bimantoro, F. (2024). Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50. *Seminar Nasional Teknologi & Sains*, 3(1), 103–108. <https://doi.org/10.29407/stains.v3i1.4357>

- Sianturi, A. G. M. (2021). Stadium, Diagnosis, dan Tatalaksana Penyakit Alzheimer. *Majalah Kesehatan Indonesia*, 2(2), 39–44. <https://doi.org/10.47679/makein.202132>
- Sutrisna, N. P., Muflikhah, L., & Setiawan, B. D. (2025). *Klasifikasi Penyakit Alzheimer Pada Citra MRI Menggunakan Pretrained VGG-19 dan Pengolahan Citra CLAHE*. 9(4), 1–10.
- Wang, S., Dai, Y., Shen, J., & Xuan, J. (2021). Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Scientific Reports*, 11(1), 1–11. <https://doi.org/10.1038/s41598-021-03430-5>
- Wardani, K. R., & Leonardi, L. (2023). Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network. *Jurnal Tekno Insentif*, 17(2), 112–126. <https://doi.org/10.36787/jti.v17i2.1130>
- Wijaya Kusuma, I. W. A., & Kusumadewi, A. (2020). Penerapan Metode Contrast Stretching, Histogram Equalization Dan Adaptive Histogram Equalization Untuk Meningkatkan Kualitas Citra Medis Mri. *Simetris: Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer*, 11(1), 1–10. <https://doi.org/10.24176/simet.v11i1.3153>
- Wirya, M. A. (2023). Deteksi Penyakit Alzheimer Pada Citra Magnetic Resonance Imaging Menggunakan Machine Learning Dengan Metode Convolutional Neural Network. *Repository.Uinjkt.Ac.Id*. <https://repository.uinjkt.ac.id/dspace/handle/123456789/73962%0Ahttps://repository.uinjkt.ac.id/dspace/bitstream/123456789/73962/1/MUHAMMAD ADI WIRYA-FST.pdf>
- Yagis, E., Atnafu, S. W., García Seco de Herrera, A., Marzi, C., Scheda, R., Giannelli, M., Tessa, C., Citi, L., & Diciotti, S. (2021). Effect of data leakage in brain MRI classification using 2D convolutional neural networks. *Scientific Reports*, 11, 22544. <https://doi.org/10.1038/s41598-021-01681-w>
- Yamanakkanavar, N., Choi, J. Y., & Lee, B. (2020). MRI segmentation and classification of human brain using deep learning for diagnosis of alzheimer's disease: A survey. *Sensors (Switzerland)*, 20(11), 1–31. <https://doi.org/10.3390/s20113243>
- Young, V. M., Gates, S., Garcia, L. Y., & Salardini, A. (2025). Data leakage in deep learning for Alzheimer's disease diagnosis: A scoping review of methodological rigor and performance inflation. *Diagnostics*, 15(18), 2348. <https://doi.org/10.3390/diagnostics15182348>