



Academia Open



By Universitas Muhammadiyah Sidoarjo

Table Of Contents

Journal Cover	1
Author[s] Statement	3
Editorial Team	4
Article information	5
Check this article update (crossmark)	5
Check this article impact.....	5
Cite this article.....	5
Title page	6
Article Title.....	6
Author information	6
Abstract	6
Article content	6

Originality Statement

The author[s] declare that this article is their own work and to the best of their knowledge it contains no materials previously published or written by another person, or substantial proportions of material which have been accepted for the published of any other published materials, except where due acknowledgement is made in the article. Any contribution made to the research by others, with whom author[s] have work, is explicitly acknowledged in the article.

Conflict of Interest Statement

The author[s] declare that this article was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Copyright Statement

Copyright © Author(s). This article is published under the Creative Commons Attribution (CC BY 4.0) licence. Anyone may reproduce, distribute, translate and create derivative works of this article (for both commercial and non-commercial purposes), subject to full attribution to the original publication and authors. The full terms of this licence may be seen at <http://creativecommons.org/licences/by/4.0/legalcode>

EDITORIAL TEAM

Editor in Chief

Mochammad Tanzil Multazam, Universitas Muhammadiyah Sidoarjo, Indonesia

Managing Editor

Bobur Sobirov, Samarkand Institute of Economics and Service, Uzbekistan

Editors

Fika Megawati, Universitas Muhammadiyah Sidoarjo, Indonesia

Mahardika Darmawan Kusuma Wardana, Universitas Muhammadiyah Sidoarjo, Indonesia

Wiwit Wahyu Wijayanti, Universitas Muhammadiyah Sidoarjo, Indonesia

Farkhod Abdurakhmonov, Silk Road International Tourism University, Uzbekistan

Dr. Hindarto, Universitas Muhammadiyah Sidoarjo, Indonesia

Evi Rinata, Universitas Muhammadiyah Sidoarjo, Indonesia

M Faisal Amir, Universitas Muhammadiyah Sidoarjo, Indonesia

Dr. Hana Catur Wahyuni, Universitas Muhammadiyah Sidoarjo, Indonesia

Complete list of editorial team ([link](#))

Complete list of indexing services for this journal ([link](#))


How to submit to this journal ([link](#))

Article information

Check this article update (crossmark)



Check this article impact (*)



Save this article to Mendeley



(*) Time for indexing process is various, depends on indexing database platform

Convolutional Neural Network Achieves 97.67 Percent Accuracy for Alzheimer MRI Classification: Convolutional Neural Network Mencapai Akurasi 97,67 Persen untuk Klasifikasi MRI Alzheimer

Ichwan Puja Pangestu, ichwan.2709@gmail.com, (1)

Program Studi Teknik Informatika, Universitas Esa Unggul Jakarta, Indonesia

Vitri Tundjungsari, vitri.tundjungsari@esaunggul.ac.id, (2)

Program Studi Teknik Informatika, Universitas Esa Unggul Jakarta, Indonesia

⁽¹⁾ Corresponding author

Abstract

General Background: Alzheimer's disease (AD) is a progressive neurodegenerative disorder requiring accurate and accessible diagnostic support. **Specific Background:** Magnetic Resonance Imaging (MRI) is widely used for structural brain assessment, and Convolutional Neural Networks (CNN) enable automated feature extraction from medical images. **Knowledge Gap:** Prior studies report high classification performance but rarely integrate comprehensive evaluation with real-time deployment for decision support. **Aims:** This study develops and evaluates a CNN-based model for classifying 2D axial MRI images into Alzheimer's Disease (AD), Mild Cognitive Impairment (MCI), and Common Normal (CN), alongside web-based implementation. **Results:** Using approximately 5,000 ADNI MRI images, the model achieved 97.67% accuracy, 97.73% precision, 97.67% recall, and 97.65% F1-score, with AUC values near 1.00. Learning curves indicated stable convergence without overfitting or underfitting, and confusion matrix analysis confirmed consistent multi-class discrimination. The deployed Hugging Face-Gradio application generated predictions in under five seconds per scan without performance degradation. **Novelty:** This research combines rigorous multi-metric validation with interactive web deployment as an artificial intelligence decision support system for early AD screening. **Implications:** The findings demonstrate the technical feasibility of CNN-based MRI classification for preliminary cognitive disorder screening, while emphasizing the need for multimodal integration and prospective clinical validation.

Highlights:

- Achieved robust multi-class discrimination among AD, MCI, and CN categories using axial brain scans.
- Demonstrated stable training dynamics validated through loss convergence and receiver operating characteristics.
- Implemented an interactive artificial intelligence platform with sub-five-second prediction time.

Keywords: Alzheimers Disease; Convolutional Neural Networks; MRI Classification; Deep Learning; Clinical Decision Support System

Published date: 2026-02-17

Pendahuluan

Alzheimer's disease (AD), penyebab utama demensia yang mempengaruhi sekitar 50 juta orang secara global, diproyeksikan meningkat empat kali lipat pada tahun 2050, melampaui 152 juta kasus [1], [2]. Sebagai gangguan neurodegenerative yang progresif, AD menyumbang 60-80% dari kasus demensia, yang ditandai dengan penurunan memori dan kognitif yang tidak dapat dipulihkan (irreversible) [1]. Faktor risiko utama meliputi usia lanjut, tingkat pendidikan rendah, jenis kelamin perempuan, ketidakaktifan fisik, hipertensi, diabetes, riwayat stroke, dan faktor gaya hidup yang dapat dimodifikasi seperti depresi dan isolasi sosial [3]. Di Indonesia, prevalensi Alzheimer's disease sangat tinggi (20,1% dari populasi lansia). Negara ini juga memiliki rasio lansia tertinggi di Asia Tenggara, yang diproyeksikan mencapai 34,4 juta pada tahun 2050, yang mengindikasikan peningkatan kasus Alzheimer di masa depan [3]. Pada tahun 2013, sekitar 1 juta individu didiagnosis dengan Alzheimer's disease dengan perkiraan prediksi peningkatan dua kali lipat pada tahun 2030 dan peningkatan empat kali lipat menjadi 4 juta pada tahun 2050 [4]. Pada tahun 2024, biaya ekonomi perawatan Alzheimer diperkirakan mencapai Rp. 139.438 miliar ($\approx$ \$454 per kapita), mencerminkan beban signifikansi pada keluarga dan sistem perawatan kesehatan karena sifat kronis penyakit ini, yang memerlukan perawatan jangka panjang [5].

Magnetic Resonance Imaging (MRI) tetap menjadi gold standard untuk deteksi AD, mengidentifikasi atrofi otak yang terkait dengan defisit kognitif dan patologi tau [1]. Kemajuan dalam machine learning, khususnya deep learning, memungkinkan analisis otomatis data pencitraan medis berdimensi tinggi tanpa ekstraksi fitur manual. Convolutional Neural Networks (CNN) unggul dalam mengekstraksi fitur diskriminatif dari pemindaian MRI, menawarkan efisiensi superior dalam mendeteksi pola AD tertentu dibandingkan dengan metode tradisional [2]. Studi sebelumnya seperti Fu'adah et al. [6] menunjukkan akurasi 95% menggunakan CNN berbasis AlexNet untuk klasifikasi AD, namun akurasi yang lebih tinggi tetap penting untuk prediksi klinis. Studi lain oleh Davuluri dan Rengaswamy [2] melaporkan akurasi 97,8% untuk deteksi AD menggunakan deep learning. Meskipun akurasinya tinggi, studi mereka tidak menyertakan analisis mendalam tentang potensi overfitting, diskusi tentang ketahanan model (robustness), atau strategi deployment yang jelas.

Studi ini bertujuan untuk mengembangkan sistem berbasis Convolutional Neural Network (CNN) untuk mencapai akurasi $>95\%$ dan meningkatkan deteksi Alzheimer's Disease (AD) pada MRI. Dengan mengoptimalkan kinerja model melalui arsitektur mutakhir dan teknik preprocessing, penelitian ini juga memastikan bahwa model memenuhi kriteria good fit dan mempertimbangkan aspek deployment praktis.

Metode

Studi eksperimental ini mengadopsi pendekatan eksperimental kuantitatif untuk mengembangkan model machine learning berbasis convolutional neural network (CNN) untuk mendeteksi biomarkers Alzheimer's disease (AD) dalam pemindaian MRI otak. Alur kerja mengikuti lima tahap berurutan:

1. Persiapan Dataset

Model dilatih menggunakan pemindaian MRI aksial 2D dari dataset Alzheimer's Disease Neuroimaging Initiative (ADNI) [7]. The data used in the preparation of this article was obtained from the Alzheimer's Disease Data yang digunakan dalam penyusunan artikel ini diperoleh dari database Alzheimer's Disease Neuroimaging Initiative (ADNI) (adni.loni.usc.edu). Dataset terdiri dari ~5.000 gambar PNG yang dikategorikan ke dalam tiga kelas diagnostik: Alzheimer's Disease (AD), bentuk paling umum dari dimensia neurodegenerative, ditandai dengan penurunan kognitif progresif, kerusakan saraf dan akumulasi protein abnormal (beta amyloid plaques dan tau angles), terutama menyerang lansia [8]. Mild Cognitive Impairment (MCI), tahap transisi antara penuaan normal dan demensia, melibatkan gejala awal seperti penyimpangan memori dan gangguan pengambilan Keputusan, meskipun individu tetap mandiri secara fungsional [9]. Common Normal (CN), kelas kontrol sehat tanpa gangguan kognitif yang terdeteksi.


2. Data Preprocessing

Fase penelitian awal melibatkan data preprocessing. Gambar MRI mengalami transformasi dan resizing untuk mencapai dimensi seragam (128×128 piksel) yang kompatibel dengan persyaratan arsitektur model CNN [10]. Label kelas (CN, AD, MCI) dikonversi menjadi vektor one-hot encoded menggunakan teknik OneHotEncoder, yang mengubah label kategorikal (0, 1, 2) menjadi representasi biner tiga dimensi. Selanjutnya, dataset dipartisi menjadi subset training (80%) dan testing (20%) untuk memfasilitasi pelatihan dan evaluasi model.

3. Implementasi CNN

Deep Convolutional Neural Network (CNN) diimplementasikan untuk mengekstraksi fitur spasial diskriminatif secara otonom (misalnya, atrofi kortikal, penyusutan hipokampus) dari data MRI mentah [1], [6]. Arsitektur ini menggunakan layer hierarkis untuk mempelajari pola kompleks tanpa rekayasa fitur manual, sejalan dengan kemajuannya dalam analisis pencitraan medis [11], [12]. Struktur Arsitektur Model yang digunakan dalam studi ini diuraikan dalam Gambar 1 di bawah ini:

Gambar 1. Struktur Arsitektur Model




Arsitektur Convolutional Neural Network (CNN) yang diimplementasikan dalam studi ini dirancang secara hierarkis untuk ekstraksi fitur dan klasifikasi gambar. Model menerima input gambar berukuran 128×128 piksel dengan 3 saluran warna (RGB). Tahap awal terdiri dari dua blok konvolusional. Blok pertama menggunakan dua convolutional layers dengan 32 filter (3×3) yang mempertahankan resolusi spasial 128×128 diikuti oleh operasi max pooling (2×2) untuk mengurangi dimensi menjadi 64×64 . Blok kedua dimulai dengan 25% dropout sebagai mekanisme regularisasi, diikuti oleh dua convolution layers dengan 64 filter (3×3) yang mempertahankan resolusi 64×64 , kemudian pooling lebih lanjut mengurangi dimensi menjadi 32×32 , dan 25% dropout diterapkan kembali. Selanjutnya, layer Flatten mengubah fitur spasial 3D ($32 \times 32 \times 64$) menjadi vektor 1D sebesar 65.536 neuron. Selama tahap klasifikasi, vektor fitur diproses melalui layer yang terhubung sepenuhnya (Dense) untuk konsolidasi pola, diikuti oleh 50% dropout untuk meningkatkan generalisasi, dan akhirnya layer Softmax yang menghasilkan probabilitas kelas.

4. Evaluasi Model

Kinerja model dievaluasi menggunakan tiga pendekatan. Yang pertama adalah learning curves, yang memainkan peran penting dalam mengevaluasi kalibrasi probabilitas prediksi terhadap label ground-truth. Indikator kinerja utama adalah nilai loss, di mana nilai yang lebih rendah berkorelasi dengan peningkatan ketahanan model (robustness) [13].

Gambar 2. Contoh learning curves: (a) kondisi normal; (b) underfitting; (c) overfitting [14]



Selain itu, alat ini mendiagnosis masalah kritis seperti: Overfitting: Terjadi ketika model menghafal noise data pelatihan, yang mengakibatkan divergensi antara training loss dan validation loss (misalnya, validation loss meningkat setelah mencapai minimum). Underfitting: Terjadi ketika model terlalu sederhana dan gagal menangkap kompleksitas data, yang mengakibatkan kesalahan pelatihan dan validasi yang tinggi.

Yang kedua adalah confusion matrix, yang merupakan alat tabular yang membandingkan label kelas yang diprediksi dengan label ground-truth aktual, memberikan rincian prediksi yang benar dan salah [15].

Gambar 3. Contoh confusion matrix. (a) Confusion matrix untuk masalah klasifikasi biner.

		Predicted Class	
		Positive	Negative
Actual Class	Positive	TP	FN
	Negative	FP	TN

(a)

		Predicted Class			
		C ₁	C ₂	...	C _N
Actual Class	C ₁	C _{1,1}	FP	...	C _{1,N}
	C ₂	FN	TP	...	FN
	...	...	...	...	...
	C _N	C _{N,1}	FP	...	C _{N,N}

(b)

(b) Confusion matrix untuk masalah klasifikasi multi-kelas [15]

Dari komponen (1)-(4) di bawah ini, metrik kinerja kritis diturunkan untuk menilai efektivitas model [16], [17]:

- Accuracy: Kebenaran prediksi secara keseluruhan:

$$Accuracy = \frac{(TP+TN)}{(TP+FP+TN+FN)} \quad (1)$$

- Precision: Kemampuan untuk meminimalkan false positives:

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

- Recall: Kemampuan untuk menangkap true positives dan menghindari false negatives:

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

- F1-Score: Ukuran seimbang dari precision dan recall:

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

Di sini TP (True Positives) dan TN (True Negatives) menunjukkan prediksi yang benar, sementara FP (False Positives) dan FN (False Negatives) mewakili kesalahan klasifikasi. Metrik-metrik ini secara kolektif mengevaluasi sejauh mana model mengklasifikasikan data dengan benar, menyeimbangkan akurasi dan penhindaran kesalahan. Yang ketiga adalah kurva Receiver Operating Characteristic (ROC), yang merupakan representasi grafis dari trade off antara sensitivitas (true, positive rate) dan spesifisitas (false positive rate) pada temuan ambang batas risiko yang mungkin dalam model prediktif.

Lebih dari sekadar alat diagnostik, kurva ROC berfungsi sebagai visualisasi alternatif dari distribusi risiko yang mendasari untuk individu yang sakit dan tidak sakit. Bentuk kurva (bulat, menyudut, atau bertahap) mengungkapkan informasi penting tentang tumpang tindih antara distribusi ini, di mana pemisahan yang lebih besar menunjukkan kemampuan diskriminatif yang lebih baik [18].

5. Model Deployment

Tahap akhir adalah model deployment. Model Convolutional Neural Network (CNN) yang telah dikembangkan kemudian di-deploy ke dalam aplikasi web interaktif. Deployment dilakukan menggunakan platform Hugging Face dan pustaka Gradio untuk memungkinkan pengguna mengunggah gambar MRI aksial 2D dan mendapatkan prediksi klasifikasi untuk Alzheimer's Disease (AD), Mild Cognitive Impairment (MCI), atau Common Normal (CN) [19].


Hasil dan Pembahasan

Arsitektur CNN yang diusulkan dievaluasi secara ketat melintasi dinamika pelatihan, kinerja klasifikasi, dan kelayakan deployment klinis. Metrik komprehensif - termasuk learning curves, confusion matrices, dan analisis ROC - menunjukkan kemampuan diagnostik model untuk kasus Alzheimer's Disease (AD), Mild Cognitive Impairment (MCI), dan Cognitively Normal (CN). Semua hasil divalidasi terhadap test set yang dipisahkan (20% dari data ADNI), dengan kelayakan deployment dinilai melalui aplikasi web real-time. Temuan kritis diatur sebagai berikut:

A. Hasil Learning Curve

Model CNN menunjukkan kemampuan belajar yang kuat selama pelatihan, sebagaimana dibuktikan oleh metrik learning curve (loss dan accuracy) yang dilacak selama 10 epochs.


Gambar 4. Grafik Loss



Seperti yang ditunjukkan pada Gambar 4, training loss menurun secara signifikan dari nilai awal 4,0 menjadi sekitar 0,3 pada epoch 10, sementara validation loss secara konsisten konvergen ke 0,1. Pola

penurunan paralel, di mana training loss dan validation loss menjadi stabil dalam rentang nilai yang sama, menunjukkan pembelajaran yang efektif tanpa overfitting [14].

Gambar 5. *Grafik Accuracy*




Pada saat yang sama, grafik akurasi pada Gambar 5 menunjukkan peningkatan kinerja yang substansial: Training accuracy meningkat dari 60% (epoch 1) menjadi >90% (epoch 10), sementara validation accuracy melebihi 95%. Ini membuktikan kemampuan model untuk menggeneralisasi dengan baik pada data yang belum pernah dilihat (unseen data).

B. Hasil Confusion Matrix

Evaluasi lebih lanjut melalui confusion matrix pada test set mengukur kinerja per kelas untuk tiga kategori: Common Normal (CN), Alzheimer’s Disease (AD), dan Mild Cognitive Impairment (MCI).

Gambar 6. *Confusion mMtrix*



Kinerja di seluruh kelas diagnostik diukur melalui analisis confusion matrix seperti yang ditunjukkan pada Gambar 6.

Tabel 1. *Rincian Confusion Matrix Berdasarkan Kelas Diagnostik*

Kelas	Benar	Kesalahan	Analisis Kesalahan
CN	222	1 → MCI	False positives minimal
AD	156	4 → CN, 10 → MCI	Risiko kritis: Diagnosis kurang (Underdiagnosis)
MCI	378	3 → CN	Salah klasifikasi yang aman

Metrik Utama:


- Accuracy: 97.67%
- Precision: 97.73% (FP rate = 2.27%)
- Recall: 97.67% (FN rate = 2.33%)
- F1-Score: 97.65%

Accuracy menunjukkan bahwa 97,67% dari seluruh sampel uji diprediksi dengan benar. Nilai ini mencerminkan konsistensi model dalam mengidentifikasi ketiga kelas. Precision berarti bahwa hanya 2,27% dari prediksi positif adalah false positives. Sebagai contoh, ketika model memprediksi “AD,” probabilitas kebenarannya adalah 97,73%. Precision yang tinggi membuktikan bahwa model memiliki diagnosis berlebih (overdiagnosis) yang minimal (jarang mengklasifikasikan sehat sebagai sakit). Recall menunjukkan bahwa model berhasil mendeteksi 97,67% kasus yang seharusnya positif. Dari semua sampel AD aktual, 97,67% berhasil diidentifikasi (hanya 2,33% false negatives). Recall tinggi berarti model jarang melewatkan kasus penyakit. F1-Score adalah rata-rata harmonik dari precision dan recall. Nilai yang mendekati 98% menegaskan keseimbangan optimal antara akurasi positif (precision) dan cakupan deteksi (recall).

C. Hasil ROC

Selanjutnya, evaluasi berdasarkan grafik ROC.

Gambar 7. Grafik ROC



Gambar 7 menunjukkan kurva ROC (Receiver Operating Characteristic) untuk tiga kelas klasifikasi:

- Biru: CN (Common Normal)

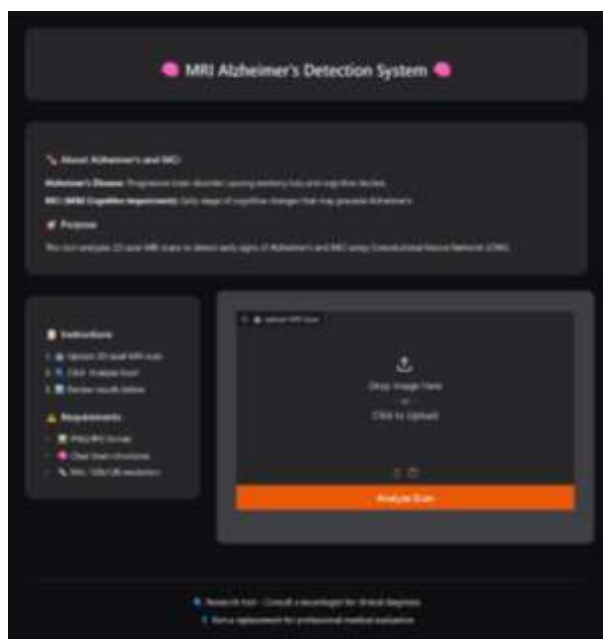
- Merah: AD (Alzheimer's)
- Hijau: MCI (Mild Cognitive Impairment)

Evaluasi ROC menunjukkan kinerja model yang luar biasa dalam membedakan antara tiga kelas: CN (Common Normal, AUC = 0,9991), AD (Alzheimer's, AUC = 0,9995), dan MCI (AUC = 0,9990). Ketiga kurva ROC mendekati sudut kiri atas (titik ideal di mana TPR = 1, FPR = 0), dengan AUC $\approx 1,00$ yang menunjukkan pemisahan sempurna antara sampel positif dan negatif. Sensitivitas tinggi (TPR >0,8) dan kesalahan minimal (FPR <0,2) menunjukkan bahwa model jarang gagal mendeteksi kasus positif (false negatives) atau menghasilkan alarm palsu (false positives). Konsistensi kurva AD dan CN di area AUC tertinggi menegaskan keandalan klasifikasi. Hasil ini mengonfirmasi keandalan model untuk aplikasi diagnostik berpresisi tinggi.

D. Model Deployment

Model CNN yang dikembangkan berhasil di-deploy sebagai aplikasi web interaktif menggunakan Hugging Face Spaces dan pustaka Gradio. Implementasi ini memungkinkan klasifikasi real-time penyakit Alzheimer dari unggahan pemindaian MRI aksial 2D, menghasilkan prediksi untuk tiga kategori diagnostik: Alzheimer's Disease (AD), Mild Cognitive Impairment (MCI), dan Common Normal (CN).

Gambar 8. Beranda (Homepage)



Antarmuka intuitif (Gambar 8) menampilkan empat komponen inti: (1) panel unggah gambar dengan operasi drag-and-drop, click-to-upload, dan clipboard; (2) tombol pemicu prediksi “Analyze Scan”; (3) tampilan hasil yang menunjukkan kelas yang diprediksi dan probabilitas kepercayaan (confidence probabilities); dan (4) penafian (disclaimer) yang menonjol tentang sifat alat ini yang berbasis penelitian. Integrasi teknis dicapai melalui backend script Phyton yang memuat arsitektur model dan bobot yang telah dilatih sebelumnya (pre-trained weights). Ketika sebuah gambar dikirimkan, system melakukan tiga Langkah preprocessing: konversi ke NumPy array, resizing menjadi 128x128 piksel, dan normalisasi nilai piksel. Alur kerja (pipeline) yang efisien ini memberikan prediksi di bawah 5 detik pergambar sambil mempertahankan akurasi 97% sesuai dengan hasil validasi offline. Meskipun metrik kinerjanya kuat, validasi klinis masih diperlukan sebelum implementasi diagnostic dunia nyata.


Putput pasca klasifikasi ditunjukkan pada gambar 9, output pasca klasifikasi memvisualisasikan probabilitaskepercayaan yang ditetapkan untuk tig akelas teratas yang diprediksi. Probabilitas ini diurutkan secara menurun (dari tertinggi ke terendah), menyoroti kepastian relative model diseluruh kelas dominan. Representasi hierarkis ini memungkinkan interpretasi yang jelas tentang keandalan klasifikasi, di mana kelas peringkat pertama menunjukkan prediksi utama, diikuti oleh alternatif sekunder.

Analisis kesalahan (error analysis) ditunjukkan pada Gambar 10. Sistem menggabungkan protokol validasi input di mana gambar non-MRI atau data yang gagal memenuhi kriteria yang telah ditentukan memicu hasil error. Ini melindungi dari klasifikasi yang tidak valid dengan mencegat input yang tidak kompatibel sebelum pemrosesan model, memastikan hanya data pencitraan medis yang memenuhi syarat yang menjalani analisis.

Gambar 9. Halaman pasca-klasifikasi



Gambar 10. Hasil klasifikasi error



Implementasi model CNN dalam bentuk aplikasi web real-time memberikan nilai tambah yang signifikan terhadap penelitian ini, karena menjembatani capaian teknis dengan potensi penerapan di dunia nyata. Integrasi model ke dalam sistem berbasis Hugging Face dan Gradio menunjukkan bahwa pendekatan yang diusulkan tidak hanya unggul secara teoretis, tetapi juga layak secara operasional untuk mendukung sistem pendukung keputusan klinis.

Meskipun demikian, implementasi ini masih memiliki keterbatasan, khususnya belum dilakukannya validasi klinis lanjutan dan uji coba pada lingkungan medis nyata, sehingga hasil prediksi model belum dapat digunakan sebagai dasar diagnosis klinis tanpa pendampingan tenaga medis profesional. Selain itu, penerapan model di lingkungan klinis nyata juga menghadapi tantangan implementasi yang perlu diperhatikan secara eksplisit, seperti kebutuhan validasi lintas institusi (cross institutional validation) untuk memastikan konsistensi kinerja model pada variasi protocol akusisi MRI, perbedaan perangkat pencitraan, serta karakteristik populasi pasien yang lebih beragam. Aspek etika penggunaan kecerdasan buatan dalam bidang medis turut menjadi perhatian penting, terutama terkait potensi bias algoritmik, transparansi pengambilan Keputusan model, perlindungan data pasien, serta penegasan bahwa system ini berfungsi sebagai alat pendukung Keputusan klinis dan bukan pengganti peran tenaga medis profesional. Dengan mempertimbangkan aspek-aspek tersebut, penelitian ini tidak hanya menunjukkan kelayakan teknis model CNN, tetapi juga memberikan landasan konseptual bagi pengembangan system kelayakan teknis model CNN, tetapi juga memberikan landasan konseptual bagi pengembangan system diagnostic berbasis AI yang lebih bertanggung jawab dan siap diadaptasi pada praktik klinis di masa depan.

Simpulan

Studi ini menunjukkan keberhasilan pengembangan model Convolutional Neural Network (CNN) untuk deteksi Alzheimer melalui gambar MRI, yang menunjukkan efektivitas dalam mengidentifikasi tiga kondisi neurologis: Common Normal (CN), Alzheimer's Disease (AD), dan Mild Cognitive Impairment

(MCI). Evaluasi kinerja mengonfirmasi akurasi tinggi (97,67%) dengan precision (97,73%), recall (97,67%), dan F1-score (97,65%), didukung oleh learning curve yang menunjukkan model bebas dari overfitting/underfitting. Nilai AUC $\approx 1,00$ menunjukkan kemampuan pemisahan sampel yang sempurna. Deployment melalui Hugging Face dan Gradio menghasilkan aplikasi web fungsional dengan waktu respons <5 detik per prediksi sambil mempertahankan akurasi model.

Implikasi dari penelitian ini menunjukkan bahwa model CNN yang dikembangkan berpotensi menjadi system pendukung Keputusan berbasis kecerdasan buatan dalam membantu proses skrining awal gangguan kognitif, khususnya Alzheimer, pada tahap pra klinis. Sebagai pengembangan lanjutan, penelitian selanjutnya disarankan untuk melakukan validasi klinis menggunakan data multisenter, mengintegrasikan citra MRI multimodal, serta mengombinasikan data klinis dan demografis guna meningkatkan robustitas, generalisasi, dan relevansi model dalam konteks praktik medis nyata.

Ucapan Terimakasih

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan, bimbingan, serta fasilitas dalam pelaksanaan dan penyusunan artikel ini. Semoga artikel ini dapat memberikan kontribusi bagi pengembangan ilmu pengetahuan, khususnya dalam penerapan Convolutional Neural Network (CNN) untuk prediksi penyakit Alzheimer.

Referensi

- [1] H. Chen, "Alzheimer's Disease Classification Using Brain MRI Based on Combination of Convolutional Neural Network and Random Forest Model," *Highlights Sci. Eng. Technol.*, vol. 14, pp. 203–212, Sept. 2022, doi: 10.54097/hset.v14i.1694.
- [2] R. Davuluri and R. Rengaswamy, "Improved Classification Model using CNN for Detection of Alzheimer's Disease," *J. Comput. Sci.*, vol. 18, no. 5, pp. 415–425, May 2022, doi: 10.3844/jcssp.2022.415.425.
- [3] N. W. Suriastini et al., "Community health centers response to the need of dementia care," *J. Public Health Res.*, vol. 12, no. 1, p. 227990362311619, Jan. 2023, doi: 10.1177/22799036231161972.
- [4] N. Nurbaiti, S. G. Sutoro, E. Supriyaningsih, S. W. Wiyanti, and I. Maesaroh, "Edukasi untuk Deteksi Dini dan Perawatan Lansia dengan Alzheimer di Masa Pandemi Covid-19," *J. Kreat. Pengabd. Kpd. Masy. PKM*, vol. 6, no. 7, pp. 2887–2895, June 2023, doi: 10.33024/jkpm.v6i7.10093.
- [5] S. Chen et al., "The global macroeconomic burden of Alzheimer's disease and other dementias: estimates and projections for 152 countries or territories," *Lancet Glob. Health*, vol. 12, no. 9, pp. e1534–e1543, Sept. 2024, doi: 10.1016/S2214-109X(24)00264-X.
- [6] Y. N. Fu'adah, I. Wijayanto, N. K. C. Pratiwi, F. F. Taliningsih, S. Rizal, and M. A. Pramudito, "Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture," *J. Phys. Conf. Ser.*, vol. 1844, no. 1, p. 012020, Mar. 2021, doi: 10.1088/1742-6596/1844/1/012020.

- [7] ADNI, "Alzheimer's Disease Neuroimaging Initiative." 2021. [Online]. Available: <https://adni.loni.usc.edu/>
- [8] Siddharta Dan et al., "Therapeutic and Diagnostic Applications of Nanocomposites in the Treatment Alzheimer's Disease Studies," *Biointerface Res. Appl. Chem.*, vol. 12, no. 1, pp. 940–960, Apr. 2021, doi: 10.33263/BRIAC121.940960.
- [9] V. García-Morales et al., "Current Understanding of the Physiopathology, Diagnosis and Therapeutic Approach to Alzheimer's Disease," *Biomedicines*, vol. 9, no. 12, p. 1910, Dec. 2021, doi: 10.3390/biomedicines9121910.
- [10] D. Y. R. Al Khayari and H. Abdallah Nasser Al Shamsi, "Optimizing MRI Preprocessing Techniques for Enhanced Alzheimer's Disease Detection," *Int. J. Emerg. Multidiscip. Comput. Sci. Artif. Intell.*, vol. 3, no. 1, May 2024, doi: 10.54938/ijemdcasai.2024.03.1.289.
- [11] L. Alzubaidi et al., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [12] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Computation*, vol. 11, no. 3, p. 52, Mar. 2023, doi: 10.3390/computation11030052.
- [13] A. W. Fazil, M. Hakimi, R. Akbari, M. M. Quchi, and K. Q. Khaliqyar, "Comparative Analysis of Machine Learning Models for Data Classification: An In-Depth Exploration," *J. Comput. Sci. Technol. Stud.*, vol. 5, no. 4, pp. 160–168, Dec. 2023, doi: 10.32996/jcsts.2023.5.4.16.
- [14] R. Barinov, V. Gai, G. Kuznetsov, and V. Golubenkov, "Automatic Evaluation of Neural Network Training Results," *Computers*, vol. 12, no. 2, p. 26, Jan. 2023, doi: 10.3390/computers12020026.
- [15] I. Markoulidakis, I. Rallis, I. Georgoulas, G. Kopsiaftis, A. Doulamis, and N. Doulamis, "Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem," *Technologies*, vol. 9, no. 4, p. 81, Nov. 2021, doi: 10.3390/technologies9040081.
- [16] A. Arafa, M. Radad, M. Badawy, and N. El-Fishawy, "Logistic Regression Hyperparameter Optimization for Cancer Classification," *Menoufia J. Electron. Eng. Res.*, vol. 0, no. 0, pp. 0–0, Jan. 2022, doi: 10.21608/mjeer.2021.70512.1034.
- [17] P. Rani, R. Lamba, R. K. Sachdeva, K. Kumar, and C. Iwendi, "A machine learning model for Alzheimer's disease prediction," *IET Cyber-Phys. Syst. Theory Appl.*, vol. 9, no. 2, pp. 125–134, June 2024, doi: 10.1049/cps2.12090.
- [18] A. C. J. W. Janssens and F. K. Martens, "Reflection on modern methods: Revisiting the area under the ROC Curve," *Int. J. Epidemiol.*, vol. 49, no. 4, pp. 1397–1403, Aug. 2020, doi: 10.1093/ije/dydz274.
- [19] V. Tundjungsari, *Dasar Machine Learning*, Edisi Revisi. Yogyakarta: Deepublish, 2024.