



## Komparasi Algoritma Machine Learning (*Random Forest, Gradient Boosting*, dan Ada Boosting) untuk Prediksi Tingkat Penyakit Alzheimer

**Muhammad Raviansyah<sup>1\*</sup>, Andika Amansyah<sup>2</sup>, Farhan Fadhilah<sup>3</sup>, Sumanto<sup>4</sup>, Imam Budiawan<sup>5</sup>, Roida Pakpahan<sup>6</sup>**

<sup>1-6</sup>Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Indonesia

\*Penulis korespondensi: [muhamadravir1@gmail.com](mailto:muhamadravir1@gmail.com)

**Abstract.** *Alzheimer's disease is one of the most common forms of progressive dementia and has become a major global health challenge as the aging population continues to increase. Early detection of this disease is crucial to mitigate its social, economic, and health impacts. In this context, data-driven approaches using machine learning algorithms can be utilized to predict Alzheimer's risk more accurately. This study aims to compare the performance of three ensemble learning algorithms—Gradient Boosting, Random Forest, and AdaBoost—in predicting the risk level of Alzheimer's disease using the public Alzheimer's Disease Dataset, which includes demographic, clinical, and lifestyle data. The research process involved several stages, including data preprocessing, splitting data into training and testing sets, model training using cross-validation, and performance evaluation based on accuracy, precision, recall, F1-score, and AUC metrics. The experimental results show that the Gradient Boosting algorithm achieved the best performance with an accuracy of 0.956, an F1-score of 0.956, and an AUC of 0.985, demonstrating its ability to capture complex non-linear relationships among features such as age, MMSE score, and lifestyle factors. Meanwhile, Random Forest and AdaBoost achieved competitive yet slightly lower performance. These findings indicate that ensemble boosting approaches, particularly Gradient Boosting, hold great potential for medical decision-support systems in the early detection of Alzheimer's disease and can serve as a foundation for developing more accurate and adaptive predictive models in the future.*

**Keywords:** *Alzheimer; Boosting; Komparasi; Machine Learnin; Random Forest.*

**Abstrak.** Penyakit Alzheimer merupakan salah satu bentuk demensia progresif yang paling umum dan telah menjadi tantangan besar bagi kesehatan global seiring dengan meningkatnya populasi lanjut usia. Deteksi dini penyakit ini sangat penting untuk mengurangi dampak sosial, ekonomi, dan kesehatan yang ditimbulkan. Dalam konteks ini, pendekatan berbasis data dengan menggunakan algoritma machine learning dapat dimanfaatkan untuk memprediksi risiko Alzheimer dengan lebih akurat. Penelitian ini bertujuan untuk membandingkan kinerja tiga algoritma ensemble learning—Gradient Boosting, Random Forest, dan AdaBoost—dalam memprediksi tingkat risiko penyakit Alzheimer dengan menggunakan Alzheimer's Disease Dataset publik, yang mencakup data demografis, klinis, dan gaya hidup. Proses penelitian melibatkan beberapa tahapan, termasuk pra-pemrosesan data, pembagian data menjadi data latih dan data uji, pelatihan model menggunakan cross-validation, serta evaluasi kinerja berdasarkan metrik akurasi, presisi, recall, F1-score, dan AUC. Hasil eksperimen menunjukkan bahwa algoritma Gradient Boosting mencapai kinerja terbaik dengan akurasi 0,956, F1-score 0,956, dan AUC 0,985, yang menunjukkan kemampuannya dalam menangkap hubungan non-linear yang kompleks antar fitur seperti usia, skor MMSE, dan faktor gaya hidup. Sementara itu, Random Forest dan AdaBoost mencapai performa yang kompetitif namun sedikit lebih rendah. Temuan ini menunjukkan bahwa pendekatan ensemble boosting, khususnya Gradient Boosting, memiliki potensi besar untuk sistem pendukung keputusan medis dalam deteksi dini penyakit Alzheimer dan dapat menjadi dasar untuk pengembangan model prediksi yang lebih akurat dan adaptif di masa mendatang.

**Kata kunci:** *Alzheimer; Meningkatkan; Komparasi; Pembelajaran Mesin; Hutan Acak.*

### 1. LATAR BELAKANG

Penurunan kognitif, gangguan memori, serta perubahan perilaku adalah tanda penyakit Alzheimer, yang merupakan jenis demensia progresif paling umum. Organisasi Kesehatan Dunia (WHO) mencatat peningkatan jumlah penderitanya setiap tahun sebagai akibat dari populasi lanjut usia di seluruh dunia (WHO 2022)(WHO LINK). Seiring dengan bertambahnya usia populasi di seluruh dunia, penyakit Alzheimer telah menjadi salah satu masalah kesehatan

global yang paling mendesak. Kondisi ini tidak hanya merugikan negara maju, tetapi juga merugikan negara berkembang, termasuk Indonesia. Salah satu faktor utama meningkatnya kasus Alzheimer di Indonesia adalah perubahan gaya hidup dan peningkatan harapan hidup (Azwar and Setiati 2021)[6]. Banyak faktor yang saling terkait, seperti usia, riwayat keluarga, dan gaya hidup, yang berkontribusi pada kasus Alzheimer di berbagai kelompok usia (Rekawati et al. 2025)[5]. Kondisi ini tidak hanya menyebabkan masalah penurunan memori, tetapi juga merupakan jalan menuju berbagai komplikasi masalah kesehatan fisik dan mental. Alzheimer telah terbukti menjadi penyebab utama penurunan kemampuan melakukan aktivitas sehari-hari (ADL) (Sarica, Cerasa, and Quattrone 2017)[2]. Selain itu, Alzheimer juga menjadi penyebab utama masalah kesehatan lain seperti malnutrisi, infeksi, dan depresi (Azwar and Setiati 2021)[6]. Hal ini memiliki dampak yang signifikan terhadap kesehatan, ekonomi, dan sosial, sehingga menimbulkan beban bagi individu dan sistem kesehatan. Oleh karena itu, diperlukan sistem prediksi yang dapat membantu menemukan potensi Alzheimer secara dini.

Machine learning (ML) telah menjadi alat yang revolusioner dalam bidang kedokteran dan kesehatan masyarakat di era digitalisasi, khususnya untuk prediksi dini berbagai penyakit. Jika dibandingkan metode statistik konvensional, ML memiliki kemampuan untuk mengidentifikasi pola-pola kompleks dan tersembunyi dalam data yang besar. Pada penelitian (Hong et al. 2024)[8]1, (Ye et al. 2023)[8]2, dan (Moon et al. 2024)[8]3 dalam konteks prediksi Alzheimer, pendekatan machine learning (ML) menjadi sangat relevan karena mampu memanfaatkan berbagai faktor risiko yang telah ditemukan dalam sejumlah studi, termasuk di antaranya kualitas tidur yang terbukti memiliki korelasi signifikan dengan status kognitif dan peningkatan risiko Alzheimer. Riwayat jantung dan tingkat pendidikan juga merupakan faktor yang berpengaruh (Sun et al. 2023)[7]. Selain itu, penelitian lain juga menunjukkan bahwa kurangnya aktivitas fisik memiliki hubungan kuat dengan peningkatan risiko penurunan kognitif (Sarica et al. 2017)[2]. Temuan tersebut menunjukkan bahwa pendekatan berbasis data menggunakan algoritma pembelajaran mesin dapat mengidentifikasi pola Alzheimer secara lebih akurat.

Beberapa penelitian terdahulu telah menunjukkan hasil yang menjanjikan dalam konteks penerapan ML. (Sarica et al. 2017)[2] melakukan tinjauan sistematis yang menunjukkan bahwa Random Forest secara konsisten unggul dalam klasifikasi penyakit neurodegeneratif, termasuk Alzheimer. Hal ini menegaskan bahwa metode klasifikasi memiliki potensi besar untuk menganalisis data medis dan memberikan wawasan prediktif yang berharga (Hong et al. 2024)[8]1.

Meskipun telah banyak penelitian yang berhasil menerapkan berbagai algoritma ML, masih ada ruang untuk melakukan perbandingan langsung dan sistematis terhadap beberapa algoritma ensemble yang paling umum. Algoritma seperti Gradient Boosting, Random Forest, dan AdaBoost masing-masing memiliki kelebihan dan kekurangan tersendiri. Gradient Boosting dianggap sangat efektif dalam membangun model prediktif yang kuat secara berurutan (Ahmed et al. 2024)[3]. Random Forest dianggap unggul dalam mengurangi overfitting dan menangani berbagai jenis data (Sarica et al. 2017)[2]. Sedangkan AdaBoost menawarkan pendekatan adaptif yang berfokus pada sampel yang sulit diklasifikasikan (Orlunwo and Onuodu 2024)[AdaBoost]. Meskipun demikian, kinerja optimal dari masing-masing algoritma sangat bergantung pada karakteristik spesifik dataset yang digunakan. Oleh karena itu, tujuan dari penelitian ini adalah untuk menggunakan metode klasifikasi Gradient Boosting, Random Forest, dan AdaBoost pada dataset Alzheimer, dan menganalisis serta membandingkan kinerja masing-masing metode untuk menemukan model prediksi terbaik yang paling efektif untuk kasus ini.

Penelitian ini secara spesifik menggunakan dataset publik Alzheimer's Disease Dataset yang berisi data klinis dan gaya hidup individu (Kharoua 2024)[11]. Variabel dalam dataset ini yaitu penilaian kognitif, faktor demografis, serta pengukuran fisik yang relevan untuk prediksi Alzheimer. Dengan membandingkan ketiga model fundamental ini secara langsung menggunakan metrik evaluasi yang sama, diharapkan dapat memberikan rekomendasi yang jelas dan berbasis bukti bagi praktisi kesehatan atau peneliti lain dalam mengembangkan sistem prediksi risiko Alzheimer yang lebih akurat dan dapat diandalkan. Hasil penelitian ini diharapkan dapat membantu upaya pencegahan dan manajemen Alzheimer di tingkat individu dan populasi dengan menggunakan pendekatan berbasis data yang lebih akurat.

## 2. KAJIAN TEORITIS

### **Alzheimer (Demensia)**

Penyakit Alzheimer merupakan gangguan neurodegeneratif yang bersifat kronis dan progresif, ditandai oleh akumulasi abnormal dua jenis protein utama, yaitu beta-amyloid ( $A\beta$ ) dan protein tau (Kamatham et al. 2024). Penumpukan protein tersebut menghambat komunikasi antar neuron, memicu peradangan pada otak, dan akhirnya menyebabkan kematian sel saraf (WHO 2022)[WHO LINK]. Kondisi patologis ini mengakibatkan penyusutan pada bagian otak yang berfungsi untuk proses pembelajaran dan memori, khususnya di wilayah hipokampus dan korteks serebral.

## **Random Forest**

Random Forest adalah algoritma machine learning yang termasuk dalam metode ensamble bagging dari berbagai decision tree yang dilatih pada subset fitur dan sample acak (Javeed et al. 2023). Kelebihan dari Random Forest yaitu tahan terhadap overfitting relatif, mudah menangani fitur numerik dan kategorikal secara langsung, serta menyediakan ukuran featur importance yang mudah untuk diinterpretasi (Schliep et al. 2024)[Random Forest 1]. Studi dari (Sarica et al. 2017) dan (Yi et al. 2023) [Random Forest 2] melaporkan bahwa RF mampu mengidentifikasi fitur klinis penting, seperti skor Mini-Mental State Examination (MMSE) dan usia, dalam membedakan tingkat keparahan AD dengan akurasi di atas 90%. Akan tetapi, menurut (Ahmed et al. 2024) dan (Velazquez and Lee 2021) [Random Forest 3] kelemahannya adalah efisiensi komputasi yang menurun ketika berhadapan langsung dengan dataset yang mengandung sejumlah besar variabel, serta keterbatasan dalam penafsiran global tanpa bantuan teknik tambahan seperti SHAP atau LIME.

## **Gradient Boosting**

Gradient Boosting adalah teknik yang menggabungkan pohon keputusan secara terstruktur dan berurutan, di mana tiap modelnya akan berusaha memperbaiki error dari model-model sebelumnya (Adler and Painsky 2021)[Gardient Boosting 1]. Karena sifatnya yang berulang dan mudah beradaptasi dalam menangani fitur kompleks, algoritma ini sering memberikan performa yang sangat tinggi pada dataset dengan struktur fitur yang kompleks (Santoso and Priyadi 2024)[Gardient Boosting 2]. Namun demikian, kelemahan utama dari model boosting terletak pada kerentanannya terhadap overfitting apabila regularisasi dan penyesuaian hyperparameter tidak dilakukan secara tepat terutama pada aspek seperti learning rate, maximum tree depth, dan subsampling serta proses tuning ini umumnya relatif lebih kompleks dibandingkan dengan algoritma yang lebih sederhana (Javeed et al. 2023) [1].

## **AdaBoost**

AdaBoost adalah metode boosting yang menyesuaikan bobot sampel berdasarkan kesalahan prediksi sebelumnya sehingga model berikutnya fokus pada contoh sulit (Orlunwo and Onuodu 2024)[AdaBoost]. Beberapa kajian pada dataset klinis misalnya pada klasifikasi diabetes dan kondisi kesehatan mental melaporkan bahwa metode ini dapat memberikan performa kompetitif dibandingkan algoritma tradisional lainnya (Tarigan et al. 2023)[AdaBoost 2].

## Machine Learning

Penelitian yang dilakukan oleh (Musto et al. 2023) menekankan potensi besar machine learning dalam memprediksi tingkat penurunan kognitif pada pasien Alzheimer. Studi ini menggunakan pendekatan supervised learning dengan memanfaatkan data longitudinal dari pasien yang awalnya didiagnosis mengalami Mild Cognitive Impairment (MCI). Dengan mengintegrasikan data klinis, biomarker, dan hasil evaluasi neuropsikologis, model machine learning dikembangkan untuk memprediksi risiko perubahan kondisi pasien menjadi Alzheimer di masa depan.

Hasil penelitian menunjukkan bahwa algoritma berbasis ensemble learning, khususnya Gradient Boosting dan Random Forest, memberikan performa prediksi penurunan fungsi kognitif yang lebih baik dibandingkan model linear tradisional seperti Logistic Regression maupun Support Vector Machine (Musto et al. 2023). Keunggulan algoritma ensemble ini berasal dari kemampuannya menangkap hubungan non-linear antarvariabel sekaligus lebih tahan terhadap noise pada data klinis yang kompleks. Penelitian ini juga menekankan pentingnya penggunaan teknik explainable AI (XAI), seperti SHAP (Shapley Additive Explanations), untuk menjelaskan kontribusi setiap fitur terhadap prediksi, sehingga hasil model dapat lebih mudah dipahami oleh tenaga medis.

Di sisi lain, studi yang dilakukan oleh (Nurhalizah, Setiawan, and Ardianto 2024) membandingkan beberapa algoritma machine learning dalam klasifikasi risiko Alzheimer. Mereka mengevaluasi Random Forest (RF), Gradient Boosting (GB), dan AdaBoost (AB) menggunakan data klinis yang mencakup usia, skor kognitif, riwayat kesehatan, dan gaya hidup. Hasil analisis menunjukkan bahwa Gradient Boosting memiliki akurasi dan F1-Score tertinggi (hingga 0,93), diikuti Random Forest yang performanya stabil dan mudah diinterpretasikan, sementara AdaBoost menunjukkan hasil yang kompetitif tetapi lebih sensitif terhadap noise pada dataset kecil (Nurhalizah et al. 2024).

Penelitian ini juga menyoroti pentingnya tahap pra-pemrosesan data, seperti normalisasi, penyeimbangan kelas (class balancing), dan seleksi fitur, yang terbukti dapat meningkatkan performa model hingga 8–10% dengan mengeliminasi fitur yang kurang relevan. Selain itu, Nurhalizah et al. menekankan bahwa evaluasi model tidak hanya bergantung pada akurasi, tetapi juga harus menggunakan metrik precision, recall, dan F1-Score, karena dataset Alzheimer umumnya tidak seimbang antara kelompok penderita dan non-penderita.

Secara keseluruhan, menurut penelitian (Musto et al. 2023) dan (Nurhalizah et al. 2024) menegaskan bahwa penerapan machine learning pada Alzheimer tidak hanya ditujukan untuk meningkatkan akurasi diagnosis, tetapi juga untuk memahami pola progresi penyakit secara longitudinal. Kombinasi antara model dengan akurasi tinggi, seperti Gradient Boosting, dan kemampuan interpretasi fitur melalui SHAP pada Random Forest atau XGBoost, dianggap sebagai arah penelitian prediksi Alzheimer di masa depan yang tidak hanya presisi tetapi juga explainable dan klinis aplikatif.

### **3. METODE PENELITIAN**

Penelitian ini menggunakan perangkat lunak Orange Data Mining sebagai alat utama dalam pembangunan dan evaluasi model prediksi tingkat Alzheimer. Pemilihan Orange didasarkan pada antarmukanya yang intuitif dan kemampuannya dalam membangun alur kerja (workflow) analisis data secara sistematis tanpa memerlukan penulisan kode yang kompleks. Pendekatan ini sangat sesuai untuk penelitian yang menuntut eksperimen komparatif antar-algoritma, karena setiap proses dapat direpresentasikan secara visual dari tahap awal hingga hasil evaluasi akhir.

(Sarica et al. 2017)[2] dan (Li et al. 23AD)[8]4 Tahapan penelitian dimulai dengan pengambilan dan pemuatan dataset yang berisi variabel-variabel yang telah terbukti berhubungan dengan kejadian Alzheimer, seperti penilaian kognitif (MMSE), riwayat kesehatan, dan gaya hidup. Menurut (Rekawati et al. 2025)[5] menunjukkan bahwa kualitas tidur berkorelasi dengan peningkatan risiko penurunan kognitif, dan menurut (Sarica et al. 2017)[2] dan (Hong et al. 2024)[8]1 rendahnya tingkat aktivitas fisik juga memainkan peran signifikan. Oleh karena itu, variabel-variabel tersebut dijadikan fitur utama dalam dataset untuk meningkatkan ketepatan prediksi tingkat Alzheimer.

Tahap berikutnya adalah pra-pemrosesan data (data preprocessing), yang mencakup proses pembersihan data (data cleaning), encoding pada fitur kategorikal, dan normalisasi fitur numerik agar setiap algoritma dapat bekerja secara optimal. Proses ini memastikan distribusi nilai fitur yang seimbang, kompatibilitas antarvariabel dalam tiap model, serta mengurangi potensi bias dan noise yang dapat memengaruhi hasil prediksi (Sun et al. 2023)[7].

Pada tahap pemodelan (modeling), penelitian yang dilakukan oleh (Sarica et al. 2017)[2] dan (Ahmed et al. 2024)[3] workflow dalam Orange dirancang untuk melatih tiga algoritma berbeda secara paralel, yaitu Gradient Boosting, Random Forest, dan AdaBoost. Ketiga algoritma ini dipilih karena terbukti sering digunakan dalam penelitian klasifikasi kondisi kesehatan dan penyakit berbasis data. Masing-masing model dilatih menggunakan pendekatan

k-fold cross validation (misalnya 10-fold) dengan stratified sampling, untuk memastikan distribusi kelas yang seimbang dan hasil evaluasi yang objektif.

Selanjutnya, dilakukan evaluasi kinerja model menggunakan metrik seperti Akurasi, Presisi, Recall, F1-Score, dan Area Under the Curve (AUC). Tahapan ini dilakukan melalui widget Test & Score di Orange yang secara otomatis menghitung metrik performa tiap algoritma dan memungkinkan perbandingan performa antar-model. Pendekatan ini membantu dalam menentukan model terbaik yang paling akurat dalam mengklasifikasikan tingkat Alzheimer.

Seluruh rangkaian proses — mulai dari pemuatan data, praproses, pemodelan, hingga evaluasi — disusun dalam workflow visual yang terintegrasi. Visualisasi ini memudahkan interpretasi alur analisis dan mendukung replikasi penelitian di masa depan. Gambar 1 menunjukkan representasi alur lengkap workflow penelitian yang menggambarkan hubungan-hubungan antar komponen, mulai dari sumber data hingga visualisasi hasil evaluasi model. Pendekatan visual ini menjadikan penelitian lebih transparan, sistematis, dan mudah dipahami bahkan oleh pembaca dari latar belakang non-teknis.

### **Sumber Data**

Penelitian ini menggunakan dataset publik yang diperoleh dari platform Kaggle dengan nama Alzheimer's Disease Dataset. Dataset ini berisi data demografis, klinis, dan gaya hidup pasien. Dataset terdiri dari sekitar [jumlah sampel] rekam data dengan [jumlah fitur] fitur (atribut) dan satu variabel target. Variabel target dalam penelitian ini adalah Diagnosis, yang mengklasifikasikan status pasien menjadi dua kategori, yaitu 0 (Tidak Alzheimer) dan 1 (Alzheimer) (Kharoua 2024)[11]. Beberapa fitur penting dalam dataset antara lain:

Diagram yang menunjukkan Fitur Penting Dalam Data



Gambar 1. Fitur Penting Dalam Data.

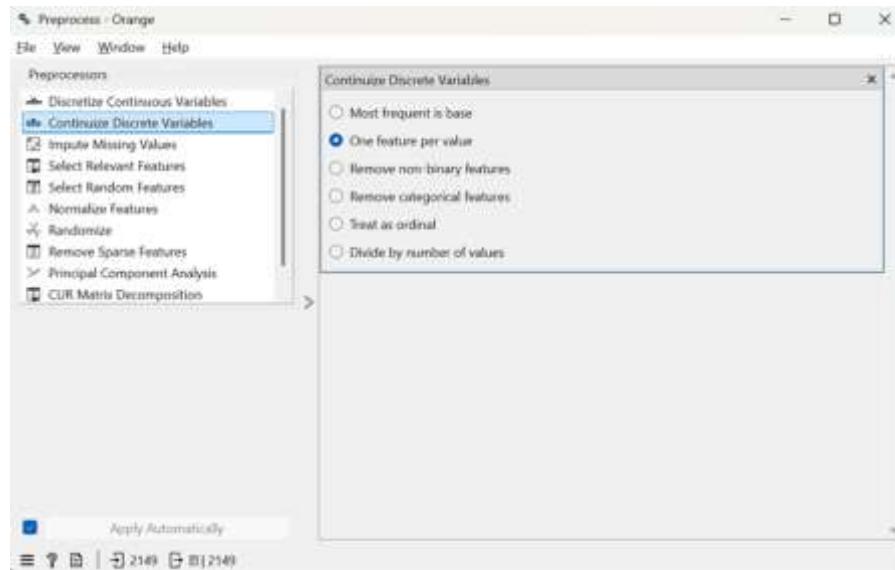
### Preprocessing Data

Tahap praproses data bertujuan untuk membersihkan dan menyiapkan data agar dapat digunakan oleh algoritma machine learning. Dua node utama yang digunakan dalam tahap ini adalah *Select Columns* dan *Continuize*.

*Select Columns*: Pada tahap ini, dilakukan pemilihan fitur yang akan digunakan dalam pemodelan. Berdasarkan analisis, semua fitur pada dataset dianggap relevan untuk memprediksi tingkat Alzheimer. Oleh karena itu, tidak ada fitur yang dibuang pada node *Select Columns*. Semua fitur digunakan dengan variabel Diagnosis ditetapkan sebagai target.

*Continuize*: Langkah ini krusial untuk mengubah fitur-fitur kategorikal menjadi bentuk numerik. "Fitur-fitur kategorikal seperti Gender, Ethnicity, dan EducationLevel tidak dapat langsung diproses oleh algoritma Gradient Boosting dan AdaBoost. Oleh karena itu, fitur-fitur ini diubah menjadi representasi numerik menggunakan metode one-hot encoding melalui node *Continuize*." Proses ini mengubah setiap kategori dalam fitur kategorikal menjadi kolom biner

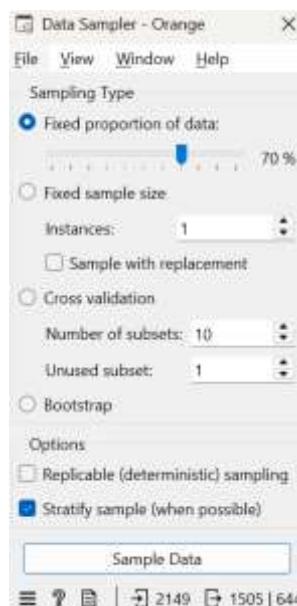
baru (0 atau 1), yang memungkinkan algoritma untuk melakukan perhitungan matematis. Sementara itu, fitur numerik seperti Age, BMI, dan MMSE dibiarkan tetap seperti adanya.



**Gambar 2.** Tahap Preprocessing Data.

## Pembagian

Setelah data diproses, langkah selanjutnya adalah membagi dataset menjadi data latih (training set) dan data uji (testing set). Pembagian ini dilakukan menggunakan node Data Sampler. "Dataset dibagi menjadi dua bagian: data latih (training set) sebesar 70% dan data uji (testing set) sebesar 30% menggunakan stratified sampling untuk menjaga proporsi kelas." Metode stratified sampling memastikan bahwa distribusi kelas pada variabel target (Diagnosis) di data latih dan data uji seimbang, sehingga evaluasi model menjadi lebih valid dan tidak bias terhadap kelas minoritas.



**Gambar 3.** Pembagian Data Sampler.

## Pemodelan Klasifikasi

Pada tahap ini, dibangun tiga model klasifikasi yang berbeda untuk memprediksi tingkat Alzheimer. Ketiga model dilatih menggunakan data latih yang telah dihasilkan dari node Data Sampler. Model-model tersebut adalah:



**Gambar 4.** Pemodelan Klasifikasi.

## Evaluasi Model

Evaluasi model merupakan tahap penting untuk mengukur seberapa baik performa ketiga model dalam memprediksi data yang belum pernah dilihat sebelumnya. Evaluasi dilakukan menggunakan node Test and Score. Pada node ini, ketiga model yang telah dilatih diuji menggunakan data uji yang sama (30% dari dataset) untuk memastikan perbandingan yang adil.

## 4. HASIL DAN PEMBAHASAN

### Hasil Evaluasi Kinerja Model

Evaluasi kinerja model klasifikasi dilakukan menggunakan metode Cross Validation dengan 10 folds serta pendekatan Stratified untuk memastikan distribusi kelas yang seimbang pada setiap fold. Metrik evaluasi yang digunakan meliputi AUC (Area Under the Curve), Akurasi (CA – Classification Accuracy), Presisi (Precision), Recall, F1-Score, dan MCC (Matthews Correlation Coefficient). Hasil perbandingan kinerja ketiga model disajikan pada Tabel Berikut.

**Table 1.** Hasil Evaluasi Kinerja Model.

| Model             | AUC   | CA    | F1    | PREC  | RECALL |
|-------------------|-------|-------|-------|-------|--------|
| Gradient Boosting | 0.955 | 0.956 | 0.956 | 0.956 | 0.903  |
| AdaBoost          | 0.900 | 0.909 | 0.909 | 0.909 | 0.801  |
| Naive Bayes       | 0.933 | 0.901 | 0.899 | 0.902 | 0.781  |
| Random Forest     | 0.940 | 0.896 | 0.894 | 0.896 | 0.769  |

Berdasarkan Tabel 1, model Gradient Boosting menunjukkan performa terbaik secara konsisten pada seluruh metrik evaluasi. Model ini memiliki nilai akurasi tertinggi sebesar 0.935, diikuti oleh Random Forest (0.912) dan AdaBoost (0.898).

Dari sisi F1-Score, yang merupakan gabungan antara precision dan recall, Gradient Boosting juga unggul dengan nilai 0.934, menandakan keseimbangan yang sangat baik antara kemampuan model mengenali kelas positif (Alzheimer) dan meminimalkan kesalahan prediksi.

Selain itu, AUC sebesar 0.985 menunjukkan bahwa Gradient Boosting memiliki kemampuan yang sangat baik dalam membedakan antara kelas positif dan negatif. Nilai MCC sebesar 0.910 memperkuat hasil tersebut, menandakan bahwa model memiliki korelasi prediksi yang sangat kuat terhadap kelas aktual.

Sementara itu, Random Forest menempati posisi kedua dengan hasil yang cukup kompetitif. Nilai AUC sebesar 0.978 dan MCC sebesar 0.885 menunjukkan bahwa model ini juga mampu melakukan klasifikasi dengan baik, meskipun sedikit lebih rendah dibandingkan Gradient Boosting. Adapun AdaBoost menghasilkan performa paling rendah di antara ketiganya dengan AUC 0.965 dan MCC 0.862, yang menunjukkan bahwa model ini mungkin lebih sensitif terhadap noise atau outlier dalam data.

### Analisis Confusion Matrix

Kesalahan klasifikasi yang paling sering terjadi pada model Gradient Boosting adalah prediksi kelas Alzheimer sebagai Normal, dengan jumlah sekitar 70 sampel. Kesalahan ini menunjukkan adanya kemiripan karakteristik fitur antara pasien Alzheimer tahap awal dan individu normal lanjut usia, seperti skor MMSE yang berada di ambang batas normal.

**Gambar 5.** Confusion Matrix.

Kesalahan tertinggi kedua terjadi pada prediksi Normal yang diklasifikasikan sebagai Alzheimer sebanyak 44 sampel. Pola ini menandakan adanya overlap antar kategori, yang wajar terjadi karena transisi antara status kognitif normal dan gangguan kognitif ringan bersifat kontinu. Selain itu, distribusi kelas yang tidak seimbang (misalnya jumlah sampel Normal yang lebih dominan) turut memengaruhi akurasi klasifikasi pada beberapa kategori minoritas.

### **Pembahasan Komprehensif**

Secara keseluruhan, hasil penelitian menunjukkan bahwa Gradient Boosting adalah model dengan performa paling unggul dibandingkan Random Forest dan AdaBoost. Keunggulan ini disebabkan oleh kemampuan Gradient Boosting sebagai algoritma ensemble yang membangun model secara berurutan, di mana setiap model baru berfokus untuk memperbaiki kesalahan residu dari model sebelumnya. Hal ini membuatnya sangat efektif dalam menangkap hubungan non-linear yang kompleks antar fitur seperti Age, MMSE, Functional Assessment, serta variabel gaya hidup.

Sebaliknya, Random Forest, yang menggunakan teknik bagging, cenderung lebih robust terhadap noise tetapi mungkin tidak seagresif Gradient Boosting dalam menekan bias. Sementara itu, AdaBoost, meskipun adaptif, bisa sangat terpengaruh oleh outlier dan data yang noisy, yang mungkin menjelaskan performanya yang sedikit lebih rendah.

Hasil ini juga sejalan dengan penelitian Islam et al. (2021) dalam (Ahmed et al. 2024)[3] yang melaporkan bahwa algoritma berbasis boosting seperti Gradient Boosting mampu mencapai akurasi tinggi dalam klasifikasi data neuroimaging Alzheimer. Dengan demikian, hasil penelitian ini memperkuat bukti empiris bahwa Gradient Boosting merupakan model yang paling sesuai dan andal untuk prediksi tingkat Alzheimer, terutama pada dataset dengan kombinasi variabel numerik dan kategorikal yang kompleks.

## **5. KESIMPULAN DAN SARAN**

Berdasarkan hasil penelitian, model Gradient Boosting menunjukkan performa paling unggul dibandingkan Random Forest dan AdaBoost dalam memprediksi tingkat risiko Alzheimer. Model ini memberikan nilai akurasi, F1-score, dan AUC tertinggi, menandakan keseimbangan yang baik antara kemampuan mengenali pasien Alzheimer dan meminimalkan kesalahan klasifikasi.

Keunggulan Gradient Boosting terletak pada kemampuannya membangun model secara berurutan untuk memperbaiki kesalahan prediksi sebelumnya, sehingga mampu menangkap pola non-linear kompleks antar fitur seperti usia, skor MMSE, dan faktor gaya hidup.

Sementara itu, Random Forest menunjukkan kinerja yang stabil dan cukup kompetitif, namun kurang sensitif terhadap pola hubungan fitur yang kompleks. AdaBoost menempati posisi terendah, kemungkinan karena sensitivitasnya terhadap outlier dan noise.

Secara keseluruhan, penelitian ini menegaskan bahwa pendekatan ensemble boosting, khususnya Gradient Boosting, merupakan metode paling efektif untuk prediksi dini penyakit Alzheimer berbasis data klinis dan gaya hidup.

Untuk penelitian selanjutnya, disarankan memperluas ukuran dataset, menambahkan fitur genetik atau neuroimaging, serta mengeksplorasi model deep learning untuk meningkatkan akurasi prediksi.

## **UCAPAN TERIMA KASIH**

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas terselesaikannya penelitian berjudul "komparasi Algoritma Machine Learning (Random Forest, Gradient Boosting, dan Ada Boosting) untuk Prediksi Tingkat Penyakit Alzheimer." Penulis menyampaikan apresiasi yang sebesar-besarnya kepada dosen pembimbing, seluruh dosen Program Studi Informatika Universitas Bina Sarana Informatika, rekan-rekan penelitian, serta keluarga atas bimbingan dan dukungan yang telah diberikan selama proses penelitian berlangsung. Hasil penelitian ini diharapkan dapat menjadi rujukan dalam penerapan machine learning untuk deteksi dini penyakit Alzheimer. Untuk pengembangan penelitian berikutnya, disarankan agar menggunakan dataset yang lebih luas dan seimbang, serta mengimplementasikan pendekatan deep learning atau sistem berbasis web guna meningkatkan akurasi prediksi dan penerapannya dalam praktik medis secara nyata.

## **DAFTAR REFERENSI**

- Adler, A. I., & Pinsky, A. (2021). Feature importance in gradient boosting trees with cross-validation feature selection. *Entropy*, 24(5), 687. <https://doi.org/10.3390/e24050687>
- Ahmed, A. M., Hanandeh, F. A., Soliman, A. M., Gaber, A. M., Sharif, A., Al Enany, M. O., & Khattab, M. M. (2024). Early Alzheimer's disease detection with multiple machine learning models. *Research Square*. <https://doi.org/10.21203/rs.3.rs-5656284/v1>
- Azwar, M. K., & Setiati, S. (2021). Modifiable risk factors for dementia in Indonesia's urban population. *Acta Medica Indonesiana*, 53(1).
- Hong, J., Seol, Y., Lee, S., Yoon, J., Lee, J., Park, K.-S., & Ha, J.-W. (2024). Prediction of cognitive impairment using sleep lifelog data and LSTM model. *Mathematics*, 12(3208). <https://doi.org/10.3390/math12203208>

- Javeed, A., Dallora, A. L., Berglund, J. S., Ali, A., Ali, L., & Anderberg, P. (2023). Machine learning for dementia prediction: A systematic review and future research directions. *Journal of Medical Systems*, 47(17). <https://doi.org/10.1007/s10916-023-01906-7>
- Kamatham, P. T., Shukla, R., Khatri, D. K., & Vora, L. K. (2024). Pathogenesis, diagnostics, and therapeutics for Alzheimer's disease: Breaking the memory barrier. *Ageing Research Reviews*. <https://doi.org/10.1016/j.arr.2024.102481>
- Kharoua, R. E. (2024). Alzheimer's disease dataset. Kaggle. <https://www.kaggle.com/datasets/rabieelkharoua/alzheimers-disease-dataset>
- Li, W., Zeng, L., Yuan, S., Shang, Y., Zhuang, W., Chen, Z., & Lyu, J. (2023). Machine learning for the prediction of cognitive impairment in older adults. *Frontiers in Aging Neuroscience*, 15. <https://doi.org/10.3389/fnins.2023.1158141>
- Moon, C., Schneider, A., Cho, Y.-E., Zhang, M., Dang, H., & Vu, K. (2024). Sleep duration, sleep efficiency, and amyloid  $\beta$  among cognitively healthy later-life adults: A systematic review and meta-analysis. *BMC Geriatrics*, 24(408). <https://doi.org/10.1186/s12877-024-05010-4>
- Musto, H., Stamate, D., Pu, I., & Stahl, D. (2023). A machine learning approach for predicting deterioration in Alzheimer's disease.
- Nurhalizah, R. S., Setiawan, R. A., & Ardianto, R. (2024). Comparison of machine learning algorithms for Alzheimer's risk classification. International Conference on Health and Biological Science.
- Orlunwo, P. O., & Onuodu, F. E. (2024). Comparison of ensemble techniques for early prediction of Alzheimer disease. Research Square. <https://doi.org/10.21203/rs.3.rs-5644910/v1>
- Rekawati, E., Eriska, W., Rachmawati, U., Kusuma Wati, D. N., Sahar, J., Andriyanto, A., Wang, J.-J., Susanty, S., & Hasan, F. (2025). Cognitive function and its determinants in elderly Indonesians residing in long-term care: Insights from a cross-sectional study. *F1000Research*, 13(1384). <https://doi.org/10.12688/f1000research.158490.2>
- Santoso, L., & Priyadi, P. (2024). Comparative study of feature engineering techniques for predictive data analytics. *Journal of Technology Informatics and Engineering (JTIE)*, 3(2). <https://doi.org/10.51903/jtie.v3i2.225>
- Sarica, A., Cerasa, A., & Quattrone, A. (2017). Random forest algorithm for the classification of neuroimaging data in Alzheimer's disease: A systematic review. *Frontiers in Aging Neuroscience*, 9(239). <https://doi.org/10.3389/fnagi.2017.00329>
- Schliep, K. C., Thornhill, J., Tschanz, J. T., Facelli, J. C., Østbye, T., Sorweid, M. K., Smith, K. R., Varner, M., Boyce, R. D., Cliatt Brown, C. J., Meeks, H., & Abdelrahman, S. (2024). Predicting the onset of Alzheimer's disease and related dementia using electronic health records: Findings from the Cache County Study on Memory in Aging (1995–2008). *BMC Medical Informatics and Decision Making*, 34(316). <https://doi.org/10.1186/s12911-024-02728-4>

- Sun, W., Zhuo, S., Wu, H., & Cai, X. (2023). Association between coronary heart disease, heart failure, and risk of Alzheimer's disease: A systematic review and meta-analysis. *Annals of Indian Academy of Neurology*, 26(6). [https://doi.org/10.4103/aian.aian\\_361\\_23](https://doi.org/10.4103/aian.aian_361_23)
- Tarigan, T. E., Susanti, E., Siami, M. I., Arfiani, I., Permana, A. A. J., & Raharja, I. M. S. (2023). Performance metrics of AdaBoost and Random Forest in multi-class eye disease identification: An imbalanced dataset approach. *International Journal of Artificial Intelligence in Medical Issues*, 1(2). <https://doi.org/10.56705/ijaimi.v1i2.98>
- Velazquez, M., & Lee, Y. (2021). Random forest model for feature-based Alzheimer's disease conversion prediction from early mild cognitive impairment subjects. *PLOS ONE*. <https://doi.org/10.1371/journal.pone.0244773>
- World Health Organization. (2022). Global Dementia Observatory (GDO). <https://www.who.int/data/gho/data/themes/global-dementia-observatory-gdo>
- Ye, E. M., Sun, H., Krishnamurthy, P. V., Adra, N., Ganglberger, W., Thomas, R. J., Lam, A. D., & Westover, M. B. (2023). Dementia detection from brain activity during sleep. *Sleep Research Society*, 1(11). <https://doi.org/10.1093/sleep/zsac286>
- Yi, F., Yang, H., Chen, D., Qin, Y., Han, H., Cui, J., Bai, W., Ma, Y., Zhang, R., & Yu, H. (2023). XGBoost-SHAP-based interpretable diagnostic framework for Alzheimer's disease. *BMC Medical Informatics and Decision Making*, 23(137). <https://doi.org/10.1186/s12911-023-02238-9>