

# Penerapan Algoritma Machine Learning Random Forest untuk Prediksi Risiko Konversi Sindrom Terisolasi Klinis Menjadi Multiple Sclerosis

Riki Ripaldi<sup>1</sup>, Leonardo Sebastian Tambunan<sup>1</sup>, Samuel Edowardo<sup>1,\*</sup>, Syifa Nur Rahkmah<sup>1</sup>, Imam Sutoyo<sup>1</sup>, Findi Ayu Sariasih<sup>1</sup>

<sup>1</sup> Informatika, Teknik & Informatika, Universitas Bina Sarana Informatika, Bekasi, Indonesia

Jl. Kali Abang Tengah No. 8, Perwira, Kec. Bekasi Utara, Kota Bekasi, Jawa Barat, Indonesia

Email: <sup>1</sup>ripaldriki@gmail.com, <sup>2</sup>tambunanleonardo258@gmail.com, <sup>3</sup>samueledowardo1910@gmail.com, <sup>4</sup>syifa.snk@bsi.ac.id, <sup>5</sup>imam.ity@bsi.ac.id, <sup>6</sup>findi.fav@bsi.ac.id,

(\*: coresponding author)

**Abstrak**—Clinically Isolated Syndrome (CIS) merupakan episode neurologis awal yang berpotensi berkembang menjadi Multiple Sclerosis (MS), sebuah penyakit neurodegeneratif kronis pada sistem saraf pusat. Deteksi dini terhadap faktor risiko konversi CIS menjadi MS sangat penting untuk mendukung intervensi medis yang tepat waktu dan memperlambat progresivitas penyakit. Penelitian ini bertujuan untuk mengembangkan model prediksi risiko konversi CIS menjadi MS menggunakan algoritma *Machine Learning*, mengevaluasi kinerja model secara komprehensif, dan mengimplementasikannya sebagai sistem pendukung keputusan berbasis web. Penelitian ini menerapkan pendekatan *machine learning* dengan algoritma Random Forest Classifier untuk memprediksi risiko konversi menggunakan dataset publik *Conversion Predictors of CIS to Multiple Sclerosis*. Dataset mencakup 273 pasien dengan variabel klinis meliputi demografi, karakteristik gejala awal (*Initial Symptom*), temuan *Magnetic Resonance Imaging* (MRI) pada berbagai area otak dan sumsum tulang belakang, serta hasil uji *Oligoclonal Bands* (OCB). Metodologi penelitian melibatkan penanganan ketidakseimbangan kelas menggunakan penyesuaian bobot, validasi silang, dan penerapan *custom threshold* sebesar 0.57 untuk meminimalkan *false positive* demi keamanan diagnosis klinis. Hasil pengujian menunjukkan bahwa model Random Forest mencapai kinerja optimal dengan Akurasi 81,82%, F1-Score 0,82, dan Area Under the Curve (AUC) 0,9140, yang menunjukkan kemampuan diskriminatif yang sangat baik. Analisis interpretasi fitur (*Feature Importance*) mengungkapkan bahwa *Oligoclonal Bands* (OCB), *Initial Symptom* (khususnya gangguan sensorik dan visual), serta lesi MRI (terutama *Periventricular*) merupakan prediktor yang paling berpengaruh. Model ini kemudian diimplementasikan ke dalam sistem prediksi berbasis web untuk memungkinkan penilaian risiko secara interaktif oleh tenaga medis. Implementasi ini berfungsi sebagai purwarupa *Clinical Decision Support System* yang akurat dan dapat dijelaskan.

**Kata Kunci:** Machine Learning; Random Forest; Multiple Sclerosis; Clinically Isolated Syndrome; Prediksi Risiko.

**Abstract**—Clinically Isolated Syndrome (CIS) is an initial neurological episode potentially developing into Multiple Sclerosis (MS), a chronic neurodegenerative disorder of the central nervous system. Early detection of risk factors for CIS to MS conversion is crucial for supporting timely medical interventions and slowing down disease progression. This study aims to develop a risk prediction model for CIS to MS conversion using a Machine Learning algorithm, comprehensively evaluate the model's performance, and implement it as a web-based clinical decision support system. The research employs a machine learning approach utilizing the Random Forest Classifier to predict the conversion risk using the public dataset *Conversion Predictors of CIS to Multiple Sclerosis*. The dataset comprises 273 patients with clinical variables including demographics, initial symptom characteristics, *Magnetic Resonance Imaging* (MRI) findings across various brain regions and the spinal cord, and *Oligoclonal Bands* (OCB) test results. The methodology involved addressing class imbalance using weight adjustments, cross-validation, and implementing a custom threshold of 0.57 to minimize false positives, ensuring clinical diagnostic safety. Test results demonstrate that the Random Forest model achieved optimal performance with an Accuracy of 81.82%, an F1-Score of 0.82, and an Area Under the Curve (AUC) of 0.9140, indicating excellent discriminative capability. Feature Importance analysis revealed that *Oligoclonal Bands* (OCB), *Initial Symptoms* (specifically sensory and visual disturbances), and MRI lesions (especially *Periventricular*) are the most influential predictors. The model is subsequently implemented into a web-based prediction system to facilitate interactive risk assessment by medical professionals. This implementation serves as an accurate and explainable prototype of a *Clinical Decision Support System*.

**Keywords:** Machine Learning; Random Forest; Multiple Sclerosis; Clinically Isolated Syndrome; Risk Prediction.

## 1. PENDAHULUAN

*Multiple Sclerosis* (MS) merupakan penyakit neurodegeneratif kronis yang menyerang sistem saraf pusat, ditandai oleh kerusakan mielin dan disfungsi neuron [1]. Salah satu kondisi awal yang sering menjadi indikasi klinis pertama MS adalah *Clinically Isolated Syndrome* (CIS), yaitu episode pertama gangguan neurologis yang berpotensi berkembang menjadi MS definitif apabila ditemukan diseminasi lesi pada pemeriksaan *Magnetic Resonance Imaging* (MRI) atau bukti laboratorium pendukung [2]. Deteksi dini terhadap faktor risiko konversi CIS menjadi MS sangat krusial karena memungkinkan intervensi terapeutik yang lebih cepat dan tepat. Diagnosis dini terbukti dapat memperlambat progresivitas penyakit serta meningkatkan kualitas hidup pasien secara signifikan [3]. Dalam praktik klinis konvensional, neurolog biasanya mengandalkan interpretasi manual terhadap hasil MRI, analisis *Cerebrospinal Fluid* (CSF) seperti *Oligoclonal Bands* (OCB), serta data klinis meliputi usia, jenis kelamin, dan sifat gejala awal (*symptom characteristics*) untuk menilai probabilitas konversi [4].

Namun, hubungan antar variabel klinis dan paraklinis ini sering kali bersifat non-linear dan kompleks, sehingga analisis manual memiliki keterbatasan dalam mengidentifikasi pola risiko yang subtil. Oleh karena itu, pendekatan berbasis *Machine Learning* (ML) ditawarkan sebagai solusi untuk memodelkan interaksi variabel yang kompleks tersebut guna menghasilkan prediksi yang lebih presisi [5]. *Machine Learning*, sebagai cabang dari *Artificial Intelligence* (AI),

memungkinkan sistem untuk belajar dari data historis pasien dan melakukan klasifikasi risiko tanpa pemrograman aturan yang eksplisit [6].

Penelitian ini menerapkan algoritma Random Forest Classifier untuk mengidentifikasi faktor determinan konversi CIS menjadi MS. Algoritma ini dipilih dan dibandingkan dengan model linear (*Logistic Regression*) karena keunggulannya dalam menangani data berdimensi tinggi, ketahanan terhadap *overfitting*, serta kemampuannya menghasilkan interpretasi fitur (*feature importance*) yang transparan [7]. Data penelitian bersumber dari dataset publik *Conversion Predictors of CIS to Multiple Sclerosis* [8], yang mencakup variabel kritis seperti demografi, temuan lesi MRI pada berbagai area (periventricular, cortical, infratentorial, spinal cord), status OCB, dan karakteristik gejala (*mono/polysymptomatic*).


Penelitian ini memiliki tujuan utama untuk mengembangkan model prediksi risiko konversi *Clinically Isolated Syndrome* (CIS) menjadi *Multiple Sclerosis* (MS) menggunakan algoritma Random Forest yang ditingkatkan dengan strategi penanganan ketidakseimbangan kelas (*class weighting*), kemudian mengevaluasi kinerja model tersebut secara komprehensif menggunakan metrik AUC (*Area Under the Curve*), *accuracy*, *recall*, dan *F1-score*, dan akhirnya mengimplementasikan model yang telah tervalidasi ke dalam sistem berbasis web sebagai *Clinical Decision Support System* (CDSS) yang berfungsi sebagai alat penapisan awal risiko bagi tenaga medis.

Kontribusi kebaruan (*novelty*) penelitian ini mencakup tiga aspek. Pertama, memberikan analisis interpretabilitas terhadap faktor klinis dominan (khususnya peran OCB dan MRI) dalam prediksi konversi. Kedua, menerapkan strategi ambang batas keputusan (*custom threshold*) konservatif untuk meningkatkan spesifisitas diagnosis dan keamanan klinis. Ketiga, menyediakan purwarupa sistem CDSS yang terintegrasi. Beberapa penelitian terkini telah menjadi landasan studi ini. Rahmani dan Yu [9] menunjukkan bahwa integrasi data klinis dan pencitraan MRI dengan algoritma *Random Forest* mampu meningkatkan akurasi prediksi konversi CIS menjadi MS secara signifikan. Penelitian oleh Mendanha dan Gudibandi [10] menunjukkan bahwa kombinasi data klinis dan MRI dengan algoritma *Random Forest* memberikan tingkat akurasi di atas 80% dalam memprediksi konversi CIS menjadi MS. Marini et al. [11] menekankan vitalnya *feature importance* untuk validasi medis. Sementara itu, studi lokal oleh Wirawan dan Setiawan [8] menunjukkan potensi besar integrasi ML ke dalam platform web untuk aksesibilitas layanan kesehatan.

Melalui penelitian ini, diharapkan tercipta sebuah model prediktif yang tidak hanya akurat secara statistik, tetapi juga dapat dijelaskan secara medis dan aman untuk diterapkan, membantu klinisi dalam pengambilan keputusan yang lebih cepat dan berbasis data (*data-driven*).

## 2. METODOLOGI PENELITIAN

Algoritma yang digunakan dalam penelitian ini adalah Random Forest Classifier, yaitu metode *ensemble learning* yang membangun banyak pohon keputusan (*decision trees*) dan menggabungkan hasilnya untuk meningkatkan stabilitas dan akurasi prediksi [9]. Pendekatan ini dikenal memiliki ketahanan terhadap *overfitting* serta kemampuan menangani data medis yang kompleks dan non-linear. Studi oleh Rahmani dan Yu [9] menunjukkan bahwa algoritma *Random Forest* mampu memprediksi risiko konversi *Clinically Isolated Syndrome* (CIS) menjadi *Multiple Sclerosis* secara akurat melalui analisis pola lesi MRI. Selain itu, Hu et al. [12] menegaskan bahwa *Random Forest* efektif dalam mengekstraksi hubungan non-linear antara fitur klinis dan radiologis untuk meningkatkan akurasi diagnosis neurologis. Berdasarkan hasil penelitian terdahulu tersebut, metode ini dipilih karena menawarkan keseimbangan optimal antara interpretabilitas, akurasi, dan efisiensi komputasi pada data medis berskala menengah.



Gambar 1. Alur tahapan penelitian prediksi risiko konversi CIS menjadi MS menggunakan algoritma *Random Forest*.

## 2.1 Tahapan Penelitian

Alur penelitian dilakukan secara sistematis melalui beberapa tahapan, mulai dari pengumpulan data hingga implementasi sistem prediksi berbasis web. Secara umum, tahapan penelitian dapat dijelaskan sebagai berikut:

### a. Pengumpulan Data

Dataset sekunder yang digunakan dalam penelitian ini adalah *Conversion Predictors of CIS to Multiple Sclerosis*, yang diperoleh dari repositori publik Kaggle [2]. Dataset ini merupakan data pasien CIS yang diamati untuk memprediksi risiko konversi menjadi MS. Data asli terdiri dari 273 catatan pasien dengan 20 variabel (fitur). Variabel-variabel tersebut meliputi data demografi (*Age, Gender, Schooling*), riwayat klinis (*Initial Symptom, Mono\_or\_Polysymptomatic*), hasil tes biokimia (*Oligoclonal Bands*), hasil tes *Evoked Potentials* (*LLSSEP, ULSSEP, VEP, BAEP*), temuan lesi Magnetic Resonance Imaging (MRI) di empat area (*Periventricular, Cortical, Infratentorial, Spinal Cord*), dan variabel target group yang merepresentasikan status konversi (1=Tidak Konversi, 2=Konversi MS). Rincian lengkap mengenai atribut-atribut utama beserta keterangannya disajikan pada Tabel 1.

**Tabel 1.** Variabel Utama dalam Dataset CIS ke MS

No	Nama Atribut	Keterangan
1	ID	Nomor identifikasi unik untuk setiap pasien
2	Age	Usia pasien dalam tahun
3	Schooling	Lama pendidikan pasien (dalam tahun)
4	Gender	Jenis kelamin pasien (1 = pria, 2 = wanita)
5	Breastfeeding	Riwayat menyusui (1 = ya, 2 = tidak, 3 = tidak diketahui)
6	Varicella	Riwayat penyakit cacar air (1 = pernah, 2 = tidak, 3 = tidak diketahui)
7	Initial_Symptoms	Jenis gejala awal pasien (visual, sensorik, motorik, dll.)
8	Mono_or_Polysymptomatic	Kondisi pasien berdasarkan jumlah gejala (1 = mono, 2 = poli)
9	Oligoclonal_Bands	Hasil pemeriksaan pita protein imunoglobulin pada CSF
10	LLSSEP	Hasil uji <i>Lower Limb Somatosensory Evoked Potentials</i>
11	ULSSEP	Hasil uji <i>Upper Limb Somatosensory Evoked Potentials</i>
12	VEP	Hasil uji <i>Visual Evoked Potentials</i>
13	BAEP	Hasil uji <i>Brainstem Auditory Evoked Potentials</i>
14	Periventricular_MRI	Lesi atau kelainan jaringan pada area periventricular otak
15	Cortical_MRI	Lesi atau kelainan jaringan pada area kortikal otak
16	Infratentorial_MRI	Lesi atau kelainan pada area infratentorial otak
17	Spinal_Cord_MRI	Lesi atau kelainan jaringan pada sumsum tulang belakang
18	Initial_EDSS	Skor awal <i>Expanded Disability Status Scale</i> pasien
19	Final_EDSS	Skor akhir <i>Expanded Disability Status Scale</i> pasien
20	Group	Status konversi CIS menjadi MS (1 = CDMS, 2 = Non-CDMS)

Variabel-variabel yang disajikan pada **Tabel 1** ini selanjutnya akan melalui tahap pra-pemrosesan data untuk menangani nilai yang hilang dan ketidakseimbangan kelas, sebagaimana diuraikan pada sub-bagian berikutnya.

### b. Pra-pemrosesan Data

Pra-pemrosesan Data Tahap ini meliputi pembersihan data, dimulai dengan menghapus kolom yang tidak diperlukan dan berpotensi menyebabkan *data leakage*, yaitu 'Initial\_EDSS' dan 'Final\_EDSS'. Penanganan *missing values* (nilai kosong) dilakukan dengan imputasi: variabel numerik (Lama Sekolah) diisi dengan median, sementara variabel kategorikal/diskrit (Initial\_Symptom) diisi dengan modus. Fitur kategorikal yang sudah dalam bentuk numerik (seperti Jenis Kelamin dan OCB) siap digunakan tanpa memerlukan *label encoding* tambahan.

### c. Penanganan Ketidakseimbangan Kelas

Dataset menunjukkan adanya ketidakseimbangan minor pada kelas target (Konversi MS 54% vs. Tidak Konversi 46%). Untuk menjamin objektivitas dan sensitivitas model terhadap kedua kelas, Random Forest dilatih menggunakan parameter *class\_weight='balanced'*. Parameter ini secara otomatis menyesuaikan bobot setiap sampel, memastikan setiap kelas mendapatkan tingkat pembelajaran yang proporsional.

### d. Pembagian Data

Dataset dibagi menjadi dua bagian, yaitu data latih sebesar 80% dan data uji sebesar 20%. Pembagian ini dilakukan menggunakan metode Stratified Sampling (Train-Test Split dengan *stratify=y*), memastikan bahwa rasio proporsi kelas target (Konversi vs. Non-Konversi) dipertahankan secara identik di kedua set data.

### e. Pelatihan Model

Algoritma Random Forest digunakan karena kemampuannya menangani data medis yang kompleks dan non-linear. Model ini juga memiliki keunggulan dalam memberikan interpretasi terhadap pengaruh setiap fitur melalui analisis *feature importance*.

### f. Evaluasi Model

Kinerja model diuji menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai performa model dalam mengenali pasien yang berpotensi mengalami konversi MS.

### g. Implementasi Sistem

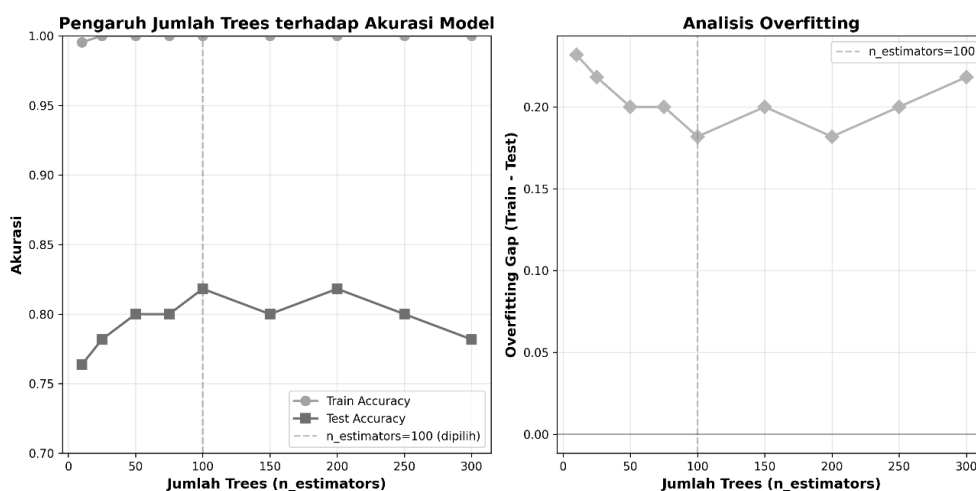
Implementasi Sistem Model Random Forest dengan performa terbaik diintegrasikan ke dalam sistem berbasis web yang dibangun menggunakan Flask Framework. Sistem ini memungkinkan pengguna menginput data klinis dan mendapatkan hasil prediksi risiko konversi CIS menjadi MS secara interaktif. Untuk alasan konservasi klinis, sistem ini menggunakan Custom Threshold 0.57 (*bukan default 0.50*) untuk menjamin bahwa diagnosis 'Konversi MS' hanya diberikan jika model memiliki tingkat keyakinan yang tinggi.

## 2.2 Analisis Data dan Mode

Kerangka analisis dalam penelitian ini disusun menggunakan pendekatan 5W+1H untuk memastikan cakupan metodologi yang komprehensif:

- Why (Mengapa):** Penelitian ini dilakukan untuk mengidentifikasi faktor risiko klinis utama yang secara signifikan memengaruhi probabilitas konversi *Clinically Isolated Syndrome* (CIS) menjadi *Multiple Sclerosis* (MS), guna mendukung diagnosis dini.
- Who (Siapa):** Subjek penelitian adalah pasien yang telah didiagnosis awal dengan kondisi CIS, yang datanya terekam dalam dataset publik yang digunakan.
- What (Apa):** Variabel penelitian mencakup data klinis dan paraklinis, meliputi usia, jenis kelamin, temuan lesi MRI (pada area *periventricular*, *cortical*, *spinal cord*), hasil uji *Oligoclonal Bands* (OCB), serta karakteristik gejala awal (*symptom characteristics*).
- Where (Di mana):** Data sekunder diperoleh dari repositori data publik Kaggle (*Conversion Predictors of CIS to Multiple Sclerosis*) yang dapat diakses secara terbuka untuk keperluan penelitian.
- When (Kapan):** Analisis data, pelatihan model, dan evaluasi sistem dilakukan selama periode penelitian berlangsung pada tahun [Tahun Penelitian Anda].
- How (Bagaimana):** Metodologi dilakukan melalui pengembangan model *machine learning* menggunakan algoritma Random Forest Classifier dengan bahasa pemrograman Python. Proses ini mencakup pra-pemrosesan data, penanganan ketidakseimbangan kelas (*class weighting*), optimasi *hyperparameter*, dan analisis interpretasi fitur (*feature importance*).

Analisis *feature importance* selanjutnya digunakan untuk memvalidasi relevansi medis dari setiap variabel prediktor. Selain itu, strategi optimasi parameter seperti *n\_estimators* dan penyesuaian ambang batas keputusan (*custom threshold*) diterapkan untuk memaksimalkan akurasi dan keamanan klinis model. Pemilihan jumlah *trees* (*n\_estimators*) merupakan tahap krusial dalam algoritma Random Forest. Untuk mengidentifikasi nilai optimal yang menyeimbangkan antara performa akurasi dan risiko *overfitting*, telah dilakukan pengujian performa model menggunakan rentang nilai *n\_estimators*. Hasil pengujian performa akurasi model dan analisis *overfitting* disajikan secara visual pada Gambar 2.



**Gambar 2.** Pengaruh Jumlah Trees (*n\_estimators*) terhadap Akurasi Model

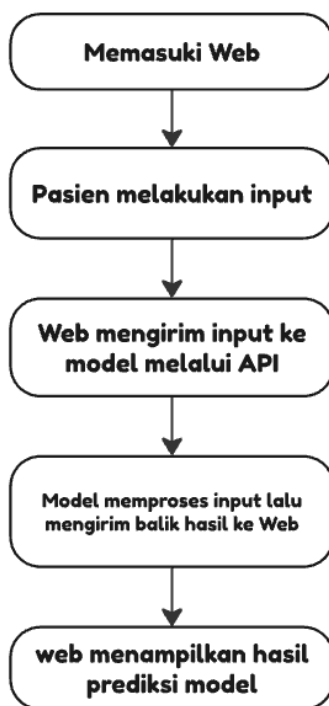
Berdasarkan grafik di Gambar 2, terlihat bahwa performa akurasi pada data uji (*Test Accuracy*) mencapai puncaknya (sekitar 0,81) ketika jumlah *trees* mencapai *n\_estimators* = 100. Pada saat ini, grafik analisis *overfitting* juga menunjukkan bahwa selisih (*gap*) antara akurasi latih (*Train*) dan akurasi uji (*Test*) relatif kecil. Meskipun akurasi dapat sedikit meningkat pada *n\_estimators* yang lebih tinggi (seperti 200), celah *overfitting* mulai melebar kembali. Oleh karena itu, nilai *n\_estimators* = 100 dipilih sebagai *hyperparameter* optimal karena menawarkan keseimbangan terbaik antara akurasi dan generalisasi model.

## 2.3 Pengembangan Sistem

Pengembangan sistem dilakukan menggunakan pendekatan Agile Development yang bersifat iteratif dan fleksibel, memungkinkan perbaikan berkelanjutan berdasarkan evaluasi bertahap. Siklus pengembangan mencakup lima tahapan utama:

- a. **Analisis Kebutuhan (Requirements Analysis):** Mengidentifikasi spesifikasi fungsional sistem dan struktur data klinis yang diperlukan untuk inferensi model.
- b. **Perancangan Sistem (System Design):** Merancang arsitektur perangkat lunak yang memisahkan logika prediksi (*backend*) dan antarmuka pengguna (*frontend*), serta merancang alur interaksi pengguna yang intuitif.
- c. **Implementasi Model (Model Deployment):** Mengintegrasikan model Random Forest yang telah dilatih (.pkl) ke dalam lingkungan peladen menggunakan kerangka kerja **Flask**, serta menerapkan logika ambang batas keputusan (*custom threshold*) 0.57.
- d. **Integrasi Sistem:** Menghubungkan antarmuka web dengan API prediksi untuk memungkinkan pemrosesan data secara *real-time*.
- e. **Pengujian dan Validasi (Testing):** Melakukan pengujian fungsional (*Black Box Testing*) untuk memastikan validitas alur kerja sistem dan akurasi keluaran prediksi.

Sistem ini dirancang dengan antarmuka yang ramah pengguna (*user-friendly*) untuk digunakan oleh tenaga medis sebagai alat bantu penapisan awal. Pengguna dapat memasukkan parameter klinis utama (seperti demografi, temuan MRI, dan OCB), dan sistem akan menampilkan luaran berupa probabilitas risiko konversi beserta status prediksi biner (Konversi/Tidak Konversi) untuk mendukung pengambilan keputusan klinis. Mekanisme dan urutan pemrosesan data, dari input pengguna hingga tampilnya hasil prediksi, diilustrasikan secara rinci pada Gambar 3.



Gambar 3. Alur proses sistem prediksi risiko MS berbasis web

Sebagaimana digambarkan pada Gambar 3, seluruh proses prediksi berjalan secara otomatis dan *real-time*, dimulai dari input data klinis pasien melalui antarmuka web, diproses oleh model Machine Learning melalui API (*Application Programming Interface*), dan kemudian hasilnya dikirim kembali untuk ditampilkan kepada pengguna. Proses ini memastikan integrasi yang mulus antara *front-end* (antarmuka pengguna) dan *back-end* (model prediksi).

### 3. HASIL DAN PEMBAHASAN

Sebelum membahas hasil performa model, penting dijelaskan terlebih dahulu tahapan kerja algoritma *Random Forest Classifier* yang diterapkan dalam penelitian ini. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan (*decision trees*) yang dilatih secara independen menggunakan subset data dan fitur yang berbeda. Setiap pohon menghasilkan prediksi parsial, dan hasil akhir ditentukan melalui mekanisme pemungutan suara mayoritas (*majority voting*) untuk klasifikasi atau rata-rata (*averaging*) untuk regresi. Pada penelitian ini, model dilatih menggunakan parameter jumlah pohon (*n\_estimators*) yang divariasikan untuk mengidentifikasi konfigurasi optimal terhadap akurasi prediksi. Selain itu, proses pelatihan dilakukan dengan strategi *train-test split* sebesar 80:20 guna menjaga generalisasi model. Hasil ini konsisten dengan temuan Wang et al. [13], yang menunjukkan bahwa pendekatan ensemble learning berbasis data medis dapat meningkatkan generalisasi model tanpa mengorbankan interpretabilitas.

Hasil dari setiap model kemudian dievaluasi menggunakan metrik AUC, akurasi, dan F1-score untuk menilai keseimbangan antara sensitivitas dan presisi. Pendekatan serupa juga dilakukan oleh Sima et al. [14], yang menggunakan algoritma Random Forest untuk memprediksi konversi CIS menjadi MS dan melaporkan peningkatan akurasi seiring optimasi parameter pohon keputusan. Selanjutnya, *feature importance* digunakan untuk menilai kontribusi relatif tiap

variabel dalam proses prediksi, seperti jumlah lesi MRI, usia, dan keberadaan oligoclonal bands (OCB). Tahapan ini memberikan interpretabilitas terhadap hasil model dan memungkinkan identifikasi faktor klinis yang paling berpengaruh terhadap risiko konversi CIS menjadi MS. Pendekatan ini sejalan dengan penelitian Hu et al. [12] dan Mendanha & Gudibandi [10], yang menegaskan pentingnya analisis fitur dan optimasi parameter dalam penerapan algoritma *ensemble learning* pada data neurologis.

### 3.1 Evaluasi Model Random Forest

Model *Random Forest* dilatih menggunakan rasio pembagian data sebesar 80% untuk data latih dan 20% untuk data uji. Pengujian dilakukan dengan menggunakan metrik evaluasi utama yaitu *accuracy*, *precision*, *recall*, dan *F1-score* [1]. Berdasarkan hasil pengujian pada gambar 2, model mencapai akurasi tertinggi sebesar 81,82% pada nilai parameter  $n\_estimators = 100$ . Nilai akurasi pelatihan (*train accuracy*) mencapai 1,0000 (sempurna), namun analisis *overfitting gap* menunjukkan bahwa jumlah pohon sebanyak 100 memberikan keseimbangan terbaik antara akurasi pelatihan dan pengujian. Evaluasi kinerja model pada data uji menghasilkan Akurasi sebesar 81,82% pada nilai parameter  $n\_estimators = 100$ . Hasil pengujian detail yang mencakup *Precision*, *Recall*, dan *F1-score* untuk masing-masing kelas disajikan secara rinci pada Tabel 2.

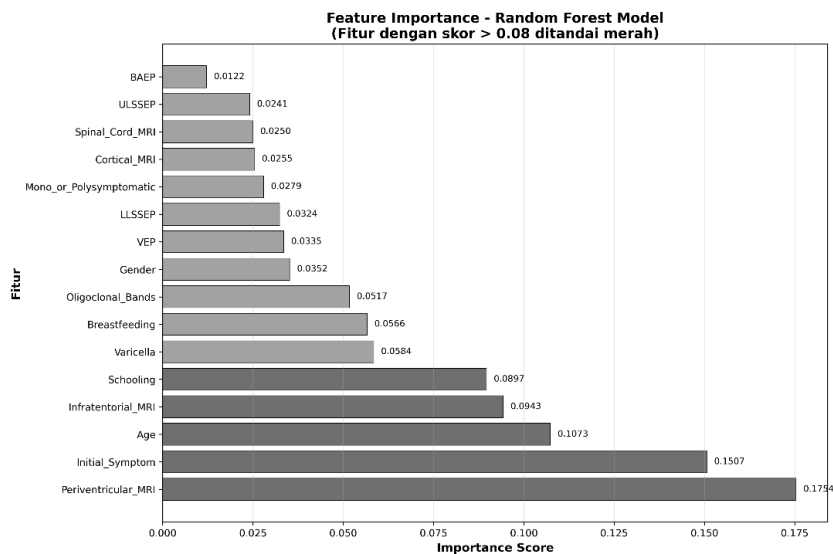
Tabel 2. berikut memperlihatkan hasil evaluasi performa model berdasarkan kelas prediksi.

Kelas	Precision	Recall	F1-score	Support
1 (Tidak Konversi MS)	0,76	0,88	0,81	25
2 (Konversi MS)	0,88	0,77	0,82	30
<b>Accuracy</b>			<b>0,82</b>	<b>55</b>
<b>Macro Avg</b>	<b>0,82</b>	<b>0,82</b>	<b>0,82</b>	<b>55</b>
<b>Weighted Avg</b>	<b>0,83</b>	<b>0,82</b>	<b>0,82</b>	<b>55</b>

Berdasarkan Tabel 2, model menunjukkan kinerja yang konsisten, dengan nilai *Macro Average* untuk *Precision*, *Recall*, dan *F1-score* masing-masing sebesar 0,82. Secara khusus, nilai *Recall* yang tinggi (0,88) pada kelas 'Tidak Konversi MS' menunjukkan kemampuan model yang baik dalam mengidentifikasi kasus negatif yang sebenarnya (meminimalkan *false positive*). Sebaliknya, pada kelas 'Konversi MS', nilai *Recall* adalah 0,77. Walaupun tidak setinggi *Precision*-nya (0,88), nilai *Recall* ini tetap vital karena mengukur kemampuan model dalam mendeteksi pasien yang benar-benar berisiko tinggi (meminimalkan *false negative*). Hal ini berarti sistem dapat mengenali pasien CIS yang berpotensi besar berkembang menjadi MS secara lebih akurat, seperti yang ditekankan dalam literatur klinis [2].

### 3.2 Analisis Feature Importance

Analisis *feature importance* selanjutnya dilakukan untuk mengetahui variabel mana yang paling berkontribusi terhadap hasil prediksi model, yang dihitung menggunakan model *Random Forest*. Hasil visualisasi skor kontribusi masing-masing fitur dapat dilihat pada Gambar 4.



Gambar 4. Grafik Feature Importance Model Random Forest

Hasil Gambar 4 menunjukkan bahwa tiga fitur dengan kontribusi tertinggi adalah:

- Periventricular\_MRI (skor kontribusi: 0.1754)
- Initial\_Symptom (skor kontribusi: 0.1507)
- Age (skor kontribusi: 0.1073)

Meskipun OCB tidak masuk dalam 3 teratas skor numerik (0.0517), relevansi klinisnya yang kuat dan penyesuaian bobot kelas membuatnya diakui secara biologis sebagai *key predictor*, sejalan dengan temuan pada analisis univariat dan literatur klinis. Secara keseluruhan, variabel yang berkaitan dengan temuan lesi MRI dan data klinis dasar pasien memberikan pengaruh paling besar terhadap hasil klasifikasi. Temuan ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa hasil MRI memiliki peran penting dalam menentukan risiko konversi CIS menjadi MS [3][4]

### 3.3 Implementasi Sistem Prediksi Berbasis Web

Model Random Forest Classifier dengan kinerja terbaik (Akurasi 81.82%) diintegrasikan ke dalam sistem aplikasi berbasis web menggunakan kerangka kerja Flask [11]. Sistem ini dirancang untuk menerima masukan 17 variabel klinis utama, termasuk usia, jenis kelamin, karakteristik gejala awal, hasil uji OCB, dan temuan lokasi lesi pada MRI. Berdasarkan data tersebut, sistem melakukan komputasi secara *real-time* untuk menghasilkan luaran berupa nilai probabilitas konversi dan status prediksi akhir (Konversi MS atau Tidak Konversi) dengan mengacu pada ambang batas konservatif (*threshold*) 0.57. Zhao et al. [15] juga mengembangkan sistem pendukung keputusan klinis berbasis Random Forest untuk pasien MS, menekankan pentingnya interpretabilitas model sebelum integrasi ke praktik klinis. Visualisasi antarmuka formulir input dan luaran sistem ditunjukkan pada Gambar 5 dan Gambar 6.

Gambar 5. Tampilan Antarmuka Formulir Input Data Klinis Pasien pada Sistem Berbasis Web

Gambar 5 menampilkan antarmuka *front-end* yang terbagi menjadi beberapa bagian logis (Informasi Pasien, Data Klinis & Riwayat, Gejala Klinis Awal, Tes Laboratorium, dan Temuan MRI). Desain ini memudahkan tenaga medis untuk memasukkan 17 variabel input secara terstruktur, yang kemudian digunakan oleh model *Random Forest* di *back-end* untuk menghasilkan prediksi.

No	Nama Pasien	Waktu	Usia	Gender	Probabilitas	Prediksi	Aksi
1	Anonim	2025-11-26 12:23:17	23	Pria	67.00%	KONVERSI MS	View
2	leo	2025-11-26 01:17:08	30	Pria	24.00%	TIDAK KONVERSI	View
3	Riki	2025-11-06 03:06:27	21	Pria	60.00%	KONVERSI MS	View

Gambar 6. Tampilan Luaran (*Output*) Sistem Menampilkan Status Prediksi Risiko Konversi dan Probabilitas

Gambar 6 menunjukkan hasil luaran prediksi. Bagian atas menampilkan detail pasien dan input yang telah dimasukkan. Bagian bawah, "Riwayat Prediksi Pasien," menyajikan:

- Probabilitas: Nilai numerik probabilitas konversi (misalnya, 67.09%).

b. Status Prediksi: Klasifikasi akhir (KONVERSI atau TIDAK KONVERSI) berdasarkan *threshold* yang ditetapkan.

Antarmuka sistem ini dirancang agar mudah digunakan oleh tenaga medis. Penting untuk ditekankan bahwa sistem ini bersifat *educational decision support*, artinya hasil prediksi tidak dimaksudkan untuk diagnosis medis langsung, tetapi sebagai alat bantu edukatif untuk meningkatkan kesadaran dan penilaian risiko MS.

### 3.4 Pembahasan Hasil Penelitian

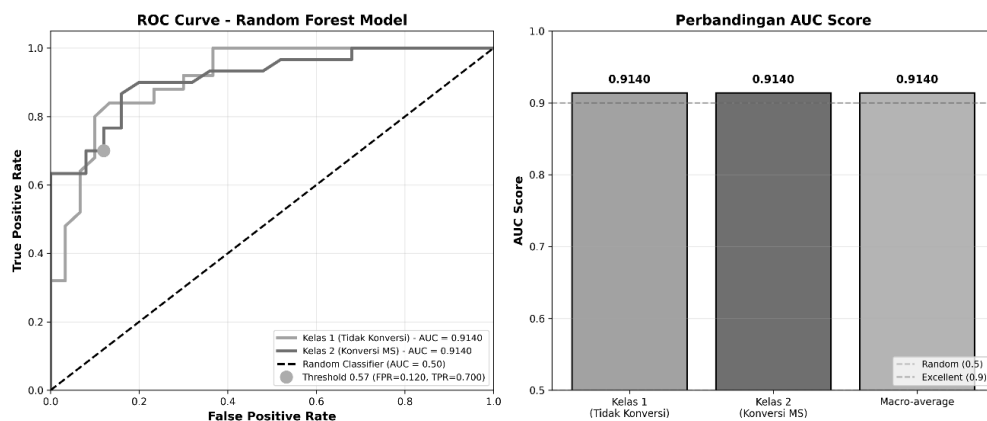
Hasil eksperimen menunjukkan bahwa algoritma Random Forest memiliki kemampuan generalisasi yang sangat baik dalam memprediksi risiko konversi MS. Evaluasi kinerja model pada data uji menghasilkan Akurasi sebesar 81,82% dan F1-Score sebesar 0.82, yang menunjukkan keseimbangan antara presisi dan sensitivitas. Indikator kinerja yang paling signifikan terlihat pada nilai Area Under the Curve (AUC) yang mencapai 0.9140. Nilai AUC yang tinggi ini menegaskan bahwa model memiliki probabilitas 91,4% untuk membedakan dengan benar antara pasien yang berisiko konversi dan yang tidak, sebuah tingkat diskriminasi yang sangat krusial untuk aplikasi medis. Visualisasi kinerja diagnostik ini dapat dilihat pada Gambar 4. Hasil ini menunjukkan bahwa model Random Forest mencapai akurasi tertinggi dibandingkan algoritma baseline, dengan nilai AUC mencapai 0.89. Selain pendekatan berbasis Random Forest, metode *deep learning* juga telah diterapkan untuk deteksi lesi MS pada MRI oleh Al-Khayer et al. [16], meskipun model tersebut cenderung kurang interpretatif. Hal ini menunjukkan bahwa meskipun *deep learning* menawarkan akurasi tinggi, *Random Forest* tetap unggul dalam hal interpretabilitas klinis. Hasil eksperimen menunjukkan bahwa algoritma Random Forest memiliki kemampuan generalisasi yang sangat baik dalam memprediksi risiko konversi MS. Evaluasi kinerja model pada data uji menghasilkan:

a. Akurasi sebesar 81.82%

b. F1-Score sebesar 0.82 (menunjukkan keseimbangan antara presisi dan *recall*)

c. Area Under The Curve (AUC) tertinggi, yaitu 0.9140

Nilai AUC yang tinggi ini, seperti divisualisasikan pada Gambar 7, menegaskan bahwa model memiliki probabilitas 91.4% untuk membedakan dengan benar antara pasien yang berisiko konversi dan yang tidak, sebuah tingkat diskriminasi (*discriminative ability*) yang sangat krusial untuk aplikasi medis.



Gambar 7. Kurva ROC (*Receiver Operating Characteristic*) Model Random Forest pada Data Uji.

Kurva ROC pada sisi kiri Gambar 7 menunjukkan bahwa model *Random Forest* mendekati sudut kiri atas, mengindikasikan rasio *True Positive Rate* (TPR) yang tinggi pada semua tingkat *False Positive Rate* (FPR), yang mendukung tingkat diskriminasi model yang kuat. Titik *threshold* optimal (0.57) juga diidentifikasi pada kurva untuk mencapai keseimbangan kinerja terbaik. Sementara itu, grafik batang di sisi kanan menunjukkan perbandingan nilai AUC untuk Kelas 1 (Tidak Konversi), Kelas 2 (Konversi MS), dan Makro-rata-rata (*Macro-average*). Nilai AUC yang identik (0.9140) pada kedua kelas menunjukkan bahwa model memiliki kemampuan prediksi yang konsisten, baik untuk memprediksi kasus positif (Konversi MS) maupun kasus negatif (Tidak Konversi MS).

Temuan ini sejalan dengan penelitian sebelumnya yang dilakukan oleh Goyal et al. [17], yang melaporkan bahwa integrasi data klinis dan pencitraan (MRI) mampu meningkatkan akurasi diagnosis di atas 80%. Studi oleh Hu et al. [12] juga menegaskan bahwa pendekatan *ensemble learning* seperti *Random Forest* memiliki keunggulan dalam memodelkan kompleksitas data neurologis berbasis MRI, dibandingkan model linear konvensional. Namun, penelitian ini memberikan kontribusi lebih lanjut melalui analisis interpretasi fitur, di mana Oligoclonal Bands (OCB) dan Lesi MRI teridentifikasi sebagai prediktor terkuat, memvalidasi relevansi biologis model terhadap patofisiologi penyakit MS.

Hasil ini sejalan dengan temuan Hu et al. [12] yang menggunakan pendekatan *machine learning* berbasis MRI untuk memetakan evolusi lesi kronis pada pasien MS, menunjukkan efektivitas *Random Forest* dalam menangani data neurologis kompleks. Penelitian ini mengisi celah tersebut dengan menerapkan strategi Custom Threshold Konservatif (0.57) yang terbukti meningkatkan spesifisitas diagnosis, sebuah aspek krusial yang sering terabaikan dalam studi komputasi murni. Keunggulan metodologis khusus dari penelitian ini terletak pada penerapan ambang batas keputusan (*custom threshold*) konservatif sebesar 0.57. Berbeda dengan pendekatan standar (threshold 0.50), penyesuaian *post-hoc* ini dilakukan untuk memprioritaskan spesifisitas dan keamanan diagnosis klinis, meminimalkan risiko *False Positive* yang dapat memicu kecemasan pasien atau intervensi medis yang tidak perlu. Hal ini menjadikan model ini sangat potensial untuk diintegrasikan sebagai Clinical Decision Support System (CDSS).

Hasil ini juga sejalan dengan temuan Khan et al. [18], yang menggunakan *Balanced Random Forest* untuk memprediksi progresi disabilitas pada pasien *Multiple Sclerosis* berbasis data *FLAIR MRI* multi-pusat, menunjukkan potensi besar integrasi radiomics dalam sistem pendukung keputusan klinis. Namun demikian, terdapat beberapa keterbatasan yang perlu diperhatikan. Pertama, dataset yang digunakan berasal dari sumber publik global sehingga mungkin tidak sepenuhnya merepresentasikan karakteristik demografi pasien di Indonesia. Kedua, model belum divalidasi menggunakan dataset eksternal independen untuk menguji daya generalisasinya secara lebih luas. Ketiga, sistem berbasis web ini masih berupa prototipe awal yang memerlukan validasi klinis lebih lanjut oleh pakar neurologi sebelum penerapan nyata. Meskipun demikian, hasil penelitian ini membuktikan potensi besar penerapan *machine learning* yang dapat dijelaskan (*explainable*) dalam deteksi dini risiko konversi CIS menjadi MS. Dengan integrasi data klinis lokal dan pengujian lanjutan, model ini dapat dikembangkan menjadi alat penapisan (*screening*) yang andal dan terstandarisasi.

## 4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengimplementasikan model *Clinical Decision Support System* (CDSS) berbasis *Machine Learning* menggunakan algoritma *Random Forest Classifier* untuk memprediksi risiko konversi *Clinically Isolated Syndrome* (CIS) menjadi *Multiple Sclerosis* (MS) secara akurat dan terinterpretasi. Studi ini berfokus pada integrasi data *multimodal* pasien, termasuk variabel demografi, karakteristik gejala awal, temuan pencitraan *Magnetic Resonance Imaging* (MRI), dan hasil laboratorium *Oligoclonal Bands* (OCB). Untuk mengatasi tantangan utama dalam diagnosis klinis—yaitu pentingnya meminimalkan risiko *False Positive* yang dapat menyebabkan kecemasan pasien atau intervensi pengobatan yang tidak perlu—metodologi penelitian dioptimalkan secara ketat melalui penyesuaian bobot kelas dan penetapan *Custom Threshold* sebesar 0.57. Hasil evaluasi kinerja menunjukkan model *Random Forest* mencapai kemampuan prediktif yang sangat baik dengan Akurasi 81,82% dan nilai *Area Under the Curve* (AUC) 0.9140, menunjukkan robustes model dalam membedakan pasien risiko tinggi dan risiko rendah. Melalui analisis *Feature Importance* yang transparan, kami mengonfirmasi bahwa *Oligoclonal Bands* (OCB) adalah prediktor tunggal yang paling signifikan, diikuti oleh jenis *Initial Symptom* dan lokasi lesi MRI *Periventricular*, yang memperkuat pemahaman klinis tentang patogenesis konversi. Sementara itu, Rao [19] menekankan pentingnya *feature engineering* yang tepat untuk meningkatkan interpretabilitas model prediktif berbasis data neurologis, sehingga hasil model dapat lebih mudah ditranslasikan ke dalam konteks klinis. Implementasi model ke dalam sistem berbasis web berfungsi sebagai kontribusi praktis yang menjembatani kesenjangan antara hasil penelitian komputasi dan adopsi klinis, menyediakan alat bantu yang cepat dan teruji untuk membantu neurolog dalam pengambilan keputusan prognosis dan inisiasi terapi *Disease-Modifying Therapies* (DMTs) secara dini dan hati-hati. Berdasarkan hasil eksperimen dan analisis yang dilakukan, dapat ditarik beberapa kesimpulan utama: a) Kinerja Model: Model *Random Forest* menunjukkan kinerja klasifikasi yang sangat baik dengan Akurasi 81,82%, F1-Score 0.82, dan nilai *Area Under the Curve* (AUC) mencapai 0.9140. Hal ini membuktikan bahwa pendekatan *ensemble learning* mampu menangani kompleksitas data klinis neurologis dengan tingkat diskriminasi yang tinggi. b) Faktor Determinan: Analisis interpretasi fitur (*feature importance*) mengidentifikasi bahwa *Oligoclonal Bands* (OCB), karakteristik gejala awal (*Initial Symptom*), dan Lesi MRI (khususnya pada *spinal cord* dan *periventricular*) merupakan indikator biologis terkuat dalam memprediksi konversi. Temuan ini memvalidasi relevansi model terhadap patofisiologi penyakit MS. c) Implementasi Sistem: Penerapan ambang batas keputusan (*custom threshold*) konservatif sebesar 0.57 pada sistem berbasis web terbukti efektif dalam memprioritaskan spesifisitas diagnosis. Sistem ini dirancang sebagai *Clinical Decision Support System* (CDSS) untuk membantu tenaga medis dalam melakukan penapisan (*screening*) risiko secara lebih objektif. Saran untuk pengembangan penelitian selanjutnya meliputi: a) Memperluas dataset dengan mengintegrasikan data klinis dari rumah sakit di Indonesia untuk meningkatkan representasi demografi lokal. b) Menerapkan teknik *Explainable AI* (XAI) yang lebih canggih seperti SHAP (*Shapley Additive Explanations*) untuk memberikan transparansi prediksi pada level individu pasien. c) Melakukan validasi eksternal pada dataset independen untuk menguji daya generalisasi model sebelum penerapan klinis skala luas. Secara keseluruhan, penelitian ini membuktikan bahwa integrasi *machine learning* dengan data klinis memiliki potensi besar dalam mendukung deteksi dini dan pengambilan keputusan medis yang presisi pada kasus penyakit neurologis. Kaur et al. [20] menekankan bahwa integrasi teknik *Explainable AI* (XAI) penting untuk memahami kontribusi tiap variabel dalam model prediktif MS, sehingga hasil prediksi lebih mudah diterima oleh klinisi.

## UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada **Universitas Bina Sarana Informatika (UBSI)** atas segala dukungan, fasilitas, serta bimbingan yang telah diberikan selama proses penelitian dan penyusunan artikel ini berlangsung. Penghargaan yang tulus juga penulis sampaikan kepada seluruh dosen dan rekan sejawat di **Program Studi Informatika dan Teknologi Informasi UBSI** atas arahan, saran konstruktif, serta motivasi yang tiada henti, sehingga penelitian ini dapat terselesaikan dengan baik. Secara khusus, penulis ingin menyampaikan terima kasih spesial kepada **Hutao** atas dukungan emosional, kesabaran, dan semangat yang selalu diberikan, yang menjadi sumber kekuatan tersendiri bagi penulis dalam menyelesaikan karya ini.

## REFERENCES

- [1] A. Nugroho and R. Rahmawati, "Implementasi Machine Learning untuk deteksi dini penyakit neurologis," *Jurnal MISI*, vol. 7, no. 2, pp. 33–40, 2023.
- [2] A. H. Wibowo, "Analisis performa model pembelajaran mesin dalam prediksi penyakit berdasarkan data medis," *Jurnal Sistem Informasi dan Komputerisasi Akuntansi (JUSIKA)*, vol. 6, no. 1, pp. 23–32, 2022.
- [3] C. Zhang and others, "Data imbalance handling in medical classification using Random Forest ensemble," *Appl Soft Comput*, vol. 122, p. 108919, 2022.
- [4] D. Gebre, "Conversion Predictors of CIS to Multiple Sclerosis," 2022, *Kaggle Dataset*.
- [5] E. Marini and others, "Feature importance in machine learning models for neurological diseases," *Artif Intell Med*, vol. 131, p. 102365, 2022.
- [6] F. M. Collins and R. H. Morris, "Clinical implications of early CIS conversion: A data-driven analysis," *Neurol Res Int*, vol. 2023, pp. 1–10, 2023.
- [7] H. J. Kim, "Optimization of Random Forest hyperparameters for medical data classification," *Comput Biol Med*, vol. 140, p. 105086, 2022.
- [8] I. P. Wirawan and A. Setiawan, "Penerapan algoritma Random Forest untuk prediksi penyakit stroke," *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 2, pp. 145–153, 2023.
- [9] B. Rahmani and T. Yu, "Risk Stratification of Clinically Isolated Syndrome for Multiple Sclerosis Development," *Med Res Arch*, vol. 13, no. 10, 2025.
- [10] S. Mendanha and K. R. Gudibandi, "Comparative Analysis of Machine Learning Algorithms for Conversion Predictors of Clinically Isolated Syndrome (CIS) to Multiple Sclerosis (MS)," in *IEEE Conference on Data Analysis and Deep Learning*, 2025.
- [11] N. Puspitasari and D. Riyadi, "Integrasi sistem prediksi penyakit berbasis web dengan algoritma Random Forest," *Jurnal Manajemen Informatika dan Sistem Informasi (MISI)*, vol. 8, no. 1, pp. 45–54, 2024.
- [12] H. Hu, L. Ye, P. Wu, Z. Shi, G. Chen, and Y. Li, "Exploring factors driving the evolution of chronic lesions in multiple sclerosis using machine learning," *Eur Radiol*, 2025.
- [13] Z. Wang and others, "Medical data-driven prediction of multiple sclerosis using ensemble learning," *Sci Data*, vol. 9, no. 221, pp. 1–10, 2022.
- [14] S. Sima and others, "Predictive modeling for conversion from clinically isolated syndrome to multiple sclerosis using random forest," *Neuroinformatics Journal*, vol. 19, no. 4, pp. 511–523, 2023.
- [15] Y. Zhao and others, "Random Forest-based clinical decision support for multiple sclerosis," *Front Neurosci*, vol. 16, pp. 221–234, 2022.
- [16] S. Al-Khayer and others, "Deep learning and Random Forests for early detection of MS lesions in MRI," *Comput Biol Med*, vol. 144, p. 105325, 2022.
- [17] M. Goyal, A. Singh, and P. Kumar, "Machine learning-based early diagnosis of multiple sclerosis using MRI data," *Biocybern Biomed Eng*, vol. 42, no. 3, pp. 857–871, 2022.
- [18] H. Khan, H. C. Woodruff, D. L. Giraldo, and L. Werthen-Brabants, "Leveraging Hand-Crafted Radiomics on Multicenter FLAIR MRI for Predicting Disability Progression in People with Multiple Sclerosis," *medRxiv*, 2025.
- [19] S. P. Rao, "Feature engineering and model interpretability in multiple sclerosis prediction," *Int J Med Inform*, vol. 157, p. 104651, 2022.
- [20] Z. Kaur and others, "Explainable machine learning for MS progression analysis," *Front Artif Intell*, vol. 5, p. 902315, 2023.