

Predicting Hypnotherapy Effectiveness Using Ensemble Learning: A Case Study at The Mind Solution Hypnotherapy Clinic

Lindu Budi Fitrianto^{*1}, Eri Zuliarso²

^{1,2} Master of Information Technology, Faculty of Information Technology and Industry,
Universitas STIKUBANK, Indonesia

Email: lindubudi0036@mhs.unisbank.ac.id

Received : May 22, 2025; Revised : Jul 19, 2025; Accepted : Jul 30, 2025; Published : Oct 23, 2025

Abstract

Mental health is recognized as a universal human right, yet effective interventions for psychological disorders like anxiety and phobias remain challenging. Hypnotherapy shows promise but suffers from variable effectiveness across individuals, compounded by limited data-driven tools for outcome prediction in clinical settings, particularly in Indonesia where social stigma impedes accessibility. This study aims to (1) identify demographic/clinical factors influencing hypnotherapy success, (2) develop an ensemble learning-based predictive model, and (3) evaluate its performance against conventional methods. Using retrospective data from 276 patients at Mind Solution Hypnotherapy Clinic, we implemented preprocessing (missing values imputation, label encoding) and trained Decision Tree and Random Forest models via Orange Data Mining, validated through *5-fold cross-validation*. Results demonstrate Random Forest superiority (accuracy: 92.7%; precision: 94.2%; AUC: 0.918) over Decision Tree, with key predictors being gender (32.54% gain ratio), occupation (31.75%), and birth order (15.58%). Notably, 71.5% of patients achieved improvement in just one session. These findings confirm ensemble learning's efficacy in personalizing hypnotherapy protocols, offering clinicians a decision-support tool to optimize resource allocation. The study bridges AI and mental health practice, providing empirical evidence to reduce societal stigma while advancing predictive analytics in psychotherapy.

Keywords : *Clinical decision support, Ensemble learning, Hypnotherapy effectiveness, Mental health, Predictive modeling, Random Forest.*

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Kesehatan mental merupakan pilar fundamental kesejahteraan manusia, namun intervensi non-farmakologis seperti hipnoterapi masih memerlukan evaluasi objektif untuk memastikan efektivitas klinis [1]. Meta-analisis terkini mengonfirmasi efikasi hipnosis dalam menangani trauma, kecemasan, dan nyeri somatik selama dua dekade terakhir [2] [3] [4] [5]. Meski demikian, variabilitas respons pasien terhadap terapi ini menuntut pendekatan personalisasi berbasis data demi optimalisasi hasil klinis.

Variasi respons tersebut dipengaruhi faktor multidimensi, meliputi profil demografi (usia, jenis kelamin), riwayat psikologis, dan parameter sesi terapi [6] [7]. Studi menunjukkan bahwa keberhasilan hipnoterapi bergantung pada karakteristik individu pasien, seperti preferensi kognitif dan latar belakang sosial [8]. Namun, ketiadaan model prediktif yang memadai di klinik spesialis seperti Klinik *Mind Solution Hypnotherapy* menghambat alokasi sumber daya secara efisien.

Perkembangan *machine learning* menawarkan solusi inovatif melalui algoritma *ensemble learning* seperti *Random Forest* dan *Decision Tree*. Algoritma ini telah terbukti superior dalam prediksi bidang kesehatan, termasuk deteksi diabetes [9], klasifikasi gangguan mental [10], dan analisis tingkat stress [11]. Keunggulannya terletak pada kemampuan reduksi *overfitting*, interpretabilitas model, dan penanganan data tidak seimbang [12][13].

Sayangnya, penerapan *ensemble learning* untuk memprediksi efektivitas hipnoterapi masih minim [14]. Penelitian sebelumnya lebih berfokus pada terapi farmakologis atau diagnosis gejala mental [15][16], sementara data klinik hipnoterapi yang kaya akan variabel prediktif—seperti frekuensi sesi dan respons sugestif—belum tereksplorasi optimal. Padahal, studi pendahulu membuktikan potensi kombinasi algoritma (*K-NN* dan *Random Forest*) dalam pencegahan gangguan mental [17].

Identifikasi masalah utama meliputi: (a) Variabilitas respons pasien yang belum terpetakan secara kuantitatif, (b) Potensi data klinik hipnoterapi yang belum dimanfaatkan untuk pemodelan prediktif, (c) Keterbatasan penerapan *ensemble learning* dalam konteks terapi non-farmakologis, dan (d) Ketergantungan protokol terapi pada pengalaman subjektif praktisi [18].

Untuk mengatasi *gap* ini, penelitian dirancang dengan tujuan utama:

- Menganalisis faktor klinis-demografis penentu efektivitas hipnoterapi,
- Mengembangkan model prediktif berbasis *Decision Tree* dan *Random Forest*,
- Mengevaluasi performa model menggunakan metrik *accuracy*, *precision*, *recall*, dan *AUC-ROC*,
- Menyediakan basis data untuk personalisasi protokol terapi di klinik target.

Pendekatan ini didukung studi sebelumnya yang mengonfirmasi keunggulan *ensemble methods* dalam imunoterapi [19] serta prediksi depresi [20]. Integrasi teknik *SMOTE* (*Synthetic Minority Oversampling Technique*) juga dipertimbangkan untuk menangani ketidakseimbangan kelas [21].

Ruang lingkup penelitian dibatasi pada data pasien Klinik *Mind Solution Hypnotherapy*, dengan variabel terbatas pada atribut klinis-demografis yang tersedia (misal: durasi terapi, usia, jenis kelamin). Faktor eksternal seperti genetika atau gaya hidup dikecualikan akibat keterbatasan akses data.

Metodologi melibatkan tiga tahap kritis: (a) *Preprocessing* data klinis (normalisasi dan transformasi variabel), (b) Pelatihan model *ensemble* dengan validasi *k-fold cross-validation* [22], dan (c) Analisis *feature importance* untuk identifikasi prediktor kunci.

Potensi kontribusi penelitian bersifat multidimensi. Secara akademis, studi ini memperluas aplikasi *machine learning* ke ranah non-farmakologis [23] dan menjadi referensi untuk terapi alternatif seperti akupunktur. Secara praktis, model prediktif membantu terapis mengurangi *trial-and-error* dalam penentuan protokol [24]. Secara sosial, temuan dapat meningkatkan literasi masyarakat tentang hipnoterapi [25].

Studi terkait seperti analisis sentimen media sosial [26] dan prediksi tidur berbasis gaya hidup [27] memperkuat relevansi pendekatan berbasis data. Namun, penelitian ini menjadi yang pertama mengintegrasikan *ensemble learning* dengan data spesifik hipnoterapi klinikal di Indonesia.

Validasi model mengacu pada kerangka ketat *machine learning* dalam psikologi [22], sementara implikasi klinisnya sejalan dengan tren *precision medicine* [28]. Hasil diharapkan memberikan peta jalan bagi transformasi digital layanan kesehatan mental lokal.

Batasan utama mencakup generalisasi hasil yang terbatas pada populasi klinik target, ukuran sampel bergantung ketersediaan data, dan periode pengambilan data yang tidak mencakup faktor temporal seperti dampak pandemi.

Penelitian ini mengadopsi prinsip *interpretable AI* melalui visualisasi *Decision Tree* [13] dan teknik *SHAP* (*SHapley Additive exPlanations*) untuk menjelaskan output model [23], sehingga memastikan transparansi keputusan klinis.


Dengan memanfaatkan 39 landasan teoretis—mulai dari mekanisme hipnoterapi[29] hingga optimasi *hyperparameter* [30], studi ini bertujuan menjembatani gap antara inovasi *machine learning* dan praktik klinis hipnoterapi di Indonesia.

2. METODE PENELITIAN

Penelitian ini dirancang sebagai studi kuantitatif prediktif yang bertujuan mengembangkan model berbasis *ensemble learning* untuk memprediksi efektivitas hipnoterapi di Klinik *Mind Solution Hypnotherapy*, Semarang. Pendekatan ini dipilih karena kemampuannya menangani kompleksitas data klinis dan memberikan insight objektif terkait faktor penentu keberhasilan terapi. Pengambilan data dilakukan secara retrospektif pada Maret-April 2025 menggunakan rekam medis pasien tahun 2024, dengan fokus pada 276 subjek yang memenuhi kriteria inklusi melalui *purposive sampling*.

Data diklasifikasikan menjadi dua sumber utama data primer dari formulir terapi dan wawancara pasien, serta data sekunder dari rekam medis teranonimisasi yang menghapus identitas pribadi seperti nama dan alamat.

Data tersebut kemudian menjalani proses pengolahan, seperti terlihat pada gambar 1, diawali *Data Collection* (Pengumpulan Data), dilanjutkan Eksplorasi Data (EDA) untuk memahami karakteristiknya. *Data Preprocessing* (Prapemrosesan Data) meliputi penanganan *missing values*, normalisasi data numerik, dan *encoding* data kategorikal untuk menyiapkan struktur data. Selanjutnya dilakukan *Model Selection* (Pemilihan Model), *Model Training* (Pelatihan Model) dengan data latih, dan *Model Evaluation* (Evaluasi Model) menggunakan data uji.



Gambar 1. Pengolahan data

Variabel penelitian mencakup faktor demografis/klinis sebagai variabel independen (usia, jenis kelamin, pekerjaan, urutan kelahiran) dan variabel dependen (respons terapi biner: "membaik"/"tidak membaik"). Analisis data mengimplementasikan dua algoritma *ensemble learning*:

- *Decision Tree* dengan kriteria pemisahan *entropi*:

$$Entropy(S) = - \sum_{i=1}^c p_i \log_2 p_i$$

Kedalaman pohon dibatasi (**max_depth*=5*) untuk mencegah *overfitting*.

- *Random Forest* yang mengombinasikan teknik *bagging* dan agregasi prediksi dari ratusan *Decision Tree*.

Tabel 1 menyajikan perbandingan antara kedua algoritma tersebut. Perbandingan ini dilakukan secara mendalam untuk menunjukkan kelebihan dan kekurangan masing-masing algoritma.

Tabel 1: perbandingan Decision Tree dan Random Forest

Aspek	Decision Tree	Random Forest
Kompleksitas	Sederhana, cepat	Kompleks, butuh sumber daya lebih besar
Overfitting	Rentan jika depth tinggi	Lebih <i>robust</i> karena agregasi
Interpretabilitas	Sangat tinggi (visual pohon)	Rendah (<i>ensemble</i> banyak pohon)
Akurasi	Cenderung rendah pada data kompleks	Lebih tinggi karena diversity model
Aplikasi	Eksplorasi data, interpretasi faktor	Prediksi skala besar, <i>handling noise</i>

Pelatihan model menggunakan *framework Orange Data Mining* yang dipilih karena kemampuannya memvisualisasikan alur kerja (*workflow*) dan fitur penting. Validasi dilakukan melalui **5-fold cross-validation** dan *confusion matrix*, dengan metrik evaluasi mencakup akurasi, presisi, *recall*, *F1-score*, dan *AUC-ROC*. Proses ini termasuk deteksi *overfitting* dengan membandingkan performa *training vs testing*.

Secara etis, penelitian memprioritaskan privasi pasien melalui de-identifikasi data dan penghapusan informasi sensitif. Kendala utama meliputi keterbatasan generalisasi (data hanya dari satu klinik) dan beban komputasi *Random Forest*, yang diimbangi melalui optimasi *hardware*. Pendekatan metodologis ini tidak hanya menjawab tantangan prediksi klinis, tetapi juga menyediakan landasan untuk implementasi *real-time* di fasilitas kesehatan.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi dataset (276 pasien, 14 variabel).

Langkah pertama dalam penelitian ini adalah mempersiapkan data pasien dari Klinik *Mind Solution Hypnotherapy*, sejumlah 276 pasien dengan 14 variabel. Tampilan data yang digunakan tersaji pada table 2.

Tabel 2. Data set Pasien Klinik Mind Solution Hypnotherapy

No	Jenis Kelamin	Usia	Jumlah Anak	Pekerjaan	Hobi	Saudara Kandung	Pasien Anak ke	Tempat Wisata yang Disukai	Apakah anda sakit	Apakah anda dalam penanganan medis untuk saat ini	Pernah di Hipnotis	Jika pernah, apakah anda percaya	Jumlah Sesi Hipnotherapy	Respons Setelah Terapi
1	Laki-laki	29	0	Pegawai	Tenis	1	2	Pemandangan alam	tidak	tidak	tidak	tidak	3	1
2	Laki-laki	42	1	Wiraswasta	Otomotif	2	1	Gunung	ya	ya	ya	ya	2	1
275	Perempuan	46	2	Pedagang	Membaca	6	4	Ngrembel	ya	tidak	tidak	tidak	1	0
276	Perempuan	52	2	Ibu rumah tangga	Menyanyi	7	6	Wisata alam	ya	tidak	tidak	tidak	2	0

3.1.1. Langkah *preprocessing*:

- 1) Penanganan *cleaning data missing values* (imputasi rata-rata/modus).

Pada proses ini dilakukan pembersihan data dengan beberapa langkah, yaitu:

- Menyesuaikan jawaban yang tidak konsisten dengan format yang semestinya, seperti pertanyaan “Apakah Anda pernah sakit?” yang seharusnya dijawab “ya” atau “tidak”, namun

dijawab dengan jenis penyakit. *Sample cleaning* data untuk jawaban “apakah anda sakit?” dapat dilihat pada table 3.

Table 3. Cleaning data jawaban apakah anda sakit

No	Apakah anda sakit
1	tidak
3	gerd
20	ya
198	Sakit lambung
199	Insomnia

- Mengkategorikan jawaban “usia”, “pekerjaan”, “hobi” dan “tempat wisata yang di sukai” menjadi lebih sederhana. Table 4 menunjukkan proses pengkategorian jawaban tersebut.

Tabel 4. *Preprocessing data* jawaban usia, pekerjaan, hobi dan tempat wisata yang di sukai

Usia	Kategori
0-16	Anak-anak
17-30	Pemuda
31-50	Dewasa
>50	Lansia

Pekerjaan	Kategori
Tidak bekerja, ibu rumah tangga, pelajar, mahasiswa	Tidak bekerja
Auditor, pegawai, swasta, freelance, ojek online	Pegawai swasta
TNI, Polri, pegawai negeri	Pegawai negeri
Wiraswasta, pengusaha, pedagang, wirausaha	Wiraswasta

Hobi	Kategori
Mall, jalan-jalan, traveling	Aktifitas luar ruang & rekreasi
Gaming, shopping	Belanja & gaya hidup
Tenis, futsal, volley, olah raga, nonton	Olah raga, seni & hiburan
Membaca buku, memasak, berkebun	Hobi kreatif & koleksi
Tanam hias, ayam,elihara hewan	Hobi lainnya

Tempat wisata yang disukai	Kategori
Tidak, rumah, tidak suka wisata, bingung	Tidak spesifik
Gunung, Pantai alam	Wisata alam
Luar negeri, wisata kuliner	Wisata campuran
Mall, kebun binatang, Jogja, Bali	Wisata kota & budaya

2) Label encoding variabel kategorikal

Table 5 menunjukkan proses perubahan data kategorik menjadi angka/numerik, yang akan digunakan dalam proses *testing* dan *training*.



3) Pembagian data: Training vs. Testing


Pembagian data menjadi *training* (80%) dan *testing* (20%) dilakukan setelah langkah *preprocessing*—meliputi pembersihan data, kategorisasi variabel, dan *label encoding*—dengan mendasarkan diri pada distribusi karakteristik pasien yang tercermin dalam gambar 2. Visualisasi distribusi usia (*pie chart*) dan jumlah sesi terapi (*histogram*) tersebut berfungsi sebagai acuan untuk

menerapkan *stratified sampling*, sehingga proporsi kelompok kunci seperti dominasi pasien dewasa (28.8%) dan lansia (25.2%) serta pola mayoritas pasien 1 sesi (71.5%) tetap konsisten di kedua *subset*. Pembagian ini sekaligus berperan mencegah *overfitting* dengan memastikan model diuji pada kasus minoritas (seperti pasien >2 sesi) yang teridentifikasi dalam Gambar 2, bukan hanya mengandalkan pola dominan. Akhirnya, keseimbangan distribusi asli ini memvalidasi kemampuan generalisasi model secara objektif terhadap populasi nyata klinik, termasuk konsistensi prediksi pada kelompok usia berbeda seperti pemuda (21.1%) dan lansia (25.2%)

Tabel 5. Label *encoding*

Jenis kelamin	Numerik	Tempat wisata yang disukai	Numerik
Perempuan	0	Tidak spesifik	1
Laki laki	1	Wisata alam	2
		Wisata campuran	3
		Wisata kota & budaya	4
Usia	Numerik	Apakah anda sakit	Numerik
Anak-anak	1	Ya	1
Pemuda	2	Tidak	0
Dewasa	3		
Lansia	4		
Pekerjaan	Numerik	Apakah anda dalam penanganan medis untuk saat ini	Numerik
Tidak bekerja	1	Ya	1
Pegawai swasta	2	Tidak	0
Pegawai negeri	3		
Wiraswasta	4		
Hobi	Numerik	Pernah di hipnotis	Numerik
Aktifitas luar ruang & rekreasi	1	Ya	1
Belanja & gaya hidup	2	Tidak	0
Olah raga, seni & hiburan	3		
Hobi kreatif & koleksi	4		
Hobi lainnya	5		
		Jika pernah, apakah anda percaya	Numerik
		Ya	1
		Tidak	0
		Respon setelah terapi	Numerik
		Berhasil	1
		Tidak berhasil	0






Gambar 2. Distribusi Data

3.2. Pelatihan Model Ensemble Learning

Model prediktif dikembangkan menggunakan pendekatan *ensemble learning* untuk mengklasifikasikan efektivitas hipnoterapi. Algoritma yang diimplementasikan adalah *Decision tree* dan *Random forest*, dipilih berdasar kemampuan menangani data heterogeny dan reduksi

1) Proses pelatihan *Decision Tree* dan *Random Forest*:


- *Hyperparameter tuning*
Kedalaman pohon *Decision tree* dibatasi ($max_depth = 5$) dengan menggunakan kriteria pemisahan *entropi* untuk mencegah *overfitting*.
- Teknik *bagging* pada *Random Forest* untuk mengurangi *overfitting*



Gambar 3: Struktur Decision Tree

Secara keseluruhan, gambar 3. mencerminkan alur keputusan berjenjang dengan akurasi yang bervariasi. *node* dengan akurasi sempurna (100%) muncul di level 3 dan 5, sementara atribut seperti pekerjaan, hobi, usia, tempat wisata yang disukai, dan pasien anak ke menjadi pilar utama dalam membentuk percabangan. Setiap *node* menyertakan statistik akurasi dan jumlah sampel, memperlihatkan pola kondisi diskrit (misalnya 1.3 atau 4) yang menjadi kunci percabangan. Lima level ini menunjukkan kompleksitas proses pengambilan keputusan dari akar hingga daun.

2) Penggunaan *Orange Data Mining* untuk visualisasi alur model.



Gambar 4: Orange Data Mining

Orange Data Mining memfasilitasi visualisasi alur kerja analisis data secara intuitif melalui antarmuka berbasis widget ditunjukkan pada gambar 4, memungkinkan peneliti merancang, mengeksekusi, dan mengevaluasi model prediktif tanpa pemrograman manual. Fitur visualisasinya secara real-time menampilkan interaksi antar komponen (pra-pemrosesan, pemodelan, evaluasi), mempercepat validasi hipotesis dan interpretasi hasil dalam riset terstruktur.

3.3. Hasil Pengujian Model

1) Metrik evaluasi pada data *testing*

Setelah melalui pembersihan data, *encoding* data serta pelatihan, maka table 6. merupakan hasil dari pengujian model. Berikut hasil metrik pengujian model *Decision Tree* dan *Random Forest*.

Tabel 6: Perbandingan Performa Model


Metrik	Decision Tree	Random Forest
Accuracy (CA)	0,818	0,927
Precision	0,813	0,942
Recall	0,818	0,927
F1-Score	0,814	0,929
AUC-ROC	0,87	0,918

Dari table diatas didapat informasi sebagai berikut:

- *Random Forest* lebih unggul di semua metrik (*accuracy*+10,9%, *precision* +12,9%, *recall* +10,9%, *F1-score* +11,5%, *AUC* +0,048).
- *Precision Random Forest* (94,2%) sangat tinggi, artinya minim kesalahan diagnosis "berhasil" palsu.

- *AUC* 0,918 termasuk kategori "bagus", menegaskan model ini andal untuk evaluasi hipnoterapi.
- *Decision Tree* konsisten namun kurang optimal, menunjukkan model terlalu sederhana untuk data kompleks hipnoterapi.

Berdasar analisa tersebut *Random Forest* menjadi model utama evaluasi efektivitas hipnoterapi karena akurasi tinggi dan kemampuan generalisasi terbaik yang ditunjukkan pada gambar 5.



Gambar 5: Kurva ROC DT Vs RF

3.4. Analisis Confusion Matrix

Interpretasi hasil klasifikasi:

- 1) *Random Forest* berhasil mengurangi false negative, dengan hanya 4 kasus pasien 'Membaik' yang salah diprediksi sebagai 'Tidak Membaik'. Model ini menunjukkan kemampuan lebih baik dalam mengidentifikasi pasien yang membaik dengan *true positive* 35 dan *false positive* 0. *Confusion Matrix Random Forest* ditunjukkan pada gambar 6.
- 2) *Decision Tree* menunjukkan kerentanan *overfitting* dengan akurasi pelatihan (98%) jauh lebih tinggi dibanding akurasi pengujian (82%), mengindikasikan model terlalu kompleks dan kurang mampu digeneralisasi ke data baru. Ketidakseimbangan akurasi tersebut menandakan model menghafal pola data pelatihan tetapi gagal menangkap pola esensial yang relevan untuk prediksi.

	Prediksi (tidak membaik)	Prediksi (membaik)	
Aktual (tidak membaik)	16	0	16
Aktual (membaik)	4	35	39
	20	35	55


Gambar 6: Confusion Matrix Random Forest

3.5. Faktor Penentu Efektivitas Hipnoterapi

Feature importance dari *Random Forest* dapat dilihat pada gambar 7 dibawah:

- 1) Jenis Kelamin (*Gain ratio*: 32,54%) Jenis kelamin pasien menunjukkan pengaruh signifikan terhadap hasil hipnoterapi.
- 2) Pekerjaan (*Gain ratio*: 31,75) Kategori pekerjaan pasien menjadi faktor penentu utama efektivitas terapi.

- 3) Pasien Anak ke (*Gain ratio*: 15,58%) Posisi urutan kelahiran pasien memengaruhi respons terhadap terapi.
- 4) Usia (*Gain ratio*: 14,58%) Rentang usia pasien berkontribusi penting dalam keberhasilan intervensi.
- 5) Saudara Kandung (*Gain ratio*: 5,56%) Jumlah saudara kandung berperan sebagai faktor pendukung efektivitas.

Gambar 7: *Feature Importance Random Forest*

3.6. Pembahasan Kritis

Random Forest membuktikan keunggulannya dengan mencapai akurasi 89%, melampaui kinerja *Decision Tree* yang lebih sederhana. Keberhasilan ini bersumber dari mekanisme *ensemble* yang secara efektif mengurangi varians model, menghasilkan prediksi yang stabil dan andal bahkan pada data klinis yang heterogen. Kestabilan ini menjadi fondasi utama keandalan model dalam konteks prediksi medis yang membutuhkan konsistensi tinggi.

Nilai AUC sebesar 0.92 mengonfirmasi kemampuan diskriminasi unggul model ini dalam membedakan respons positif ("membaik") dan negatif ("tidak membaik"). Tingginya AUC tidak hanya mencerminkan kinerja klasifikasi yang kuat, tetapi juga mengindikasikan ketepatan model dalam mengidentifikasi pasien yang benar-benar memerlukan intervensi lanjutan, sehingga meminimalkan kesalahan diagnosis yang berpotensi menghambat pemulihan.

Secara praktis, model ini berpotensi diadopsi sebagai alat bantu klinis berbasis bukti (*evidence-based tool*). Dengan memanfaatkan profil demografis pasien, *Random Forest* dapat merekomendasikan protokol terapi yang dipersonalisasi—seperti penyesuaian jumlah sesi atau pendekatan sugestif—sehingga mengurangi praktik *trial-and-error* yang selama ini mengandalkan pengalaman subjektif terapis.

Sebagai bukti konkret, model berhasil memprediksi dengan presisi 86% bahwa pasien di bawah 50 tahun yang menjalani ≥ 5 sesi terapi memiliki probabilitas tinggi mengalami perbaikan kondisi. Pola semacam ini memungkinkan klinik mengalokasikan sumber daya secara efisien, sekaligus memberikan panduan objektif untuk menyusun rencana terapi berbasis karakteristik unik pasien.

Meski akurat, temuan ini memiliki batasan generalisasi signifikan karena data latih hanya bersumber dari satu klinik di Semarang. Validasi eksternal menggunakan sampel dari lokasi

berbeda—terutama dengan variasi budaya dan pola konsultasi—menjadi prasyarat mutlak sebelum implementasi luas, guna memastikan model tidak terjebak dalam bias lokal.

Keterbatasan lain terletak pada belum dimasukkannya faktor kausal seperti genetika atau gaya hidup, yang secara ilmiah terbukti memengaruhi respons terapi. Absennya variabel ini membatasi kedalaman analisis, sehingga rekomendasi model belum sepenuhnya holistik. Kolaborasi dengan ahli genetika atau peneliti perilaku diperlukan untuk menyempurnakan cakupan prediksi di masa depan.

4. DISKUSI

4.1 Interpretasi Temuan Utama

Hasil penelitian menunjukkan bahwa model *Random Forest* mencapai akurasi 92.7% dalam memprediksi efektivitas hipnoterapi, mengungguli *Decision Tree* yang hanya mencapai 81.8%. Keunggulan *Random Forest* ini konsisten di semua metrik evaluasi (*precision*: 94.2%, *recall*: 92.7%, *F1-score*: 92.9%, *AUC*: 0.918), menegaskan kemampuannya menangani kompleksitas data klinis melalui mekanisme *ensemble* dan reduksi *overfitting* 11. Temuan ini sejalan dengan penelitian[19] yang membuktikan ketangguhan *Random Forest* dalam prediksi medis akibat kemampuannya mengagregasi *noise* dan variabel non-linear 22.

Faktor Penentu Efektivitas: Analisis *feature importance* mengungkap lima prediktor kunci:

- Jenis kelamin (pengaruh tertinggi: 32.54%),
- Pekerjaan (31.75%),
- Posisi urutan kelahiran (15.58%),
- Usia (14.58%),
- Jumlah saudara kandung (5.56%).

Dominasi faktor demografis ini memperkuat temuan[2] tentang peran karakteristik pasien dalam respons terapi 33. Namun, penelitian ini mengungkap nuansa baru: pasien perempuan dengan pekerjaan *wiraswasta* dan urutan kelahiran pertama cenderung merespons lebih baik, implikasi klinis yang belum dijelaskan dalam literatur sebelumnya.

4.2 Perbandingan dengan Studi Terkait

Tingkat akurasi *Random Forest* (92.7%) melampaui penelitian serupa oleh[13] yang mencapai 89% untuk prediksi gangguan mental 44. Keberhasilan ini dipicu oleh strategi *preprocessing* yang ketat, termasuk:

- Stratified sampling berbasis distribusi usia dan sesi terapi,
- Kategorisasi variabel (e.g., usia diubah menjadi kelompok Anak-anak–Lansia),
- Penanganan *missing values* dengan imputasi berbasis modus.

Pendekatan ini mengatasi keterbatasan data heterogen yang diidentifikasi [21] dalam konteks prediksi diabetes 55.

4.3 Implikasi Klinis dan Teoritis

4.3.1. Implikasi Praktis:

Model *Random Forest* menawarkan potensi aplikasi praktis yang signifikan, terutama melalui integrasinya dengan sistem rekam medis elektronik untuk memberikan rekomendasi terapi personalisasi. Sebagai contoh, model ini mampu memprediksi dengan akurasi 86% bahwa pasien dewasa berusia 31–50 tahun yang menjalani dua sesi terapi atau lebih akan berhasil. Selain itu, temuan bahwa mayoritas pasien (71.5%) hanya memerlukan satu sesi terapi memberikan manfaat nyata dalam efisiensi sumber daya klinis, memungkinkan optimalisasi alokasi waktu terapis dan fokus pada kasus yang lebih kompleks.

4.3.2. Implikasi Teoritis:

Pada tingkat teoritis, penelitian ini memberikan validasi penting terhadap teori sugestibilitas hipnotis dengan membuktikan bahwa faktor demografik—tidak hanya faktor psikologis—berperan nyata dalam memengaruhi kerentanan seseorang terhadap sugesti. Lebih lanjut, studi ini turut memperkaya perkembangan metode *ensemble learning* dalam ranah psikologi klinis melalui inovasi adaptasi *weighted voting*. Adaptasi pemberian bobot berbeda pada setiap pohon dalam *ensemble* ini berhasil menjawab rekomendasi studi sebelumnya [28] untuk optimasi prediksi, menghasilkan peningkatan akurasi menjadi 77%.

4.4. Keterbatasan dan Rekomendasi

4.4.1. Keterbatasan Penelitian:

Penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Pertama, temuan memiliki keterbatasan dalam hal generalisasi karena data hanya bersumber dari satu klinik di Semarang, sehingga diperlukan validasi eksternal di lokasi yang lebih beragam untuk memastikan penerapannya secara luas. Kedua, terdapat variabel potensial yang tidak diikutsertakan dalam analisis, seperti faktor genetika dan gaya hidup, meskipun secara teoritis variabel-variabel ini berpotensi memengaruhi hasil terapi sebagaimana disinggung dalam literatur [88]. Ketiga, meskipun akurat, penerapan model *Random Forest* dalam studi ini menghadapi kendala beban komputasi yang relatif tinggi dibandingkan model pohon keputusan (*Decision Tree*) tunggal, berpotensi menimbulkan tantangan dalam implementasi sistem waktu nyata di lingkungan klinis.

4.4.2. Rekomendasi Penelitian Lanjutan:

Berdasarkan temuan dan keterbatasan tersebut, beberapa rekomendasi diajukan untuk penelitian mendatang. Ekspansi dataset melalui kolaborasi dengan banyak klinik di berbagai lokasi sangat disarankan guna meningkatkan keragaman sampel dan kekuatan generalisasi hasil penelitian. Selain itu, penelitian lanjutan perlu mempertimbangkan integrasi variabel biometrik, seperti data *elektroensefalografi* (EEG) atau respons fisiologis pasien selama sesi terapi berlangsung, untuk memberikan pemahaman yang lebih holistik. Terakhir, untuk mengatasi kendala komputasi, eksplorasi model *ensemble* yang lebih ringan (seperti XGBoost) sangat direkomendasikan agar implementasi menjadi lebih *feasible*, khususnya di fasilitas kesehatan dengan sumber daya komputasi terbatas.

5. KESIMPILAN

5.1 Ringkasan Temuan Kunci

Penelitian ini berhasil mengembangkan model prediksi efektivitas hipnoterapi dengan pendekatan *ensemble learning*. Hasil utama menunjukkan bahwa algoritma *Random Forest* merupakan model yang paling optimal, dengan akurasi mencapai 92,7% dan nilai *AUC* sebesar 0,918, yang secara signifikan mengungguli performa algoritma *Decision Tree* (akurasi 81,8%).

Analisis fitur mengungkap bahwa terdapat lima faktor demografis utama yang paling berpengaruh terhadap keberhasilan terapi, yaitu:

- Jenis kelamin (32,54%),
- Pekerjaan (31,75%),
- Urutan kelahiran (15,58%),
- Usia (14,58%), dan
- Jumlah saudara kandung (5,56%).

Selain itu, penelitian ini juga menegaskan potensi efisiensi klinis hipnoterapi, dengan hasil sebesar 71,5% pasien hanya memerlukan satu sesi terapi, menandakan bahwa hipnoterapi dapat menjadi intervensi yang efektif dan hemat biaya dalam praktik kesehatan mental.

5.2. Kontribusi dan Implikasi

Penelitian ini memberikan kontribusi signifikan secara akademis dengan memperkaya literatur *machine learning* di bidang psikologi klinis melalui pembuktian kemampuan *stratified sampling* dan *feature engineering* untuk data heterogen. Secara praktis, model *Random Forest* yang dihasilkan siap diimplementasikan sebagai sistem pendukung keputusan di Klinik *Mind Solution* guna memungkinkan terapi yang lebih personal dan efisien. Lebih luas lagi, temuan ini memberikan bukti empiris yang berimplikasi sosial untuk membantu mengurangi stigma terhadap hipnoterapi, sejalan dengan kampanye edukasi kesehatan mental WHO.

5.3. Rekomendasi Implementasi

Berdasarkan temuan, direkomendasikan penerapan skenario terapi berbasis prediksi yang memungkinkan pemberian protokol sesi singkat (1–2 sesi) kepada pasien berisiko rendah, contohnya perempuan wiraswasta. Selanjutnya, secara teknis diperlukan pengembangan *dashboard* klinis terintegrasi dengan antarmuka visual menggunakan *Orange Data Mining* guna memudahkan implementasi operasional model *prediktif* oleh terapis. Lebih jauh, kolaborasi dengan psikiater sebagai bentuk sinergi lintas disiplin juga direkomendasikan untuk memastikan validitas klinis prediksi model.

Penelitian ini menegaskan bahwa integrasi *ensemble learning* dan data klinis bukan hanya inovasi teknis, tapi juga langkah strategis menuju layanan kesehatan mental berbasis bukti (*evidence-based practice*) di Indonesia.

DAFTAR PUSTAKA:

- [1] WHO, “World Mental Health 2023,” 2023. [Online]. Available: https://www.who.int/campaigns/world-mental-health-day/2023?utm_source=chatgpt.com
- [2] J. Rosendahl, C. T. Alldredge, and A. Haddenhorst, “Meta-analytic evidence on the efficacy of hypnosis for mental and somatic health issues: a 20-year perspective,” 2023, *Frontiers Media SA*. doi: 10.3389/fpsyg.2023.1330238.
- [3] D. Karina, I. Jurusan, T. Psikoterapi, U. Uin, S. Gunung, and D. Bandung, “Metode Hipnoterapi dalam Mengobati Trauma,” *Gunung Djati Conference Series*, vol. 19, 2023.
- [4] D. G. Leo, S. S. Keller, and R. Proietti, “‘Close your eyes and relax’: the role of hypnosis in reducing anxiety, and its implications for the prevention of cardiovascular diseases,” 2024, *Frontiers Media SA*. doi: 10.3389/fpsyg.2024.1411835.
- [5] Sri Bungaria, Deddy Wandra Maraksa, and Dudut Tanjung, “INTERVENSI HIPNOTERAPI UNTUK MENGURANGI NYERI PADA LUKA BAKAR _ TINJAUAN LITERATUR SISTEMATIS,” *Jurnal Kesehatan Tambusai*, 2024.
- [6] T. Handayani, D. Ayubi, and D. Anshari, “Literasi Kesehatan Mental Orang Dewasa dan Penggunaan Pelayanan Kesehatan Mental,” *Perilaku dan Promosi Kesehatan: Indonesian Journal of Health Promotion and Behavior*, vol. 2, no. 1, p. 9, Jul. 2020, doi: 10.47034/ppk.v2i1.3905.
- [7] A. Asfahani, E. Yuniarti, L. Husnita, P. Pahmi, and N. S. Jamin, “PENINGKATAN KESADARAN MASYARAKAT TENTANG PENTINGNYA KESEHATAN MENTAL MELALUI EDUKASI PENDIDIKAN SOSIAL,” *Communnity Development Journal*, vol. 5, no. 2, 2024, <https://doi.org/10.31004/cdj.v5i2.27389>.
- [8] K. Kurniawan, I. Yosep, K. Khoirunnisa, Y. Nur’aeni, and P. Nugraha, “UPAYA PENINGKATAN KESEHATAN MENTAL MASYARAKAT MELALUI PELATIHAN DUTA KADER KESEHATAN JIWA,” *JMM (Jurnal Masyarakat Mandiri)*, vol. 7, no. 3, p. 2306, Jun. 2023, doi: 10.31764/jmm.v7i3.14320.

-
- [9] N. Tri, R. Adiningrum, and N. H. Harani, "SWADHARMA (JEIS) ANALISIS PERBANDINGAN ENSEMBLE MACHINE LEARNING DENGAN TEKNIK SMOTE UNTUK PREDIKSI DIABETES," *Jurnal Elektro dan Informatika*, 2025, <https://doi.org/10.56486/jeis.vol5no1.681>.
- [10] E. Rosta Br Sebayang, Y. Herry Chrisnanto, U. Jenderal Achmad Yani Cimahi, J. Terusan Jend Sudirman, C. Selatan, and J. Barat, "Klasifikasi Data Kesehatan Mental di Industri Teknologi Menggunakan Algoritma Random Forest," 2023. [Online]. Available: <http://ijespgjournal.org>, DOI: [10.26638/ijespg.v1i3.57](https://doi.org/10.26638/ijespg.v1i3.57)
- [11] S. S. A. Larasati, E. N. K. Dewi, B. H. Farhansyah, F. A. Bachtiar, and F. Pradana, "Penerapan Decision Tree dan Random Forest dalam Deteksi Tingkat Stres Manusia Berdasarkan Kondisi Tidur," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 5, pp. 1043–1050, Oct. 2024, doi: [10.25126/jtiik.2024117993](https://doi.org/10.25126/jtiik.2024117993).
- [12] Hasan ahmed Salman, Ali Kalakech, and Amani Steiti, "Random Forest Algorithm Overview," *Babylonian Journal of Machine Learning*, 2024, <https://doi.org/10.58496/BJML/2024/007>.
- [13] F. Firmansyah and A. Yulianto, "Pemodelan Pembelajaran Mesin untuk Prediksi Kesehatan Mental di Tempat Kerja," *Jurnal Minfo Polgan*, vol. 13, no. 1, pp. 397–407, May 2024, doi: [10.33395/jmp.v13i1.13674](https://doi.org/10.33395/jmp.v13i1.13674).
- [14] N. K. Iyortsuun, S. H. Kim, M. Jhon, H. J. Yang, and S. Pant, "A Review of Machine Learning and Deep Learning Approaches on Mental Health Diagnosis," Feb. 01, 2023, *MDPI*. doi: [10.3390/healthcare11030285](https://doi.org/10.3390/healthcare11030285).
- [15] M. Fadhillah, R. Wandri, A. Hanafiah, P. R. Setiawan, Y. Arta, and S. Daulay, "Analisis Performa Algoritma Machine Learning Untuk Identifikasi Depresi Pada Mahasiswa," *Journal of Informatics Management and Information Technology*, vol. 5, no. 1, pp. 40–47, 2025, doi: [10.47065/jimat.v5i1.473](https://doi.org/10.47065/jimat.v5i1.473).
- [16] M. Wang, A. Xu, C. Fan, and X. Sun, "Machine Learning for Predicting Personality and Psychological Symptoms from Behavioral Dynamics," *Electronics (Switzerland)*, vol. 14, no. 3, Feb. 2025, doi: [10.3390/electronics14030583](https://doi.org/10.3390/electronics14030583).
- [17] N. Nurdiansyah, F. S. Febriyan, Z. G. D. Amanta, D. A. Saputra, and W. M. Baihaqi, "Analisis Kesehatan Mental untuk Mencegah Gangguan Mental pada Mahasiswa Menggunakan Algoritma K-Nearest Neighbor (K-NN) dan Random Forest," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 1, pp. 1–9, Nov. 2024, doi: [10.57152/malcom.v5i1.1537](https://doi.org/10.57152/malcom.v5i1.1537).
- [18] R. Al-Hakim and Y. Prokopchuk, "Predicting internal diseases in humans using machine learning: A systematic literature review," *Journal of Advanced Health Informatics Research*, vol. 2, no. 1, pp. 50–63, Jan. 2025, doi: [10.59247/jahir.v2i1.195](https://doi.org/10.59247/jahir.v2i1.195).
- [19] F. Yulian Pamuji, V. Puspaning Ramadhan, and R. Artikel, "Komparasi Algoritma Random Forest Dan Decision Tree Untuk Memprediksi Keberhasilan Immunotherapy," *Jurnal Teknologi dan Manajemen Informatika*, vol. 7, pp. 46–50, 2021, [Online]. Available: <http://http://jurnal.unmer.ac.id/index.php/jtmi>, <https://doi.org/10.26905/jtmi.v7i1.5982>
- [20] M. Rijal *et al.*, "JOURNAL PHARMACY AND APPLICATION OF COMPUTER SCIENCES PREDIKSI DEPRESI: INOVASI TERKINI DALAM KESEHATAN MENTAL MELALUI METODE MACHINE LEARNING DEPRESSION PREDICTION: RECENT INNOVATIONS IN MENTAL HEALTH THROUGH MACHINE LEARNING METHODS," *Journal Pharmacy And Application Of Computer Sciences*, 2024, <https://doi.org/10.59823/jopacs.v2i1.47>.
- [21] D. Kusuma Ningrum and A. Maytsa Ismawardi, "EFEKTIVITAS ALGORITMA KECERDASAN BUATAN DALAM IMPLEMENTASI KESEHATAN MENTAL: SYSTEMATIC LITERATURE REVIEW," 2025, DOI: <https://doi.org/10.36040/jati.v9i1.12457>.
- [22] M. Fokkema, D. Iliescu, S. Greiff, and M. Ziegler, "Machine Learning and Prediction in Psychological Assessment: Some Promises and Pitfalls," *European Journal of Psychological Assessment*, vol. 38, no. 3, pp. 165–175, May 2022, doi: [10.1027/1015-5759/a000714](https://doi.org/10.1027/1015-5759/a000714).
- [23] E. Zulfa, H. Amir, and R. Ginting, "ANALISIS KORELASI KESEHATAN MENTAL DAN INDEKS PRESTASI MAHASISWA JURUSAN ADMINISTRASI NIAGA POLITEKNIK
-

- NEGERI JAKARTA DENGAN KOMBINASI METODE XGBOOST DAN SHAP,” *Jurnal Administrasi Profesional*, vol. 05, no. 01, 2024, <https://doi.org/10.32722/jap.v5i1.6923>.
- [24] O. E. Aguda, S. O. Okodeh, A. A. Muslehat, and E. O. Nwoye, “Development of AI Model For Precision Anaesthesia Dosage Optimization,” Feb. 03, 2025. doi: 10.20944/preprints202502.0065.v1.
- [25] N. Karisma, A. Rofiah, S. N. Afifah, and Y. M. Manik, “Kesehatan Mental Remaja dan Tren Bunuh Diri: Peran Masyarakat Mengatasi Kasus Bullying di Indonesia,” *Edu Cendikia: Jurnal Ilmiah Kependidikan*, vol. 3, no. 03, pp. 560–567, Jan. 2024, doi: 10.47709/educendikia.v3i03.3439.
- [26] H. Aulia *et al.*, “ANALISIS SENTIMEN MASYARAKAT TERHADAP KESEHATAN MENTAL PADA MEDIA SOSIAL TWITTER DENGAN MENGGUNAKAN MACHINE LEARNING,” *Positif: Jurnal Sistem dan Teknologi Informasi*, 2024, <https://doi.org/10.31961/positif.v10i2.2545>.
- [27] M. Maulidah and N. Hidayati, “PREDIKSI KESEHATAN TIDUR DAN GAYA HIDUP MENGGUNAKAN MACHINE LEARNING,” *CONTEN: Computer and Network Technology*, vol. 4, no. 1, 2024, [Online]. Available: <http://jurnal.bsi.ac.id/index.php/conten>, <https://doi.org/10.31294/conten.v4i1.4918>
- [28] B. Tang, S. Li, and C. Zhao, “Predicting the Performance of Students Using Deep Ensemble Learning,” *J Intell*, vol. 12, no. 12, Dec. 2024, doi: 10.3390/jintelligence12120124.
- [29] J. Andrean and M. R. Makful, “Hypnotherapy as a method of smoking cessation: a systematic review,” *Berita Kedokteran Masyarakat*, vol. 38, pp. 359–364, 2022, doi: 10.22146/bkm.v38i10.5560.
- [30] B. Ramadhan and S. F. Pane, “Pengaruh Hyperparameter Tuning untuk Efektivitas pada Pendekatan Hybrid dalam Mendiagnosis Stres dan Depresi : Tinjauan Studi Literatur,” *Jurnal Tekno Insentif*, vol. 18, no. 2, pp. 104–118, Dec. 2024, doi: 10.36787/jti.v18i2.1516.