

Classification of the Effectiveness of Balur Therapy on Patients at the Malang Health Center Using the Decision Tree Algorithm

Riski Puji Lestari¹, Mochammad Anshori^{2*}, Wahyu Teja Kusuma³

^{1,2,3}Informatika, Fakultas Sains dan Teknologi, Institut Teknologi, Sains, dan Kesehatan RS.dr. Soepraoen Kesdam V/BRW
riskipujilestari796@gmail.com¹, moanshori@itsk-soepraoen.ac.id^{2*}, wtkusuma@itsk-soepraoen.ac.id³

Article Info

Article history:

Received 2026-04-04

Revised 2026-04-26

Accepted 2026-05-05

Keyword:

Balur Therapy,
Classification,
Decision Tree,
LIME,
Machine Learning.

ABSTRACT

This study addresses the classification of balur therapy effectiveness as a complementary treatment using a machine learning approach, aiming to develop an accurate, balanced, and transparent model to support clinical decision-making. The methodology employs the Decision Tree algorithm, data imbalance handling using Synthetic Minority Oversampling Technique, and model interpretation through Local Interpretable Model-Agnostic Explanations. The dataset consists of 520 medical records, reduced to 478 after preprocessing, including data cleaning, binning, and outlier removal. The results indicate that the model without data balancing achieved the highest specificity of 0.8276 at a 90:10 split ratio, while the application of Synthetic Minority Oversampling Technique improved sensitivity toward the minority class but reduced specificity. Key influential features include occupation, diagnosis, and therapy duration. The interpretability analysis demonstrates that the model can clearly explain feature contributions to predictions. This study concludes that integrating classification, data balancing, and explainable modeling enhances medical data analysis. The findings imply strong potential for developing objective and transparent clinical decision support systems.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Terapi balur merupakan bentuk pengobatan komplementer yang mengintegrasikan pendekatan tradisional dan modern dalam upaya meningkatkan kesehatan pasien secara holistik. Terapi ini memanfaatkan bahan herbal kaya antioksidan seperti fermentasi kelor dan bawang sabrang[1]. Dikombinasikan dengan teknik *grounding* menggunakan lempengan tembaga serta pembungkusan tubuh dengan aluminium foil untuk mempercepat proses detoksifikasi melalui kulit [2]. Dalam perspektif ilmiah, pendekatan ini dikaitkan dengan konsep nano-sains dan biofisika yang berfokus pada eliminasi radikal bebas dan logam berat dalam tubuh [3]. Seiring berkembangnya teknologi di bidang kesehatan, pemanfaatan data rekam medis untuk analisis berbasis kecerdasan buatan menjadi semakin penting. *Machine learning* sebagai bagian dari kecerdasan buatan telah banyak digunakan untuk prediksi, klasifikasi, dan pengenalan pola dalam data klinis [4]. Berbagai penelitian menunjukkan bahwa algoritma klasifikasi seperti *Decision Tree* memiliki

kinerja yang baik dalam menangani data medis yang kompleks serta mampu memberikan interpretasi yang mudah dipahami oleh praktisi kesehatan [5]. Selain itu, konsep *Explainable Artificial Intelligence* (XAI) menjadi perhatian utama dalam pengembangan sistem berbasis AI di bidang kesehatan karena mampu memberikan transparansi dalam pengambilan keputusan model [6].

Penelitian ini merupakan sebuah *pilot project* yang bertujuan untuk menjembatani terapi balur dengan teknologi *machine learning*. Hingga saat ini, belum terdapat penelitian yang secara spesifik menerapkan algoritma klasifikasi untuk mengevaluasi efektivitas terapi balur, sehingga penelitian ini menjadi studi perintis (*pioneering study*) dalam domain tersebut. Permasalahan utama dalam penelitian ini adalah belum adanya model klasifikasi berbasis *machine learning* yang mampu mengidentifikasi tingkat efektivitas terapi balur secara objektif berdasarkan data rekam medis pasien. Selain itu, tantangan lain yang dihadapi adalah ketidakseimbangan distribusi data antara kelas Efektif dan Kurang Efektif yang dapat menyebabkan bias pada model klasifikasi[7]. Kondisi

ini menuntut pengembangan pendekatan yang tidak hanya mampu meningkatkan akurasi klasifikasi, tetapi juga menjaga keseimbangan performa model serta menyediakan interpretasi yang dapat dipahami oleh tenaga medis.


Berbagai solusi telah dikembangkan dalam literatur untuk mengatasi permasalahan klasifikasi pada data medis. Salah satu algoritma yang banyak digunakan adalah *Decision Tree* karena kemampuannya dalam menangani data numerik dan kategorikal serta menghasilkan model yang transparan [8]. *Decision Tree* bekerja dengan membangun struktur pohon berdasarkan perhitungan *entropy* dan *information gain* untuk menentukan atribut terbaik dalam proses pemisahan data [9]. Selain itu, untuk mengatasi bias pada atribut dengan banyak kategori, digunakan pendekatan *gain ratio* [10]. Di sisi lain, permasalahan ketidakseimbangan data sering diatasi dengan teknik *oversampling* seperti *Synthetic Minority Oversampling Technique* (SMOTE), yang mampu meningkatkan jumlah sampel pada kelas minoritas tanpa menghilangkan informasi penting [11]. Dalam konteks interpretasi model, metode seperti *Local Interpretable Model-Agnostic Explanations* (LIME) telah digunakan untuk memberikan penjelasan lokal terhadap prediksi model sehingga meningkatkan transparansi dan kepercayaan pengguna [12].

Sejumlah penelitian sebelumnya telah menunjukkan keberhasilan penggunaan *Decision Tree* dalam berbagai kasus medis. Misalnya, algoritma ini mampu mencapai akurasi hingga 90% dalam penilaian risiko luka baring pada pasien imobilisasi [13], serta 90,38% dalam klasifikasi penyakit diabetes [14]. Selain itu, penelitian lain melaporkan

akurasi sebesar 96,67% dalam klasifikasi diagnosis pasien di klinik [15]. Di sisi lain, penerapan teknik SMOTE terbukti efektif dalam meningkatkan performa model pada data yang tidak seimbang dengan meningkatkan nilai recall dan F1-score pada kelas minoritas [16]. Penggunaan metode interpretasi seperti LIME juga telah banyak diterapkan dalam berbagai studi untuk menjelaskan keputusan model berbasis machine learning secara lebih transparan [17]. Namun demikian, integrasi antara *Decision Tree*, SMOTE, dan LIME dalam konteks klasifikasi efektivitas terapi balur masih belum banyak diteliti. Hal ini menunjukkan adanya kesenjangan penelitian, khususnya dalam pengembangan model yang tidak hanya akurat tetapi juga dapat diinterpretasikan secara klinis dalam domain terapi komplementer.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan untuk membangun model klasifikasi efektivitas terapi balur pada pasien di Rumah Sehat Malang menggunakan algoritma *Decision Tree*. Penelitian ini mengusulkan penggunaan teknik SMOTE untuk mengatasi ketidakseimbangan data serta integrasi metode LIME untuk meningkatkan interpretabilitas model. Kebaruan penelitian ini terletak pada kombinasi pendekatan klasifikasi, penyeimbangan data dan interpretasi model pada domain terapi balur. Hipotesis yang diajukan adalah bahwa penerapan *Decision Tree* yang dioptimasi dengan SMOTE dan didukung oleh LIME mampu menghasilkan model klasifikasi yang akurat, seimbang dan transparan sebagai dasar pengambilan keputusan klinis yang berbasis data.

II. METODE



Gambar 1. Alur Penelitian

A. Identifikasi Masalah dan Tujuan

Berdasarkan hasil forum group discussion (FGD) dengan tenaga medis di Rumah Sehat Malang, diketahui bahwa penelitian terkait terapi balur sebelumnya telah dilakukan penelitian dengan metode *in vitro* namun belum memanfaatkan metode machine learning untuk klasifikasi efektivitas terapi. Oleh karena itu, penelitian ini bertujuan membangun model klasifikasi menggunakan algoritma *Decision Tree* serta mengidentifikasi fitur dominan yang memengaruhi keberhasilan terapi guna mendukung pengambilan keputusan klinis.

B. Pengumpulan Data

Data berisi 520 yang bersumber dari data primer berupa rekam medis pasien terapi balur. Data diperoleh secara resmi dengan izin dari pihak Rumah Sehat Malang dan telah melalui

proses validasi oleh dokter ahli (*expert validation*) untuk memastikan keakuratan label kelas.

TABEL 1.
IDENTIFIKASI VARIABEL REKAM MEDIS PASIEN TERAPI BALUR

Variabel	Tipe Data
Jenis Kelamin	Kategorikal
Usia	Numerikal
Pekerjaan	String
Diagnosa	String
Status Merokok	Kategorikal
Durasi Total Terapi	Numerikal
Kelas	Kategorikal

Variabel yang digunakan mencakup karakteristik demografis dan klinis pasien, yaitu usia, jenis kelamin, pekerjaan, diagnosa, status merokok, dan durasi total terapi,

dengan variabel target berupa tingkat efektivitas terapi (Efektif dan Kurang Efektif).

C. Pra Pemrosesan

Pra Pemrosesan data bertujuan meningkatkan kualitas data sebelum digunakan dalam pelatihan model. Tahap ini meliputi beberapa proses. Pertama, pembersihan data dilakukan dengan menghapus atribut yang tidak relevan seperti identitas pasien dan informasi administratif, serta memastikan konsistensi label kelas [18]. Kedua, rekayasa fitur dilakukan melalui teknik data binning untuk mengelompokkan variabel numerik seperti usia dan durasi terapi ke dalam kategori tertentu guna mengurangi kompleksitas dan meningkatkan interpretabilitas [19].

TABEL 2. VARIABEL BINNING

Variabel	Binning	Kriteria/Rentang Nilai
Usia	Anak-anak	<18
	Dewasa Muda	<35
	Dewasa	<50
	Lansia Muda	<65
	Lansia	>65
Durasi Total Terapi	Sangat singkat	<=5
	Singkat	<=10
	Sedang	<=20
	Panjang	>20
Pekerjaan	Non Produktif	Ibu rumah, irt, rumah tangga
	PNS/ASN	PNS, guru, dosen, polri, TNI, pegawai
	Swasta	Swasta, karyawan, pegawai
	Wiraswasta	Wiraswasta, dagang, pedagang, usaha
	Pensiunan	Pensiun, pensiunan
	Pelajar	Pelajar, mahasiswa, siswa, siswi
	Lainnya	Lain-lain
Durasi Total Terapi	Sangat singkat	<=5
	Singkat	<=10
	Sedang	<=20
	Panjang	>20
Pekerjaan	Non Produktif	Ibu rumah, irt, rumah tangga
	PNS/ASN	PNS, guru, dosen, polri, TNI, pegawai
	Swasta	Swasta, karyawan, pegawai
	Wiraswasta	Wiraswasta, dagang, pedagang, usaha
	Pensiunan	Pensiun, pensiunan
	Pelajar	Pelajar, mahasiswa, siswa, siswi
	Lainnya	Lain-lain
Diagnosa	Kanker/tumor	Kanker, ca, tumor, kista, myoma, lymphoma, leukimia, melanoma, neurofibroma, hemangioma
	Metabolik	Diabetes, dm, kolestarol, asam urat, gula

Kardiovaskular	Jantung, hipertensi, cardio, stroke, ht, pulmonary, cardiomegaly
Respirasi	Paru, tb, tbc, pneumonia, bronchitis, asma, sinusitis
Ginjal/kemih	Ginjal, batu ginjal, prostat, hemoroid, bph, nefro
Pencernaan	Lambung, maag, gastritis, gerd, hepar, hepatitis, cirrhosis
Reproduksi	Mamae, payudara, serviks, ovarium, invertility, haid, menopause
Lainnya	Lain-lain

Selain itu, dilakukan label encoding untuk mengubah data kategorikal menjadi numerik agar dapat diproses oleh algoritma [20]. Ketiga, penanganan data pencilan (*outlier*) dilakukan menggunakan metode *Interquartile Range* (IQR) untuk menghindari bias model, serta penghapusan data duplikat guna menjaga objektivitas pelatihan [21]. Keempat, dilakukan penyeimbangan data menggunakan *Synthetic Minority Oversampling Technique* (SMOTE) untuk mengatasi ketidakseimbangan kelas dengan menambahkan data sintetis pada kelas minoritas [22].

$$P_{ij} = X_i + random(0,1) * (X_{ij} - X_i) \tag{1}$$

Persamaan(1) adalah rumus SMOTE untuk membuat data baru dengan cara interpolasi (menghubungkan) sampel yang sudah ada. Tujuannya adalah menciptakan data tiruan (sintetis) bagi kelas yang jumlahnya minoritas, sehingga seluruh dataset menjadi seimbang. P_{ij} merupakan data baru yang disintesis, x_i adalah data sampel dari kelas minoritas yang dipilih, x_{ij} adalah salah satu tetangga terdekat dari x_i dan $random(0,1)$ adalah bilangan acak antara 0 dan 1. Terakhir, data dibagi menjadi data latih dan data uji menggunakan teknik *stratified split* dengan rasio 70:30, 80:20, dan 90:10 untuk menjaga proporsi distribusi kelas [23].

D. Pembangunan Model

Pembangunan model klasifikasi menggunakan algoritma *Decision Tree* dipilih karena kemampuannya dalam menghasilkan model yang transparan dan mudah diinterpretasikan [24]. Proses pembentukan pohon keputusan dimulai dengan menghitung nilai *entropy* untuk mengukur tingkat ketidakpastian data [25].

$$Entropy(S) = \sum_i^m = 1 P_i \log_2(pi) \tag{2}$$

Persamaan 2 untuk mencari nilai *entropy*, dimana m adalah jumlah kelas klasifikasi dan P_i jumlah proposi sampel (peluang) untuk kelas i.

Selanjutnya, dilakukan perhitungan *information gain* untuk menentukan atribut terbaik dalam proses pemisahan data [26].

$$Gain(S, A) = Entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} * Entropy(S_i) \quad (3)$$

Untuk mengatasi bias terhadap atribut dengan banyak kategori, digunakan *gain ratio* yang mempertimbangkan nilai *split information*[27]. Model dibangun melalui eksperimen komparatif antara skenario dengan dan tanpa SMOTE pada berbagai rasio pembagian data, sehingga diperoleh model dengan performa optimal.

$$SplitInfo(S, A) = -\sum \left(\frac{n_i}{n} \right) = 1 - \frac{Si}{S} \log_2 \frac{Si}{S} \quad (4)$$

Persamaan 4 berikut untuk menghitung *split info* yang dimana S merupakan jumlah total pada himpunan S (sebelum dibagi berdasarkan atribut A), A sebagai atribut, n Jumlah atribut/kategori, Si Jumlah sampel untuk atribut i .

$$Gain\ ratio = \frac{Gain(S,A)}{Split\ Information(S,A)} \quad (5)$$

Persamaan 5 untuk mengatasi masalah pada atribut yang memiliki nilai sangat bervariasi. *Gain ratio* tertinggi dipilih sebagai atribut test untuk simpul.

E. Evaluasi Kinerja & Interpretasi Model

Penelitian ini menetapkan *Specificity* sebagai metrik evaluasi utama dalam mengukur kinerja model klasifikasi *Decision Tree* untuk menentukan efektivitas terapi balur. Penggunaan *specificity* yang dihitung berdasarkan rasio *True Negative* terhadap total observasi kelas negative dipilih secara strategis untuk meminimalisir risiko kesalahan *False Positive*, yakni kondisi di mana model salah mengklasifikasikan terapi sebagai efektif bagi pasien yang sebenarnya tidak merespons pengobatan. Dalam konteks klinis di Rumah Sehat Malang, pemilihan metrik ini didasarkan pada prinsip kehati-hatian medis (*clinical conservatism*), di mana kemampuan model untuk mengidentifikasi kasus yang "tidak efektif" secara akurat jauh lebih krusial untuk mencegah penyusutan informasi terapi. Dengan memprioritaskan *specificity* sebagai parameter tunggal dalam tahap *pilot project* ini, penelitian bertujuan untuk memastikan bahwa model yang dikembangkan memiliki integritas praktis dalam menyaring pasien yang memerlukan peninjauan medis lebih lanjut atau perubahan rencana terapi, sehingga sistem pendukung keputusan yang dihasilkan benar-benar dapat diandalkan untuk mendukung pengambilan keputusan klinis yang aman dan tepat sasaran. Dengan rumus *specificity* pada persamaan 6 :

$$Specificity = \frac{True\ Negative}{True\ Negative + False\ Positive} \quad (6)$$

Selain evaluasi performa, penelitian ini juga menekankan pada interpretasi model. Model *Decision Tree* divisualisasikan dalam bentuk struktur pohon untuk menunjukkan alur pengambilan keputusan berdasarkan fitur-fitur klinis. Selain itu, dilakukan *perhitungan feature importance* untuk mengidentifikasi variabel yang paling

berpengaruh dalam klasifikasi[30]. Untuk meningkatkan transparansi model sesuai prinsip *Explainable Artificial Intelligence* (XAI), digunakan metode *Local Interpretable Model-Agnostic Explanations* (LIME). Metode ini bekerja dengan membangun model lokal sederhana untuk menjelaskan prediksi pada setiap individu, sehingga memungkinkan identifikasi kontribusi masing-masing fitur terhadap hasil klasifikasi [31]. Keandalan utama LIME terletak pada sifatnya yang *model-agnostic*, yang berarti dapat digunakan untuk menjelaskan algoritma *machine learning* apapun tanpa perlu mengetahui struktur internalnya. Selain itu, LIME mampu menangani hubungan fitur yang kompleks dan non-linear dengan cara menyederhanakannya menjadi model linear yang interpretable pada tingkat lokal[32]. Dengan begitu, hasil penjelasannya jadi lebih masuk akal dan mudah dimengerti sehingga dapat diketahui faktor spesifik apa yang membuat seorang pasien masuk kedalam kategori Efektif atau Kurang Efektif. Pada rumus LIME menunjukkan proses pencarian model sederhana (g) yang memiliki tingkat kesalahan terkecil (L) dalam meniru model asli (f) pada area lokal (π_x), dengan tetap menjaga tingkat kompleksitas model (Ω) sekecil mungkin agar mudah dipahami. Dengan rumus LIME pada persamaan 7:

$$explain(x) = arg\ min_{g \in G} L(f, g, \pi_x) + \Omega(g) \quad (7)$$

III. HASIL DAN PEMBAHASAN


A. Pengumpulan Data dan Hasil Pra Pemrosesan Data

TABEL 3
DESKRIPSI DATASET

Nama Kolom	Tipe Data	Nilai Variabel
Usia	Numerikal	0, 1, 2, 3, 4
Jenis Kelamin	Kategorikal	Perempuan atau Laki-laki
Pekerjaan	String	Non Produktif, PNS/ASN, Swasta, Wiraswasta, Pensiunan, Pelajar, Lainnya
Diagnosa	String	Kanker/tumor, Metabolik, Kardiovaskular, Respirasi, Ginjal/kemih, Pencernaan, Reproduksi Lainnya
Status Merokok	Kategorikal	Iya atau tidak
Durasi Total Terapi	Numerikal	0, 1, 2, 3
Kelas	Kategorikal	Efektif atau Tidak Efektif

Dataset yang digunakan terdiri dari 520 data rekam medis pasien dengan berbagai atribut demografis dan klinis. Jumlah data yang ada sekarang berkurang menjadi 478 data yang siap untuk pemodelan setelah proses pembersihan data, penanganan data pencilan, duplikat, dan penghapusan atribut yang tidak relevan. Proses ini menghilangkan 35 data pencilan dan 7 data duplikat, sehingga meningkatkan kualitas dan konsistensi data. Selain itu, penerapan teknik binning pada variabel usia dan durasi terapi berhasil

menyederhanakan variasi data numerik menjadi kategori yang lebih terstruktur, yang pada akhirnya meningkatkan kemampuan model dalam mengenali pola. Tahap pra-pemrosesan ini menjadi krusial karena kualitas data sangat memengaruhi performa model klasifikasi. Visualisasi mengenai data pencilan (*outlier*) pada variabel usia dan durasi total terapi yang teridentifikasi dalam proses ini disajikan pada Gambar 2:




Gambar 2. Visualisasi Outlier Menggunakan Violin Plot

Berdasarkan visualisasi Violin Plot pada Gambar 2, variabel Usia menunjukkan distribusi yang cenderung normal dengan pemusatan data pada rentang usia 40-60 tahun. Di sisi lain, variabel Durasi_Total_Terapi menunjukkan distribusi yang tidak normal (*positively skewed*) dengan mayoritas data terkonsentrasi pada durasi singkat, namun terdapat pencilan (*outliers*) pada durasi terapi yang lebih lama.

TABEL 4
PENANGANAN PENCILAN (OUTLIER) DAN DUPLIKAT

Kelas	Data Asli	Pra Pemrosesan Data	
		Pencilan (Outlier)	Penghapusan Data Duplikat
Efektif	317	23	4
Kurang Efektif	203	12	3

B. Analisis Performa Model dan Pengaruh SMOTE

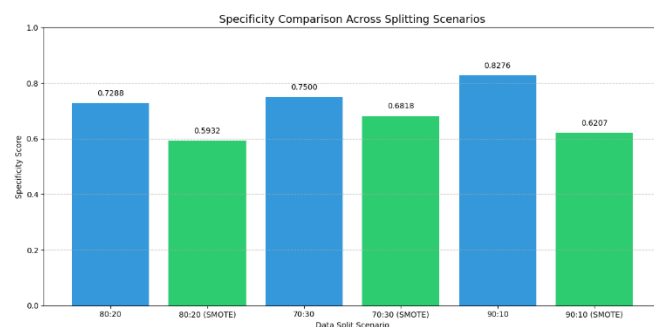


Gambar 3. Diagram distribusi kelas sebelum dan sesudah dilakukan SMOTE

Berdasarkan gambar 3, sebelum dilakukan penyeimbangan data, distribusi kelas menunjukkan dominasi kategori Efektif dengan 293 sampel dibandingkan Kurang Efektif dengan 185 sampel, sehingga berpotensi menyebabkan bias pada model. Model cenderung lebih akurat dalam memprediksi kelas

mayoritas, namun kurang optimal dalam mengenali pola pada kelas minoritas. Setelah diterapkan teknik Synthetic Minority Oversampling Technique (SMOTE), distribusi data latih menjadi lebih seimbang dengan 234 sampel untuk masing-masing kelas. Tindakan penyeimbangan data ini bertujuan untuk mengurangi ketergantungan model pada kelas mayoritas, sekaligus memperkuat kemampuan model dalam mengenali pola kelas minoritas, guna menghasilkan *output* klasifikasi yang konsisten dengan standar keamanan klinis. Hal ini sejalan dengan tujuan utama SMOTE, yaitu memperbaiki representasi kelas minoritas tanpa menghilangkan informasi penting.

C. Evaluasi performa model pada berbagai skenario pembagian data

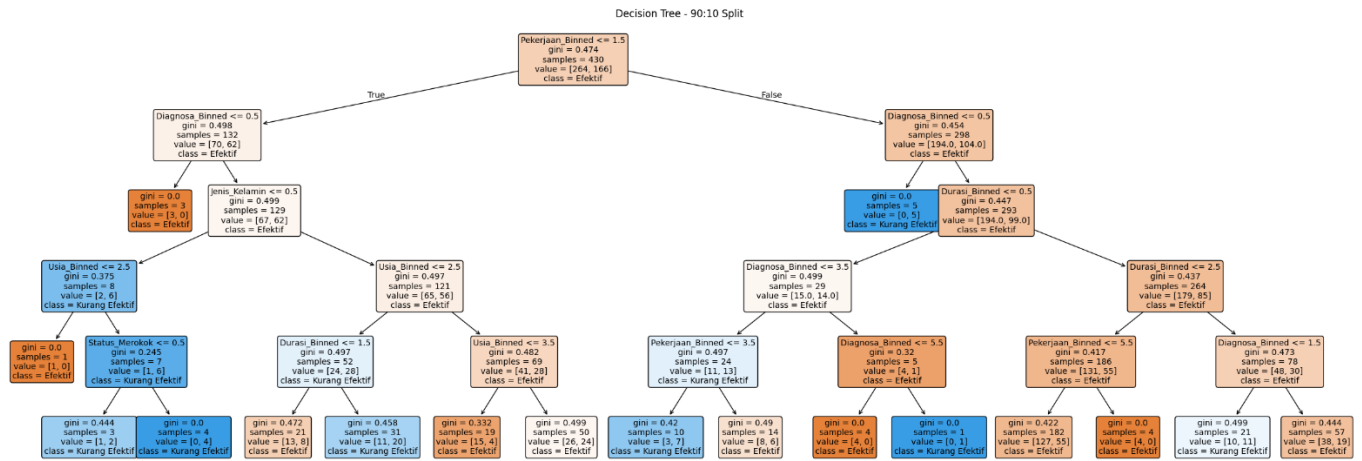


Gambar 4. Specificity pemisahan antar perbandingan skenario

Berdasarkan gambar 4, pengujian dilakukan menggunakan tiga rasio pembagian data, yaitu 70:30, 80:20, dan 90:10 untuk mengevaluasi nilai spesifisitas model. Pada rasio 90:10 tanpa SMOTE, model mencapai nilai spesifisitas tertinggi sebesar 0,8276, yang mengindikasikan kemampuan model yang sangat baik dalam mengenali kelas mayoritas (efektif). Namun, setelah penerapan SMOTE pada rasio ini, spesifisitas menurun menjadi 0,6207. Tren serupa juga terlihat pada rasio lainnya; pada rasio 70:30, spesifisitas turun dari 0,7500 menjadi 0,6818 dan pada rasio 80:20 turun dari 0,7288 menjadi 0,5932 setelah penggunaan SMOTE.

Penurunan nilai spesifisitas setelah penerapan SMOTE ini merupakan konsekuensi logis dari perubahan fokus model. Dengan penggunaan SMOTE, model diarahkan untuk lebih sensitif dalam mendeteksi kelas minoritas (Kurang Efektif), sehingga model menjadi kurang konservatif dalam memprediksi kelas mayoritas (negatif). Fenomena ini merefleksikan adanya *trade-off* antara peningkatan sensitivitas (*recall*) pada kelas minoritas dan upaya mempertahankan spesifisitas yang tinggi. Meskipun spesifisitas mengalami penurunan, penggunaan SMOTE tetap krusial untuk memitigasi bias model terhadap kelas mayoritas, sehingga menghasilkan performa klasifikasi yang lebih adil dan seimbang secara keseluruhan.

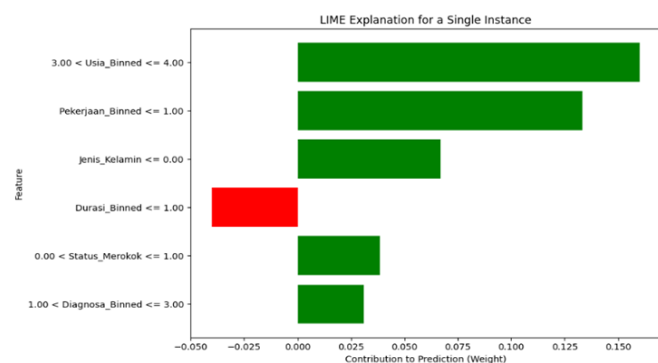
D. Interpretasi Model Decision Tree



Gambar 5. Visualisasi Decision Tree

Berdasarkan gambar 5, visualisasi pohon keputusan menunjukkan bahwa variabel pekerjaan menjadi root node atau faktor utama dalam proses klasifikasi, diikuti oleh variabel diagnosa, durasi terapi, jenis kelamin, dan usia. Pemilihan variabel pekerjaan sebagai node utama menunjukkan bahwa faktor aktivitas atau kondisi sosial ekonomi pasien memiliki pengaruh signifikan terhadap efektivitas terapi. Nilai Gini Impurity pada node awal menunjukkan tingkat heterogenitas data yang cukup tinggi, sehingga pemilihan atribut ini mampu memberikan pemisahan data yang optimal. Analisis feature importance juga mengonfirmasi bahwa pekerjaan, diagnosa, dan durasi terapi merupakan variabel paling dominan dalam menentukan hasil klasifikasi. Temuan ini memberikan wawasan klinis yang penting terkait faktor-faktor yang memengaruhi keberhasilan terapi balur.

E. Pengujian Dengan LIME (Local Interpretable Model-Agnostic Explanation)

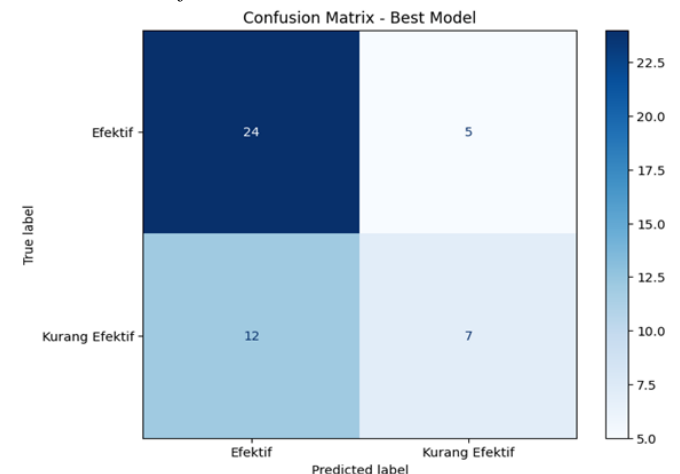


Gambar 6. Visualisasi LIME

Gambar 6 menyajikan visualisasi LIME untuk memberikan pemahaman mendalam pada tingkat individu pasien sebagai bagian dari pendekatan *Explainable Artificial Intelligence*

(XAI). Sebagai contoh, untuk salah satu *instance* pasien, fitur $3.00 < Usia_Binned \leq 4.00$ memberikan kontribusi positif terbesar terhadap prediksi model dengan bobot sebesar 0,16, yang berarti faktor usia pasien ini menjadi pendorong utama hasil klasifikasi model. Sebaliknya, fitur $Durasi_Binned \leq 1.00$ dan $1.00 < Diagnosa_Binned \leq 3.00$ masing-masing memberikan kontribusi negatif dengan bobot sekitar -0,04, yang menunjukkan bahwa faktor durasi terapi dan diagnosis tersebut cenderung berlawanan dengan prediksi model. Pendekatan ini memungkinkan tenaga medis untuk tidak hanya melihat hasil klasifikasi, tetapi juga memahami faktor-faktor penentu yang mendasari keputusan model secara objektif. Penggunaan LIME secara signifikan memperkuat transparansi model, memastikan bahwa sistem klasifikasi tidak bekerja sebagai kotak hitam (*black box*), melainkan dapat dijustifikasi secara logis dan klinis berdasarkan variabel rekam medis pasien.

F. Analisis Confusion Matrix dan Metrik Evaluasi



Gambar 7. Confusion Matrix

Gambar 7 bukti kemampuan model dalam mengklasifikasikan kelas Efektif dengan benar sebanyak 24

data, sedangkan 12 data salah diklasifikasikan sebagai Kurang Efektif. Untuk kelas Kurang Efektif, model berhasil mengklasifikasikan 7 data dengan tepat dan melakukan kesalahan pada 5 data yang diklasifikasikan sebagai Efektif. Berdasarkan hasil ini, terlihat bahwa model dapat mengenali kedua kelas dengan baik, tetapi masih ada kesalahan klasifikasi, terutama yang berkaitan dengan kelas minoritas. Namun demikian, penerapan SMOTE terbukti meningkatkan nilai *recall* dan *F1-score*, yang menunjukkan peningkatan sensitivitas model terhadap kelas minoritas. Hal ini penting dalam konteks klinis, karena kesalahan dalam mendeteksi pasien dengan terapi kurang efektif dapat berdampak pada pengambilan keputusan medis.

IV. KESIMPULAN

Penelitian ini membahas evaluasi efektivitas terapi balur dengan menggunakan pendekatan machine learning, khususnya algoritma Decision Tree yang dikombinasikan dengan teknik SMOTE untuk mengatasi ketidakseimbangan data serta metode LIME untuk meningkatkan interpretabilitas model. Pendekatan ini dirancang untuk menghasilkan sistem klasifikasi yang tidak hanya akurat tetapi juga transparan dalam menjelaskan faktor-faktor yang memengaruhi hasil prediksi.

Hasil penelitian menunjukkan bahwa algoritma Decision Tree mampu memberikan performa klasifikasi yang cukup baik dalam membedakan kategori efektivitas terapi, terutama pada data yang tidak melalui proses penyeimbangan. Model menunjukkan nilai specificity tertinggi sebesar 0,8276 pada skenario tanpa SMOTE dengan rasio pembagian data 90:10, yang menandakan kemampuan yang sangat baik dalam mengidentifikasi kelas negatif secara tepat. Namun, model cenderung lebih optimal dalam mengenali kelas mayoritas, sehingga muncul bias terhadap hasil tertentu. Penerapan SMOTE terbukti efektif dalam menyeimbangkan distribusi data dan meningkatkan sensitivitas model terhadap kelas minoritas, meskipun di sisi lain menyebabkan penurunan pada nilai spesifisitas. Hal ini mengindikasikan adanya trade-off yang perlu dipertimbangkan dalam pengembangan model klasifikasi medis. Selain itu, analisis menggunakan LIME berhasil mengidentifikasi kontribusi fitur secara individual, dengan variabel seperti pekerjaan, diagnosa, dan durasi terapi menjadi faktor dominan dalam menentukan efektivitas terapi. Secara keseluruhan, temuan utama penelitian ini menegaskan bahwa integrasi teknik klasifikasi, penanganan data imbalance, dan explainable AI dapat meningkatkan kualitas analisis data medis, khususnya dalam konteks terapi komplementer seperti terapi balur. Implikasi praktisnya adalah potensi pengembangan sistem pendukung keputusan klinis yang lebih objektif, transparan, dan dapat dipercaya oleh tenaga medis.

Kontribusi penelitian ini terletak pada penggabungan tiga pendekatan utama Decision Tree, SMOTE, dan LIME dalam satu kerangka analisis yang komprehensif, yang masih jarang diterapkan pada studi terapi balur. Untuk penelitian

selanjutnya, disarankan untuk mengeksplorasi algoritma lain seperti ensemble learning, memperluas jumlah dan keragaman dataset, serta mengintegrasikan validasi klinis secara langsung agar hasil model semakin relevan dan aplikatif dalam praktik kesehatan nyata.

DAFTAR PUSTAKA

- [1] S. Aristyani, S. Subagio, T. Rahayu, and S. B. Sumitro, "Biological Perspective of Balur Therapy: A Network Pharmacology Study," pp. 1–10, 2020, doi: <https://doi.org/10.1101/2020.11.05.366039>.
- [2] P. Prasetyowati, G. I. Lestari, and I. Islamiyati, "The Effectiveness Of Aluminum Foil Swaddling On Increased Body Temperature Of Newborns At The Midwife ' s Independent Practice Sulisty Rahayu Central Lampung," *Int. Sci. Heal. J.*, vol. 1, no. 1, pp. 1–8, 2023, doi: <https://doi.org/10.59680/ishel.v1i1.231>.
- [3] S. Aristyani, S. Subagio, T. Rahayu, and S. B. Sumitro, "Integrated bioinformatic approach of Balur therapy for breast cancer subtypes," vol. 02008, pp. 1–23, 2025, doi: <https://doi.org/10.1051/bioconf/202515402008>.
- [4] N. R. Muntiari and K. H. Hanif, "Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma Machine Learning," *J. Ilmu Komput. dan Teknol.*, vol. 3, no. 1, pp. 1–6, 2022, doi: <https://doi.org/10.35960/ikomti.v3i1.766>.
- [5] I. D. Mienye and N. Jere, "A Survey of Decision Trees: Concepts, Algorithms, and Applications," *IEEE Access*, vol. 12, no. June, pp. 86716–86727, 2024, doi: [10.1109/ACCESS.2024.3416838](https://doi.org/10.1109/ACCESS.2024.3416838).
- [6] R. Setyawan, W. Tumbur, M. L. Tobing, and S. Handoko, "The Ethical Dilemmas of AI-Driven Decision-Making in Business: A Multi-Perspective Case Study on Corporate Accountability and Transparency," *J. Manaj. Sos. Ekon.*, vol. 4, no. 1, pp. 270–278, 2024, doi: <https://doi.org/10.51903/z0b0ep50>.
- [7] Muhammad Azis Sularso and J. Jupron, "Pengaruh ketidakseimbangan data terhadap kinerja Algoritma Naive Bayes dalam klasifikasi stroke," *INFOTECH J. Inform. Teknol.*, vol. 6, no. 2, pp. 212–218, 2025, doi: [10.37373/infotech.v6i2.2075](https://doi.org/10.37373/infotech.v6i2.2075).
- [8] S. Ishaque, N. Khan, and S. Krishnan, "Physiological Signal Analysis and Stress Classification from VR Simulations Using Decision Tree Methods," *Bioengineering*, 2023, doi: <https://doi.org/10.3390/bioengineering10070766>.
- [9] N. A. Lumbanbatu, Y. L. Maha, and S. Pardingotansipayung, "Penerapan Metode Decision Tree untuk Memprediksi Dampak Kesehatan Akibat Penggunaan Gadget," *J. Artif. Intell. Digit. Bus.*, vol. 4, no. 4, pp. 14842–14851, 2026, doi: <https://doi.org/10.31004/riggs.v4i4.5787>.
- [10] A. Lutfia, G. Gunawan, R. S. Rohman, and A. Gunawan, "Penerapan Seleksi Fitur Gain Ratio Pada Prediksi Penyakit Jantung Berbasis Naive Bayes," *J. Responsif Ris. Sains dan Inform.*, vol. 6, no. 1, pp. 1–10, 2024, doi: [10.51977/jti.v6i1.1396](https://doi.org/10.51977/jti.v6i1.1396).
- [11] F. N. Yahya, M. Anshori, and A. Naseh Khudori, "Evaluasi Performa XGBoost dengan Oversampling dan Hyperparameter Tuning untuk Prediksi Alzheimer," *Techno.COM*, vol. 24, no. 1, pp. 1–12, 2025, doi: <https://doi.org/10.62411/tc.v24i1.12057>.
- [12] V. Hassija, V. Chamola, A. Mahapatra, A. Singal, D. Goel, and K. Huang, "Interpreting Black - Box Models: A Review on Explainable Artificial Intelligence," *Cognit. Comput.*, pp. 45–74, 2024, doi: [10.1007/s12559-023-10179-8](https://doi.org/10.1007/s12559-023-10179-8).
- [13] E. Vera-Salmerón, C. Domínguez-Nogueira, J. L. Romero-Béjar, J. A. Sáez, and E. Mota-Romero, "Decision-Tree-Based Approach for Pressure Ulcer Risk Assessment in Immobilized Patients," *Int. J. Environ. Res. Public Health*, vol. 19, no. 18, 2022, doi: [10.3390/ijerph191811161](https://doi.org/10.3390/ijerph191811161).
- [14] B. A. C. Permana, R. Ahmad, H. Bahtiar, S. A., and I. Gunawan, "Classification of diabetes disease using decision tree algorithm (C4.5)," *J. Phys. Conf. Ser. Pap.*, 2021, doi: [10.1088/1742-6596/1869/1/012082](https://doi.org/10.1088/1742-6596/1869/1/012082).
- [15] I. F. Rahman, W. A. Shestia, S. D. Rama, S. Azzahra, and A. A. Dermawan, "Klasifikasi Diagnosa Pasien Di Klinik Sri Dengan

- Metode Decision Tree,” *J. Tek. Ibnu Sina*, vol. 9, no. 01, 2024, doi: <https://doi.org/10.36352/jt-ibsi.v9i01.890>.
- [16] G. Samudra, A. W. Anggraeni, A. R. B. Jamroni, A. Sarif, and W. Wiyanto, “Efektivitas Teknik SMOTE Dalam Meningkatkan Performa Naïve Bayes Deteksi Gangguan Kecemasan Mahasiswa,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 12, no. 3, 2025, doi: [10.35957/jatisi.v12i3.12197](https://doi.org/10.35957/jatisi.v12i3.12197).
- [17] I. M. Explanations, N. R. Nuraeda, M. Liebenlito, and T. E. Sutanto, “Explainable Sentiment Analysis pada Ulasan Aplikasi Shopee Menggunakan Local Interpretable Model-agnostic Explanations,” *Indones. J. Comput. Sci.*, vol. 13, no. 1, pp. 4529–4542, 2024, doi: <https://doi.org/10.33022/ijcs.v13i3.3870>.
- [18] T. Gori *et al.*, “Preprocessing Data dan Klasifikasi Untuk Prediksi Kinerja Akademik Siswa,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 1, pp. 215–224, 2024, doi: [10.25126/jtiik.20241118074](https://doi.org/10.25126/jtiik.20241118074).
- [19] M. Rahman, Faidhul, “Optimasi Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Binning Dan SMOTE,” *J. Artif. Intelligence Data Sci.*, vol. 4, no. 1, pp. 30–36, 2024, doi: <https://doi.org/10.24252/jagti.v4i1.77>.
- [20] M. K. Dahouda and I. Joe, “A Deep-Learned Embedding Technique for Categorical Features Encoding,” *IEEE Access*, vol. 9, pp. 114381–114391, 2021, doi: [10.1109/ACCESS.2021.3104357](https://doi.org/10.1109/ACCESS.2021.3104357).
- [21] R. Efendi, A. Junaidi, and A. M. Rizki, “Penentuan Pusat Kluster Secara Otomatis Pada Algoritma Density Peaks Clustering Berbasis Metode Inter Quartile Range,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: [10.23960/jitet.v12i3.4997](https://doi.org/10.23960/jitet.v12i3.4997).
- [22] S. Sidiq, P. Korespondensi, and N. Shobi Mabru, “Pengembangan model prediksi risiko diabetes menggunakan pendekatan AdaBoost dan Teknik Oversampling SMOTE,” *J. Ilm. Inform. Dan Ilmu Komput.*, vol. 4, pp. 13–23, 2025, doi: <https://doi.org/10.58602/jima-ilkom.v4i1.41>.
- [23] F. S. Utomo *et al.*, “Optimasi Klasifikasi Gaya Belajar Mahasiswa Inklusif Berdasarkan Model Vak Dengan Stratified Split Dan Multilayer Perceptron,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 5, pp. 1163–1172, 2025, doi: <https://doi.org/10.25126/jtiik.2025125>.
- [24] A. Nurzahputra, A. Ratna Safitri, and M. Aziz Muslim, “Klasifikasi Pelanggan pada Customer Churn Prediction Menggunakan Decision Tree,” *Prism. Pros. Semin. Nas. Mat.*, no. 02, pp. 717–722, 2016, doi: <http://dx.doi.org/10.30813/j-alu.v2i2.8812>.
- [25] R. Fahrizal, M. N. Falah, E. Rilvani, U. P. Bangsa, and K. Bekasi, “Prediksi Jumlah UMKM Berdasarkan Kategori Usaha dan Lokasi Kabupaten / Kota di Provinsi Jawa Barat Menggunakan Decision Tree,” *J. Media Akad.*, vol. 3, no. 7, 2025, doi: <https://doi.org/10.62281/v3i7.2658>.
- [26] Z. Ali, M. Anshori, and W. Teja, “Prediksi Dini Penyakit Diabetes pada Wanita dengan Algoritma Klasifikasi Berbasis Pohon,” *J. Ilmu Komput.*, vol. 18, pp. 44–54, 2020, doi: <https://doi.org/10.24843/JIK.2025.v18.i01.p05>.
- [27] I. Septian *et al.*, “Decision Tree Regression untuk Prediksi Prevalensi Stunting di Provinsi Nusa Tenggara Timur,” *J. Teknologi Inform. dan Komput. MH. Thamrin*, vol. 10, no. 2, pp. 413–427, 2024, doi: <https://doi.org/10.37012/jtik.v10i2.2179>.
- [28] E. N. Nst, G. W. Nurcahyo, M. T. Informatika, L. Begalung, and S. Barat, “Penerapan Machine Learning Menggunakan Algoritma Decision Tree Untuk Prediksi Tingkat Kelulusan Mahasiswa,” *J. Sist. Inf. dan Inform.*, vol. 8, no. 2, pp. 428–439, 2025, doi: <https://doi.org/10.47080/ctjbg21>.
- [29] Z. A. Dwiyantri and C. Prianto, “Prediksi Cuaca Kota Jakarta menggunakan Metode Random Forest: Studi Optimalitas,” *J. Tekno Insentif*, vol. 17, no. 2, pp. 127–137, 2023, doi: <https://doi.org/10.36787/jti.v17i2.1136>.
- [30] I. F. Hawari *et al.*, “Pengaruh Teknik Oversampling Pada Algoritma Machine Learning Dalam Klasifikasi Body Mass Index (Bmi),” *J. Ris. dan Apl. Mat.*, vol. 08, no. 01, pp. 51–68, 2024, doi: <https://orcid.org/0000-0002-4372-4661>.
- [31] M. E. Ramadhan and J. Zeniarja, “Implementasi Deep Transfer Learning dan Explainable AI dalam Klasifikasi Kanker Kulit Implementation of Deep Transfer Learning and Explainable AI in Skin Cancer Classification,” *Sist. J. Sist. Inf.*, vol. 14, no. 5, pp. 2266–2279, 2025, doi: <https://doi.org/10.32520/stmsi.v14i5.5425>.
- [32] C. O. Suryaputri and M. Rahardi, “Analysis of Gradient Boosted Trees Algorithm in Breast Cancer Classification,” *J. Appl. Informatics Comput.*, vol. 10, no. 1, pp. 605–618, 2026, doi: <https://doi.org/10.30871/jaic.v10i1.11875>.