

Perbandingan Kinerja Algoritma KNN-DT-RF-SVM untuk Deteksi Dini Risiko Kematian Ibu

Angga Rahagiyanto¹, Bakhtiyar Hadi Prakoso^{1*}, Muhammad Yunus¹, Veronika Vestine¹,
Gandu Eko Juliato Suyoso¹, Atma Deharja^{1,2}

¹Program Studi Manajemen Informasi Kesehatan, Jurusan Kesehatan, Politeknik Negeri Jember
rahagiyanto@polije.ac.id, bakhtiyar.hp@polije.ac.id, m.yunus@polije.ac.id, veronikavestine@polije.ac.id,
gandu.eko.js@polije.ac.id, atma_deharja@polije.ac.id

²Program Studi Doktor Kesehatan Masyarakat, Universitas Airlangga
atma.deharja@gmail.com

Keywords:

Maternal Mortality Rate,
Decision Tree,
K-Nearest Neighbors,
Random Forest,
Support Vector Machine

ABSTRACT

Maternal Mortality Rate (MMR) in Indonesia remains a significant health issue, with data indicating a mortality rate far exceeding the Sustainable Development Goals (SDGs) target. This study aimed to explore and compare the performance of K-Nearest Neighbors (KNN), Decision Tree (DT), Random Forest (RF), and Support Vector Machine (SVM) algorithms in detecting maternal mortality risk. Using a medical dataset of pregnant women from Summersari Community Health Center, models were developed to classify three pregnancy risk categories: low risk (KRR), high risk (KRT), and very high risk (KRST). Model evaluation was conducted based on accuracy, precision, recall, and F1-score metrics. The results showed that the Random Forest algorithm achieved the highest performance with an accuracy of 76.7%, followed by Decision Tree and SVM with 70%, while KNN had the lowest accuracy at 50%. The main challenge encountered was data imbalance in the classification of very high-risk cases. This study suggests the use of data balancing methods such as SMOTE and additional data augmentation to enhance model performance. These findings can serve as a foundation for Puskesmas to implement machine learning-based early detection systems to reduce maternal mortality rates.

Kata Kunci

Angka Kematian Ibu,
Decision Tree,
K-Nearest Neighbors,
Random Forest,
Support Vector Machine

ABSTRAK

Angka Kematian Ibu (AKI) di Indonesia masih menjadi permasalahan kesehatan yang signifikan, dengan data menunjukkan tingkat kematian ibu yang jauh di atas target *Sustainable Development Goals* (SDGs). Penelitian ini bertujuan untuk mengeksplorasi dan membandingkan kinerja algoritma *K-Nearest Neighbors* (KNN), *Decision Tree* (DT), *Random Forest* (RF), dan *Support Vector Machine* (SVM) dalam mendeteksi risiko kematian ibu. Dengan menggunakan dataset medis ibu hamil dari Puskesmas Summersari, model dibangun untuk mengklasifikasikan tiga kategori risiko kehamilan: risiko rendah (KRR), risiko tinggi (KRT), dan risiko sangat tinggi (KRST). Evaluasi model dilakukan berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil menunjukkan bahwa algoritma *Random Forest* memberikan kinerja terbaik dengan akurasi sebesar 76.7%, diikuti oleh *Decision Tree* dan SVM dengan akurasi 70%, sedangkan KNN memberikan akurasi terendah sebesar 50%. Tantangan utama yang dihadapi adalah ketidakseimbangan data dalam klasifikasi risiko sangat tinggi. Penelitian ini menyarankan penggunaan metode balancing data seperti SMOTE dan penambahan data untuk meningkatkan performa model. Temuan ini dapat digunakan untuk puskesmas dalam memberikan dasar untuk implementasi sistem deteksi dini

berbasis machine learning guna mengurangi angka kematian ibu.

Korespondensi Penulis:

Bakhtiyar Hadi Prakoso,
Politeknik Negeri Jember,
Jl. Mastrip 164, Jember
Telepon: +6282257197272
Email: bakhtiyar.hp@polije.ac.id

**Submitted : 19-11-2024; Accepted : 24-03-2025;
Published : 30-03-2025**

Copyright (c) 2025 The Author (s)

*This article is distributed under a Creative Commons
Attribution-ShareAlike 4.0 International License (CC BY-SA
4.0)*

1. PENDAHULUAN

Angka Kematian Ibu (AKI) merupakan salah satu indikator utama untuk mengukur tingkat kesehatan reproduksi di suatu negara [1]. Di Indonesia, angka kematian ibu masih cukup tinggi, dengan data terakhir menunjukkan 189 kematian per 100.000 kelahiran hidup pada tahun 2020, jauh di atas target *Sustainable Development Goals* (SDGs), yaitu di bawah 70 kematian per 100.000 kelahiran hidup [2]. Tingginya angka ini menandakan masih adanya masalah signifikan dalam deteksi dini faktor risiko pada kehamilan dan persalinan [3]. Oleh karena itu, upaya penurunan angka kematian ibu sangat penting untuk dilakukan secara menyeluruh, baik dari sisi pencegahan maupun intervensi dini [4].

Angka Kematian Ibu yang tinggi merupakan menjadi sebuah tantangan di sejumlah daerah di Indonesia. Dengan kondisi geografis dan demografi yang beragam tentunya anatar wilayah mempunyai penanganan yang berbeda-beda. Salah satu penyebab tingginya AKI adalah komplikasi kehamilan dan persalinan seperti kondisi seperti preeklamsia, perdarahan postpartum, dan infeksi. Kondisi tersebut sebenarnya dapat ditekan jika terdapat sistem deteksi dini yang baik. Sistem deteksi dini dapat digunakan sebagai upaya preventif untuk mencegah nilai AKI meningkat.

Jember merupakan salah satu kabupaten di Jawa Timur. Pemerintah setempat telah melakukan berbagai upaya untuk menurunkan angka kematian ibu, termasuk program *Antenatal Care* (ANC) yang terintegrasi dan peningkatan tim PONED (Pelayanan Obstetri Neonatal Emergensi Dasar). Meskipun demikian, AKI di Jember masih tinggi yang mencapai 150 kematian per 100.000 kelahiran hidup pada tahun 2023. Hal ini tentu saja tidak sesuai dengan program SDGs dimana targetnya 70 kematian per 100.000 kelahiran hidup. Oleh karena perlu adanya tindakan yang dapat menurunkan AKI. Salah satu cara yang dapat digunakan adalah dengan melakukan deteksi dini kematian ibu dengan memanfaatkan teknologi informasi yang lebih cepat dan akurat [5].

Deteksi dini sangat erat kaitannya dengan peran dari kecerdasan buatan dimana dalam kecerdasan buatan terdapat domain *data mining*. *Data mining* adalah teknik untuk mengidentifikasi pola dalam sejumlah besar data dan informasi. Sumber data dapat berupa basis data, pusat data, serta berbagai format penyimpanan data lainnya [6]. Implementasi deteksi dini dapat dilakukan dengan berbagai bantuan beberapa algoritma seperti *K-Nearest Neighbors* (KNN), *Decision Tree* (DT), *Random Forest* (RF), dan *Support Vector Machine* (SVM) yang dapat digunakan untuk mengklasifikasikan risiko kematian ibu berdasarkan faktor-faktor risiko seperti usia ibu, tekanan darah, kehamilan ektopik, dan kondisi medis lainnya [7].

Penggunaan metode *data mining* ini dipengaruhi oleh tingkat akurasi. Semakin bagus tingkat akurasinya semakin bagus deteksi dini yang dihasilkan. Dengan menggunakan algoritma prediktif ini, petugas kesehatan dapat mengidentifikasi kehamilan berisiko tinggi lebih dini, sehingga intervensi yang tepat dapat dilakukan untuk mengurangi kemungkinan terjadinya kematian ibu [8]. Penelitian ini bertujuan untuk membandingkan performa beberapa algoritma klasifikasi, yaitu KNN, DT, RF, dan SVM, dalam memprediksi risiko kematian ibu di Jember.

Berdasarkan hasil perbandingan ini, peneliti berharap dapat menemukan algoritma yang paling sesuai untuk mendeteksi risiko kematian ibu secara efektif dan akurat, serta memberikan rekomendasi penggunaan model terbaik dalam sistem deteksi dini di layanan kesehatan. Adapun algoritma yang paling sesuai inilah yang selanjutnya dapat digunakan sebagai rekomendasi dasar pembuatan sistem deteksi dini bagi Puskesmas Sumbersari [9].

2. METODE PENELITIAN

2.1 Metode Penelitian

Penelitian ini menggunakan pendekatan *supervised learning* untuk membandingkan performa empat algoritma klasifikasi dalam mendeteksi risiko kematian ibu, yaitu *K-Nearest Neighbors* (KNN),

Decision Tree, *Random Forest*, dan *Support Vector Machine* (SVM). Pada penelitian ini, *dataset* yang digunakan adalah data medis ibu hamil yang diperoleh dari Puskesmas Sumpster Jember, dengan total 98 data pasien yang diklasifikasikan ke dalam tiga kelompok risiko: KRR (*Low-Risk Pregnancy*), KRT (*High-Risk Pregnancy*), dan KRST (*Very High-Risk Pregnancy*). Berikut adalah tabel variabel yang digunakan.

Tabel 1. Variabel yang Digunakan Berdasarkan Data Ibu Hamil di Puskesmas

No	Nama Variabel	Deskripsi	Tipe Data
1	Status Resiko	Status risiko kehamilan (KRR, KRT, KRST)	Kategorik
2	SKOR	Skor total risiko ibu hamil	Numerik
3	Usia Ibu	Usia ibu pada saat kehamilan	Numerik
4	Usia Hamil Terlalu Muda	Apakah usia ibu terlalu muda saat hamil	Kategorik
5	Umur Ibu Terlalu Tua	Apakah usia ibu terlalu tua saat hamil	Kategorik
6	Usia Kehamilan (minggu)	Usia kehamilan dalam minggu	Numerik
7	Tinggi Badan Ibu	Tinggi badan ibu hamil	Numerik
8	Ibu Terlalu Pendek	Apakah tinggi ibu terlalu pendek	Kategorik
9	Hamil Ke	Kehamilan ke berapa	Numerik
10	Terlalu Banyak Anak	Apakah ibu memiliki terlalu banyak anak	Kategorik
11	Pernah gagal Hamil	Apakah Ibu pernah gagal hamil	Kategorik
12	Jarak hamil	Berapa jarak hamil terakhir	Numerik
13	Terlalu lama hamil lagi	Apakah Ibu pernah terlalu lama hamil lagi	Kategorik
14	Terlalu cepat hamil lagi	Apakah Ibu pernah terlalu cepat hamil lagi	Kategorik
15	Terlalu tua hamil pertama	Kondisi kehamilan pertama Ibu	Kategorik
16	Lambat hamil pertama	Kondisi kehamilan pertama Ibu	Kategorik
17	Lingkar lengan	Lingkar lengan ibu hamil	Numerik
18	Kehamilan lebih bulan	Kondisi kehamilan Ibu lebih berapa bulan	Kategorik
19	Berat Badan (kg)	Berat Badan Ibu saat hamil	Numerik
20	Tensi A	Tensi Ibu saat hamil	Numerik
21	Tensi B	Tensi Ibu saat hamil	Numerik
22	Bayi sungsang	Posisi Bayi Ibu saat hamil	Kategorik
23	Bayi lintang	Posisi Bayi Ibu saat hamil	Kategorik
24	Vakum	Posisi Vakum Ibu saat hamil	Kategorik
25	Uri dirogoh	Posisi Uri Ibu saat melahirkan	Kategorik
26	Infus	Infus Ibu saat hamil	Kategorik
27	SC	Proses melahirkan Ibu saat melahirkan	Kategorik
28	Malaria	Malaria Ibu saat hamil	Kategorik
29	TBC Paru	TBC Ibu saat hamil	Kategorik
30	Pacu Jantung	Pacu Jantung Ibu saat hamil	Kategorik
31	Bengkak Wajah	Apakah ibu mengalami bengkak wajah	Kategorik
32	Perdarahan dalam kehamilan	Riwayat perdarahan selama kehamilan	Kategorik
33	Hb (Hemoglobin)	Kadar hemoglobin ibu hamil	Numerik
34	Kurang Darah	Apakah ibu mengalami anemia	Kategorik
35	PMS	Riwayat penyakit menular seksual	Kategorik
36	PEB/Eklamsia	Riwayat preeklamsia/eklamsia	Kategorik
37	Kencing Manis	Riwayat diabetes gestasional	Kategorik
38	Bayi Meninggal	Riwayat bayi meninggal sebelumnya	Kategorik
39	Hamil Kembar	Apakah ibu hamil kembar	Kategorik

No	Nama Variabel	Deskripsi	Tipe Data
40	Hydramnion	Kondisi kelebihan cairan ketuban	Kategorik

2.2 Dataset dan Preprocessing

Dataset terdiri dari beberapa atribut penting yang dapat mempengaruhi kondisi kesehatan ibu hamil, seperti: usia ibu, usia kehamilan, tekanan darah, Hemoglobin (Hb), indikator komplikasi (seperti praeklampsia, anemia, infeksi, dan sebagainya). Sebelum diterapkan ke model, data telah melalui proses *preprocessing* untuk memastikan konsistensi dan kualitas data. Langkah-langkah yang dilakukan dalam *preprocessing* adalah sebagai berikut:

1. Pembersihan Data

Menghapus variabel “SKOR” yang memiliki banyak nilai *missing* atau NaN agar tidak mempengaruhi performa model.

2. Label Encoding

Kategori target “Status Risiko” (KRR, KRT, KRST) dikonversi ke bentuk numerik menggunakan teknik *Label Encoding* agar dapat digunakan dalam algoritma klasifikasi.

2.3 Pembagian Data

Data dibagi menjadi dua yaitu 70% data untuk pelatihan (*training set*) dan 30% data untuk pengujian (*test set*). Teknik pembagian ini menggunakan metode *train-test split* yang memastikan tidak ada kebocoran data (*data leakage*) antara set pelatihan dan set pengujian, sehingga hasil evaluasi model dapat lebih valid.

2.4 Algoritma yang Digunakan

Berikut adalah algoritma yang diterapkan dalam penelitian ini:

1. *K-Nearest Neighbors* (KNN)

Algoritma ini bekerja dengan mengklasifikasikan data berdasarkan mayoritas dari k tetangga terdekat menggunakan *Euclidean Distance* [10]. Pada penelitian ini, nilai k yang digunakan adalah 5. KNN bekerja dengan menghitung jarak antara titik data baru dan data yang ada. Jarak *Euclidean* digunakan untuk mengukur kedekatan antar titik.

Rumus *Euclidean Distance*:

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

Dimana:

- 1) p dan q adalah dua titik data.
- 2) p_i dan q_i adalah nilai pada dimensi ke- i .
- 3) n adalah jumlah dimensi (fitur).

Setelah menghitung jarak, KNN mengambil k tetangga terdekat dan mengklasifikasikan titik baru berdasarkan kelas mayoritas dari tetangga-tetangga tersebut.

2. *Decision Tree* (DT)

Algoritma ini membentuk model pohon keputusan untuk menentukan klasifikasi berdasarkan pemecahan data menggunakan aturan-aturan sederhana [11]. Pada implementasinya, parameter *max_depth* dan *min_samples_split* diatur untuk mencegah *overfitting*. DT bekerja dengan memecah dataset menjadi subset yang lebih kecil menggunakan atribut yang memaksimalkan informasi.

Rumus *Entropy* (untuk mengukur ketidakpastian dalam subset data):

$$E(S) = - \sum_{i=1}^c p_i \log_2(p_i) \quad (2)$$

Dimana:

- 1) S adalah kumpulan data.
- 2) c adalah jumlah kelas.
- 3) p_i adalah probabilitas dari kelas ke- i

Rumus *Information Gain* (untuk menentukan atribut terbaik dalam membagi data):

$$IG(S, A) = E(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{|S|} E(S_v) \quad (3)$$

Dimana:

- 1) A adalah atribut yang digunakan untuk membagi data.
- 2) S_v adalah subset data yang dibagi oleh nilai v dari atribut A
- 3) $E(S_v)$ adalah entropi dari subset S_v

3. Random Forest (RF)

Algoritma *ensemble learning* ini menggunakan beberapa pohon keputusan yang dibentuk secara acak [12]. Kemudian prediksi akhir ditentukan berdasarkan mayoritas suara dari pohon-pohon tersebut [7]. Pada penelitian ini, dilakukan *hyperparameter tuning* menggunakan teknik *GridSearchCV* untuk mendapatkan parameter terbaik seperti jumlah $n_estimators$, kedalaman pohon (max_depth), dan lainnya. RF adalah kombinasi dari beberapa DT, dimana setiap *tree* dibangun dari *subset* data yang berbeda (*bootstrapped samples*) dan *subset* fitur yang berbeda.

Algoritma dasar:

- 1) Pilih B sampel acak dari data (dengan pengulangan)
- 2) Untuk setiap sampel, buat pohon keputusan
- 3) Setiap node hanya menggunakan subset acak dari fitur untuk memilih split terbaik
- 4) Gabungkan prediksi semua pohon menggunakan voting (untuk klasifikasi)

Rumus *Voting* (untuk klasifikasi):

$$\hat{y} = \arg \max_{y_j} \sum_{i=1}^B I(h_i(x) = y_j) \quad (4)$$

Dimana:

- 1) B adalah jumlah pohon dalam hutan.
- 2) $h_i(x)$ adalah prediksi dari pohon ke- i .
- 3) y_j adalah kelas yang mungkin, dan I adalah fungsi indikator.

4. Support Vector Machine (SVM)

Algoritma ini menggunakan pendekatan pemisahan kelas melalui *hyperplane* optimal di ruang dimensi tinggi. SVM bekerja dengan mencari *hyperplane* yang memisahkan kelas-kelas data dengan margin terbesar [13]. *Kernel linier* dipilih dalam penelitian ini untuk mengoptimalkan waktu komputasi, dengan pengaturan parameter yang dilakukan secara manual.

Rumus *Hyperplane*:

$$w^T x + b = 0 \quad (5)$$

Dimana:

- 1) w adalah vector bobot.
- 2) x adalah titik data.
- 3) b adalah bias

Rumus *Margin* (jarak antara *hyperplane* dan titik terdekat):

$$Margin = \frac{2}{\|w\|} \quad (6)$$

SVM berusaha untuk memaksimalkan margin ini, yaitu meminimalkan $\|w\|$, sambil tetap memastikan semua titik data terklasifikasi dengan benar.

$$y_i(w^T x_i + b) \geq 1 \text{ untuk semua } i \quad (7)$$

Dimana y_i adalah label kelas dari data ke- i

2.5 Evaluasi Model

Untuk mengukur kinerja setiap model, digunakan beberapa metrik evaluasi, yaitu:

1. Akurasi: Persentase prediksi yang benar dari total prediksi.
2. *Precision*: Persentase prediksi positif yang benar dari total prediksi positif.

3. *Recall*: Kemampuan model dalam menemukan semua kasus positif sebenarnya.
4. *F1-Score*: Rata-rata harmonis dari *precision* dan *recall*, yang memberikan gambaran lebih seimbang pada performa model, terutama pada data yang tidak seimbang.

Setiap model dievaluasi menggunakan data pengujian untuk memastikan kinerja model pada data yang belum dilihat selama pelatihan. Selain itu dilakukan analisis terhadap *confusion matrix* untuk memahami kesalahan prediksi yang dihasilkan oleh setiap model.

2.6 Tuning Hyperparameter untuk Random Forest

Setelah evaluasi awal, dilakukan tuning *hyperparameter* pada algoritma *Random Forest* untuk meningkatkan performa model. Teknik *GridSearchCV* digunakan untuk melakukan pencarian parameter terbaik berdasarkan akurasi [7]. Parameter yang diuji meliputi:

1. *n_estimators*: Jumlah pohon dalam hutan.
2. *max_depth*: Kedalaman maksimum pohon.
3. *min_samples_split*: Jumlah minimum sampel yang diperlukan untuk memecah simpul internal.
4. *min_samples_leaf*: Jumlah minimum sampel yang diperlukan di simpul daun.

Tuning dilakukan dengan pembagian *cross-validation* sebanyak 3 kali lipat untuk memastikan konsistensi hasil.

3. HASIL DAN ANALISIS

Pada bagian ini, hasil dari penerapan keempat algoritma, yaitu KNN, *Decision Tree*, *Random Forest*, dan SVM, akan dibahas berdasarkan metrik evaluasi yang telah disebutkan. Tujuan utama dari bagian ini adalah untuk membandingkan performa masing-masing algoritma dalam memprediksi risiko kematian ibu pada data yang digunakan.

3.1 Hasil Perbandingan Akurasi

Berdasarkan perhitungan evaluasi dari ke empat algoritma yang diteliti, akurasi dari setiap algoritma ditampilkan dalam tabel 2 sebagai berikut.

Tabel 2. Hasil Algoritma dari Masing-masing Pengolahan

Algoritma	Akurasi	<i>Precision</i>	<i>Recall</i>	F1-Score
KNN	50%	43%	50%	46%
<i>Decision Tree</i>	70%	65%	70%	67%
<i>Random Forest</i>	76.7%	68%	77%	71%
SVM	70%	61%	70%	65%

Dari hasil di atas, terlihat bahwa algoritma *Random Forest* menghasilkan akurasi tertinggi dengan 76.7%, diikuti oleh *Decision Tree* dan SVM yang masing-masing memiliki akurasi 70%. Algoritma KNN menunjukkan performa terendah dengan akurasi 50%. Hal ini sesuai dengan penelitian yang dilakukan oleh Udin dimana KNN tidak terpengaruh oleh data yang sifatnya minoritas [14]. Sedangkan data, yang digunakan ini tidak berimbang. Sehingga hasil uji performa menunjukkan bahwa KNN mempunyai tingkat performa yang rendah dibandingkan dengan yang lainnya.

3.2 Analisis Performansi Algoritma

Algoritma KNN menunjukkan hasil yang kurang optimal dengan akurasi yang cukup rendah. Hal ini disebabkan oleh sensitivitas KNN terhadap distribusi data, serta pemilihan nilai *k* yang tidak optimal untuk dataset ini. Selain itu, performa KNN juga dapat dipengaruhi oleh *imbalanced dataset*, dimana jumlah data dari setiap kelas tidak seimbang [15]. Algoritma *Decision Tree* memberikan akurasi yang lebih baik dibandingkan KNN, yakni 70%. Algoritma ini mampu mengklasifikasikan data dengan cukup baik, namun hasil evaluasi juga menunjukkan bahwa *Decision Tree* mengalami *overfitting* pada beberapa bagian data yang menyebabkan penurunan performa pada kelas risiko sangat tinggi (KRST). Hal ini terlihat dari rendahnya *precision* pada kelas ini yang tidak terklasifikasi dengan baik. Adapun solusi dari permasalahan ini dapat diselesaikan dengan algoritma genetika melalui proses *pruning* [16].

Algoritma *Random Forest* terbukti unggul dengan akurasi tertinggi. Algoritma ini berhasil memanfaatkan kekuatan dari *ensemble learning* dimana beberapa pohon keputusan yang dibentuk secara acak mampu menangani variasi pada data dan mengurangi *overfitting* [17]. Setelah dilakukan *tuning hyperparameter*, hasil akurasi mencapai 76.7%. Meskipun demikian, sama seperti algoritma lainnya,

Random Forest masih kesulitan dalam mengklasifikasikan kelas KRST (*Very High Risk*) yang jumlahnya relatif lebih sedikit dibandingkan kelas lain. Algoritma SVM menghasilkan performa yang hampir setara dengan *Decision Tree*, dengan akurasi 70%. SVM dikenal mampu menangani data dengan dimensi tinggi, namun pada dataset ini, performanya belum optimal karena pemilihan kernel linier yang mungkin tidak sepenuhnya cocok untuk data ini. SVM juga cenderung lebih sensitif terhadap pemilihan parameter, sehingga tuning lebih lanjut mungkin diperlukan untuk meningkatkan akurasinya.

3.3 Tuning Hyperparameter pada Random Forest

Setelah evaluasi awal, dilakukan *tuning hyperparameter* pada *Random Forest* menggunakan *GridSearchCV*. Parameter yang diuji meliputi:

1. *n_estimators*: 50, 100, 200
2. *max_depth*: 5, 10, 15
3. *min_samples_split*: 2, 5, 10
4. *min_samples_leaf*: 1, 2, 4

Hasil *tuning* menunjukkan bahwa konfigurasi terbaik diperoleh dengan:

1. *n_estimators*: 100
2. *max_depth*: 15
3. *min_samples_split*: 2
4. *min_samples_leaf*: 1

Dengan konfigurasi ini, akurasi model meningkat menjadi 76.7%, dan *precision* serta *recall* juga meningkat untuk kelas risiko rendah (KRR) dan risiko tinggi (KRT). Namun, kelas KRST tetap sulit diklasifikasikan dengan baik yang menunjukkan bahwa data pada kelas ini mungkin memerlukan teknik *oversampling* atau SMOTE untuk memperbaiki ketidakseimbangan.

3.4 Pembahasan

Hasil penelitian menunjukkan bahwa *Random Forest* adalah algoritma terbaik untuk deteksi risiko kematian ibu pada dataset ini. Keunggulan *Random Forest* dalam menangani data yang variatif dan mengurangi *overfitting* membuatnya menjadi pilihan yang lebih unggul dibandingkan algoritma lain. Meski demikian, semua algoritma kesulitan dalam mengklasifikasikan kelas KRST (*Very High-Risk Pregnancy*). Hal ini disebabkan oleh jumlah data yang tidak seimbang dimana kelas KRST memiliki data yang jauh lebih sedikit dibandingkan kelas KRR dan KRT. Dalam penelitian lanjutan, teknik *balancing data* atau penggunaan algoritma khusus seperti XGBoost atau SMOTE dapat dicoba untuk meningkatkan akurasi pada kelas ini. Dengan akurasi yang cukup tinggi, sistem berbasis *Random Forest* ini memiliki potensi besar untuk diimplementasikan dalam sistem deteksi dini risiko kehamilan di Puskesmas dan rumah sakit.

Hal tersebut sejalan dengan penelitian yang dilakukan oleh Liao (2023) dimana peran dari algoritma dapat digunakan untuk deteksi dini sebuah penyakit [18]. Salah satunya yang dilakukan oleh Yan (2023) dimana dalam penelitiannya telah membuat sistem deteksi kanker payudara [19]. Dengan adanya tingkat akurasi yang lebih bagus, maka sistem deteksi dini yang dihasilkan akan memberikan hasil yang lebih akurat. Hal ini tentu saja akan membantu Puskesmas dalam melakukan deteksi secara dini. Program deteksi dini yang bagus diharapkan dapat mengurangi angka Resiko Kematian Ibu.

4. KESIMPULAN

Berdasarkan hasil penelitian dan evaluasi performa beberapa algoritma klasifikasi untuk mendeteksi risiko kematian ibu, dapat disimpulkan bahwa *Random Forest* merupakan algoritma terbaik dengan akurasi tertinggi sebesar 76.7%. Algoritma ini unggul dalam menangani variasi pada data dan mampu mengurangi risiko *overfitting* yang biasanya dialami oleh *Decision Tree*. Meskipun demikian, tantangan terbesar terletak pada kesulitan dalam mengklasifikasikan kelas risiko sangat tinggi (KRST) yang memiliki jumlah data lebih sedikit dibandingkan kelas lain. Algoritma *Decision Tree* dan SVM juga menunjukkan performa yang baik dengan akurasi masing-masing 70%, sementara KNN memiliki performa terendah dengan akurasi 50%. KNN tampaknya kurang optimal dalam konteks dataset ini yang mungkin dipengaruhi oleh ketidakseimbangan data antar kelas. Meskipun *Random Forest* memiliki performa yang paling baik, hasil penelitian menunjukkan bahwa semua algoritma mengalami kesulitan dalam mengklasifikasikan kelas risiko sangat tinggi (KRST). Hal ini menandakan bahwa dataset yang

digunakan memerlukan teknik penyeimbangan data atau metode khusus yang dapat lebih baik menangani kelas-kelas dengan jumlah data yang tidak seimbang.

Sebagai bahan penellitan selanjutnya dapat menambahkan algoritma *oversampling* seperti SMOTE atau metode *balancinng* lainnya untuk menaangani ketidak seimbangan data karena dataset yang digunakan dalam penelitian ini cukup terbatas, dengan hanya 98 data. Penambahan data dari berbagai sumber atau wilayah lain dapat membantu meningkatkan performa model secara keseluruhan dan memberikan hasil prediksi yang lebih akurat. Model *Random Forest* menjadi alternatif algoritma yang dipakai Oleh Puskesmas Summersari untuk mengembangkan sistem deteksi dini Angka Kematian Ibu.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Politeknik Negeri Jember atas dukungan dan fasilitas yang diberikan selama proses penelitian ini. Sebagian kegiatan penelitian ini dilakukan saat penulis pertama masih aktif sebagai dosen di Program Studi Manajemen Informasi Kesehatan. Penulis pertama juga mencantumkan afiliasi saat ini di Ritsumeikan University, Jepang, sebagai bagian dari status studi lanjut, meskipun institusi tersebut tidak terlibat langsung dalam pendanaan penelitian ini.

REFERENSI

- [1] J. P. Souza *et al.*, “A global analysis of the determinants of maternal health and transitions in maternal mortality,” *Lancet Glob. Heal.*, vol. 12, no. 2, pp. e306–e316, Feb. 2024, doi: 10.1016/S2214-109X(23)00468-0.
- [2] M. Syairaji, D. S. Nurdianti, B. S. Wiratama, Z. D. Prüst, K. W. M. Bloemenkamp, and K. J. C. Verschueren, “Trends and causes of maternal mortality in Indonesia: a systematic review,” *BMC Pregnancy Childbirth*, vol. 24, no. 1, pp. 1–14, Jul. 2024, doi: 10.1186/s12884-024-06687-6.
- [3] M. N. Islam, S. N. Mustafina, T. Mahmud, and N. I. Khan, “Machine learning to predict pregnancy outcomes: a systematic review, synthesizing framework and future research agenda,” *BMC Pregnancy Childbirth*, vol. 22, no. 1, pp. 1–19, Apr. 2022, doi: 10.1186/s12884-022-04594-2.
- [4] E. da Silva Rocha, F. L. de Moraes Melo, M. E. F. de Mello, B. Figueiroa, V. Sampaio, and P. T. Endo, “On usage of artificial intelligence for predicting mortality during and post-pregnancy: a systematic review of literature,” *BMC Med. Inform. Decis. Mak.*, vol. 22, no. 1, pp. 1–17, Dec. 2022, doi: 10.1186/s12911-022-02082-3.
- [5] X. Zhang and H. Yang, “Improving Maternal Mortality Prediction through Machine Learning Algorithms,” *J. Med. Syst.*, vol. 45, no. 2, pp. 65–72, 2021.
- [6] S. Suparji, H. S. W. Nugroho, S. Sunarto, and A. S. Prayogi, “The high maternal mortality rate in Indonesia is a challenge that must be addressed immediately,” *PAMJ - One Heal.*, vol. 14, pp. 1–6, 2024, doi: 10.11604/pamj-oh.2024.14.13.44464.
- [7] M. H. Sylvain, E. C. Nyabyenda, M. Uwase, I. Komezusenge, F. Ndikumana, and I. Ngaruye, “Prediction of adverse pregnancy outcomes using machine learning techniques: evidence from analysis of electronic medical records data in Rwanda,” *BMC Med. Inform. Decis. Mak.*, vol. 25, no. 1, pp. 1–13, Feb. 2025, doi: 10.1186/s12911-025-02921-z.
- [8] E. N. Ekwonwune, C. I. Ubochi, and A. E. Duroha, “Data Mining as a Technique for Healthcare Approach,” *Int. J. Commun. Netw. Syst. Sci.*, vol. 15, no. 09, pp. 149–165, 2022, doi: 10.4236/ijcns.2022.159011.
- [9] N. Jothi, N. A. Rashid, and W. Husain, “Data Mining in Healthcare – A Review,” *Procedia Comput. Sci.*, vol. 72, pp. 306–313, 2015, doi: 10.1016/j.procs.2015.12.145.
- [10] H. S. Khamis, K. W. Cheruiyot, and S. Kimani, “Application of k- Nearest Neighbour Classification in Medical Data Mining,” *Int. J. Inf. Commun. Technol. Res.*, vol. 4, no. 4, pp. 121–128, 2014.
- [11] K. E. Setiawan, A. Kurniawan, and S. Y. Prasetyo, “Comparative analysis of machine learning decision tree-based models for predicting maternal health risks,” *Procedia Comput. Sci.*, vol. 245, pp. 57–64, 2024, doi: 10.1016/j.procs.2024.10.229.
- [12] A. Raza, H. U. R. Siddiqui, K. Munir, M. Almutairi, F. Rustam, and I. Ashraf, “Ensemble learning-based feature engineering to analyze maternal health during pregnancy and health risk prediction,” *PLoS One*, vol. 17, no. 11, pp. 1–29, Nov. 2022, doi: 10.1371/journal.pone.0276525.
- [13] M. A. Rahman, R. M. Noor, S. Mallik, N. K. Santa, S. Deb, and A. Pathak, “Classification Of Health Risk Levels For Pregnant Women Using Support Vector Machine (SVM) Algorithm,” *J. Comput. Eng.*, vol. 26, no. 3, pp. 7–17, 2024, doi: 10.9790/0661-2603010717.
- [14] S. Uddin, I. Haque, H. Lu, M. A. Moni, and E. Gide, “Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction,” *Sci. Rep.*, vol. 12, no. 1, pp. 1–11, Apr. 2022, doi: 10.1038/s41598-022-10358-x.
- [15] T. M. Bosschieter *et al.*, “Interpretable Predictive Models to Understand Risk Factors for Maternal and Fetal Outcomes,” *J. Healthc. Informatics Res.*, pp. 1–25, Oct. 2023, doi: 10.1007/s41666-023-00151-4.

- [16] M. M. Mijwil and R. A. Abttan, "Utilizing the Genetic Algorithm to Pruning the C4.5 Decision Tree Algorithm," *Asian J. Appl. Sci.*, vol. 9, no. 1, pp. 45–52, Feb. 2021, doi: 10.24203/ajas.v9i1.6503.
- [17] D. Mennickent *et al.*, "Machine learning applied in maternal and fetal health: a narrative review focused on pregnancy diseases and complications," *Front. Endocrinol. (Lausanne)*, vol. 14, pp. 1–22, May 2023, doi: 10.3389/fendo.2023.1130139.
- [18] J. Liao *et al.*, "Artificial intelligence assists precision medicine in cancer treatment," *Front. Oncol.*, vol. 12, pp. 1–16, Jan. 2023, doi: 10.3389/fonc.2022.998222.
- [19] S. Yan, J. Li, and W. Wu, "Artificial intelligence in breast cancer: application and future perspectives," *J. Cancer Res. Clin. Oncol.*, vol. 149, no. 17, pp. 16179–16190, Nov. 2023, doi: 10.1007/s00432-023-05337-2.