

DELIVERY METHOD PREDICTION USING BORUTA FEATURE SELECTION AND RANDOM FOREST ALGORITHM

Tiara Farhana Salsabila Putri^{*1}, Rendra Gustriansyah¹, Zaid Romegar Mair¹

¹Teknik Informatika, Fakultas Ilmu Komputer dan Sains, Universitas Indo Global Mandiri,
Palembang, Indonesia

Penulis korespondensi: Tiara Farhana Salsabila Putri (2022110005@students.uigm.ac.id)

Keputusan metode persalinan yang masih subjektif dapat memengaruhi ketepatan rujukan maternal. Penelitian ini bertujuan membangun model prediksi metode persalinan secara objektif menggunakan algoritma Random Forest dan seleksi fitur Boruta. Penelitian ini menggunakan 503 data rekam medis ibu hamil dari RSUP Dr. Mohammad Hoesin Palembang. Algoritma Boruta diterapkan untuk menyeleksi fitur paling relevan dari 13 variabel awal guna melatih model Random Forest. Hasil penelitian menunjukkan Boruta berhasil mengidentifikasi 12 fitur penting, dengan preeklampsia, riwayat caesar, dan mean arterial pressure sebagai prediktor klinis utama. Evaluasi model Random Forest menghasilkan tingkat akurasi 94,00% dengan performa seimbang tanpa indikasi overfitting. Simpulannya, kombinasi metode Boruta dan Random Forest menghasilkan model prediksi metode persalinan yang akurat sehingga berpotensi kuat diaplikasikan sebagai sistem pendukung keputusan klinis.

Kata Kunci - Boruta, Klasifikasi, Machine Learning, Persalinan, Random Forest.

I. PENDAHULUAN

Persalinan merupakan fase penentu yang sangat kritis bagi keselamatan ibu dan bayi. Keputusan dalam menentukan metode persalinan yang tepat—baik per vaginam secara fisiologis maupun operasi *sectio caesarea*—membutuhkan evaluasi komprehensif terhadap berbagai parameter klinis seperti usia ibu, tekanan darah, usia kehamilan, kondisi janin, dan riwayat obstetri sebelumnya [1], [2]. Kesalahan atau ketidaktepatan dalam pengambilan keputusan medis ini berisiko tinggi memicu komplikasi fatal, seperti perdarahan parah hingga kematian [3]. Tingkat urgensi dari permasalahan ini tercermin jelas pada tingginya angka kematian ibu di Indonesia. Berdasarkan data Program Kesehatan Keluarga Kementerian Kesehatan RI tahun 2024, angka kematian maternal mencapai 4.151 kasus yang didominasi oleh komplikasi kehamilan, hipertensi, dan perdarahan obstetri [4]. Oleh karena itu, ketidakmampuan dalam memprediksi kondisi darurat secara dini menjadi ancaman mematikan yang menuntut adanya sistem pengambilan keputusan klinis yang jauh lebih objektif dan berbasis data [5].

Perkembangan *Artificial Intelligence* (AI), khususnya *Machine Learning*, memberikan peluang besar untuk

membangun Sistem Pendukung Keputusan (SPK) klinis yang mampu menganalisis hubungan antarvariabel medis secara lebih akurat dibandingkan pendekatan konvensional [6]. Salah satu algoritma yang banyak digunakan adalah *Random Forest* karena memiliki kemampuan klasifikasi yang baik pada data berdimensi tinggi dan dapat mengurangi risiko *overfitting* melalui pendekatan *ensemble learning* [7]. Namun, data rekam medis pada umumnya mengandung variabel yang tidak relevan atau redundan yang dapat memengaruhi kinerja model. Oleh karena itu, diperlukan proses seleksi fitur untuk mempertahankan variabel yang benar-benar berkontribusi terhadap proses klasifikasi.

Algoritma Boruta merupakan metode seleksi fitur berbasis *wrapper* yang bekerja berdampingan dengan *Random Forest* dengan cara membandingkan fitur asli dengan *shadow features* (fitur bayangan) untuk mengidentifikasi seluruh variabel yang relevan dengan target prediksi [8]. Penggunaan Boruta diharapkan dapat meningkatkan kualitas data masukan, sehingga menghasilkan model klasifikasi yang lebih akurat dan efisien.

Penelitian terdahulu menunjukkan bahwa *Random Forest* memiliki performa yang baik dalam memprediksi metode persalinan. Sebagai contoh, Fernández et al. [9] melaporkan akurasi sebesar 91% dalam mengklasifikasikan persalinan normal dan caesar, sementara Alsaad et al. [10] mencapai nilai ROC-AUC sebesar 0,90 dengan akurasi mendekati 89% menggunakan dataset kehamilan berskala besar. Baru-baru ini, Owusu et al. [11] membuktikan bahwa integrasi algoritma Boruta untuk seleksi fitur secara signifikan berhasil meningkatkan performa model *Random Forest*, mencapai akurasi yang luar biasa sebesar 98,1% dalam memprediksi persalinan *caesar*.


Meskipun pendekatan tersebut memberikan hasil yang menjanjikan di tingkat global, analisis kesenjangan (*gap analysis*) menunjukkan bahwa penerapan kombinasi algoritma Boruta dan *Random Forest* pada data klinis maternal di Indonesia masih sangat terbatas. Kebanyakan penelitian sebelumnya belum berfokus pada evaluasi efektivitas integrasi algoritma ini dalam menangani karakteristik dan kompleksitas rekam medis nyata dari rumah sakit rujukan lokal di Indonesia. Oleh karena itu, kebaruan (*novelty*) dari penelitian ini terletak pada pemodelan komputasi cerdas yang secara spesifik dirancang dan dioptimalkan untuk mengekstraksi pola

dari karakteristik demografis dan klinis ibu hamil di Indonesia, sebuah aspek krusial yang belum terakomodasi oleh literatur-literatur sejenis sebelumnya.

Berdasarkan urgensi permasalahan dan kesenjangan penelitian tersebut, penelitian ini bertujuan untuk membangun model prediksi metode persalinan yang objektif menggunakan algoritma *Random Forest* yang dipadukan dengan seleksi fitur Boruta. Hasil dari penelitian ini diharapkan dapat memperkuat penerapan *machine learning* di bidang obstetri dan menjadi landasan inovatif bagi pengembangan sistem pendukung keputusan klinis di masa depan.

II. METODOLOGI PENELITIAN

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis yang terstruktur, mulai dari identifikasi masalah klinis hingga penarikan kesimpulan. Secara garis besar, tahap penelitian diilustrasikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Proses pengumpulan data secara umum terbagi menjadi dua jenis, yaitu data primer dan data sekunder. Data primer didefinisikan sebagai data yang dikumpulkan atau diperoleh langsung oleh peneliti dari objek yang diteliti, sedangkan data sekunder adalah data yang diperoleh secara tidak langsung melalui media perantara atau dokumen historis yang sudah dicatat sebelumnya [12].

Sumber data yang digunakan pada penelitian ini merupakan data sekunder, yang berfokus pada rekam medis klinis ibu bersalin. Data ini diperoleh secara resmi dari instansi RSUP Dr. Mohammad Hoesin Palembang yang tercatat selama periode Januari 2023 hingga Desember 2025. Setelah proses pengumpulan data dari rekam medis selesai, seluruh informasi yang terhimpun disusun dan diorganisir ke dalam sebuah berkas (*file*) dengan format *.xlsx* agar dapat diproses oleh sistem komputasi. Total keseluruhan dataset yang digunakan dalam penelitian ini berjumlah 503 data observasi pasien, yang masing-masing memuat 13 variabel prediktor klinis dan 1 kelas target cara persalinan (Normal / Caesar).

Rincian mengenai variabel-variabel yang dianalisis dalam penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Variabel Penelitian

No	Nama Variabel		Keterangan
1	Usia Ibu		Usia Ibu Hamil
2	Tekanan Sistolik	Darah	Angka tekanan darah atas
3	Tekanan Diastolik		Angka tekanan darah bawah
4	Tinggi Badan	Darah	Tinggi badan ibu
5	Berat Badan		Berat badan ibu
6	Usia Kehamilan		Lama kehamilan
7	Gravida		Jumlah kehamilan
8	Paritas		Jumlah persalinan
9	Abortus		Riwayat keguguran
10	Presentasi Janin		Posisi janin
11	Preeklampsia		Kondisi preeklampsia
12	Riwayat SC		Riwayat operasi caesar
13	Persalinan		Target klasifikasi

B. Data Preprocessing

Tahap *data preprocessing* merupakan proses persiapan data mentah yang bertujuan untuk mempermudah jalannya proses pelatihan (*training*) sekaligus mengoptimalkan performa model yang dihasilkan [13]. Proses ini meliputi pembersihan data (*data cleaning*) untuk menangani nilai kosong (*missing values*), dilanjutkan dengan *encoding* untuk mengubah variabel kategorial (seperti presentasi janin, preeklampsia, dan riwayat *caesar*) menjadi format numerik. Selanjutnya, dilakukan *feature engineering* guna mengekstraksi nilai BMI dan MAP. Keseluruhan tahapan ini memastikan data telah terstandarisasi dan siap digunakan pada proses seleksi fitur.

C. Boruta Feature Selection

Setelah tahap *preprocessing*, tidak semua dari 14 variabel klinis memiliki kontribusi signifikan terhadap target persalinan. Oleh karena itu, seleksi fitur dilakukan menggunakan algoritma Boruta guna mengeliminasi atribut yang tidak relevan (*noise*) dan mencegah *overfitting*. Tahap seleksi fitur menggunakan algoritma Boruta bertujuan mengeliminasi variabel klinis yang tidak relevan (*noise*). Boruta mengevaluasi setiap atribut dengan membandingkannya terhadap *shadow features* (duplikasi fitur yang diacak). Hanya variabel dengan skor kepentingan lebih tinggi dibandingkan *shadow features* yang dipertahankan untuk tahap pemodelan. Metode ini dinilai lebih tangguh menangani data *non-linear* dibandingkan pendekatan tradisional [8].

D. Pembagian Data

Setelah fitur-fitur terbaik diperoleh, fitur selanjutnya diproses ke tahap pembagian data. Dataset dipisahkan menjadi data latih untuk membentuk model dan data uji untuk evaluasi kinerja. Pemisahan ini esensial guna mencegah *overfitting* serta menjaga keandalan model saat dihadapkan pada data baru [14]. Pada penelitian ini digunakan rasio 70:30, sebanyak 70% data digunakan untuk data latih model *Random Forest* dan 30% data digunakan untuk data uji.

E. Pemodelan Random Forest

Proses klasifikasi dilakukan menggunakan algoritma *Random Forest* yang dilatih pada 70% data latih. Guna

mencapai tingkat akurasi prediksi yang optimal, proses pelatihan ini diintegrasikan dengan metode *k-fold cross validation* (CV) menggunakan nilai $k = 10$. Metode ini bekerja dengan membagi ulang (*resampling*) data latih ke dalam 10 lipatan (*folds*) skenario secara sistematis untuk dilatih dan divalidasi secara bergantian. Pendekatan ini secara efektif mampu meminimalisir bias prediksi dan memastikan stabilitas model, sehingga sering diekomendasikan dalam berbagai studi klasifikasi [15].

F. Evaluasi Model

Tahap evaluasi model klasifikasi dilakukan menggunakan *confusion matrix* dengan membandingkan hasil prediksi terhadap data aktual. Pengukuran ini didasarkan pada empat komponen perhitungan: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dari matriks tersebut, diperoleh metrik *accuracy* (persentase total prediksi yang benar), *precision* (proporsi ketepatan tebakan kelas positif), *recall* (kemampuan akurat model mengenali data aktual positif), dan *F1-score* yang mencerminkan rasio harmonis antara nilai *precision* dan *recall* [16]. Secara matematis, metrik-metrik tersebut dirumuskan sebagai berikut [17].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

$$F1 - Score = \frac{2 \times (Recall \times Precision)}{(Recall + Precision)} \quad (8)$$

III. HASIL DAN PEMBAHASAN


A. Hasil

Tahapan prapemrosesan data mencakup tiga prosedur esensial. Proses pertama adalah pembersihan data (*data cleaning*) guna mengeliminasi nilai kosong (*missing values*) dan rekam medis ganda (*duplicate records*). Proses ini berhasil menyaring 503 data mentah menjadi 498 data bersih yang siap diolah. Proses kedua melibatkan teknik transformasi data (*encoding*) untuk mengonversi variabel kategoris menjadi format numerik, sehingga kompatibel dengan komputasi *Random Forest*. Pada tahap ini, atribut biner dan variabel target (Preeklampsia, Riwayat *Caesar*, serta Metode Persalinan) direpresentasikan ke dalam nilai 0 dan 1, sementara atribut multikelas (Presentasi Janin) dikodekan menjadi 0, 1, dan 2.

Prosedur terakhir dari prapemrosesan adalah rekayasa fitur (*feature engineering*), yang dilakukan dengan mengekstraksi variabel BMI dan MAP. Penambahan kedua parameter baru ini bertujuan untuk memperkuat dan memperkaya nilai informasi dari prediktor klinis pasien sebelum keseluruhan dataset diumpungkan ke tahap seleksi fitur.

Algoritma ini menggunakan *Random Forest* sebagai model dasar ($n_estimators = 100$, $max_depth = 5$, dan $class_weight = 'balanced'$) untuk mengevaluasi tingkat kepentingan fitur (*feature importance*). Melalui proses maksimal 100 iterasi, sistem membandingkan tingkat signifikansi dari variabel asli terhadap *shadow features*. Atribut yang secara signifikan mengungguli *shadow*

features diklasifikasikan dengan status *Confirmed* (diterima), sedangkan atribut dengan nilai yang lebih rendah diberi label *Rejected* (ditolak). Hasil dari implementasi Boruta ini dapat dilihat pada Gambar 2.



Gambar 2. Hasil Boruta

Berdasarkan hasil implementasi, Preeklampsia (0,160) dan Riwayat *Caesar* (0,125) teridentifikasi sebagai dua prediktor yang paling dominan. Dari total 14 variabel yang dievaluasi, sebanyak 12 variabel berhasil memperoleh status *Confirmed*. Sebaliknya, Riwayat Abortus dan Presentasi Janin diklasifikasikan sebagai *Rejected* karena terindikasi sebagai noise. Oleh karena itu, kedua atribut tersebut dieliminasi, sehingga menyisakan 12 fitur klinis yang relevan untuk diteruskan ke tahap pemodelan.

Setelah melalui tahap seleksi fitur Boruta, dataset dipartisi menjadi dua bagian, yakni data latih (*training set*) dan data uji (*testing set*). Berdasarkan skenario rasio pembagian 70:30 tersebut, dari total keseluruhan 498 rekam medis, sistem mengalokasikan 348 data untuk melatih algoritma *Random Forest*, sedangkan 150 data sisanya disimpan untuk keperluan pengujian akhir.

Data latih yang telah dipartisi kemudian digunakan untuk membangun model klasifikasi *Random Forest*. Guna menghindari *overfitting* serta mengatasi masalah ketidakseimbangan kelas (*class imbalance*), model ini dikonfigurasi dengan 100 pohon keputusan ($n_estimators = 100$), kedalaman maksimum 10 ($max_depth = 10$), jumlah sampel minimum sebanyak 10 untuk memecah simpul internal ($min_samples_split = 10$), dan penyesuaian bobot kelas secara otomatis ($class_weight = 'balanced'$).

Sebelum dievaluasi pada data yang belum pernah dilihat (*unseen data*), keandalan model divalidasi terlebih dahulu menggunakan metode *10-Fold Cross Validation*. Evaluasi ini menerapkan pendekatan *macro average* untuk memastikan bahwa kelas persalinan normal maupun caesar dinilai secara proporsional. Rincian hasil validasi tersebut disajikan pada Tabel 2.

Tabel 2. Hasil Pemodelan *Random Forest*


(Fold) ke-	Accuracy	Precision	Recall	F1-Score
1	0,9714	0,9722	0,9722	0,9714
2	0,9722	0,9091	0,8824	0,8833
3	0,9714	0,9722	0,9722	0,9714
4	0,9714	0,9722	0,9722	0,9714
5	0,9714	0,9737	0,9706	0,9713
6	0,8857	0,9091	0,8824	0,8833

(Fold) ke-	Accuracy	Precision	Recall	F1-Score
7	0,7143	0,7255	0,7108	0,7083
8	0,9143	0,9161	0,9134	0,9140
9	0,9412	0,9474	0,9412	0,9410
10	0,8529	0,8864	0,8529	0,8497
Mean	0,9080	0,9184	0,9070	0,9065
SD	0,0767	0,0714	0,0779	0,0785

Berdasarkan Tabel 2, model *Random Forest* menunjukkan kinerja yang cukup baik dengan rata-rata *accuracy* sebesar 90,80%, *precision* 91,84%, *recall* 90,70%, dan F1-score 90,65%. Meskipun terjadi penurunan *accuracy* pada fold ketujuh menjadi 71,43%, kondisi tersebut menunjukkan adanya variasi performa antar-fold yang dapat dipengaruhi oleh perbedaan distribusi karakteristik data pada setiap fold. Dengan jumlah data pengujian sekitar 49–50 instans pada setiap fold, beberapa kesalahan prediksi pada kasus dengan karakteristik klinis yang lebih kompleks atau berbeda dari pola umum dapat memberikan pengaruh yang cukup besar terhadap nilai metrik.

Pembatasan kompleksitas pohon melalui parameter *max_depth* = 10 dapat membantu mengurangi kecenderungan model dalam mempelajari pola yang terlalu spesifik pada data latih. Secara keseluruhan, model tetap menghasilkan performa yang baik pada sebagian besar *fold*. Nilai standar deviasi sebesar $\pm 0,0767$ menunjukkan adanya variasi performa antar-fold, tetapi model masih mampu mempertahankan rata-rata kinerja yang relatif baik. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik dan tidak menunjukkan indikasi *overfitting* yang dominan pada proses validasi.

Pascaproses validasi, model *Random Forest* diuji menggunakan 150 data uji (*testing data*) baru guna mengukur kemampuan generalisasi model secara objektif. Kinerja model dievaluasi dengan membandingkan hasil prediksi terhadap label aktual menggunakan instrumen *confusion matrix*. Pengukuran metrik dihitung melalui pendekatan *macro average* agar kelas persalinan "Normal" dan "Caesar" dapat dievaluasi secara seimbang. Distribusi ketepatan dan kesalahan prediksi dari pengujian tersebut divisualisasikan lebih rinci melalui *confusion matrix* pada Gambar 3.



Gambar 3. *Confusion Matrix* Data Uji

Berdasarkan matriks tersebut, dari total 150 data uji, model berhasil mengklasifikasikan 141 data dengan tepat dan hanya menghasilkan 9 kesalahan prediksi. Secara lebih rinci, dari 75 pasien dengan label aktual persalinan "Normal", model mampu memprediksi 73 data secara akurat, sementara 2 instans lainnya keliru diklasifikasikan sebagai persalinan caesar. Sebaliknya, pada kelompok 75 pasien dengan label aktual "Caesar", model berhasil memprediksi 68 data dengan tepat, sedangkan 7 data sisanya secara keliru diprediksi sebagai persalinan normal.

Selanjutnya, perhitungan metrik evaluasi dilakukan menggunakan pendekatan *macro average* untuk menjamin bahwa performa pada kelas persalinan "Normal" maupun "Caesar" dinilai secara proporsional. Hasil akhir pengukuran metrik dari pengujian model ini disajikan pada Tabel 3.

Tabel 3. Hasil Pengujian Model

Kelas	Precision	Recall	F1-Score	Accuracy
Normal	0,9125	0,9733	0,9419	-
Caesar	0,9714	0,9067	0,9379	-
Macro Avg	0,9420	0,9400	0,9399	0,9400

Merujuk pada tabel metrik evaluasi tersebut, model klasifikasi menunjukkan performa yang sangat optimal dengan tingkat akurasi keseluruhan mencapai 94,00%. Model ini terbukti sangat sensitif dalam mendeteksi persalinan normal (ditunjukkan oleh nilai *recall* sebesar 97,33%) dan memiliki tingkat *precision* yang tinggi dalam memprediksi persalinan caesar (nilai presisi sebesar 97,14%). Tingginya capaian metrik rata-rata *macro (macro average)* mengindikasikan bahwa model *Random Forest* yang dibangun terdistribusi secara seimbang dan tidak memiliki bias terhadap salah satu kelas tertentu. Rendahnya tingkat kesalahan prediksi (baik *false positive* maupun *false negative*) dalam pengujian ini membuktikan bahwa algoritma *Random Forest* yang diusulkan memiliki keandalan yang sangat tinggi untuk diimplementasikan sebagai sistem pendukung keputusan klinis pada rujukan persalinan maternal.

B. Pembahasan

Tingginya tingkat keberhasilan klasifikasi dalam penelitian ini sangat didukung oleh penerapan tahap reduksi dimensi menggunakan algoritma Boruta yang secara efektif menyaring fitur-fitur klinis esensial. Variabel seperti Preeklampsia, Riwayat Caesar, dan MAP teridentifikasi sebagai prediktor yang paling signifikan. Secara medis, ketiga fitur tersebut merupakan indikator krusial dalam mendeteksi kehamilan berisiko tinggi serta potensi komplikasi pada saat persalinan. Melalui eliminasi variabel *noise*, algoritma *Random Forest* mampu beroperasi secara jauh lebih efisien karena komputasinya terfokus pada ekstraksi pola dari data medis yang benar-benar relevan.

Pada tahap pemodelan, konfigurasi *Random Forest* yang membatasi kompleksitas pohon keputusan terbukti sangat berhasil dalam mencegah terjadinya *overfitting*. Temuan menarik ditunjukkan saat model dihadapkan pada data uji (*testing data*), di mana tingkat akurasi mengalami peningkatan dari 90,80% (pada fase *cross-validation*)

menjadi 94,00%. Peningkatan performa ini merupakan hasil dari efek sinergis antara algoritma Boruta—yang mengeliminasi data redundan pemicu tingginya varians—dengan konfigurasi pohon yang optimal. Sinergi tersebut memungkinkan model untuk menangkap pola yang lebih jelas dan memiliki daya generalisasi tinggi terhadap 150 data yang belum pernah dipelajari sebelumnya (*unseen data*). Analisis menggunakan instrumen *confusion matrix* lebih lanjut menegaskan bahwa model mampu mengklasifikasikan kelas persalinan "Normal" dan "Caesar" secara sangat proporsional, yang dibuktikan dengan capaian *macro average* untuk presisi sebesar 94,20% dan *recall* 94,00%.

Rangkaian hasil ini secara meyakinkan berhasil menjawab kesenjangan penelitian (*research gap*) yang telah diidentifikasi sebelumnya. Berbeda dengan sejumlah studi terdahulu yang menggunakan model standar tanpa seleksi fitur yang ketat, seperti penelitian Fernández et., al [9] dan Alsaad et., al [10] dengan capaian akurasi masing-masing sebesar 91% dan 89%, model yang diusulkan dalam penelitian ini mampu menunjukkan performa yang jauh lebih unggul. Lebih dari itu, studi ini memperkuat temuan Owusu et., al [11] yang menegaskan bahwa integrasi Boruta dengan *Random Forest* dapat mendongkrak kemampuan prediksi secara signifikan. Poin paling krusial dari temuan ini adalah pembuktian bahwa pendekatan hibrida tersebut tidak hanya efektif secara teoretis atau pada dataset global, tetapi juga sangat andal ketika diaplikasikan secara spesifik pada data klinis aktual ibu hamil (*real-world data*) dari rumah sakit rujukan tingkat lokal di Indonesia. Hal ini memvalidasi ketangguhan model dalam menghadapi konteks demografis dan klinis yang spesifik.

Secara keseluruhan, arsitektur komputasi yang diusulkan terbukti stabil, tangguh terhadap *noise*, dan memiliki kemampuan generalisasi yang sangat baik. Karakteristik ini menjadikannya fondasi yang sangat potensial untuk dikembangkan sebagai Sistem Pendukung Keputusan (SPK) klinis guna membantu tenaga medis dalam mengambil keputusan secara objektif. Meskipun demikian, penelitian ini tidak lepas dari sejumlah keterbatasan. Dataset yang digunakan relatif terbatas (503 rekam medis) dan hanya bersumber dari satu rumah sakit terpusat, sehingga berpotensi membatasi tingkat generalisasi model jika diterapkan pada fasilitas pelayanan kesehatan berskala lebih kecil atau pada wilayah yang berbeda. Oleh karena itu, penelitian lanjutan disarankan untuk menggunakan dataset multisenter dari berbagai rumah sakit dengan ukuran sampel yang lebih masif guna memperkuat keandalan model.

IV. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa integrasi algoritma Boruta dengan klasifikasi *Random Forest* sangat efektif dalam mengoptimalkan pemodelan prediksi metode persalinan melalui ekstraksi variabel klinis maternal yang paling esensial. Arsitektur yang dihasilkan terbukti mampu menyediakan landasan komputasi yang tangguh, kebal terhadap *noise*, dan sepenuhnya berbasis data (*data-driven*). Capaian ini memiliki urgensi dan signifikansi yang tinggi di bidang obstetri, karena keberadaan model ini dapat menjadi tulang punggung bagi pengembangan

Sistem Pendukung Keputusan (SPK) klinis yang andal. Implementasi sistem ini dinilai akan sangat memberdayakan tenaga medis dalam merumuskan keputusan rujukan yang cepat, objektif, dan akurat guna memitigasi risiko komplikasi, yang pada akhirnya akan meningkatkan kualitas keselamatan dan layanan kesehatan maternal secara keseluruhan.

Sebagai saran untuk aplikasi praktis, model komputasi ini sangat direkomendasikan untuk diintegrasikan ke dalam Sistem Informasi Manajemen Rumah Sakit (SIMRS) agar dapat berfungsi sebagai instrumen skrining real-time bagi dokter maupun bidan. Untuk pengembangan sistem di masa depan, ruang lingkup penelitian perlu diperluas melalui pemanfaatan dataset multisenter yang tidak hanya berpusat pada rumah sakit rujukan, tetapi juga mencakup fasilitas kesehatan tingkat pertama (seperti Puskesmas). Selain itu, eksplorasi menggunakan algoritma berbasis deep learning juga patut dipertimbangkan guna menguji dan meningkatkan skalabilitas serta daya generalisasi sistem pada populasi pasien yang lebih masif dan heterogen.

DAFTAR PUSTAKA

- [1] D. M. U. Atmaja, A. R. Hakim, A. Basri, and A. Ariyanto, "Klasifikasi Metode Persalinan pada Ibu Hamil Menggunakan Algoritma Random Forest Berbasis Mobile," *J. Ris. Sains dan Teknol.*, vol. 7, no. 2, pp. 161–168, 2023, doi: 10.30595/jrst.v7i2.16705.
- [2] A. Bayuana et al., "Komplikasi Pada Kehamilan, Persalinan, Nifas dan Bayi Baru Lahir: Literature Review," *J. Wacana Kesehat.*, vol. 8, no. 1, pp. 27–37, 2023, doi: 10.52822/jwk.v8i1.517.
- [3] A. Mahadi and E. Utami, "Analisa Perbandingan Algoritma K-Nearest Neighbors dan Random Forest untuk Klasifikasi Tindakan Medis Persalinan pada Data Kehamilan Multi-Variabel," *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 424–433, 2025, doi: 10.47065/bulletincsr.v5i4.556.
- [4] Kementerian Kesehatan Republik Indonesia, *Profil Kesehatan Indonesia 2024*. Kementerian Kesehatan Republik Indonesia, 2025. [Online]. Available: <http://www.kemkes.go.id>
- [5] D. Sartika, N. K. P. Gumay, R. Gustriansyah, Y. Florensia, and M. Falah, "Comparative Analysis of SMOTE, WMOTE, and ADASYN Oversampling Methods on Multinomial Naive Bayes Performance in Classifying Toddlers Nutritional Status," *J. Teknol. dan Manaj. Inform.*, vol. 12, no. 1, pp. 10–20, 2026, doi: 10.26905/jtmi.v12i1.16438.
- [6] Z. Ullah, F. Saleem, M. Jamjoom, and B. Fakieh, "Reliable Prediction Models Based on Enriched Data for Identifying the Mode of Childbirth by Using Machine Learning Methods: Development Study," *J. Med. Internet Res.*, vol. 23, no. 6, pp. 1–12, 2021, doi: 10.2196/28856.
- [7] I. H. Sarker, "Machine learning: Algorithms, real-world applications and research directions," *SN Comput. Sci.*, vol. 2, p. 160, 2021, doi: 10.1007/s42979-021-00592-x.
- [8] M. G. Saputra and B. J. Santoso, "Implementation of Feature Selection Using Boruta to Improve the Accuracy of the Lapser Prediction Model," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. July, pp. 886–895, 2025, doi: 10.57152/malcom.v5i3.1992.
- [9] A. D. R. Fernández, D. R. Fernández, and M. T. P. Sánchez, "Prediction of the mode of delivery using artificial intelligence algorithms," *Comput. Methods Programs Biomed.*, vol. 219, 2022, doi: 10.1016/j.cmpb.2022.106740.
- [10] R. Alsaad, T. Farrell, J. Dela Cruz, A. Abd-alrazaq, and R. Thomas, "Artificial intelligence models for predicting the mode of delivery in maternal care," *J. Gynecol. Obstet. Hum. Reprod.*, vol. 54, no. 7, p. 102976, 2025, doi: 10.1016/j.jogoh.2025.102976.
- [11] F. O. Owusu et al., "Prediction of caesarean section birth using machine learning algorithms among pregnant women in a district hospital in Ghana," *BMC Pregnancy Childbirth*, vol. 25, no. 690, pp. 1–13, 2025, doi: 10.1186/s12884-025-07716-8.
- [12] M. A. F. Rahman, Z. R. Mair, and D. Sartika, "Klasifikasi Ulasan

- Pelanggan Shopee Mall Terhadap E-Commerce Penjualan Baju Batik Metode Naïve Bayes,” *Idealis Indones. J. Inf. Syst.*, vol. 7, no. 2, pp. 164–177, 2024, doi: 10.36080/idealis.v7i2.3178.
- [13] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, “Klasifikasi Penyakit Daun Pisang Menggunakan Convolutional Neural Network (CNN),” *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 1–6, 2024, doi: 10.54914/jtt.v10i1.1167.
- [14] M. I. Akbar, R. Heriansyah, and M. H. Irfani, “Pengaruh Splitting Data terhadap Akurasi Klasifikasi Demam Berdarah Dengue Menggunakan K-Nearest Neighbors,” *J. Algoritma*, vol. 6, no. 2, pp. 244–255, 2026, doi: 10.35957/algoritme.v6i2.13274.
- [15] R. Gustriansyah, N. Suhandi, S. Puspasari, A. Sanmorino, and D. Sartika, “Toddlers ’ Nutritional Status Prediction Using the Multinomial Logistics Method,” *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 6, no. 1, pp. 25–33, 2024, doi: 10.47709/cnahpc.v6i1.3372.
- [16] M. U. F. M. P, S. Kurniawan, and R. Gustriansyah, “Penerapan Metode Decision Tree Dalam Klasifikasi Status Gizi Balita,” *KOMPUTA J. Ilm. Komput. dan Inform.*, vol. 14, no. 2, pp. 2–10, 2025, doi: 10.34010/komputa.v14i2.16468.
- [17] F. Nur, M. Ahsan, and W. Harianto, “Komparasi Tingkat Akurasi Information Gain Dan Gain Ratio Pada Metode K-Nearest Neighbor,” *J. Mhs. Tek. Inform.*, vol. 6, no. 1, pp. 386–391, 2022, doi: 10.36040/jati.v6i1.4694.