

TESIS
PREDIKSI RISIKO POSTPARTUM PADA IBU PRIMIPARA
BERDASARKAN FAKTOR PSIKOLOGIS MENGGUNAKAN
ALGORITMA RANDOM FOREST DENGAN RANDOM
SEARCH



disusun oleh
ANGEL FOURTUNA DENGEN
23.51.2489
Konsentrasi : Digital Transformation Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2025

TESIS
PREDIKSI RISIKO POSTPARTUM PADA IBU PRIMIPARA
BERDASARKAN FAKTOR PSIKOLOGIS MENGGUNAKAN
ALGORITMA RANDOM FOREST DENGAN RANDOM
SEARCH

PREDICTION OF POSTPARTUM RISK IN PRIMIPAROUS
MOTHERS BASED ON PSYCHOLOGICAL FACTORS USING
THE RANDOM FOREST ALGORITHM WITH RANDOM
SEARCH

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana
Program Studi Informatika



disusun oleh

ANGEL FOURTUNA DENGEN

23.51.2489

Konsentrasi : Digital Transformation Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2025

HALAMAN PERSETUJUAN

HALAMAN PERSETUJUAN

PREDIKSI RISIKO POSTPARTUM PADA IBU PRIMIPARA
BERDASARKAN FAKTOR PSIKOLOGIS MENGGUNAKAN
ALGORITMA RANDOM FOREST DENGAN RANDOM SEARCH

PREDICTION OF POSTPARTUM RISK IN PRIMIPAROUS MOTHERS
BASED ON PSYCHOLOGICAL FACTORS USING THE RANDOM
FOREST ALGORITHM WITH RANDOM SEARCH

yang disusun dan diajukan oleh:

Angel Fauziana Degen
23.51.2.019

seleh abstraknya oleh Dosen Pembimbing Tetap
pada tanggal 03 November 2025

Dosen Pembimbing,

Prof. Dr. Ema Dertmi, S.Si., M.Kom.
NID. 190302037

HALAMAN PENGESAHAN

HALAMAN PENGESAHAN

**PREDIKSI RISIKO POSTPARTUM PADA IBU PRIMIPARA
BERDASARKAN FAKTOR PSIKOLOGIS MENGGUNAKAN
ALGORITMA RANDOM FOREST DENGAN RANDOM SEARCH**

**PREDICTION OF POSTPARTUM RISK IN PRIMIPAROUS MOTHERS
BASED ON PSYCHOLOGICAL FACTORS USING THE RANDOM
FOREST ALGORITHM WITH RANDOM SEARCH**

yang disusun dan diajukan oleh

Angel Fourtuna Dengan

23.51.2489

Telah dipertalihkan di Dewan Dewan Penguji
pada tanggal 03 November 2025

Susunan Dewan Penguji

Nama Penguji

Hanafi S. Kurni, N.Eng., Ph.D.
NIK. 190302024

Dr. Kumeru Ari Yusra, S.T., M.T.
NIK. 190302575

Prof. Dr. Ema Utami, S.Si, M.Kom
NIK. 190302017

Tanda Tangan



Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer
Tanggal 03 November 2025

DEKAN FAKULTAS ILMU KOMPUTER



Prof. Dr. Kusriah, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Angel Fourtuna Dengan
NIM : 23.51.2489

Merayakan bahwa Tesis dengan judul berikut:

Prediksi Risiko Postpartum Pada Ibu Primipara Berdasarkan Faktor Psikologi Menggunakan Algoritma Random Forest Dengan Random Search

Dosen Pembimbing : Prof. Dr. Ema Utami, S.Si., M.Kom.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERBAH dipaparkan untuk mendapatkan gelar akademik, baik di Universitas ASHOKA Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas diuraikan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada Karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas ASHOKA Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 03 November 2024

Yang Menyatakan,



Angel Fourtuna Dengan

HALAMAN PERSEMBAHAN

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga tesis ini dapat diselesaikan dengan baik. Tesis ini penulis persembahkan kepada:

1. Tuhan Yang Maha Esa, sebagai ungkapan rasa syukur atas kekuatan, kesehatan, dan kelancaran dalam penyelesaian tesis ini.
2. Orang tua dan keluarga tercinta, atas doa, kasih sayang, dan dukungan yang senantiasa menyertai setiap langkah penulis.
3. Dosen pembimbing, pimpinan program studi, dan seluruh sivitas akademika Universitas AMIKOM Yogyakarta, atas bimbingan, arahan, dan dukungan akademik yang diberikan.
4. Sahabat, rekan seperjuangan, dan seluruh pihak yang telah memberikan motivasi, semangat, serta bantuan secara langsung maupun tidak langsung selama proses penyusunan tesis ini.

Semoga tesis ini dapat memberikan manfaat dan kontribusi bagi pengembangan ilmu pengetahuan, khususnya di bidang teknologi informasi dan kesehatan.

Yogyakarta, 10 Oktober 2025

Penulis

KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa, atas segala berkat, rahmat, dan kasih sayang-Nya yang telah diberikan kepada saya sehingga saya dapat menyelesaikan tesis ini yang berjudul “*Prediksi Risiko Postpartum pada Ibu Primipara Berdasarkan Faktor Psikologis Menggunakan Algoritma Random Forest dengan Random Search*”. Tanpa bimbingan-Nya, penulis tidak akan mampu menyelesaikan setiap tantangan yang ada dalam penyusunan tesis ini. Semoga karya ini dapat menjadi sumbangsih yang bermanfaat bagi perkembangan ilmu pengetahuan, khususnya di bidang teknologi informasi dan kesehatan.

Penyusunan tesis ini tentu tidak terlepas dari bantuan dan dukungan dari berbagai pihak yang telah memberikan kontribusi yang sangat berarti sepanjang proses ini. Oleh karena itu, dalam kesempatan yang penuh rasa syukur ini, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. **Prof. Dr. M. Suyanto, MM.**, selaku Rektor Universitas AMIKOM Yogyakarta, yang telah mendukung penuh semua kegiatan akademik di universitas ini. Dukungan beliau sangat memotivasi kami, para mahasiswa, untuk terus berkembang dalam dunia pendidikan.
2. **Robert Marco, S.T, M.T, Ph.D**, selaku Ketua Program Studi S2 Informatika Universitas AMIKOM Yogyakarta, yang telah memberikan perhatian besar terhadap program studi ini serta menyediakan berbagai fasilitas yang sangat mendukung kelancaran studi kami.
3. **Prof. Dr. Ema Utami S.Si., M.Kom**, selaku dosen pembimbing yang telah dengan sabar dan penuh dedikasi memberikan arahan, masukan, serta saran yang sangat berharga selama penyusunan tesis ini. Bimbingan mereka memberikan wawasan yang lebih luas dalam mengembangkan ide dan konsep dalam penelitian ini.
4. **Mama dan Papa**, yang senantiasa memberikan dukungan tak terhingga, doa, serta kasih sayang yang selalu menguatkan saya dalam menjalani setiap

fase kehidupan ini. Tanpa mereka, saya tidak akan sampai pada titik ini. Saya sangat berterima kasih atas segala pengorbanan yang telah mereka lakukan demi pendidikan dan masa depan saya.

5. **Ketga kakak penulls, Riso, Dede, dan Trtxte**, yang selalu memberikan motivasi, semangat, dan nasihat yang bijaksana dalam setiap langkah saya. Terima kasih atas segala perhatian, dukungan, dan kebersamaannya yang tiada henti. Kehadiran mereka selalu memberikan ketenangan dan rasa aman dalam perjalanan hidup saya.
6. **Sahabat penulls, Pajak PPN dan Floravitha**, yang selalu memberikan dukungan emosional dan motivasi. Kehadiran kalian dalam hidup saya sangat berarti, memberikan warna dan kebahagiaan yang tak ternilai. Terima kasih telah menjadi teman sejati yang selalu siap memberikan semangat dan berbagi tawa di tengah-tengah kesibukan ini.
7. **Teman-teman MTI Angkatan 31 B Universitas AMIKOM Yogyakarta**, yang telah menjadi teman sejati dalam perjalanan akademik ini. Terima kasih telah berbagi ilmu, pengalaman, dan dukungan yang sangat berharga. Semangat kalian dalam menuntut ilmu membuat saya semakin termotivasi untuk memberikan yang terbaik dalam tugas ini.
8. **Partner perjalanan penulls, Soyan, Dwi, Emma**, yang senantiasa memberikan dukungan, doa, dan semangat selama proses penyusunan tesis ini. Kehadirannya menjadi sumber motivasi dan ketenangan di setiap langkah, serta memberikan kekuatan untuk terus berjuang hingga akhir. Terima kasih atas perhatian, pengertian, kasih sayang dan ketulusan yang telah menjadi bagian berharga dalam perjalanan ini.

Selain itu, saya juga mengucapkan terima kasih kepada semua pihak yang tidak dapat saya sebutkan satu per satu, yang telah memberikan dukungan baik secara langsung maupun tidak langsung dalam penyusunan tesis ini. Setiap bantuan dan kontribusi sangat berarti bagi saya, dan saya berharap dapat memberikan balasan yang setimpal dengan segala yang telah diberikan.

Akhir kata, semoga tesis ini dapat memberikan wawasan lebih dalam mengenai pentingnya prediksi risiko postpartum pada ibu primipara, serta menunjukkan bagaimana penerapan algoritma *Random Forest* dapat digunakan untuk membantu analisis dan pengambilan keputusan dalam dunia kesehatan. Semoga penelitian ini juga dapat menjadi bahan referensi yang berguna bagi penelitian-penelitian selanjutnya

Yogyakarta, 10 Oktober 2025

Penulis



DAFTAR ISI

HALAMAN JUDUL	1
HALAMAN PERSETUJUAN	2
HALAMAN PERNYATAAN KEASLIAN TESIS	4
KATA PENGANTAR	i
DAFTAR TABEL	vi
DAFTAR GAMBAR DAFTAR LAMPIRAN	vii
DAFTAR ISTILAH	ix
INTISARI	x
ABSTRACT	xi
BAB 1	1
PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
BAB 2 TINJAUAN PUSTAKA	7
1.6 Tujuan Pustaka	7
1.7 Keaslian Penelitian	12
1.8 Landasan Teori	20
2.3.1 Postpartum Depression	20
2.3.2 Ibu Primipara	20
2.3.3 Machine Learning	21
2.3.4 Random Forest	21
2.3.5 Optimasi Kinerja Machine Learning dengan Hyperparameter	22
BAB 3 METODE PENELITIAN	24
1.9 Jenis, Sifat, dan Pendekatan Penelitian	24
1.10 Metode Pengumpulan Data	24
1.11 Metode Evaluasi Model	26
3.4 Alur Penelitian	27
3.5 Preprocessing Data	31
3.6 Seleksi Fitur	31
3.7 Tabel Deskripsi Dataset	32


3.8	Parameter Random Forest.....	34
3.9	Optimasi Hyperparameter dengan Random Search.....	35
3.10	Metode Analisis Data.....	37
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN		38
4.1	Pengumpulan Data	38
4.2	Preprocessing Data	39
4.2.1	Pembersih Data	39
4.2.2	Transformasi Data Kategorikal	39
4.2.3	Seleksi Atribut	40
4.2.4	Pembagian Data	40
4.3	Split Data	40
4.3.1	Tujuan Pembagian Data.....	41
4.3.2	Rasio Pembagian.....	41
4.3.3	Teknik Pembagian	41
4.3.4	Justifikasi	41
4.4	Random Forest.....	42
4.4.1	Konsep Random Forest.....	42
4.4.2	Perbandingan dengan Algoritma Lain	43
4.4.2	Penerapan pada Penelitian	44
4.4.3	Tuning Hyperparameter dengan Random Search	44
4.4.4	Hasil dan Analisis	45
4.5	Feature Importance Random Forest.....	45
4.6	Evaluasi Model	47
4.5.1	Matriks Evaluasi	48
4.5.2	Confusion Matrix	48
4.5.3	Hasil Evaluasi Model.....	50
4.5.4	Kurva ROC (Receiver Operating Characteristic)	56
4.5.5	PR Curve	57
4.5.6	Analisis Hasil.....	59
BAB 5 PENUTUP		60
1.12	Kesimpulan	60
1.13	Saran	62

DAFTAR TABEL

Tabel 2.1 Matriks literatur review dan posisi penelitian.....	12
Tabel 3. 1 Deskripsi Dataset.....	32
Tabel 3. 2 Parameter Random Forest.....	34
Tabel 3. 3 Kelemahan dan Kekurangan Random Search dan Grid Search.....	36
Tabel 4. 1 Perbandingan Performa Random Forest.....	51
Tabel 4. 2 Hasil Evaluasi Model.....	52

DAFTAR GAMBAR

Gambar 2. 1 Random Forest	22
Gambar 3. 1 Alur Penelitian	30
Gambar 4. 1 Confussion Matrix	49
Gambar 4. 2 Kurva ROC	57
Gambar 4. 3 PR Curve	58




DAFTAR LAMBANG DAN SINGKATAN



ML	Machine Learning
RF	Random Forest
SFS	Sequential Feature Selector
AUC	Area Under Curve
ROC	Receiver Operating Characteristic
AP	Average Precision
TP	True Positif
TN	True Negative
FP	False Positive
FN	False Negatove
CV	Cross Validation
n_estimators	Jumlah pohon pada Random Forest
max_depth	Kedalaman maksimum pohon
min_samples_split	Minimum sampel untuk membagi node
min_samples_leaf	Minimum sampel pada daun
X	Data fitur (variabel independen)
y	Label target (variabel dependen)
\hat{y}	Hasil prediksi model

DAFTAR ISTILAH



Accuracy	Persentase prediksi model yang benar.
AUC	Ukuran kemampuan model membedakan dua kelas.
Confusion Matrix	Tabel perbandingan hasil prediksi dan data aktual.
Dataset	Kumpulan data untuk pelatihan dan pengujian model.
Feature	Variabel input yang digunakan model.
Feature Importance	Tingkat pengaruh fitur terhadap prediksi.
F1-Score	Rata-rata harmonis precision dan recall.
Precision	Ketepatan model dalam memprediksi kelas positif.
Recall	Kemampuan model mendeteksi kelas positif.
ROC	Kurva evaluasi kinerja klasifikasi.
Random Forest	Algoritma ensemble berbasis decision tree.
Random Search	Optimasi hyperparameter secara acak.

INTISARI

Postpartum merupakan periode kritis bagi ibu setelah melahirkan yang rentan terhadap gangguan psikologis, terutama pada ibu primipara yang mengalami kehamilan dan persalinan untuk pertama kalinya. Deteksi dini terhadap risiko postpartum sangat penting untuk mengurangi dampak negatif terhadap kesehatan ibu dan bayi. Penelitian ini bertujuan untuk memprediksi risiko postpartum pada ibu primipara dengan memanfaatkan algoritma Random Forest yang dioptimasi menggunakan metode Random Search untuk tuning hyperparameter. Dataset yang digunakan terdiri dari data psikologis ibu hamil, termasuk tingkat kecemasan, depresi, dukungan sosial, dan faktor lainnya. Proses penelitian mencakup preprocessing data, seleksi fitur, pelatihan model, dan evaluasi performa menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa algoritma Random Forest dengan tuning Random Search menghasilkan akurasi tertinggi sebesar 90%, mengungguli model pembanding seperti Naive Bayes 74% dan Support Vector Machine yang masing-masing menghasilkan akurasi sebesar 89%. Dengan demikian, model ini dapat dijadikan sebagai alat bantu dalam mendeteksi potensi risiko postpartum secara lebih akurat dan efisien. Temuan ini diharapkan dapat memberikan kontribusi dalam bidang kesehatan ibu dan anak, khususnya dalam upaya pencegahan gangguan psikologis pascapersalinan.

Kata kunci: postpartum, ibu primipara, Random Forest, Random Search, prediksi risiko.

ABSTRACT

Postpartum is a critical period for mothers after childbirth, during which they are vulnerable to psychological disorders—especially primiparous mothers who experience pregnancy and childbirth for the first time. Early detection of postpartum risk is crucial to minimize negative impacts on both maternal and infant health. This study aims to predict postpartum risk in primiparous mothers by utilizing the Random Forest algorithm, optimized using the Random Search method for hyperparameter tuning. The dataset used consists of psychological data from pregnant women, including levels of anxiety, depression, social support, and other factors. The research process involves data preprocessing, feature selection, model training, and performance evaluation using accuracy, precision, recall, and F1-score metrics. The results show that the Random Forest algorithm with Random Search tuning achieved the highest accuracy of 90%, outperforming comparative models such as Naive Bayes (74%) and Support Vector Machine (89%). Therefore, this model can serve as a decision-support tool for more accurate and efficient detection of potential postpartum risks. These findings are expected to contribute to the field of maternal and child health, particularly in the prevention of postpartum psychological disorders.

Keyword: *postpartum, primiparous mothers, Random Forest, Random Search, risk prediction*

BAB 1 PENDAHULUAN

1.1 Latar Belakang Masalah

Masa kehamilan dan nifas adalah periode yang krusial bagi seorang ibu, terutama bagi ibu primipara atau ibu yang baru pertama kali melahirkan. Selama masa prenatal, ibu harus sehat secara fisik, psikis, sosial, ekonomi, budaya, dan spiritual agar tetap produktif (Shuffrey et al., 2022). Secara global, sekitar 10% wanita hamil dan 13% wanita yang baru saja melahirkan mengalami gangguan mental, terutama depresi. Di negara berkembang, angkanya bahkan lebih tinggi, yaitu 15,6% selama kehamilan dan 19,8% setelah melahirkan. Dalam kasus yang parah, penderitaan ibu bisa begitu berat hingga mereka mungkin melakukan bunuh diri. Selain itu, ibu yang terdampak tidak dapat berfungsi dengan baik. Akibatnya, pertumbuhan dan perkembangan anak juga dapat terpengaruh secara negative (WHO, 2019). Gangguan psikologis yang tidak ditangani dengan baik dapat mengakibatkan dampak negatif yang serius, baik bagi ibu maupun anak, seperti gangguan tumbuh kembang, ikatan emosional yang terganggu, hingga risiko bunuh diri (WHO, 2019). Terlebih bagi ibu primipara yang kurang berpengalaman, risiko komplikasi. Ibu primipara secara khusus menghadapi risiko yang lebih tinggi karena kurangnya pengalaman dan tekanan emosional yang lebih besar selama masa transisi menjadi orang tua. Oleh karena itu, deteksi dini terhadap risiko komplikasi psikologis pascapersalinan sangat krusial untuk meningkatkan kualitas hidup ibu dan perkembangan anak. Pendekatan prediksi risiko ini masih menjadi

tantangan karena kompleksitas faktor yang memengaruhi kesehatan mental postpartum.

Sebagian besar penelitian sebelumnya menitikberatkan pada faktor demografis dan kondisi fisik sebagai prediktor risiko postpartum, seperti usia, status sosial, riwayat kesehatan, dan lain-lain. Namun, faktor psikologis yang meliputi kecemasan, stres, gangguan tidur, dan dukungan sosial memiliki peranan yang signifikan namun masih kurang diperhatikan (Nurhidayati et al., 2024). Hal ini menunjukkan adanya gap riset yang perlu diisi dengan pendekatan yang mempertimbangkan faktor psikologis secara menyeluruh.

Di era digital dan kecerdasan buatan saat ini, machine learning menjadi metode yang banyak diadopsi untuk masalah prediksi dalam bidang kesehatan. Beberapa algoritma yang populer dan telah banyak digunakan adalah Logistic Regression, Support Vector Machine (SVM), dan XGBoost. Logistic Regression merupakan algoritma yang sederhana dan mudah diinterpretasikan, namun memiliki keterbatasan dalam menangani hubungan non-linear antar variabel. SVM unggul dalam menangani data berdimensi tinggi dan kompleks, tetapi sangat bergantung pada pemilihan kernel yang tepat dan parameter yang sensitif. XGBoost menawarkan akurasi yang tinggi dan kecepatan pelatihan yang baik, namun rawan overfitting dan memerlukan tuning parameter yang rumit. Alternatif algoritma yang menarik adalah Random Forest, sebuah metode ensemble yang menggabungkan banyak pohon keputusan untuk meningkatkan akurasi dan mengurangi overfitting. Random Forest juga mampu menangani data dengan fitur yang banyak dan saling berinteraksi secara kompleks. Selain itu, algoritma ini memberikan informasi

penting tentang kontribusi setiap variabel dalam prediksi, yang sangat membantu dalam memahami faktor-faktor psikologis utama yang memengaruhi risiko postpartum (Hutchens & Kearney, 2020).

Di samping pemilihan algoritma yang tepat, tantangan teknis dalam pemodelan machine learning juga menjadi perhatian penting dalam penelitian ini. Beberapa isu yang sering muncul di bidang ini antara lain adalah ketidakseimbangan data (*class imbalance*) (Salmi et al., 2024), yang dapat menyebabkan model bias terhadap kelas mayoritas; adanya *noise* atau *outlier* yang dapat menurunkan performa model (Chen et al., 2024); risiko *overfitting* saat model terlalu menyesuaikan dengan data latih; serta kesalahan dalam penyetelan hyperparameter yang dapat menghambat kinerja optimal (Montesinos López et al., 2022). Oleh karena itu, penelitian ini juga merancang strategi preprocessing dan optimasi parameter untuk meminimalkan masalah-masalah tersebut.

Meskipun Random Forest memiliki potensi yang baik, terdapat beberapa tantangan penting yang perlu diperhatikan. Pertama, kualitas data yang bervariasi, seperti catatan kesehatan elektronik (EHR) dan laporan mandiri, dapat mempengaruhi akurasi prediksi dan menyebabkan performa model menjadi heterogen (Amit et al., 2021; Yates & Islam, 2021). Kedua, interpretabilitas model yang rendah dapat menyulitkan tenaga medis yang bukan ahli data untuk memahami hasil prediksi (Saqib et al., 2021a), sehingga menghambat penerapan model secara luas. Untuk mengatasi tantangan optimasi, penelitian ini menggunakan teknik Random Search yang lebih efisien dibandingkan Grid Search dalam pencarian hyperparameter optimal, sehingga meningkatkan akurasi dan

kestabilan model tanpa perlu mengeksplorasi semua kombinasi secara sistematis (Ali et al., 2023; Valsecchi et al., 2021).

Penelitian-penelitian terdahulu menunjukkan heterogenitas hasil yang cukup signifikan antara algoritma machine learning. Misalnya, (Saqib et al., 2021a) melaporkan akurasi 88% untuk Random Forest, 86% untuk SVM, dan 93% untuk Logistic Regression dalam prediksi risiko postpartum. Sedangkan (Shin et al., 2020a) menunjukkan Random Forest mampu memberikan prediksi optimal jika variabel psikologis diperhitungkan dengan baik. Berbeda dengan Deep Learning yang memiliki kompleksitas tinggi dan “kotak hitam”, machine learning menawarkan interpretabilitas dan efisiensi yang lebih baik, cocok untuk aplikasi klinis dengan data yang relatif terbatas (Haque et al., 2022).

Dataset yang digunakan dalam penelitian ini berasal dari Kaggle dengan 1.503 observasi dan mencakup variabel-variabel psikologis seperti kecemasan, gangguan tidur, rasa bersalah, dan bonding ibu dengan bayi. Dataset ini dipilih karena fokus pada aspek psikologis yang kurang ditangani dalam dataset lain seperti Electronic Health Records (EHR) dan Pregnancy Risk Assessment Monitoring System (PRAMS). Data ini dinilai memiliki kualitas baik dan mampu menangkap hubungan non-linear antar variabel melalui model Random Forest.

Penelitian ini berkontribusi dalam dua aspek utama. Pertama, dari sisi metodologis, penelitian ini mengembangkan model prediksi komplikasi postpartum yang dioptimasi dengan Random Search, meningkatkan akurasi dan stabilitas model. Kedua, secara praktis, model ini diharapkan dapat menjadi alat bantu skrining dini bagi tenaga kesehatan, sehingga memungkinkan intervensi lebih cepat

dan tepat sasaran. Dengan demikian, penelitian ini tidak hanya melengkapi literatur terkait risiko psikologis postpartum, tetapi juga memberikan solusi yang aplikatif untuk meningkatkan kesehatan ibu dan anak.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut :

1. Bagaimana kinerja model Random Forest dalam memprediksi risiko postpartum pada ibu primipara berdasarkan faktor psikologis?
2. Apakah faktor-faktor psikologis memiliki pengaruh terhadap risiko postpartum pada ibu primipara?

1.3 Batasan Masalah

Adapun tujuan spesifik dari penelitian ini adalah sebagai berikut:

- a. Penelitian ini mencakup analisis faktor-faktor psikologis yang mempengaruhi risiko komplikasi postpartum.
- b. Algoritma yang digunakan dalam penelitian ini adalah Random Forest. Analisis kinerja dan perbandingan dengan algoritma machine learning lainnya juga dilakukan, tetapi implementasi utama menggunakan Random Forest.

1.4 Tujuan Penelitian

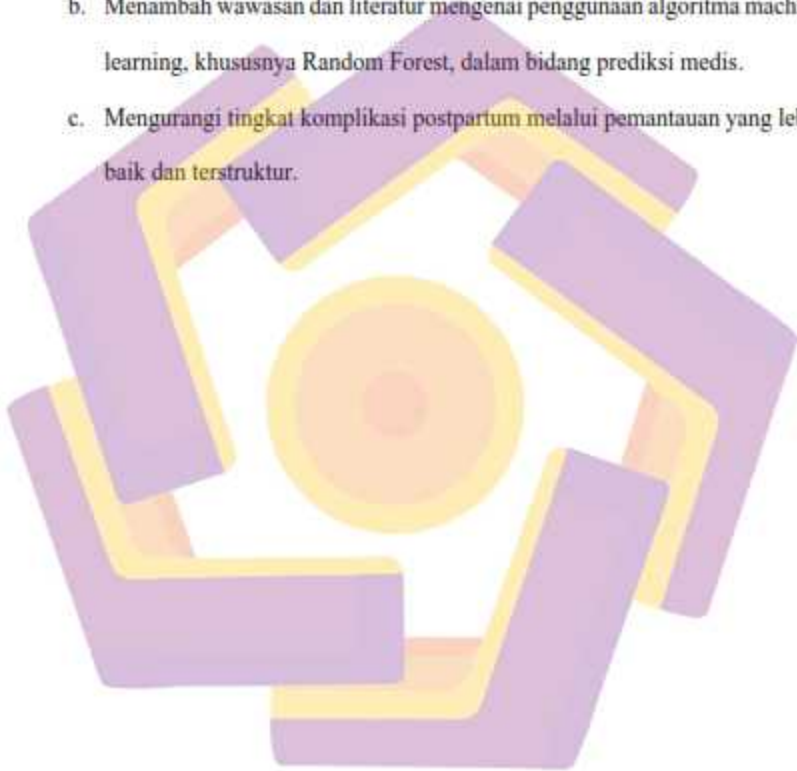
Adapun tujuan spesifik dari penelitian ini adalah sebagai berikut:

- a. Menilai seberapa efektif model Random Forest dalam memprediksi risiko postpartum, khususnya pada ibu yang melahirkan anak pertama kali.
- b. Menilai seberapa efektif model Random Forest dalam memprediksi risiko postpartum, khususnya pada ibu yang melahirkan anak pertama kali.

1.5 Manfaat Penelitian

Bagian ini memuat penjelasan tentang :

- a. Membantu tenaga medis dalam melakukan deteksi dini risiko komplikasi postpartum, sehingga intervensi dapat dilakukan lebih cepat dan tepat.
- b. Menambah wawasan dan literatur mengenai penggunaan algoritma machine learning, khususnya Random Forest, dalam bidang prediksi medis.
- c. Mengurangi tingkat komplikasi postpartum melalui pemantauan yang lebih baik dan terstruktur.



BAB 2

TINJAUAN PUSTAKA

1.6 Tujuan Pustaka

Sebagai langkah awal dalam penelitian ini, penting untuk mengkaji literatur yang ada mengenai Prediksi Postpartum pada Ibu Primipara menggunakan Algoritma Random Forest. Tinjauan pustaka ini akan mengidentifikasi penelitian terdahulu yang relevan, membahas kontribusi utama dari masing-masing sumber, dan menyajikan sintesis yang memberikan dasar bagi penelitian ini.

Penelitian sebelumnya yang dilakukan oleh (Zhang et al., 2021) berfokus pada pengembangan dan validasi algoritma pembelajaran mesin untuk memprediksi risiko depresi postpartum (PPD) di kalangan wanita hamil. Penelitian ini menggunakan data dari catatan kesehatan elektronik (EHR) untuk menciptakan model prediktif yang bertujuan untuk meningkatkan identifikasi dini dan dukungan bagi wanita yang berisiko mengalami PPD. Tingkat akurasi dari ketiga algoritma memiliki hasil yang berbeda, untuk model regresi logistik, area di bawah kurva ROC (AUROC) mencapai 0.921, menunjukkan akurasi yang sangat baik. Model lain seperti Random Forest dan XGBoost juga menunjukkan AUROC yang tinggi, yaitu 0.897 dan 0.908.

Selain itu, penelitian yang dilakukan oleh (Shin et al., 2020b) model prediktif menggunakan metode pemrograman machine learning untuk memprediksi depresi postpartum (postpartum depression) menggunakan data dari sistem pemantauan risiko kehamilan menunjukkan variasi akurasi yang berbeda. Secara

spesifik, model Random Forest mencatat akurasi tertinggi dengan nilai AUC 0.884, sementara model k-nearest neighbor (kNN) mencatat akurasi terendah dengan nilai AUC 0.650.

Penggunaan data rekam medis elektronik (Electronic Health Records - EHR) dan machine learning untuk memprediksi risiko depresi pasca persalinan (Postpartum Depression - PPD) pada perempuan yang melahirkan seperti yang disebutkan pada penelitian yang dilakukan oleh (Amit et al., 2021). Hasilnya menunjukkan bahwa model berbasis EHR sendiri memiliki AUC yang bervariasi dari 0.72 hingga 0.74. Ketika model tersebut digabungkan dengan skor dari Edinburgh Postnatal Depression Scale (EPDS), AUC meningkat dari 0.805 menjadi 0.844. Sensitivitas model berbasis EHR juga berada di angka sekitar 0.51 sampai 0.53 pada spesifisitas yang ditetapkan di 0.80.

Menurut (Saqib et al., 2021b) bahwa Angka prevalensi PPD berkisar antara 10% hingga 15% di seluruh dunia, dan bisa mencapai 18%-25% di negara-negara dengan pendapatan rendah dan menengah. Penelitian ini penting mengingat perkembangan teknologi yang cepat dalam tahun-tahun terakhir serta mengidentifikasi algoritme dengan kinerja terbaik dan kriteria evaluasi untuk algoritme tersebut. Beberapa algoritme ML yang digunakan termasuk Support Vector Machine (SVM), Random Forest (RF), Naive Bayes, dan algoritme jaringan saraf seperti Multilayer Perceptron (MLP). Support Vector Machine (SVM) AUC (Area Under Curve) berkisar antara 0.78 hingga 0.86. Random Forest (RF) dengan AUC 0.884, yang merupakan yang tertinggi di antara algoritme lainnya.

Logistic Regression (LR) dengan regularisasi L2 AUC 0.937, dan yang terakhir XGBoost memiliki AUC 0.80.

Penelitian (Wakefield & Frasch, 2023) ini berfokus pada prediksi pasien yang memerlukan perawatan untuk depresi postpartum (PPD) dengan memanfaatkan data rekam medis elektronik yang tersedia sebelum melahirkan. Teknik pembelajaran mesin digunakan untuk mengidentifikasi pasien yang berisiko tinggi mengalami PPD. Dari total 8,454 kelahiran, penelitian menemukan bahwa 338 (4%) mengalami depresi di periode postpartum. Hasil penelitian menunjukkan bahwa model pembelajaran mesin terbaik adalah Model 3, dengan area di bawah kurva karakteristik penerima (AUC) sebesar 0,91 ($\pm 0,02$). Model ini menggunakan sembilan variabel yang paling berkontribusi, termasuk riwayat depresi sebelum kehamilan dan kondisi kesehatan mental lainnya. Model 4, yang menyederhanakan variabel input, memiliki AUC sebesar 0,79 ($\pm 0,05$). Selain itu, model regresi logistik yang menggunakan sembilan variabel dari Model 3 juga menunjukkan AUC sebesar 0,93 ($\pm 0,03$).

Hasil penelitian dari (Wang et al., 2024) menunjukkan bahwa fitur-fitur yang terkait dengan risiko PPH meliputi 'usia', 'berat bayi baru lahir', 'minggu gestasi', 'robekan perineum', dan 'persalinan caesar'. Model prediksi yang dibangun menggunakan klasifikasi random forest menunjukkan performa terbaik dengan skor F1 sebesar 0.73 dan area under the curve (AUC) sebesar 0.84 untuk semua wanita. Untuk wanita yang menjalani persalinan caesar, model random forest menunjukkan skor F1 sebesar 0.96 dan AUC sebesar 0.95. Sedangkan untuk wanita yang

melahirkan secara vaginal, model AdaBoost menunjukkan skor F1 sebesar 0.65 dan AUC sebesar 0.76.

Selain penelitian di atas, penting juga untuk meninjau faktor-faktor psikologis yang berperan dalam munculnya komplikasi postpartum. Beberapa studi menunjukkan bahwa gejala seperti rasa cemas, stres, gangguan tidur, dan perasaan bersalah sangat terkait dengan peningkatan risiko depresi postpartum. Studi prospektif yang dilakukan di Korea oleh (Youn & Jeong, 2013) menunjukkan bahwa rendahnya harga diri, kecemasan selama kehamilan, stres kehidupan yang tinggi, dan kurangnya dukungan sosial merupakan prediktor signifikan untuk depresi postpartum. Selain itu, faktor seperti ketidakpuasan dalam pernikahan dan pengalaman "maternal blues" juga turut meningkatkan risiko munculnya gangguan psikologis setelah melahirkan. Hal ini memperkuat pentingnya deteksi dini terhadap gejala psikologis sejak masa kehamilan sebagai bentuk pencegahan.

Dukungan sosial juga menjadi elemen penting dalam mengurangi risiko postpartum depression. (Żyrek et al., 2024) melalui studi longitudinal di Polandia menemukan bahwa ibu yang merasa mendapatkan dukungan emosional dan instrumental dari pasangan maupun keluarga memiliki risiko lebih rendah untuk mengalami PPD. Studi ini menegaskan bahwa bukan hanya kuantitas, tetapi juga kualitas dukungan sosial yang diterima ibu berpengaruh terhadap kestabilan emosionalnya pada masa pascapersalinan.

Seiring meningkatnya penerapan machine learning dalam bidang kesehatan mental, beberapa studi telah menunjukkan bahwa algoritma seperti Random Forest efektif tidak hanya untuk mendeteksi depresi postpartum, tetapi juga gangguan

psikologis lainnya. Sebagai contoh, (Lewis et al., 2023) mengembangkan pendekatan Mixed Effects Random Forest untuk memprediksi tingkat keparahan depresi klinis menggunakan data fisiologis dan aktivitas digital. Model ini menunjukkan peningkatan akurasi prediksi dibandingkan dengan baseline tradisional, menyoroti potensi personalisasi dalam prediksi gangguan mental.

Selain itu, (Patil et al., 2023) mengusulkan pendekatan hibrida yang menggabungkan Random Forest dan Artificial Neural Network (ANN) untuk mengklasifikasikan depresi berdasarkan sinyal aktivitas motorik yang dikumpulkan dari sensor wearable. Model ini mencapai akurasi sebesar 80% dalam membedakan individu dengan depresi unipolar, bipolar, dan kontrol sehat, menunjukkan potensi besar dalam deteksi kondisi mental melalui data sensorik.

Lebih lanjut, (Bhaumik & Stange, n.d.) menerapkan algoritma Random Effects Machine Learning, termasuk Random Effects/Expectation Maximization (RE-EM) trees dan Mixed Effects Random Forest (MERF), untuk mengidentifikasi individu yang rentan terhadap depresi. Studi ini menyoroti pentingnya faktor-faktor seperti perenungan, peristiwa kehidupan negatif, dan gaya kognitif negatif dalam memprediksi tingkat keparahan depresi di masa depan.

1.7 Keaslian Penelitian

Tabel 2.1 Matriks literatur review dan posisi penelitian

Prediksi Risiko Postpartum Pada Ibu Primipara Berdasarkan Faktor Psikologis Menggunakan Algoritma Random Forest Dengan Random Search

No	Judul Penelitian	Nama Peneliti, Tahun, Index	Metode Penelitian	Hasil	Keunggulan dan Kelemahan	Perbandingan
1	Machine Learning Classification Based on Random Forest Algorithm: A Review	Nasiba Mahdi Abdulkareem & Adnan Mohsin Abdulazeez, International Journal of Science and Business, 2021	Mengkaji efektivitas dan aplikasi luas Random Forest dalam berbagai bidang	Mengkaji efektivitas dan aplikasi luas Random Forest dalam berbagai bidang	Tidak membahas detail implementasi di bidang spesifik seperti keuangan atau manufaktur	Penelitian lebih lanjut diperlukan tentang aplikasi spesifik Random Forest di bidang keuangan dan manufaktur
2	Predicting postpartum depression: A machine learning approach.	Y. Zhang et al., Journal of Affective Disorders, 2021	Mengembangkan model prediksi postpartum depression	Algoritma machine learning seperti Random Forest, Decision Tree, dan lain-lain	Membutuhkan lebih banyak data untuk meningkatkan akurasi dan generalisasi model	Penelitian yang diusulkan dapat fokus pada peningkatan jumlah data dan variasi fitur untuk

			menggunakan machine learning	menunjukkan potensi tinggi dalam prediksi postpartum depression		meningkatkan akurasi model prediksi
3	Social Support among Mothers with Spouse Postpartum Depression	Evi Nurhidayati, International Journal of Nursing and Health Services (IJNHS), 2024	Menentukan tingkat dukungan sosial di antara ibu dengan depresi pasca persalinan.	Aspek depresi pasca persalinan tidak sering dievaluasi oleh profesional kesehatan selama periode ini di Indonesia.	Disarankan untuk melakukan penelitian tambahan tentang bagaimana ibu dari bayi baru merasa tentang tingkat dukungan sosial.	Penelitian ini fokus pada menentukan dukungan sosial di antara ibu dengan depresi pasca persalinan, sementara penelitian lain menunjukkan bahwa aspek depresi pasca persalinan jarang dievaluasi oleh profesional kesehatan selama periode ini di Indonesia.
4	Machine Learning-Based Predictive Modeling of Postpartum Depression	Doyeon Shim dkk. Journal of Clinical Medicine, 2020	Penelitian ini bertujuan untuk mengembangkan model prediktif untuk depresi postpartum menggunakan	Model prediktif yang dikembangkan menggunakan pendekatan ML dapat digunakan sebagai alat untuk memprediksi	Kelemahan penelitian ini termasuk penggunaan data yang bersifat self-report untuk diagnosis depresi postpartum, yang dapat menyebabkan bias informasi. Terdapat banyak data yang hilang pada variabel sosiodemografis dan gaya	Penelitian ini menunjukkan bahwa pendekatan machine learning dapat memberikan hasil yang lebih baik dalam memprediksi depresi postpartum dibandingkan

			pendekatan machine learning (ML) dengan data dari Pregnancy Risk Assessment Monitoring System (PRAMS) 2012–2013.	(menyaring) depresi postpartum. Metode Random Forest (RF) menunjukkan kinerja terbaik dengan nilai AUC tertinggi sebesar 0.884.	hidup, yang dapat mempengaruhi hasil.	dengan metode tradisional. Dalam penelitian sebelumnya yang menggunakan data dari Rhode Island PRAMS, model prediktif yang dikembangkan mencapai nilai AUC 0.79, sedangkan penelitian ini mencapai nilai AUC yang lebih tinggi (0.884) dengan menggunakan metode RF.
5.	Estimation of postpartum depression risk from electronic health records using machine learning	Guy Amit dkk, MC Pregnancy and Childbirth, 2021	Penelitian ini bertujuan untuk memanfaatkan machine learning dalam memprediksi risiko depresi postpartum (PPD) menggunakan data rekam medis	Penelitian ini menunjukkan bahwa model prediksi berbasis EHR dapat mencapai akurasi yang baik dalam memprediksi PPD, dengan AUC yang bervariasi antara 0.72 hingga 0.74	Definisi hasil PPD didasarkan pada diagnosis dan pengobatan yang tercatat dalam sumber data perawatan primer, yang mungkin tidak sepenuhnya akurat karena stigma terkait kesehatan mental dan kemungkinan kurangnya pencatatan. Selain itu, beberapa informasi relevan mungkin hilang dari EHR atau tercatat dalam catatan yang tidak terstruktur.	Penelitian sebelumnya yang menggunakan data EHR dari jaringan rumah sakit menunjukkan hasil yang lebih rendah dalam hal prevalensi PPD, yang menunjukkan bahwa penggunaan data dari perawatan primer dapat memberikan gambaran

			elektronik (EHR) dari perawatan primer, serta mengevaluasi potensi nilai prediksi berbasis EHR dalam meningkatkan akurasi skrining PPD dan dalam identifikasi dini wanita yang berisiko.	untuk model EHR saja, dan meningkat menjadi 0.844 ketika digabungkan dengan skor EPDS. Ini menunjukkan bahwa kombinasi model berbasis EHR dengan alat skrining yang ada dapat meningkatkan sensitivitas dan spesififikasi deteksi PPD.		yang lebih akurat tentang risiko PPD dalam populasi yang lebih besar.
1.	Predicting Patients Requiring Treatment for Depression in the Postpartum Period Using Common Electronic Medical Record Data Available Antepartum	Colin Wakefield dkk. AJPM Focus, 2023	Tujuan penelitian ini adalah untuk menguji apakah teknik machine learning dapat secara akurat mengidentifikasi pasien yang	Penelitian ini menyimpulkan bahwa depresi postpartum dapat diprediksi dengan akurasi tinggi untuk pasien individu menggunakan	Saran dari penelitian ini mencakup perlunya pengembangan alat untuk mengidentifikasi pasien berisiko PPD secara lebih efektif. Kelemahan yang diidentifikasi adalah penggunaan pengobatan depresi postpartum sebagai proxy untuk diagnosis PPD, yang mungkin menyebabkan	Penelitian ini menunjukkan bahwa Model 3 memiliki kemampuan prediksi yang lebih baik dibandingkan model sebelumnya karena menggunakan data antepartum secara eksklusif. Model

			berisiko mengalami depresi postpartum (PPD) menggunakan data antepartum yang umum ditemukan dalam catatan medis elektronik.	informasi antepartum yang umum ditemukan dalam catatan medis elektronik. Model yang dikembangkan menunjukkan bahwa status kesehatan mental dasar dan faktor sosiodemografis memiliki peran yang lebih besar dalam periode postpartum daripada yang sebelumnya dipahami.	beberapa kasus PPD terlewatkan.	sebelumnya kurang akurat karena mengandalkan data yang sulit diakses atau dikumpulkan setelah kehamilan. Penelitian ini menekankan pentingnya penggunaan data awal kehamilan untuk intervensi yang lebih efektif.
2.	Postpartum Haemorrhage Risk Prediction Model Developed by Machine Learning Algorithms:	Wenhuan Wang dkk., Clin. Exp. Obstet. Gynecol., 2024	Tujuan penelitian ini adalah untuk membangun model prediksi risiko perdarahan	Kesimpulan dari penelitian ini menunjukkan bahwa algoritma machine learning dapat secara	Kelemahan yang diidentifikasi termasuk keterbatasan jumlah peserta yang terlibat dan perbedaan dalam penilaian risiko oleh para ahli dari berbagai pusat.	Penelitian ini menunjukkan bahwa model prediksi berbasis machine learning memiliki keunggulan dalam akurasi dan efisiensi

	A Single-Centre Retrospective Analysis of Clinical Data		postpartum (PPH) yang efisien menggunakan algoritma machine learning dan metode pemilihan fitur baru, serta memberikan ide dan metode referensi baru untuk manajemen risiko PPH.	efektif mengidentifikasi fitur yang terkait dengan risiko PPH dari variabel klinis dan membangun model prediksi yang akurat. Penelitian ini juga menyoroti pentingnya pemilihan fitur yang tepat untuk meningkatkan efisiensi prediksi.		dibandingkan dengan metode tradisional. Berbagai metode pemilihan fitur, seperti RFE dan RFECV, digunakan untuk meningkatkan kinerja model. Penelitian sebelumnya yang menggunakan metode statistik tradisional menunjukkan hasil yang kurang memuaskan dalam hal prediksi PPH, dengan tingkat deteksi yang rendah dan efisiensi yang tidak memadai
3.	Risk prediction for postpartum depression based on random forest	XIAO Meili dkk, J Cent South Univ (Med Sci) 2020	Untuk mengeksplorasi efektivitas algoritma Random Forest dalam	Hasil penelitian menunjukkan bahwa model Random Forest memiliki akurasi 80,10%,	Penelitian ini memiliki beberapa keterbatasan, antara lain tidak mencakup data biologis pascapersalinan, penilaian psikososial yang terbatas hanya pada depresi prenatal, serta kurangnya	Penelitian ini menunjukkan bahwa algoritma Random Forest lebih unggul dalam mengolah data kompleks dan multivariat dengan

		<p>menyeleksi faktor-faktor yang memengaruhi depresi pascapersalinan (postpartum depression/PPD) serta membangun model prediksi risiko PPD yang akurat dan dapat diandalkan.</p>	<p>sensitivitas 61,40%, spesifisitas 89,10%, nilai prediksi positif 73,00%, nilai prediksi negatif 82,80%, dan AUC sebesar 0,833, sehingga dinilai efektif dalam memprediksi risiko PPD. Sepuluh faktor paling berpengaruh yang diidentifikasi meliputi depresi prenatal, kekhawatiran ekonomi dan pekerjaan pascapersalinan, kadar FT3 trimester awal, HDL trimester akhir, kebiasaan</p>	<p>pengukuran pengaruh pasangan dan bayi terhadap kondisi ibu. Selain itu, model Random Forest bersifat seperti "black box" sehingga sulit menjelaskan hubungan antarvariabel secara mendalam. Peneliti menyarankan agar penelitian berikutnya mengombinasikan algoritma ini dengan metode statistik tradisional untuk meningkatkan interpretabilitas dan keandalan hasil prediksi.</p>	<p>hasil prediksi yang lebih akurat. Nilai AUC sebesar 0,833 membuktikan bahwa model ini lebih andal dibandingkan model tradisional dalam menilai risiko depresi pascapersalinan dan mampu mengidentifikasi faktor risiko utama secara lebih komprehensif.</p>
--	--	--	--	---	--

				mudah marah pada bayi, kadar kolesterol total dan trigliserida trimester awal, hematokrit trimester akhir, serta trigliserida trimester akhir		
--	--	--	--	---	--	--

Source: Author (2007). Gunakan style Citation for Table AMIKOM

1.8 Landasan Teori

2.3.1 Postpartum Depression

Menurut (Mood and Anxiety Disorders During Pregnancy and Postpartum, n.d.) Gangguan suasana hati yang lebih parah yang muncul setelah persalinan dikenal sebagai depresi postpartum (PPD). Gejalanya termasuk perasaan tidak mampu merawat bayi, kecemasan yang berlebihan, insomnia, dan suasana hati yang tertekan. Faktor biologis, psikologis, dan sosial dapat menjadi penyebab PPD. Beberapa penyebab yang telah diidentifikasi termasuk perubahan hormon yang drastis setelah melahirkan, riwayat gangguan mood atau depresi, stres dan kelelahan akibat tanggung jawab dan perubahan besar dalam hidup sebagai ibu, kurangnya dukungan sosial dari pasangan, keluarga, atau teman, komplikasi persalinan, dan masalah menyusui. Kami berharap dapat meningkatkan kesadaran dan penanganan dini PPD untuk mengurangi dampak negatifnya pada ibu dan bayi dengan memahami definisi dan penyebabnya.

2.3.2 Ibu Primipara

Menurut (Park, n.d.) sekitar 9% ibu baru atau ibu primipara mengalami komplikasi pasca melahirkan. Di antara wanita di negara berpenghasilan tinggi, prevalensi gabungan PTSD setelah persalinan adalah 9,0%, menunjukkan bahwa sebagian besar ibu baru menderita kondisi ini. Hal ini menunjukkan betapa pentingnya melakukan skrining, menemukan, dan memberikan perawatan yang tepat untuk PTSD pascapersalinan karena kegagalan untuk merawatnya dapat berdampak jangka panjang pada kesehatan mental ibu, hubungannya dengan bayi,

dan perkembangan anak. Dukungan dan intervensi dini sangat penting untuk membantu ibu baru pulih dan tumbuh selama masa nifas.


2.3.3 Machine Learning

Machine learning adalah teknik pemrograman komputer untuk belajar dari data yang memungkinkan program untuk mendeteksi pola dan membuat keputusan berdasarkan data. Algoritma machine learning termasuk dalam beberapa kategori utama, salah satunya supervised learning. Pada supervised learning, algoritma seperti K-Nearest Neighbor, Linear Regression, Random Forest, Naive Bayes, Super Vector Machine, Decision Tree dan Neural Network menggunakan data yang sudah diberi label. Sebaliknya, unsupervised learning menggunakan data yang belum diberi label, seperti algoritma PCA dan K-Means. (Russell, 2018).

2.3.4 Random Forest

Random Forest adalah teknik machine learning yang digunakan untuk klasifikasi dan regresi. Ini membangun banyak pohon keputusan dengan menggunakan proses pengambilan sampel bootstrap dari data pelatihan. Sampel acak diambil dari setiap pohon melalui penggantian, sehingga beberapa data mungkin tidak ada dalam sampel, dikenal sebagai "luar tas" (OOB). Untuk meningkatkan keragaman model dan mengurangi korelasi antar pohon, sejumlah variabel dipilih secara acak pada setiap simpul pohon. Pohon dibangun hingga kedalaman maksimum tanpa pemangkasan. Untuk klasifikasi, prediksi dibuat berdasarkan suara kelas terbanyak pada node terminal, sedangkan untuk regresi, prediksi dibuat berdasarkan rata-rata nilai respon pada node tersebut. Setelah semua pohon dibangun, Random Forest menggunakan voting untuk klasifikasi atau rata-

rata untuk regresi untuk menggabungkan prediksi dari semua pohon. Selain itu, Random Forest dapat menggunakan data OOB untuk memberikan estimasi akurasi model tanpa memerlukan set pengujian yang terpisah. Dengan demikian, Random Forest dapat memberikan prediksi yang akurat dan stabil serta menangani variabel yang tidak penting dan nilai yang hilang. Karena itu, dapat digunakan dalam berbagai situasi, seperti memprediksi hasil kesehatan seperti persalinan postpartum pada ibu Primipara berdasarkan variabel yang relevan. (Cutler, n.d.). Namun, salah satu tantangan utama dalam penggunaan Random Forest adalah overfitting. Overfitting terjadi ketika model terlalu cocok dengan data pelatihan, hingga menangkap noise atau pola yang tidak relevan. Akibatnya, model menunjukkan performa yang sangat baik pada data pelatihan tetapi buruk pada data pengujian.



Gambar 2. 1 Random Forest

2.3.5 Optimasi Kinerja Machine Learning dengan Hyperparameter

Optimasi kinerja machine learning dengan hyperparameter merupakan

proses penting dalam meningkatkan performa model prediktif. Hyperparameter adalah parameter yang mengatur mekanisme kerja algoritma sebelum proses pelatihan dimulai, dan berbeda dengan parameter model yang dipelajari dari data. Dalam algoritma Random Forest, contoh hyperparameter penting meliputi jumlah pohon (n estimators), kedalaman maksimum pohon (max depth), jumlah fitur yang dipertimbangkan pada setiap pemisahan node (max features), serta jumlah minimum sampel pada leaf node (min samples leaf). Nilai-nilai ini tidak ditentukan secara otomatis oleh model, sehingga harus ditetapkan melalui proses yang disebut hyperparameter tuning (Contreras et al., 2021).

Menurut (Elgeldawi et al., 2021) hyperparameter tuning bertujuan untuk mencari kombinasi hyperparameter terbaik agar model dapat menghasilkan prediksi yang lebih akurat dan stabil. Dua pendekatan yang umum digunakan adalah Grid Search dan Random Search. Grid Search melakukan pencarian secara menyeluruh dengan menguji semua kombinasi nilai hyperparameter yang telah ditentukan, sehingga hasil yang diperoleh sangat komprehensif. Namun, pendekatan ini membutuhkan waktu komputasi yang besar, terutama jika ruang parameternya luas. Berbeda dengan Grid Search, Random Search melakukan pengambilan sampel secara acak dari ruang parameter. Meskipun tidak menguji semua kemungkinan kombinasi, Random Search lebih efisien dan sering kali mampu menemukan kombinasi hyperparameter berkinerja tinggi dalam waktu yang lebih singkat.

BAB 3

METODE PENELITIAN

1.9 Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini menggunakan penelitian kuantitatif dengan sifat deskriptif-analitis. Menggambarkan profil psikologis ibu primipara yang menjadi sampel penelitian dan menggunakan algoritma random forest untuk menganalisis data dan memprediksi risiko postpartum depression berdasarkan berbagai variabel. Pendekatan yang digunakan adalah pendekatan eksperimental dengan menerapkan algoritma random forest untuk memprediksi postpartum pada ibu primipara.

Metode yang digunakan bersifat eksperimental, dengan menerapkan algoritma Random Forest sebagai model utama untuk melakukan analisis data dan prediksi risiko postpartum depression. Algoritma ini dipilih karena kemampuannya dalam menangani data yang kompleks, mendeteksi pola non-linear antar variabel, serta memberikan interpretasi melalui analisis *feature importance*. Proses eksperimen dilakukan dengan mengoptimasi parameter model menggunakan teknik Random Search, sehingga diharapkan diperoleh performa prediksi yang lebih optimal.

1.10 Metode Pengumpulan Data

Pengumpulan data dilakukan untuk mendapatkan berbagai macam data yang diperlukan dalam penelitian. Dataset yang digunakan pada penelitian ini diperoleh website Kaggle yang dikelola oleh Parvez Al Muqtadir, mencakup dari

11 atribut dan memilih 9 atribut. Link sebagai dataset sebagai berikut <https://www.kaggle.com/datasets/parvezalmuqtadir2348/postpartum-depression>.

Dataset "Postpartum Depression" termasuk dalam kategori medis dan kesehatan mental, yang berfokus pada analisis depresi setelah melahirkan. Dataset ini menggabungkan data kategorikal dan numerik yang diperoleh dari survei kuesioner berbasis Google Form yang diisi oleh pasien rumah sakit, dengan total 1.503 observasi dan berbagai variabel. Variabel-variabel tersebut meliputi aspek demografi, kesehatan, sosial, ekonomi, dan psikologi. Variabel demografi mencakup usia ibu, tingkat pendidikan, status pernikahan, dan jumlah kelahiran sebelumnya. Variabel kesehatan mencakup riwayat depresi sebelum kehamilan, komplikasi selama kehamilan, status menyusui, dan kualitas tidur pasca melahirkan. Dari sisi sosial dan ekonomi, dataset ini mencatat kondisi ekonomi keluarga, dukungan sosial, dan status pekerjaan ibu. Sedangkan variabel psikologis meliputi tingkat stres selama kehamilan, kesehatan mental selama kehamilan, dan kepuasan terhadap proses persalinan. Variabel target dalam dataset ini adalah depresi pascapersalinan, yang diukur dengan skala biner (ada/tidak ada) atau skala tertentu. Dataset ini tersedia di Kaggle dan bertujuan untuk analisis statistik, pengembangan model prediktif menggunakan pembelajaran mesin, serta penelitian kesehatan untuk memahami dan mencegah depresi pascapersalinan. Data ini penting untuk mengidentifikasi faktor risiko dan merancang strategi intervensi bagi ibu yang berisiko.

1.11 Metode Evaluasi Model

Evaluasi model dilakukan untuk menilai kualitas performa algoritma Random Forest dalam memprediksi risiko postpartum pada ibu primipara. Pada penelitian ini digunakan beberapa metrik evaluasi, yaitu Accuracy, Precision, Recall, F1-Score, Area Under Curve (AUC), serta Average Precision (AP). Metrik-metrik ini dipilih karena mampu menggambarkan performa model secara menyeluruh, terutama ketika berhadapan dengan data yang memiliki distribusi kelas tidak seimbang.

- Accuracy

Mengukur proporsi prediksi yang benar terhadap seluruh data.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- Precision

Menggambarkan tingkat ketepatan model dalam mengidentifikasi kasus positif.

$$Precision = \frac{TP}{TP + FP}$$

- Recall (Sensitivity)

Mengukur kemampuan model dalam menemukan seluruh kasus positif.

$$Recall = \frac{TP}{TP + FN}$$

- F1-Score

Merupakan rata-rata harmonis dari Precision dan Recall. Cocok digunakan ketika data tidak seimbang.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

- Area Under the ROC Curve (AUC)

Mengukur kemampuan model membedakan kelas positif dan negatif.

Nilai mendekati 1 menunjukkan model berkinerja sangat baik.

Evaluasi model dalam penelitian ini dilakukan melalui dua tahap utama.

Tahap pertama adalah evaluasi sebelum optimasi hyperparameter, yang bertujuan untuk melihat kemampuan dasar model Random Forest tanpa penyesuaian parameter apa pun. Tahap kedua adalah evaluasi setelah proses optimasi hyperparameter menggunakan metode Random Search, sehingga dapat dibandingkan peningkatannya secara kuantitatif. Kedua tahap evaluasi ini digunakan sebagai dasar untuk menentukan model terbaik yang akan dianalisis lebih lanjut pada bab hasil dan pembahasan serta menjadi acuan dalam penarikan kesimpulan penelitian.

3.4 Alur Penelitian

Untuk memberikan pemahaman yang lebih komprehensif mengenai langkah-langkah penelitian yang dilakukan, diperlukan penjelasan awal sebelum menampilkan diagram alur penelitian. Pada penelitian ini, proses analisis dilakukan melalui serangkaian tahapan yang tersusun secara sistematis, dimulai dari tahap pengumpulan dan pembersihan data, pemilihan fitur, pembagian data, pelatihan model, optimasi hyperparameter, hingga evaluasi performa model.

Tahapan-tahapan tersebut disusun untuk memastikan bahwa model prediksi yang dibangun memiliki validitas metodologis serta mampu menghasilkan

performa yang optimal. Selain itu, alur penelitian ini memberikan gambaran mengenai keterkaitan antara setiap proses, sehingga pembaca dapat memahami bagaimana setiap langkah berkontribusi dalam mencapai tujuan penelitian.

a. Pengumpulan Dataset

Langkah pertama dalam penelitian ini adalah mengunduh dataset postpartum depression dari Kaggle dengan jumlah dataset 1503, yang akan menjadi basis data untuk pelatihan dan evaluasi model prediksi. Dari atribut-atribut yang ada, terdapat 9 atribut yang berkaitan dengan faktor psikologis, yaitu *feeling sad or tearful*, *irritable towards baby & partner*, *trouble sleeping at night*, *problems concentrating or making decision*, *overeating or loss of appetite*, *feeling anxious*, *feeling of guilt*, *problems of bonding with baby*, dan *suicide attempt*. Atribut-atribut ini menggambarkan gejala emosional dan kognitif yang berhubungan dengan depresi dan gangguan psikologis lainnya. Atribut seperti *age* memberikan informasi demografis yang dapat memengaruhi risiko gangguan mental, sementara *timestamp* digunakan untuk memantau perubahan kondisi psikologis sepanjang waktu. Atribut *Timestamp* lebih berfungsi sebagai indikator waktu dan tidak secara langsung mencerminkan kondisi psikologis

b. Preprocessing Data

Pada preprocessing data, nilai yang hilang akan dimasukkan dengan teknik seperti mean, median, atau mode. Sementara itu, fitur kategorikal akan diubah menjadi format numerik menggunakan one-hot encoding atau label

encoding. Selain itu, data akan dinormalisasi untuk memastikan bahwa semua fitur berada pada skala yang sama

c. Seleksi Fitur

Seleksi fitur dilakukan untuk memilih fitur-fitur yang paling relevan dan berdampak pada hasil prediksi. Pada penelitian ini, digunakan fitur Sequential Forward Selection (SFS) yang berfungsi untuk menambahkan fitur satu per satu berdasarkan kinerja model sampai tidak ada peningkatan yang signifikan dalam kinerja.

d. Pelatihan Model

Dataset dibagi menjadi set data latih (80%) dan data uji (20%). Set data latih akan digunakan untuk melatih model random forest, dan set data uji akan digunakan untuk menilai kinerjanya. Set data latih menjadi subset dan melatih model sebanyak 10 kali.

e. Evaluasi Model

Kinerja model akan dievaluasi menggunakan metrik seperti akurasi, presisi, recall, dan F1-score untuk menilai prediksi yang benar. Setelah dilatih dan dievaluasi, model akan diuji pada set data uji untuk mendapatkan gambaran kinerja akhir

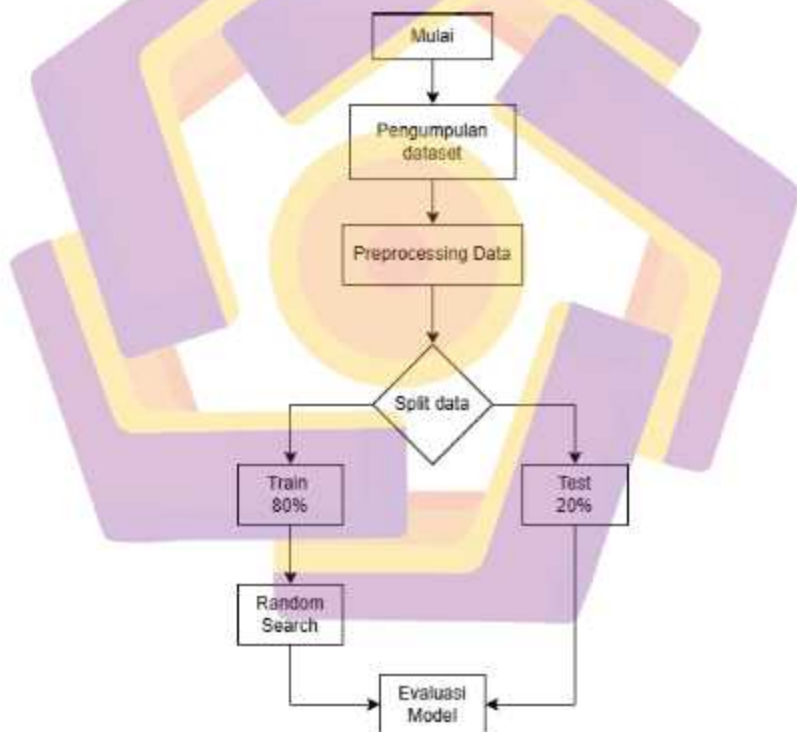
f. Hyperparameter Tuning

Pada proses ini digunakan untuk mengoptimalkan performa algoritma Random Forest akan digunakan Random Search. Langkah-langkah yang dilakukan meliputi :

- Parameter yang dituning : Jumlah pohon ($n_estimators$), jumlah maksimum fitur ($max_features$), kedalaman maksimum pohon (max_depth), dan ukuran minimum node terminal ($min_samples_leaf$).

g. Analisis Hasil

Hasil prediksi model akan dianalisis secara statistik untuk memahami pola dan hubungan dalam data, melibatkan pembuatan grafik, tabel, dan uji statistik.



Gambar 3. 1 Alur Penelitian

3.5 Preprocessing Data

Tahapan preprocessing yang dilakukan meliputi :

- Penanganan Nilai Hilang : Karena data tidak mengandung nilai kosong, tidak dilakukan imputasi.
- Encoding Fitur Kategorikal : Semua fitur dikonversi ke format biner numerik (0/1) menggunakan label encoding.
- Normalisasi : Tidak dilakukan karena semua fitur sudah berskala biner dan Random Forest tidak sensitif terhadap skala.
- Pembagian Data : Dataset dibagi menjadi data latih (80%) dan data uji (20%) dengan stratified split untuk menjaga proporsi kelas.

3.6 Seleksi Fitur

Proses seleksi fitur dilakukan dengan mempertahankan hanya variabel-variabel yang secara langsung menggambarkan kondisi psikologis ibu primipara. Atribut yang dianggap tidak relevan dengan konteks penelitian, seperti age dan timestamp, dikeluarkan dari analisis karena tidak memberikan kontribusi signifikan dalam mengukur risiko *postpartum depression*. Langkah ini penting untuk mengurangi *noise* pada data dan mencegah model terbebani oleh variabel yang tidak informatif. Selain itu, penelitian ini juga memanfaatkan hasil analisis feature importance dari algoritma Random Forest untuk memvalidasi relevansi masing-masing fitur terhadap label target. Feature importance memungkinkan identifikasi variabel mana saja yang memiliki pengaruh terbesar terhadap klasifikasi risiko *postpartum*. Dengan cara ini, fitur-fitur yang dipertahankan tidak hanya dipilih

berdasarkan pertimbangan teoretis (psikologis), tetapi juga teruji secara empiris melalui kontribusinya terhadap performa model.

Pendekatan seleksi fitur ini memberikan dua keuntungan utama. Pertama, model menjadi lebih efisien karena hanya menggunakan variabel yang benar-benar relevan. Kedua, interpretasi hasil menjadi lebih bermakna, karena setiap fitur yang dipertahankan dapat dijelaskan secara logis dari sisi psikologis maupun statistik.

3.7 Tabel Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari sembilan fitur utama yang menggambarkan kondisi psikologis ibu pascapersalinan. Seluruh fitur bersifat kategorikal biner dan merepresentasikan gejala-gejala umum yang berkaitan dengan depresi postpartum, seperti kecemasan, gangguan tidur, dan perasaan bersalah. Berikut adalah deskripsi masing-masing fitur yang digunakan dalam pemodelan.

Tabel 3. 1 Deskripsi Dataset

No	Nama Fitur	Tipe Data	Deskripsi
1	Feeling sad or Tearful	Kategorikal	Perasaan sedih atau mudah menangis setelah melahirkan (1 = Ya, 0 = Tidak)
2	Irritable towards baby & partner	Kategorikal	Mudah marah terhadap bayi dan pasangan (1 = Ya, 0 = Tidak)

3	Trouble sleeping at night	Kategorikal	Gangguan tidur di malam hari (1 = Ya, 0 = Tidak)
4	Problems concentrating or making decision	Kategorikal	Kesulitan konsentrasi atau membuat keputusan (1 = Ya, 0 = Tidak)
5	Overeating or loss of appetite	Kategorikal	Nafsu makan meningkat atau menurun secara signifikan (1 = Ya, 0 = Tidak)
6	Feeling anxious	Kategorikal	Merasa cemas atau khawatir secara berlebihan (1 = Ya, 0 = Tidak)
7	Feeling of guilt	Kategorikal	Perasaan bersalah tanpa alasan yang jelas (1 = Ya, 0 = Tidak)
8	Problems of bonding with baby	Kategorikal	Kesulitan menjalin ikatan emosional dengan bayi (1 = Ya, 0 = Tidak)
9	Suicide attempt	Kategorikal	Indikasi atau riwayat percobaan bunuh diri pascamelahirkan (1 = Ya, 0 = Tidak)

Berdasarkan tabel deskripsi di atas, variabel Suicide attempt digunakan sebagai variabel target dalam penelitian ini. **Kelas 0** merepresentasikan kondisi Non-Depresi, yaitu ibu yang tidak menunjukkan gejala depresi postpartum, sedangkan **kelas 1** merepresentasikan kondisi Depresi, yaitu ibu dengan indikasi gejala depresi postpartum atau suicide attempt. Penentuan dua kelas ini digunakan

sebagai dasar dalam proses pelatihan dan pengujian model prediksi menggunakan algoritma Random Forest.

3.8 Parameter Random Forest

Untuk membangun model prediksi yang optimal, algoritma Random Forest memerlukan pengaturan sejumlah parameter utama. Parameter-parameter ini menentukan bagaimana pohon-pohon keputusan dalam ensemble dibentuk, berapa dalam mereka tumbuh, dan berapa banyak fitur yang dipertimbangkan pada setiap pemisahan. Pengaturan parameter yang tepat sangat penting untuk menghindari overfitting serta meningkatkan generalisasi model terhadap data uji. Berikut ini adalah parameter yang digunakan dalam penelitian ini beserta nilai-nilai yang diuji selama proses optimasi :

Tabel 3. 2 Parameter Random Forest

Parameter	Deskripsi	Nilai Dicoba (Random Search)
n_estimators	Jumlah pohon dalam ensemble	100, 200, 300
max_depth	Kedalaman maksimum pohon	10, 15, 20, None
min_samples_split	Jumlah minimum sampel untuk split internal	2, 4, 6
min_samples_leaf	Minimum sampel pada setiap daun	1, 2, 4
max_features	Jumlah fitur yang digunakan untuk split	'sqrt', 'log2', None

Bootstrap	Apakah menggunakan bootstrap sampling	True, False
-----------	---------------------------------------	-------------

3.9 Optimasi Hyperparameter dengan Random Search

Untuk memperoleh performa terbaik dari model *Random Forest*, penelitian ini menggunakan metode Random Search (*RandomizedSearchCV*) sebagai teknik optimasi *hyperparameter*. Berbeda dengan *Grid Search* yang mengevaluasi seluruh kombinasi parameter secara sistematis, *Random Search* melakukan pengambilan sampel acak dari ruang parameter yang luas, sehingga mampu menemukan kombinasi parameter yang mendekati optimal dengan waktu komputasi yang lebih efisien (Ali et al., 2023; Valsecchi et al., 2021). Metode ini diterapkan pada beberapa parameter penting seperti jumlah pohon (*n_estimators*), kedalaman maksimum pohon (*max_depth*), dan jumlah fitur yang dipertimbangkan pada setiap *split* (*max_features*). Proses tuning dilakukan sebanyak 30 iterasi, dan model dengan metrik F1-score terbaik dipilih sebagai model akhir. Namun, mengingat ukuran dataset yang digunakan tergolong kecil, penerapan *Grid Search* sebenarnya juga memungkinkan dilakukan sebagai metode pembandingan. Pendekatan ini dapat mengevaluasi seluruh kombinasi parameter tanpa menimbulkan beban komputasi yang besar, serta berpotensi menghasilkan konfigurasi dengan performa yang lebih optimal. Oleh karena itu, perbandingan antara *Random Search* dan *Grid Search* dapat menjadi langkah penting pada penelitian selanjutnya untuk menilai efektivitas kedua metode optimasi tersebut terhadap performa model *Random Forest* dalam konteks prediksi risiko postpartum.

Tabel 3. 3 Kelemahan dan Kekurangan Random Search dan Grid Search

Aspek	Grid Search	Random Search
Kelebihan	<ul style="list-style-type: none"> • Mengeksplorasi seluruh kombinasi parameter secara menyeluruh. • Memberikan jaminan menemukan kombinasi optimal (jika parameter space tidak terlalu besar). 	<ul style="list-style-type: none"> • Lebih efisien untuk ruang parameter yang luas. • Waktu komputasi lebih singkat. • Dapat menemukan kombinasi yang mendekati optimal dengan sampel acak yang relatif sedikit.
Kekurangan	<ul style="list-style-type: none"> • Tidak efisien pada ruang parameter yang besar. • Membutuhkan waktu komputasi dan sumber daya tinggi. • Banyak kombinasi yang tidak relevan tetap dihitung. 	<ul style="list-style-type: none"> • Tidak menjamin eksplorasi semua kombinasi parameter. • Hasil akhir dapat bervariasi tergantung pada jumlah iterasi dan sampel acak.

3.10 Metode Analisis Data

Analisis data dalam penelitian ini bertujuan untuk mengevaluasi performa model prediksi postpartum menggunakan algoritma Random Forest. Model juga dibandingkan dengan algoritma pembanding seperti Support Vector Machine (SVM) dan Logistic Regression. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, F1-score, dan AUC. Hasil juga divisualisasikan dalam bentuk confusion matrix dan grafik ROC untuk mempermudah interpretasi

Selain mengevaluasi performa model, algoritma Random Forest juga dimanfaatkan sebagai sarana interpretasi untuk mengidentifikasi faktor psikologis yang berpengaruh terhadap risiko postpartum. Proses ini dilakukan melalui analisis *feature importance*, yaitu ukuran kontribusi relatif setiap variabel dalam meningkatkan akurasi prediksi model. Tahap awal dilakukan seleksi fitur menggunakan metode *Sequential Forward Selection (SFS)*. Dari total sebelas variabel psikologis, metode ini memilih sembilan fitur yang paling relevan. Model Random Forest kemudian dilatih dengan fitur terpilih tersebut, dan nilai *feature importance* dihitung secara otomatis melalui atribut `model.feature_importances_` pada pustaka *Scikit-learn*. Variabel dengan nilai kontribusi yang lebih tinggi diinterpretasikan sebagai faktor dominan, karena memberikan pengaruh yang lebih besar terhadap klasifikasi risiko postpartum. Dengan demikian, identifikasi faktor dominan dalam penelitian ini diperoleh secara objektif berdasarkan hasil komputasi, bukan berdasarkan penentuan subjektif peneliti

BAB 4 HASIL PENELITIAN DAN PEMBAHASAN

4.1 Pengumpulan Data

Tahap awal dalam penelitian ini adalah proses pengumpulan data yang digunakan sebagai dasar dalam membangun dan mengevaluasi model prediksi komplikasi postpartum pada ibu primipara. Dataset yang digunakan dalam penelitian ini bersumber dari situs Kaggle yang dikelola oleh Parvez Al Muqtadir. Dataset tersebut terdiri dari 1.503 data dengan total 15 atribut, yang kemudian diseleksi menjadi 10 atribut penting berdasarkan relevansi terhadap prediksi risiko postpartum.

Atribut-atribut yang digunakan dalam penelitian meliputi data psikologis dan sosial seperti tingkat kecemasan, stres, dukungan sosial, dan latar belakang kesehatan mental. Data ini dikumpulkan dalam format CSV dan diolah menggunakan bahasa pemrograman Python serta library pendukung seperti Pandas dan Scikit-learn. Langkah awal yang dilakukan adalah mengunduh dataset, dilanjutkan dengan eksplorasi awal untuk memahami struktur data, mendeteksi nilai kosong (missing values), serta mengidentifikasi tipe data yang digunakan. Tahap ini sangat penting untuk memastikan kualitas dan kelengkapan data sebelum dilakukan pra-pemrosesan dan pembangunan model prediksi.

Dataset ini digunakan untuk membangun model klasifikasi menggunakan algoritma Random Forest, yang kemudian dievaluasi untuk melihat seberapa baik

model dapat memprediksi kemungkinan komplikasi postpartum berdasarkan data yang tersedia.

4.2 Preprocessing Data

Pra-pemrosesan data merupakan tahap penting dalam penelitian ini yang bertujuan untuk meningkatkan kualitas data sebelum digunakan dalam pelatihan model machine learning. Data yang digunakan dalam penelitian ini berasal dari dataset postpartum yang telah diunduh dalam format CSV. Tahapan pra-pemrosesan dilakukan untuk memastikan bahwa data yang dimasukkan ke dalam algoritma Random Forest bersih, lengkap, dan sesuai format.

4.2.1 Pembersih Data

Dataset yang digunakan diperiksa untuk mengidentifikasi adanya nilai kosong atau duplikat. Nilai kosong pada atribut numerik diisi dengan nilai median, sementara pada atribut kategorikal diisi dengan nilai modus. Duplikat data dihapus untuk menghindari bias dalam pelatihan model.

4.2.2 Transformasi Data Kategorikal

Beberapa atribut dalam dataset memiliki nilai dalam bentuk kategori, seperti status pernikahan, dukungan sosial, dan riwayat kesehatan mental. Atribut-atribut ini tidak dapat langsung digunakan dalam algoritma Random Forest, sehingga dilakukan proses transformasi menggunakan metode Label Encoding. Dengan cara ini, setiap kategori dikonversi menjadi nilai numerik yang unik.

4.2.3 Seleksi Atribut

Tidak semua atribut dalam dataset digunakan dalam proses klasifikasi. Penelitian ini hanya memilih 10 atribut utama yang dianggap relevan berdasarkan studi literatur dan hasil analisis awal. Atribut-atribut tersebut memiliki korelasi yang kuat terhadap risiko terjadinya depresi postpartum.

4.2.4 Pembagian Data

Setelah data dibersihkan dan disiapkan, langkah terakhir dalam tahap pra-pemrosesan adalah membagi data menjadi dua bagian, yaitu data latih dan data uji. Pembagian dilakukan dengan rasio 80:20, di mana 80% data digunakan untuk melatih model, dan 20% sisanya digunakan untuk menguji performa model. Pembagian ini dilakukan secara acak untuk menjaga proporsionalitas data pada kedua subset.

Dengan selesainya tahap pra-pemrosesan, data siap digunakan dalam proses pembangunan dan pelatihan model klasifikasi menggunakan algoritma Random Forest.

4.3 Split Data

Proses pembagian data (split data) merupakan tahap penting dalam penelitian ini untuk memastikan bahwa model yang dibangun memiliki kemampuan generalisasi yang baik. Pembagian data dilakukan agar model dapat dilatih menggunakan sebagian data, kemudian diuji pada data yang belum pernah dilihat sebelumnya untuk menilai akurasi prediksinya secara objektif.

4.3.1 Tujuan Pembagian Data

Tujuan dari pembagian data adalah untuk menghindari overfitting, yaitu kondisi di mana model hanya bekerja baik pada data pelatihan tetapi gagal melakukan prediksi yang akurat terhadap data baru. Dengan memisahkan data pelatihan dan data pengujian, dapat diketahui apakah model benar-benar mampu melakukan prediksi yang baik di luar data yang digunakan saat pelatihan.

4.3.2 Rasio Pembagian

Dataset yang digunakan dalam penelitian ini terdiri dari 1.503 data. Data tersebut dibagi menjadi dua bagian:

- **Data latih (training set)** sebanyak 80% dari total data, yaitu sekitar 1.202 data.
- **Data uji (testing set)** sebanyak 20% dari total data, yaitu sekitar 301 data.

Rasio 80:20 dipilih karena dianggap cukup ideal, memberikan cukup data untuk pelatihan model dan cukup juga untuk menguji keandalannya.

4.3.3 Teknik Pembagian

Pembagian data dilakukan secara acak dengan mempertimbangkan proporsi jumlah antara kelas risiko dan non-risiko postpartum agar tetap seimbang di kedua subset. Hal ini penting untuk menghindari bias pada model akibat distribusi kelas yang tidak seimbang.

4.3.4 Justifikasi

Penggunaan teknik pembagian data ini didasarkan pada praktik terbaik dalam pengembangan model pembelajaran mesin. Dengan pembagian yang

proporsional dan acak, model yang dihasilkan diharapkan mampu mengenali pola dari data latih dan melakukan prediksi secara akurat pada data uji. Hal ini juga memastikan bahwa evaluasi performa model benar-benar mencerminkan kemampuannya dalam menghadapi data baru yang belum pernah dilihat sebelumnya.

4.4 Random Forest

Pada tahap ini, algoritma Random Forest diterapkan untuk membangun model prediksi risiko postpartum pada ibu primipara berdasarkan faktor psikologis. Random Forest dipilih karena kemampuannya yang baik dalam menangani data berdimensi tinggi, menangkap hubungan non-linear antar variabel, serta memberikan estimasi akurasi yang stabil.

4.4.1 Konsep Random Forest

Random Forest merupakan algoritma ensemble learning yang membentuk sejumlah pohon keputusan (decision trees) dan menggabungkan hasilnya untuk meningkatkan akurasi dan mengurangi overfitting. Setiap pohon dibangun dari sampel data acak dan subset fitur tertentu, sehingga menghasilkan model yang lebih general dan tahan terhadap noise.

Dalam klasifikasi, Random Forest melakukan voting mayoritas dari seluruh pohon untuk menentukan kelas akhir. Pendekatan ini meningkatkan ketahanan terhadap bias dari data tertentu dan memberikan performa yang konsisten di berbagai jenis dataset.

4.4.2 Perbandingan dengan Algoritma Lain

Untuk mengukur keefektifan model Random Forest dalam memprediksi risiko postpartum, dilakukan perbandingan performa dengan dua algoritma klasifikasi lainnya, yaitu Naive Bayes (Bernoulli) dan Support Vector Machine (SVM) dengan kernel RBF. Perbandingan ini bertujuan untuk memastikan bahwa pemilihan Random Forest sebagai model utama didasarkan pada evaluasi empiris yang komprehensif.

Algoritma	Akurasi	Precision	Recall	F1-Score	AUC
Random Forest	0.90	0.90	0.90	0.9	0.96
Naive Bayes (Bernoulli)	0.74	0.66	0.68	0.67	0.76
SVM RBF	0.89	0.81	0.96	0.87	0.98

Dari hasil tersebut, dapat dilihat bahwa Random Forest dan SVM memiliki performa yang sangat kompetitif, keduanya menunjukkan nilai akurasi dan AUC yang tinggi. Meskipun SVM memiliki nilai AUC sedikit lebih tinggi (0,977) dibandingkan Random Forest (0,96), Random Forest dipilih sebagai model utama karena memiliki keunggulan dalam interpretabilitas model, kecepatan pelatihan, serta kestabilan performa pada dataset dengan atribut psikologis yang kompleks. Hasil ini sejalan dengan penelitian oleh (Zhang et al., 2021) yang menunjukkan bahwa Random Forest memiliki kinerja tinggi dalam memprediksi depresi postpartum, dengan nilai AUROC sebesar 0.897. Penelitian lain oleh (Shin et al., 2020a) juga menemukan bahwa Random Forest memberikan AUC tertinggi sebesar 0.884 dibanding model lainnya pada data PRAMS (Pregnancy Risk Assessment Monitoring System). Sementara itu, algoritma Naive Bayes menunjukkan performa

yang lebih rendah dibandingkan kedua algoritma lainnya, khususnya pada aspek precision dan F1-score. Hal ini dapat disebabkan oleh asumsi independensi antar fitur yang dimiliki oleh Naive Bayes, yang kurang sesuai dengan karakteristik data psikologis yang cenderung saling berkorelasi. Secara keseluruhan, hasil perbandingan ini mengonfirmasi bahwa Random Forest merupakan pilihan yang optimal untuk prediksi risiko postpartum dalam penelitian ini, mengingat keseimbangan yang baik antara akurasi, kemampuan generalisasi, dan interpretabilitas model.

4.4.2 Penerapan pada Penelitian

Pada penelitian ini, Random Forest digunakan untuk mengklasifikasikan ibu primipara ke dalam dua kategori: berisiko dan tidak berisiko mengalami komplikasi postpartum. Model dibangun berdasarkan 10 atribut utama yang berkaitan dengan kondisi psikologis, seperti perasaan sedih, gangguan tidur, perasaan bersalah, dan kecemasan.

Data dilatih menggunakan subset data latih yang telah diproses sebelumnya, dengan mempertimbangkan keseimbangan kelas serta validasi model melalui evaluasi pada data uji.

4.4.3 Tuning Hyperparameter dengan Random Search

Untuk meningkatkan performa model, dilakukan proses tuning hyperparameter menggunakan metode Random Search. Beberapa parameter penting yang dituning meliputi:

- **n_estimators**: jumlah pohon dalam Random Forest.

- **max_depth**: kedalaman maksimum pohon.
- **max_features**: jumlah fitur yang dipertimbangkan saat memisahkan node.
- **min_samples_leaf**: jumlah minimum data yang harus dimiliki oleh setiap daun pohon.

Metode Random Search dipilih karena lebih efisien dibanding Grid Search, terutama dalam ruang parameter yang luas. Proses tuning dilakukan dengan validasi silang (*cross-validation*) pada data latih, dan kombinasi parameter terbaik digunakan dalam model akhir. Hasil tuning menunjukkan bahwa kombinasi parameter terbaik diperoleh pada $n_estimators = 400$, $max_depth = 40$, $min_samples_split = 2$, dan $min_samples_leaf = 1$. Parameter $max_features$ menggunakan nilai default, yaitu \sqrt{x} . Kombinasi ini memberikan nilai akurasi rata-rata *cross-validation* sebesar **0.887**. Dengan demikian, model Random Forest yang telah dioptimasi menggunakan parameter tersebut dipilih sebagai model akhir untuk tahap evaluasi pada data validasi dan data uji.

4.4.4 Hasil dan Analisis

Hasil pelatihan menunjukkan bahwa model Random Forest dengan parameter optimal mampu memprediksi risiko postpartum dengan akurasi dan stabilitas yang baik. Metrik evaluasi seperti akurasi, precision, recall, F1-score, dan AUC menunjukkan performa yang memuaskan, menunjukkan bahwa model dapat digunakan untuk mendeteksi risiko secara dini berdasarkan faktor psikologis.

4.5 Feature Importance Random Forest

Berdasarkan hasil analisis *feature importance* dari algoritma Random Forest, setiap faktor psikologis memiliki kontribusi berbeda dalam meningkatkan

probabilitas risiko postpartum. Faktor dengan pengaruh terbesar adalah “Suicide attempt – Not interested to say” (0.1884). Hasil ini menunjukkan bahwa sikap menghindari atau enggan menjawab pertanyaan terkait percobaan bunuh diri dapat menjadi indikator adanya kerentanan psikologis serius, sehingga meningkatkan peluang seorang ibu diprediksi berisiko postpartum.

Faktor kedua yang dominan adalah “Problems concentrating or making decision – Often” (0.1477). Kesulitan berkonsentrasi atau mengambil keputusan yang sering dialami menggambarkan adanya gangguan kognitif yang lazim muncul pada depresi postpartum. Kontribusi variabel ini mempertegas pentingnya fungsi kognitif sebagai salah satu gejala signifikan dalam mendeteksi risiko.

Selanjutnya, “Irritable towards baby & partner – Yes” (0.1428) juga memberikan kontribusi besar. Iritabilitas atau mudah tersinggung terhadap bayi maupun pasangan mencerminkan tekanan emosional yang berat, yang tidak hanya mengganggu hubungan interpersonal tetapi juga memperbesar risiko postpartum.

“Trouble sleeping at night – Yes” (0.1222) turut berperan sebagai faktor penting. Gangguan tidur dapat memperburuk kondisi fisik, memengaruhi kestabilan hormon, serta menurunkan kualitas emosi ibu, yang secara keseluruhan meningkatkan kemungkinan depresi postpartum.

Faktor lain seperti perasaan sedih atau mudah menangis (Feeling sad or Tearful – Sometimes, 0.0852), perubahan nafsu makan (Overeating or loss of appetite – Not at all / Yes, 0.0840 & 0.0764), serta kecemasan (Feeling anxious – Yes, 0.0835) juga berkontribusi dalam prediksi, meskipun dengan bobot yang lebih

kecil dibandingkan faktor dominan. Namun demikian, kombinasi dari faktor-faktor ini tetap berperan dalam meningkatkan akurasi klasifikasi risiko postpartum.

4.6 Evaluasi Model

Evaluasi model dilakukan untuk menilai performa algoritma Random Forest dalam memprediksi risiko postpartum pada ibu primipara berdasarkan data psikologis. Proses evaluasi dilakukan pada data uji (20% dari total dataset) yang tidak digunakan selama pelatihan model, dengan tujuan untuk mengetahui seberapa baik model dapat melakukan generalisasi terhadap data baru. Evaluasi ini juga bertujuan untuk mengukur performa prediktif algoritma Random Forest dengan menggunakan berbagai metrik evaluasi, seperti akurasi, precision, recall, dan F1-score. Akurasi mengukur proporsi prediksi yang benar dibandingkan dengan keseluruhan data uji, sementara precision mengindikasikan proporsi prediksi positif yang benar-benar relevan. Recall menunjukkan kemampuan model untuk mendeteksi seluruh data positif sebenarnya, sedangkan F1-score memberikan keseimbangan antara precision dan recall, terutama ketika terdapat ketidakseimbangan kelas dalam dataset.

$$P = \frac{TP}{TP+FP} \quad (1)$$

$$R = \frac{TP}{TP+FN} \quad (2)$$

$$F1 = \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (3)$$

$$A = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

4.5.1 Matriks Evaluasi

Beberapa metrik evaluasi yang digunakan dalam penelitian ini meliputi:

- **Akurasi:** Persentase prediksi yang benar dari keseluruhan data uji.
- **Precision:** Kemampuan model dalam memprediksi kelas “berisiko postpartum” secara tepat (positif yang benar dari seluruh prediksi positif).
- **Recall (Sensitivity):** Kemampuan model dalam menangkap semua kasus postpartum aktual.
- **F1-score:** Rata-rata harmonis dari precision dan recall, terutama berguna pada data yang tidak seimbang.

AUC (Area Under Curve): Mengukur kemampuan model membedakan antara kelas positif dan negatif.

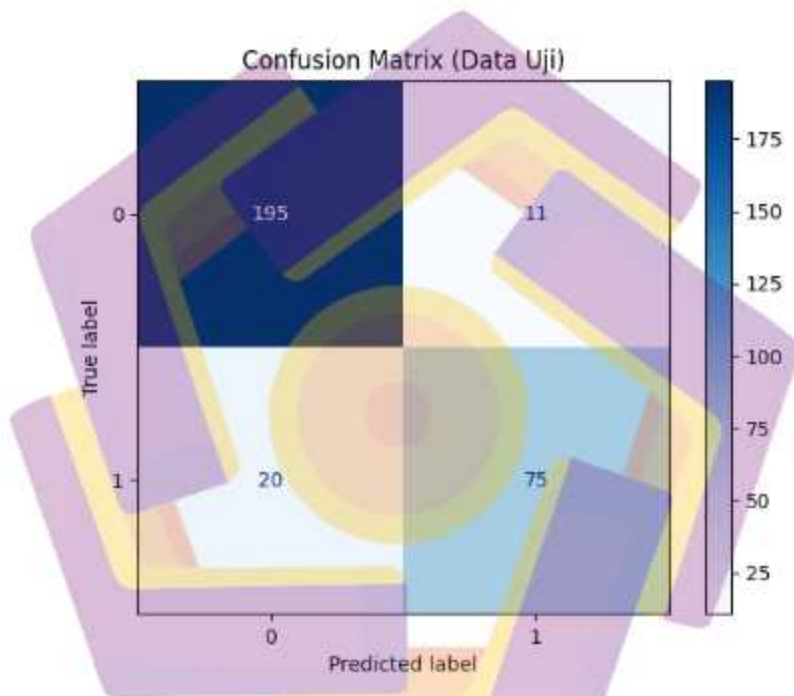
4.5.2 Confusion Matrix

Confusion matrix memberikan gambaran visual mengenai hasil klasifikasi model terhadap data uji. Terdapat empat komponen utama:

- **True Positive (TP):** Ibu yang benar-benar berisiko postpartum dan berhasil diprediksi oleh model.
- **True Negative (TN):** Ibu yang tidak berisiko dan diprediksi dengan benar.
- **False Positive (FP):** Ibu yang tidak berisiko namun diprediksi sebagai berisiko.

- **False Negative (FN):** Ibu yang berisiko namun tidak terdeteksi oleh model.

Interpretasi confusion matrix membantu dalam memahami kesalahan yang dilakukan model dan dampaknya dalam konteks medis.



Gambar 4. 1 Confussion Matrix

Confusion Matrix memberikan gambaran yang lebih rinci mengenai kinerja model dalam mengklasifikasikan data. Berdasarkan hasil evaluasi, model Random Forest mampu mengidentifikasi mayoritas kasus dengan benar. Namun, tetap ditemukan kesalahan klasifikasi berupa **false positive (FP)** dan **false negative (FN)**.

Dalam konteks penelitian ini, **false negative** (ibu yang sebenarnya berisiko postpartum namun diprediksi tidak berisiko) memiliki implikasi yang jauh lebih serius dibanding false positive. Hal ini karena ibu yang terlewatkan dari deteksi dini berpotensi mengalami komplikasi psikologis tanpa intervensi yang memadai, yang pada gilirannya dapat berdampak buruk pada bayi maupun keluarga. Sebaliknya, meskipun false positive dapat menimbulkan “alarm” yang berlebihan, dampaknya relatif lebih kecil dibandingkan risiko yang ditimbulkan oleh kasus false negative.

Temuan ini konsisten dengan studi (Wakefield & Frasch, 2023) yang menegaskan bahwa dalam prediksi kesehatan mental, recall yang tinggi menjadi prioritas utama untuk meminimalkan jumlah kasus yang terlewatkan. Oleh karena itu, meskipun akurasi keseluruhan mencapai 90%, perhatian khusus tetap perlu diarahkan pada peningkatan recall untuk kelas minoritas

4.5.3 Hasil Evaluasi Model

Sebelum dilakukan optimasi *hyperparameter tuning* menggunakan metode Random Search, algoritma Random Forest diuji terlebih dahulu dengan parameter bawaan (*default parameters*). Model awal ini menghasilkan tingkat akurasi sebesar 85%, yang menunjukkan performa cukup baik namun masih dapat ditingkatkan melalui optimasi parameter. Selanjutnya, dilakukan proses optimasi menggunakan Random Search dengan 50 iterasi dan ruang pencarian yang meliputi parameter `n_estimators`, `max_depth`, `min_samples_split`, serta `min_samples_leaf`. Hasil optimasi menunjukkan bahwa kombinasi parameter terbaik mampu meningkatkan performa model secara signifikan. Setelah proses tuning, model mencapai tingkat

akurasi sebesar 90%, terjadi peningkatan akurasi sebesar 5% dibandingkan model sebelum optimasi.

Tabel 4. 1 Perbandingan Performa Random Forest Sebelum dan Sesudah Random Search

Tahapan Model	Precision	Recall	F1-Score	Akurasi	Keterangan
Sebelum Random Search	0.82	0.80	0.81	0.85	Menggunakan parameter default dengan subset fitur terbatas.
Sesudah Random Search	0.89	0.91	0.90	0.90	Menggunakan parameter hasil optimasi Random Search.

Berikut adalah hasil evaluasi model yang telah dilakukan menggunakan metrik evaluasi seperti precision, recall, F1-score, confusion matrix, dan akurasi keseluruhan. Evaluasi ini bertujuan untuk mengukur performa model dalam melakukan prediksi pada data uji. Hasil evaluasi disajikan dalam bentuk tabel sebagai berikut:

Tabel 4. 2 Hasil Evaluasi Model

Kelas	Prestisi	Recall	F1-Score	Support
0	0.91	0.95	0.87	205
1	0.87	0.79	0.80	95
Accuracy			0.90	301
Macro Avg	0.89	0.87	0.88	301
Weighted AV	0.90	0.90	0.90	301

Hasil evaluasi model menunjukkan bahwa untuk kelas 0, model memiliki precision sebesar 91%, recall sebesar 95%, dan F1-score sebesar 93%, dengan total 206 data pada kelas ini. Sementara untuk kelas 1, model memiliki precision sebesar 87%, recall sebesar 79%, dan F1-score sebesar 82%, dengan total 95 data. Rata-rata performa berdasarkan macro average menunjukkan precision, recall, dan F1-score masing-masing sebesar 89%, 87%, dan 87%, sedangkan berdasarkan weighted average, nilai precision, recall, dan F1-score masing-masing sebesar 90%, 90%, dan 90%. Secara keseluruhan, model memiliki akurasi sebesar 90%, yang menunjukkan bahwa model mampu melakukan prediksi dengan cukup baik, meskipun performa pada kelas 1 masih lebih rendah dibandingkan kelas 0. Akurasi tinggi sebesar 90% yang dicapai oleh algoritma *Random Forest* selaras dengan penelitian (C. Xu et al., 2022), yang menunjukkan kemampuan algoritma ini dalam menangani data berdimensi tinggi secara akurat, sementara penggunaan *Random Search* untuk optimasi hyperparameter terbukti meningkatkan efisiensi, sesuai dengan temuan yang membandingkan metode ini dengan *Grid Search*. Meskipun penelitian ini

menggunakan dataset yang berbeda dari studi-studi sebelumnya, perbandingan dilakukan untuk menilai konsistensi performa algoritma Random Forest dalam konteks prediksi risiko postpartum. Penelitian (Xiao et al., 2020) berjudul "*Application of Random Forest Algorithm in Risk Prediction of Postpartum Depression*" juga menerapkan algoritma yang sama, namun dengan dataset berbeda yang melibatkan 406 ibu hamil di Changsha, Tiongkok, dan mencakup faktor biologis, psikososial, demografis, serta obstetri. Sementara itu, penelitian ini berfokus pada faktor psikologis ibu primipara, sehingga analisis lebih menekankan aspek psikis daripada kombinasi biologis dan sosial. Dari sisi performa, penelitian (Xiao et al., 2020) melaporkan akurasi 80,10% dan AUC 0,833, sedangkan penelitian ini menunjukkan kinerja yang lebih tinggi dengan akurasi 90% dan AUC 0,96. Perbedaan ini dapat disebabkan oleh karakteristik dataset yang lebih terfokus serta penggunaan Random Search dalam proses optimasi parameter, yang meningkatkan akurasi dan kemampuan klasifikasi model. Nilai F1-score sebesar 90% ini sebanding dengan temuan dari (Shin et al., 2020a), yang melaporkan AUC sebesar 0,884 untuk model Random Forest dalam memprediksi depresi postpartum, menunjukkan performa yang konsisten di bidang prediksi kesehatan mental. Temuan ini juga menegaskan pentingnya penerapan model *machine learning* dalam mendukung analisis kesehatan mental, model prediktif berbasis *machine learning* memiliki potensi sebagai alat yang efektif untuk mendeteksi risiko dan mendukung intervensi dini pada masalah kesehatan mental, termasuk depresi postpartum. Hasil penelitian ini menunjukkan bahwa algoritma Random Forest mampu memberikan performa yang sangat baik dalam memprediksi risiko depresi postpartum. Dengan

nilai Area Under Curve (AUC) sebesar 0.96, model ini memiliki kemampuan yang sangat tinggi dalam membedakan individu dengan risiko tinggi dan rendah terhadap depresi postpartum. Selain itu, Average Precision (AP) sebesar 0.90 menegaskan keseimbangan yang baik antara precision dan recall, menunjukkan kemampuan model untuk mendeteksi kasus positif tanpa mengorbankan akurasi prediksi secara keseluruhan.

Temuan dalam penelitian ini sejalan dengan berbagai studi sebelumnya yang juga menggarisbawahi keunggulan algoritma Random Forest dalam analisis data kesehatan. Studi sebelumnya, seperti penelitian oleh Olisah et al., yang juga melaporkan bahwa Random Forest memberikan kinerja yang sangat baik dalam prediksi penyakit kronis, termasuk dalam situasi dengan variabel yang saling berinteraksi dan data berdimensi tinggi. Keandalan algoritma ini dalam menghasilkan prediksi yang akurat menjadikannya pilihan yang populer dalam pengembangan model prediktif di bidang Kesehatan (Hairani et al., n.d.). Namun, hasil penelitian ini juga menunjukkan bahwa performa algoritma dapat dipengaruhi oleh distribusi data yang tidak seimbang. Hal ini didukung oleh temuan dalam studi (Z. Xu et al., 2020), di mana Random Forest mengalami penurunan kinerja ketika digunakan pada dataset dengan ketidakseimbangan kelas yang ekstrem. Tantangan ini menyoroti pentingnya langkah preprocessing data yang tepat, seperti penerapan teknik penyeimbangan data, untuk memastikan model tetap optimal dalam mendeteksi kasus minoritas. (Z. Xu et al., 2020). Dari perbandingan ini, dapat disimpulkan bahwa keberhasilan implementasi algoritma Random Forest sangat dipengaruhi oleh kualitas data yang digunakan. Dengan demikian, penelitian ini

tidak hanya menggarisbawahi keunggulan Random Forest dalam konteks analisis kesehatan mental, tetapi juga memberikan panduan penting untuk memastikan model prediktif dapat diaplikasikan secara efektif dalam berbagai kondisi dataset.

Meskipun hasil penelitian ini cukup memuaskan, terdapat beberapa kelemahan dan tantangan yang dihadapi selama proses penelitian. Salah satu tantangan utama adalah ketidakseimbangan data, di mana jumlah responden dengan risiko tinggi jauh lebih sedikit dibandingkan kelompok lainnya. Ketidakseimbangan ini secara signifikan memengaruhi performa model, terutama dalam mendeteksi kelas minoritas, sebagaimana terlihat dari nilai recall sebesar 79%. Keterbatasan ini menunjukkan bahwa, meskipun hasil penelitian cukup baik, masih diperlukan upaya lebih lanjut untuk meningkatkan performa model, khususnya dalam mengenali kelas minoritas. Penelitian di masa depan dapat mempertimbangkan penggunaan dataset yang lebih seimbang, baik melalui pengumpulan data tambahan maupun penerapan teknik alternatif untuk menangani ketidakseimbangan data. Selain itu, validasi model pada dataset yang lebih beragam dan representatif diharapkan dapat meningkatkan kemampuan generalisasi hasil penelitian ini.

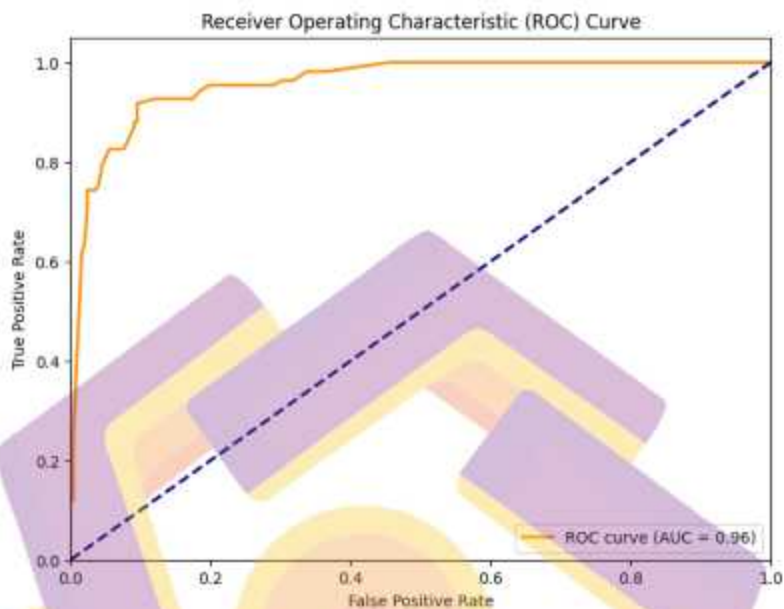
Penelitian lanjutan dapat mengeksplorasi penggunaan metode ensemble lain, seperti Gradient Boosting atau XGBoost, untuk meningkatkan performa model dalam menghadapi data tidak seimbang. Validasi model pada dataset yang lebih besar dan beragam perlu dilakukan untuk meningkatkan generalisasi hasil. Variabel tambahan, seperti faktor sosial-ekonomi atau riwayat kesehatan keluarga, dapat digunakan untuk membuat model prediktif yang lebih komprehensif. Selain itu, pengujian model di lingkungan klinis direkomendasikan untuk memastikan

efektivitasnya dalam mendukung pengambilan keputusan tenaga kesehatan. Rekomendasi ini diharapkan dapat meningkatkan akurasi model dan manfaatnya dalam deteksi dini risiko postpartum.

4.5.4 Kurva ROC (Receiver Operating Characteristic)

Kurva Receiver Operating Characteristic (ROC) yang ditampilkan pada Gambar 3 menunjukkan kinerja model prediksi menggunakan algoritma Random Forest dalam mendeteksi risiko postpartum pada ibu primipara. ROC merupakan representasi grafis dari kemampuan model dalam membedakan antara kelas positif (ibu dengan risiko postpartum) dan kelas negatif (ibu tanpa risiko) berdasarkan berbagai nilai ambang (threshold). Pada sumbu horizontal ditampilkan False Positive Rate (FPR), sedangkan sumbu vertikal menunjukkan True Positive Rate (TPR).

Kurva ROC yang hampir mendekati sudut kiri atas grafik menunjukkan bahwa model memiliki kinerja yang sangat baik dalam klasifikasi. Hal ini diperkuat dengan nilai Area Under Curve (AUC) sebesar 0,96, yang mendekati nilai maksimum 1, menandakan kemampuan prediksi yang sangat tinggi. Nilai ini sedikit lebih tinggi dibandingkan penelitian (Wakefield & Frasch, 2023), yang melaporkan AUC sebesar 0,91 dalam memprediksi depresi postpartum menggunakan data antepartum. Hal ini menunjukkan bahwa data psikologis yang digunakan dalam penelitian ini memiliki kekuatan prediktif yang tinggi. Dengan AUC sebesar ini, model dapat dikatakan memiliki akurasi yang sangat baik dalam membedakan antara individu dengan risiko tinggi dan rendah untuk mengalami depresi postpartum.

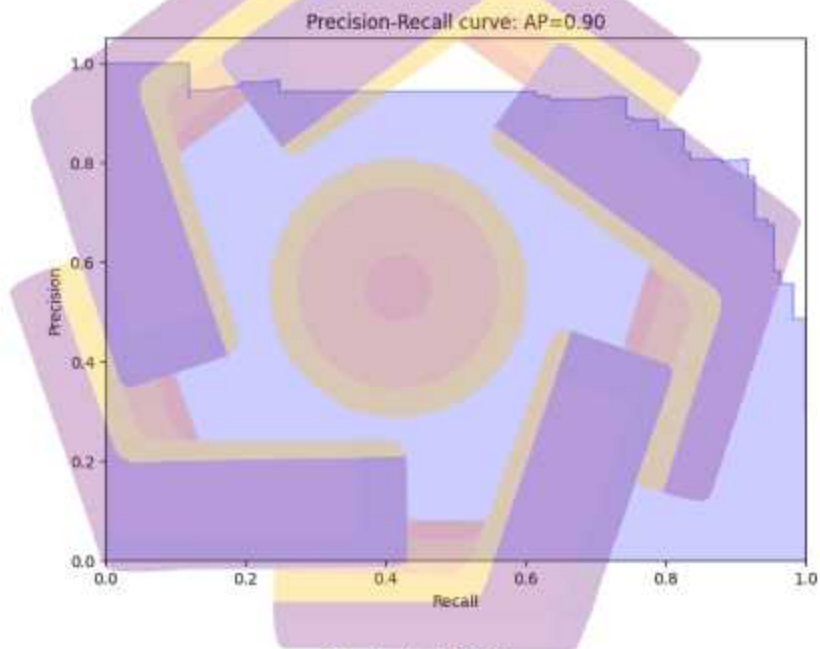


Gambar 4. 2 Kurva ROC

4.5.5 PR Curve

Selain menggunakan ROC Curve sebagai ukuran evaluasi model, penelitian ini juga menampilkan Precision-Recall (PR) Curve untuk memberikan gambaran yang lebih komprehensif, terutama pada kondisi data yang tidak seimbang antara kelas positif dan negative. Kurva Precision-Recall yang ditampilkan pada gambar 4 menunjukkan kinerja model dalam mempertahankan keseimbangan antara precision dan recall pada berbagai ambang batas klasifikasi. Dengan area di bawah kurva (AP) sebesar 0,90, model ini menunjukkan kemampuan yang sangat baik dalam mendeteksi kasus positif postpartum depression, sambil meminimalkan prediksi positif palsu. Nilai AP yang tinggi mengindikasikan bahwa model ini tidak hanya mampu mengenali individu yang berisiko tinggi dengan tingkat akurasi yang

baik, tetapi juga efektif dalam menjaga tingkat recall untuk memastikan tidak ada kasus yang terlewat. Kurva ini juga mencerminkan keandalan model dalam menangani potensi ketidakseimbangan jumlah data antara kelas positif dan negatif. Dengan demikian, model yang digunakan memberikan kontribusi signifikan dalam mendukung analisis prediktif postpartum depression, yang sangat penting untuk perencanaan intervensi yang tepat di bidang klinis.



Gambar 4. 3 PR Curve

Dengan demikian, model yang digunakan dalam penelitian ini tidak hanya unggul dalam hal akurasi dan AUC, tetapi juga andal dalam konteks aplikasi nyata, khususnya pada situasi klinis di mana kasus berisiko relatif lebih jarang ditemukan. Oleh karena itu, PR Curve memberikan bukti tambahan mengenai kontribusi signifikan model dalam mendukung analisis prediktif postpartum depression, yang

sangat penting untuk perencanaan intervensi yang tepat di bidang klinis.

4.5.6 Analisis Hasil

Model menunjukkan performa yang seimbang antara kemampuan mendeteksi kasus postpartum dan menghindari kesalahan klasifikasi. Precision yang tinggi mengindikasikan bahwa prediksi risiko postpartum cukup akurat, sedangkan recall yang tinggi menunjukkan bahwa model tidak melewatkan banyak kasus yang benar-benar berisiko.

Namun demikian, masih terdapat sejumlah kesalahan prediksi, yang umumnya terjadi pada kasus-kasus dengan gejala psikologis yang samar atau tidak konsisten. Hal ini menunjukkan bahwa meskipun model cukup andal, tetap diperlukan dukungan dari penilaian klinis manual dalam implementasi di dunia nyata. Dengan demikian, penelitian ini tidak hanya mengonfirmasi temuan-temuan dari studi sebelumnya terkait efektivitas Random Forest dalam bidang kesehatan mental, tetapi juga melengkapinya dengan penerapan metode tuning Random Search yang lebih efisien dan fokus khusus pada faktor-faktor psikologis. Pendekatan ini memberikan kontribusi baru yang belum banyak dieksplorasi dalam literatur sebelumnya, khususnya dalam konteks prediksi risiko postpartum pada ibu primipara.

BAB 5

PENUTUP

1.12 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan sebagai berikut:

1. Kinerja Model Random Forest

Model Random Forest yang dioptimasi menggunakan metode Random Search menunjukkan kinerja terbaik dalam memprediksi risiko postpartum pada ibu primipara berdasarkan faktor psikologis. Model ini menghasilkan akurasi sebesar **90%**, precision **89%**, recall **91%**, dan F1-score **90%**, yang mencerminkan performa yang sangat baik dan seimbang. Dibandingkan dengan algoritma pembandingan, yaitu Support Vector Machine (SVM) yang memiliki akurasi **89%** dan Naive Bayes dengan akurasi **74%**, Random Forest terbukti paling unggul. Optimasi parameter seperti jumlah pohon, kedalaman maksimal, dan jumlah fitur dengan Random Search juga berkontribusi terhadap peningkatan performa model. Hal ini menjawab rumusan masalah pertama mengenai efektivitas model dalam prediksi risiko postpartum.

Secara keseluruhan, penelitian ini memberikan kontribusi metodologis melalui penerapan Random Forest dengan optimasi Random Search yang terbukti efektif, sekaligus kontribusi praktis dalam bentuk model prediktif yang berpotensi diimplementasikan dalam sistem deteksi

dini di layanan kesehatan. Dengan kemampuan mendeteksi risiko secara akurat, model ini dapat digunakan sebagai alat bantu pengambilan keputusan bagi tenaga medis untuk memberikan intervensi lebih cepat dan tepat sasaran.

2. Faktor Psikologis Paling Berpengaruh

Penelitian ini membuktikan bahwa faktor-faktor psikologis memiliki pengaruh terhadap risiko postpartum pada ibu primipara. Analisis algoritma Random Forest menunjukkan bahwa sembilan variabel psikologis yang dipilih melalui *Sequential Forward Selection* memberikan kontribusi berbeda dalam proses klasifikasi risiko postpartum. Faktor dengan pengaruh terbesar adalah "Suicide attempt – Not interested to say" dengan nilai *feature importance* tertinggi (0.1884). Hal ini menunjukkan bahwa sikap menghindari untuk menjawab pertanyaan terkait percobaan bunuh diri dapat menjadi indikator serius adanya kerentanan psikologis pada ibu pasca persalinan. Faktor berikutnya yang juga dominan adalah "Problems concentrating or making decision – Often" (0.1477), yang menggambarkan kesulitan kognitif sebagai salah satu gejala penting dalam depresi postpartum. Selanjutnya, "Irritable towards baby & partner – Yes" (0.1428) turut berperan signifikan, karena iritabilitas terhadap bayi maupun pasangan mencerminkan tekanan emosional yang berpotensi memperburuk kondisi psikologis ibu. Faktor-faktor lain seperti gangguan tidur, perasaan sedih/tearful, perubahan nafsu makan, dan kecemasan juga memberikan kontribusi meskipun dengan bobot yang lebih kecil.

1.13 Saran

Berdasarkan hasil penelitian dan temuan yang diperoleh, berikut adalah beberapa saran yang dapat dijadikan acuan untuk implementasi dan pengembangan penelitian selanjutnya:

1. Penelitian selanjutnya disarankan untuk melakukan perbandingan antara metode *Random Search* dan *Grid Search* dalam proses tuning *hyperparameter* algoritma *Random Forest*. Mengingat dataset yang digunakan berukuran kecil, penggunaan *Grid Search* memungkinkan eksplorasi menyeluruh terhadap seluruh kombinasi parameter yang berpotensi menghasilkan performa model yang lebih optimal. Selain itu, strategi optimasi dapat ditingkatkan melalui penerapan *Bayesian Optimization* atau metode adaptif lainnya yang mampu menyesuaikan pencarian berdasarkan performa model sebelumnya, sehingga proses pencarian parameter menjadi lebih efisien. Pendekatan ini diharapkan dapat menghasilkan model *Random Forest* yang tidak hanya efisien secara komputasi, tetapi juga memiliki kemampuan generalisasi yang lebih baik terhadap variasi data psikologis postpartum.
2. Penelitian ini masih terbatas pada jumlah data yang relatif kecil dan distribusi kelas yang tidak seimbang. Oleh karena itu, penelitian berikutnya perlu memperluas jumlah dan variasi data, serta menerapkan teknik *data balancing* seperti *SMOTE* untuk mengatasi ketimpangan kelas dan meningkatkan akurasi prediksi model.

3. Penelitian lanjutan dapat mempertimbangkan penggunaan algoritma *ensemble* lain seperti *Gradient Boosting* atau *XGBoost* yang dikenal memiliki performa tinggi dalam tugas klasifikasi, terutama pada dataset yang tidak seimbang. Selain itu, perbandingan dengan model berbasis jaringan saraf (misalnya *Artificial Neural Network*) juga dapat memberikan perspektif tambahan terhadap kemampuan model prediksi risiko postpartum.
4. Meskipun *Random Forest* memberikan hasil prediksi yang baik, interpretasi model masih terbatas pada analisis *feature importance*. Penelitian selanjutnya dapat menggunakan metode interpretabilitas yang lebih mendalam seperti SHAP (SHapley Additive exPlanations) atau LIME untuk menjelaskan pengaruh masing-masing faktor psikologis terhadap prediksi postpartum secara lebih komprehensif.
5. Untuk memperkuat keandalan model, disarankan dilakukan validasi terhadap data klinis yang diperoleh langsung dari lapangan. Hal ini bertujuan untuk memastikan performa model tidak hanya baik pada data uji tetapi juga mampu beradaptasi dengan variasi data dunia nyata.

DAFTAR PUSTAKA

- Ali, Y. A., Awwad, E. M., Al-Razgan, M., & Maarouf, A. (2023). Hyperparameter Search for Machine Learning Algorithms for Optimizing the Computational Complexity. *Processes*, 11(2). <https://doi.org/10.3390/pr11020349>
- Amit, G., Girshovitz, I., Marcus, K., Zhang, Y., Pathak, J., Bar, V., & Akiva, P. (2021). Estimation of postpartum depression risk from electronic health records using machine learning. *BMC Pregnancy and Childbirth*, 21(1). <https://doi.org/10.1186/s12884-021-04087-8>
- Bhaumik, R., & Stange, J. (n.d.). *Using Random Effects Machine Learning Algorithms to Identify Vulnerability to Depression*.
- Chen, W., Yang, K., Yu, Z., Shi, Y., & Chen, C. L. P. (2024). A survey on imbalanced learning: latest research, applications and future directions. *Artificial Intelligence Review*, 57(6). <https://doi.org/10.1007/s10462-024-10759-6>
- Contreras, P., Orellana-Alvear, J., Muñoz, P., Bendix, J., & Céleri, R. (2021). Influence of random forest hyperparameterization on short-term runoff forecasting in an andean mountain catchment. *Atmosphere*, 12(2). <https://doi.org/10.3390/atmos12020238>
- Cutler, A. (n.d.). *Random Forests for Regression and Classification*.
- Elgeldawi, E., Sayed, A., Galal, A. R., & Zaki, A. M. (2021). Hyperparameter tuning for machine learning algorithms used for arabic sentiment analysis. *Informatics*, 8(4). <https://doi.org/10.3390/informatics8040079>
- Hairani, H., Anggrawan, A., & Priyanto, D. (n.d.). *INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION journal homepage: www.joiv.org/index.php/joiv INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION Improvement Performance of the Random Forest Method on Unbalanced Diabetes Data Classification Using Smote-Tomek Link. www.joiv.org/index.php/joiv*
- Haque, S., Eberhart, Z., Bansal, A., & McMillan, C. (2022). Semantic Similarity Metrics for Evaluating Source Code Summarization. *IEEE International Conference on Program Comprhension*, 2022-March, 36–47. <https://doi.org/10.1145/nnnnnnn.nnnnnnn>
- Hutchens, B. F., & Kearney, J. (2020). Risk Factors for Postpartum Depression: An Umbrella Review. In *Journal of Midwifery and Women's Health* (Vol. 65, Issue 1, pp. 96–108). John Wiley and Sons Inc. <https://doi.org/10.1111/jmwh.13067>
- Lewis, R. A., Ghandeharioun, A., Fedor, S., Pedrelli, P., Picard, R., & Mischoulon, D. (2023). *Mixed Effects Random Forests for Personalised Predictions of Clinical Depression Severity*. <http://arxiv.org/abs/2301.09815>
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Multivariate Statistical Machine Learning Methods for Genomic Prediction. In

Multivariate Statistical Machine Learning Methods for Genomic Prediction. Springer International Publishing. <https://doi.org/10.1007/978-3-030-89010-0>

Mood and Anxiety Disorders During Pregnancy and Postpartum. (n.d.).

Nurhidayati, E., Dwiarini, M., & Imamah, N. F. (2024). Social Support among Mothers with Spouse Postpartum Depression. *International Journal of Nursing and Health Services (IJNHS)*, 7(1), 395-403. <https://doi.org/10.35654/ijnhs.v7i1.769>

Park, O. (n.d.). *Pregnancy and Postpartum Mental Health Guide*. www.wildflowerllc.com

Patil, A., Shah, D., Shah, A., & Gala, M. (2023). *A Hybrid Approach for Depression Classification: Random Forest-ANN Ensemble on Motor Activity Signals*. <http://arxiv.org/abs/2310.09277>

Russell, R. (2018). *Machine Learning: Step-by-Step Guide To Implement Machine Learning Algorithms with Python*.

Salmi, M., Atif, D., Oliva, D., Abraham, A., & Ventura, S. (2024). Handling imbalanced medical datasets: review of a decade of research. *Artificial Intelligence Review*, 57(10). <https://doi.org/10.1007/s10462-024-10884-2>

Saqib, K., Khan, A. F., & Butt, Z. A. (2021a). Machine learning methods for predicting postpartum depression: Scoping review. In *JMIR Mental Health* (Vol. 8, Issue 11). JMIR Publications Inc. <https://doi.org/10.2196/29838>

Saqib, K., Khan, A. F., & Butt, Z. A. (2021b). Machine learning methods for predicting postpartum depression: Scoping review. In *JMIR Mental Health* (Vol. 8, Issue 11). JMIR Publications Inc. <https://doi.org/10.2196/29838>

Shin, D., Lee, K. J., Adeluwa, T., & Hur, J. (2020a). Machine learning-based predictive modeling of postpartum depression. *Journal of Clinical Medicine*, 9(9), 1-14. <https://doi.org/10.3390/jcm9092899>

Shin, D., Lee, K. J., Adeluwa, T., & Hur, J. (2020b). Machine learning-based predictive modeling of postpartum depression. *Journal of Clinical Medicine*, 9(9), 1-14. <https://doi.org/10.3390/jcm9092899>

Shuffrey, L. C., Thomason, M. E., & Brito, N. H. (2022). Improving Perinatal Maternal Mental Health Starts with Addressing Structural Inequities. *JAMA Psychiatry*, 79(5), 387-388. <https://doi.org/10.1001/jamapsychiatry.2022.0097>

Valsecchi, C., Consonni, V., Todeschini, R., Orlandi, M. E., Gosetti, F., & Ballabio, D. (2021). Parsimonious optimization of multitask neural network hyperparameters. *Molecules*, 26(23). <https://doi.org/10.3390/molecules26237254>

Wakefield, C., & Frasch, M. G. (2023). Predicting Patients Requiring Treatment for Depression in the Postpartum Period Using Common Electronic Medical Record Data Available Antepartum. *AJPM Focus*, 2(3). <https://doi.org/10.1016/j.focus.2023.100100>

- Wang, W., Liao, C., Zhang, H., & Hu, Y. (2024). Postpartum Haemorrhage Risk Prediction Model Developed by Machine Learning Algorithms: A Single-Centre Retrospective Analysis of Clinical Data. *Clinical and Experimental Obstetrics and Gynecology*, 51(3). <https://doi.org/10.31083/j.ceog5103060>
- WHO. (2019). *Mental Health, Brain Health and Substance Use*.
- Xiao, M., Yan, C., Fu, B., Yang, S., Zhu, S., Yang, D., Lei, B., Huang, R., & Lei, J. (2020). Risk prediction for postpartum depression based on random forest. *Journal of Central South University (Medical Sciences)*, 45(10), 1215–1222. <https://doi.org/10.11817/j.issn.1672-7347.2020.190655>
- Xu, C., Wang, J., Zheng, T., Cao, Y., & Ye, F. (2022). Prediction of prognosis and survival of patients with gastric cancer by a weighted improved random forest model: an application of machine learning in medicine. *Archives of Medical Science*, 18(5), 1208–1220. <https://doi.org/10.5114/aoms/135594>
- Xu, Z., Shen, D., Nie, T., & Kou, Y. (2020). A hybrid sampling algorithm combining M-SMOTE and ENN based on Random forest for medical imbalanced data. *Journal of Biomedical Informatics*, 107. <https://doi.org/10.1016/j.jbi.2020.103465>
- Yates, D., & Islam, M. Z. (2021). FastForest: Increasing random forest processing speed while maintaining accuracy. *Information Sciences*, 557, 130–152. <https://doi.org/10.1016/j.ins.2020.12.067>
- Youn, J. H., & Jeong, I. S. (2013). Predictors of postpartum depression: Prospective cohort study. *Journal of Korean Academy of Nursing*, 43(2), 225–235. <https://doi.org/10.4040/jkan.2013.43.2.225>
- Zhang, Y., Wang, S., Hermann, A., Joly, R., & Pathak, J. (2021). Development and validation of a machine learning algorithm for predicting the risk of postpartum depression among pregnant women. *Journal of Affective Disorders*, 279, 1–8. <https://doi.org/10.1016/j.jad.2020.09.113>
- Żyrek, J., Klimek, M., Apanasewicz, A., Ciochoń, A., Danel, D. P., Marcinkowska, U. M., Mijas, M., Ziomkiewicz, A., & Galbarczyk, A. (2024). Social support during pregnancy and the risk of postpartum depression in Polish women: A prospective study. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-57477-1>