

# PERBANDINGAN ALGORITMA MACHINE LEARNING UNTUK PREDIKSI TINGKAT RISIKO IBU HAMIL

Jefri Jaya <sup>1)</sup>

<sup>1)</sup> Teknik Informatika Universitas Tarumanagara  
Jl. Letjen S. Parman No. 1, JakartaMerdeka 10, Jakarta 12020 Indonesia  
email : [jefri.535210048@stu.untar.ac.id](mailto:jefri.535210048@stu.untar.ac.id)

## ABSTRACT

Risiko yang dialami pada ibu hamil merupakan hal yang harus diperhatikan serius karena risiko tersebut dapat mempengaruhi kesehatan pada ibu dan janin bahkan dapat menyebabkan kematian. Oleh karena itu dilakukan perbandingan hasil evaluasi klasifikasi tingkat risiko pada ibu hamil dengan menggunakan algoritma XGB, SVM, DT dan menggunakan teknik resampling data RUS, ROS dan SMOTE untuk menentukan model dan teknik resampling yang baik. Hasil evaluasi rata - rata dari ketika sebelum dan sesudah menggunakan teknik resampling bahwa model XGB memiliki hasil accuracy 0.827, sedangkan pada model DT memiliki hasil accuracy 0.767, kemudian model SVM memiliki hasil accuracy 0.722. Sehingga dari perbandingan hasil evaluasi dapat disimpulkan bahwa model XGB memberikan hasil yang lebih baik dari model DT dan SVM. Sedangkan pada implementasi teknik resampling data ROS dan SMOTE memberikan hasil evaluasi yang baik untuk metode XGB kemudian SMOTE memberikan hasil yang baik untuk DT namun semua teknik resampling tidak memberikan hasil yang baik untuk model SVM.

## Key words

Algoritma, Machine learning, Risiko Ibu Hamil, Resampling

## 1. Pendahuluan

Proses kehamilan biasanya dialami pada setiap wanita yang sudah menikah tetapi terdapat juga wanita yang telah mengalami kehamilan diluar pernikahan bahkan masih dibawah umur. Pada tiap wanita baik yang sudah menjadi ibu maupun calon ibu biasanya memiliki risiko - risiko yang berbeda pada saat mengalami kehamilan [1]. Pada seorang ibu yang telah sampai melewati proses melahirkan tentu memiliki pemahaman selama proses mengandung sampai melahirkan berlangsung. Namun, bagi seorang calon ibu yang baru pertama kali mengalami kehamilan tentu tidak memiliki wawasan pemahaman yang mendalam sehingga ini akan berdampak pada calon ibu maupun janin yang berada dikandungan. Risiko pada setiap wanita yang sedang mengandung biasanya diawali karena tidak memiliki pengetahuan tentang bagaimana cara meminimalisir dari dampak risiko yang akan dihadapi [2]. Hal ini tentu terjadi dikarenakan dari

beberapa faktor seperti kurangnya ketidakingintahuan untuk mencari informasi, tidak ada edukasi dari tim kesehatan, infrakstruktur kesehatan yang kurang memadai, keuangan keluarga, tempat tinggal yang jauh dari rumah sakit dan masih banyak orang percaya terhadap pengaruh budaya yang bertentangan terhadap ilmu kesehatan[3].

Oleh karena itu pentingnya peran dari pemerintah untuk memerintahkan tim kesehatan agar dapat membantu untuk meningkatkan kesadaran pada masyarakat khususnya bagi yang sudah berkeluarga[4]. Sehingga untuk dapat mengidentifikasi tingkat risiko yang dialami pada setiap ibu yang sedang mengalami proses kehamilan diperlukan beberapa variabel pendukung kesehatan dari ibu hamil agar dari sekumpulan data tersebut dapat digunakan dalam melakukan prediksi klasifikasi tingkat risiko kesehatan pada ibu hamil lalu akan analisis dengan mengimplementasikan ilmu *machine learning*. Penelitian ini bertujuan untuk melakukan perbandingan hasil prediksi dari 3 algoritma *machine learning* yang akan digunakan adalah *Extreme Gradient Boosting* (XGB), *Support Vector Machine* (SVM), dan *Decision Tree* (DT) kemudian pada sekumpulan dataset akan digunakan teknik penyeimbang data, teknik yang akan digunakan adalah *Random Undersampling* (RUS), *Random Oversampling* (ROS), dan *Synthetic Minority Over-sampling Technique* (SMOTE).

## 2. Metode Penelitian

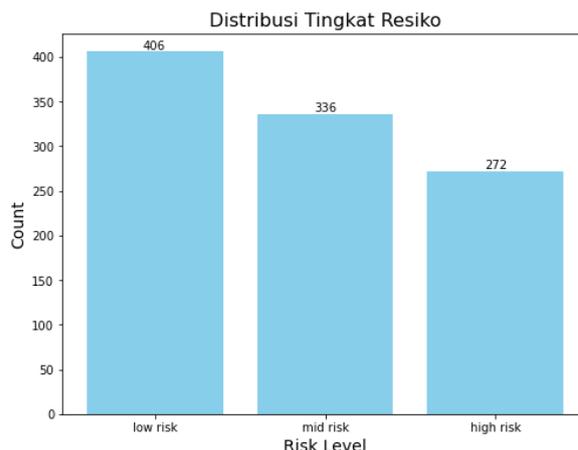
### 2.1 Data

Pada Penelitian ini berfokus pada perbandingan hasil prediksi tingkat risiko ibu hamil dengan menggunakan algoritma machine learning dari yang merupakan bagian dari metode supervised learning seperti Extreme Gradient Boosting (XGBoost), Support Vector Machine (SVM), dan Decision Tree (DT). Selain itu membandingkan hasil dengan teknik penyeimbang data menggunakan random undersampling (RUS), random oversampling (ROS) dan Synthetic Minority Oversampling Technique (SMOTE). Sekumpulan data yang digunakan diperoleh dari link (<https://archive.ics.uci.edu/dataset/863/maternal+he>

[alth+risk](#)). Sekumpulan data yang digunakan pada penelitian ini terdiri dari 1013 data pasien dan atribut.

Tabel 1. Deskripsi Atribut

| No | Atribut     | Dekripsi               | Tipe   |
|----|-------------|------------------------|--------|
| 1  | Age         | Usia pada wanita hamil | Int    |
| 2  | SystolicBP  | Tekanan darah tinggi   | Int    |
| 3  | DiastolicBP | Tekanan darah rendah   | Int    |
| 4  | BS          | Kadar glukosa          | Float  |
| 5  | BodyTemp    | Suhu tubuh             | Float  |
| 6  | HeartRate   | Denyut jantung         | Int    |
| 7  | RiskLevel   | Tingkat risiko         | Object |



Gambar 2. Jumlah Kelas Risk

## 2.2 Pra-Premprosesan

Pada sekumpulan data yang telah dilakukan proses pembersihan data dan pengecekan nilai data yang hilang, tidak ada perubahan yang signifikan dikarenakan data sudah sesuai dengan standar yang diharapkan. Sekumpulan data yang telah dikumpulkan untuk penelitian ini dilakukan proses pembagian dengan komposisi data latih 80% dan data uji 20% kemudian akan dilakukan pada *random state* 10, 20 dan 30 pada setiap menggunakan data asli dan data yang telah diseimbangkan dengan teknik RUS, ROS dan SMOTE dengan ini diharapkan untuk dapat melakukan perbandingan hasil dari setiap metode *machine learning* dan teknik penyeimbang data yang digunakan pada penelitian ini.

|      | Age | SystolicBP | DiastolicBP | BS   | BodyTemp | HeartRate | RiskLevel |
|------|-----|------------|-------------|------|----------|-----------|-----------|
| 0    | 25  | 130        | 80          | 15.0 | 98.0     | 86        | high risk |
| 1    | 35  | 140        | 90          | 13.0 | 98.0     | 70        | high risk |
| 2    | 29  | 90         | 70          | 8.0  | 100.0    | 80        | high risk |
| 3    | 30  | 140        | 85          | 7.0  | 98.0     | 70        | high risk |
| 4    | 35  | 120        | 60          | 6.1  | 98.0     | 76        | low risk  |
| ...  | ... | ...        | ...         | ...  | ...      | ...       | ...       |
| 1009 | 22  | 120        | 60          | 15.0 | 98.0     | 80        | high risk |
| 1010 | 55  | 120        | 90          | 18.0 | 98.0     | 60        | high risk |
| 1011 | 35  | 85         | 60          | 19.0 | 98.0     | 86        | high risk |
| 1012 | 43  | 120        | 90          | 18.0 | 98.0     | 70        | high risk |
| 1013 | 32  | 120        | 65          | 6.0  | 101.0    | 76        | mid risk  |

Gambar 1 Sekumpulan Data

Sebelum melakukan pembagian data dan penyeimbangan data, terdapat pasien yang menderita tergolong *low risk* sebanyak 406 pasien, pasien yang menderita tergolong *mid risk* terdapat sebanyak 336 pasien, sedangkan pada penderita tergolong *high risk* terdapat 272 pasien. Berdasarkan jumlah data ini terdapat data yang tidak seimbang, sehingga pada penelitian ini diperlukan penggunaan teknik penyeimbangan data agar dapat mengetahui model mana yang lebih unggul dan apakah dapat mempengaruhi hasil pada setiap model *machine learning*.

Setelah dilakukan proses pembagian data menggunakan komposisi data latih 80% dan data uji 20%, sehingga data latih memiliki 811 data dan data uji memiliki 202 data. Pada data latih dilakukan teknik penyeimbangan data. Hasil pada komposisi 80:20.

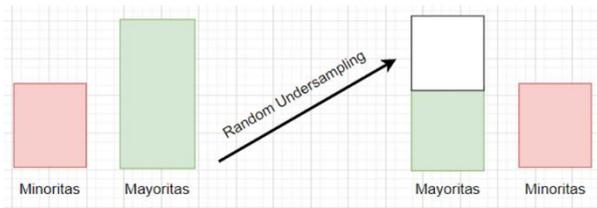
Tabel 3. Hasil pada komposisi 80:20

| Keterangan               | Low Risk | Mid Risk | High Risk |
|--------------------------|----------|----------|-----------|
| Tanpa Penyeimbangan Data | 319      | 278      | 214       |
| Dataset + RUS            | 214      | 214      | 214       |
| Dataset + ROS            | 319      | 319      | 319       |
| Dataset + SMOTE          | 319      | 319      | 319       |

## 2.3 Random Undersampling (RUS)

*Random Undersampling* (RUS) merupakan teknik *resampling* data digunakan untuk mengatasi permasalahan ketidakseimbangan pada sekumpulan data. Teknik ini bekerja secara acak untuk dapat menghapus beberapa instance dari kelas mayoritas menyesuaikan dengan jumlah sample instance dari kelas minoritas, sehingga model dapat dilatih secara seimbang[5].

Teknik *Resampling* RUS memiliki kelemahan yaitu menyebabkan banyak hilangnya instance dari kelas mayoritas dan suatu potensi informasi yang dapat menyebabkan hasil kinerja pada model menjadi rendah [6]. Pada teknik ini cocok untuk jenis sekumpulan data yang kurang seimbang, namun tidak direkomendasikan pada penggunaan sekumpulan data yang sangat tidak seimbang [7].

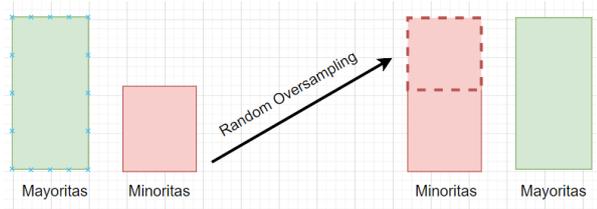


Gambar 3. Skema RUS

### 2.4 Random Oversampling (ROS)

Random Oversampling (ROS) merupakan teknik upsampling untuk menangani kumpulan data yang tidak seimbang. Untuk mengatasi data tidak seimbang dengan teknik upsampling yaitu dengan cara melakukan replikasi instance pada kelas minoritas secara acak agar memiliki jumlah sample instance yang sama dengan kelas mayoritas [8].

Dalam penggunaan teknik ROS ini mungkin tidak membuat informasi menjadi hilang tetapi pada penggunaan teknik ini dapat menimbulkan suatu kerugian karena terjadinya overfitting sebagai pengenalan biaya komputasi tambahan jika rasio ketidakseimbangan tinggi. ROS lebih efisien dengan menggunakan sekumpulan data yang sangat tidak seimbang [9].

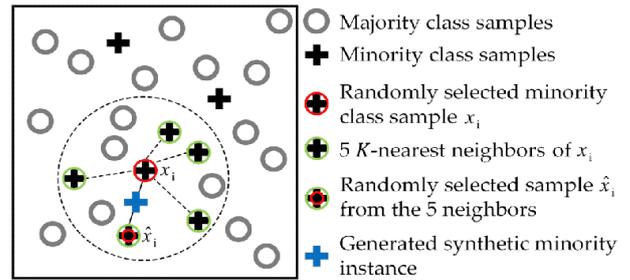


Gambar 4. Skema ROS

### 2.5 Synthetic Minority Oversampling Technique (SMOTE)

Syentthetic Minority Oversampling Technique (SMOTE) merupakan bagian dari teknik oversampling yang bertujuan untuk menangani sekumpulan pada data penelitian yang tidak seimbang [10].

Pendekatan pada teknik ini dengan cara melakukan meningkatkan kelas minoritas untuk menghasilkan instance baru berdasarkan pada jumlah K tetangga terdekatnya dan pilih titik random padaruas garis antara kejadian terdekatnya [11]. Teknik penyeimbang data ini memiliki tingkat klasifikasi yang tinggi dibandingkan oversampling dan undersampling [12].



Gambar 5. Smote (Sumber: Rich Data)

### 2.6 Algoritma Klasifikasi

Algoritma klasifikasi adalah bagian dari ilmu data mining dan machine learning berfokus untuk menentukan suatu kategori dari sekumpulan data untuk dapat memprediksi dan menganalisis model yang lebih baik [13]. Di dalam penelitian ini menggunakan algoritma Extreme Gradient Boosting (XGBoost), Support Vector Machine (SVM), dan Decision Tree (DT) bertujuan untuk melakukan perbandingan hasil analisis dari sekumpulan data.

### 2.7 Extreme Gradient Boosting (XGB)

Extreme Gradient Boosting (XGB) merupakan algoritma dari machine learning yang bertujuan untuk dapat menemukan solusi yang optimal [14].

Selain itu, metode ini memiliki nilai cukup baik dalam implementasi penggunaan pada pengklasifikasi dan regresi, selain itu mampu menghindari overfitting secara efektif [15]. Algoritma XGB dapat menghasilkan optimasi lebih baik dari algoritma Gradient Boosting Machine (GBM) lainya. Tetapi mendapatkan hasil accuracy yang baik, klasifikasi tergantung pada penggunaan parameter di setiap eksperimen [16].

Rumus menghitung fungsi loss:

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (1)$$

Keterangan:

- L(t): Total fungsi loss
- y<sub>i</sub>: Nilai sebenarnya observasi
- y<sup>^</sup><sub>i</sub>: Prediksi model
- x<sub>i</sub>: input dari observasi
- f<sub>t</sub>: Output dari model
- Ω(f<sub>t</sub>): fungsi regulasi

Rumus menghitung gain:

$$L_{split} = \frac{1}{2} \left[ \frac{(\sum_{i \in L} g_i)^2}{\sum_{i \in L} h_i + \lambda} + \frac{(\sum_{i \in R} g_i)^2}{\sum_{i \in R} h_i + \lambda} + \frac{(\sum_{i \in L} g_i)^2}{\sum_{i \in L} h_i + \lambda} \right] - y \quad (2)$$

$L_{split}$ : Nilai keuntungan gain  
 $g_i$ : Turunan pertama dari fungsi loss  
 $h_i$ : Turunan kedua dari fungsi loss  
 $IL$ : Indeks data yang masuk ke cabang kiri  
 $IR$ : Indeks data yang masuk ke cabang kanan  
 $\lambda$ : Parameter regulasi  
 $\gamma$ : Parameter penalti

### 2.8 Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah metode supervised learning, metode ini memiliki 4 kernel terdiri dari linear, rbf, polynomial dan sigmoid, biasanya metode ini implementasikan untuk klasifikasi dan regresi [17].

Dengan menggunakan metode SVM, SVM mampu untuk mengatasi suatu masalah baik linear maupun non-linear [18]. Pada penelitian ini kernel yang digunakan pada metode SVM adalah kernel RBF.

Rumus kernel RBF:

$$K(x, x') = e^{-\gamma \|x-x'\|^2} \quad (3)$$

Keterangan:

K: Kernel RBF  
 $x$ : Vektor fitur sampel pertama  
 $x'$ : Vektor fitur sampel kedua  
 $\gamma$ : parameter skala  
 $e$ : Bilangan Eksponensial

### 2.9 Decision Tree (DT)

Decision Tree (DT) adalah salah satu model dari supervised learning yang cukup populer dan mudah untuk diimplementasikan serta divisualisasikan [19]. Selain itu model DT biasa digunakan untuk masalah klasifikasi dan membentuk struktur yang dapat membagi data besar menjadi data kecil [20].

Rumus menghitung persamaan nilai gain:

$$Gain(S, A) = E(s) - \sum_{i=1}^n \frac{|S_i|}{|S|} * E(S_i) \quad (4)$$

Keterangan:

A: Properti  
 $N$ : Total Jumlah  
 $S$ : Sekumpulan Kasus  
 $|S_i|$ : Jumlah kasus pada partisi ke- $i$   
 $|S|$ : Jumlah kasus dalam  $S$

Rumus menghitung persamaan nilai entropy:

$$E(s) = \sum_{i=1}^n -p_i * \log_2 p_i \quad (5)$$

Keterangan:

$S$ : Sekumpulan Kasus  
 $A$ : Properti  
 $N$ : Total Jumlah  
 $P_i$ : Rasio dari  $S_i$  terhadap  $S$

### 2.2 Skema Eksperimen

Pada penelitian ini memiliki skema eksperimen yang bertujuan melibatkan suatu pendekatan agar dapat membangun setiap model dari machine learning untuk memprediksi tingkat risiko kesehatan pada ibu hamil. Skema eksperimen dapat dilihat pada Gambar 5. Langkah awal memasukkan dataset yang telah dibersihkan serta dilakukan proses pembagian komposisi dan kemudian dilakukan penerapan teknik resampling pada dataset sehingga dapat diimplementasikan kedalam setiap model



Gambar 6. Skema Eksperimen

## 3. Hasil Percobaan

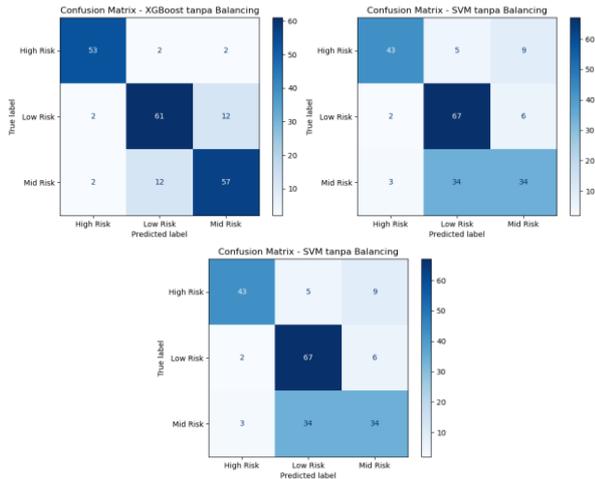
### 3.1 Tanpa Teknik Penyeimbang Data

Pada sekumpulan data yang digunakan untuk penelitian ini melakukan percobaan dengan pembagian komposisi sekumpulan data 80% data latih dan 20% data uji dengan melakukan 12 kali percobaan setiap model sebelum dan sesudah menggunakan teknik resampling. Dari model XGB, SVM, dan DT akan dilatih dengan komposisi data tersebut dan menghasilkan nilai accuracy, precision, recall dan f1-score. Sehingga dari setiap model memiliki hasil nilai yang baik.

Pada eksperimen 1 menggunakan data yang tidak seimbang dengan *random state* = 10, hasil evaluasi model XGB memiliki *accuracy* 0.84 kemudian diikuti model DT dengan memiliki *accuracy* 0.78, kemudian diikuti model SVM dengan memiliki *accuracy* 0.71.

Tabel 4. Hasil Evaluasi Percobaan 1

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.85      | 0.85   | 0.85     | 0.84     |
| SVM   | 0.74      | 0.71   | 0.71     | 0.71     |
| DT    | 0.81      | 0.78   | 0.78     | 0.78     |

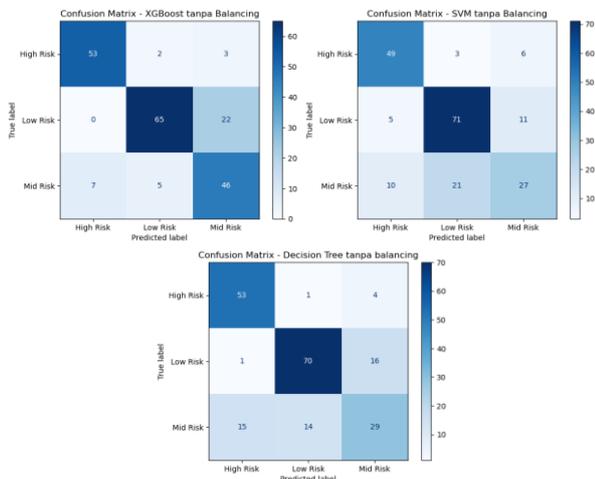


Gambar 7. Confusion Matrix Percobaan 1

Pada eksperimen 2 menggunakan data yang tidak seimbang dengan *random state* = 20, hasil evaluasi model XGB memiliki *accuracy* 0.81 kemudian diikuti model DT dengan memiliki *accuracy* 0.72, kemudian diikuti model SVM dengan memiliki *accuracy* 0.75.

Tabel 5. Hasil Evaluasi Percobaan 2

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.81      | 0.82   | 0.81     | 0.81     |
| SVM   | 0.71      | 0.71   | 0.70     | 0.72     |
| DT    | 0.73      | 0.74   | 0.73     | 0.75     |

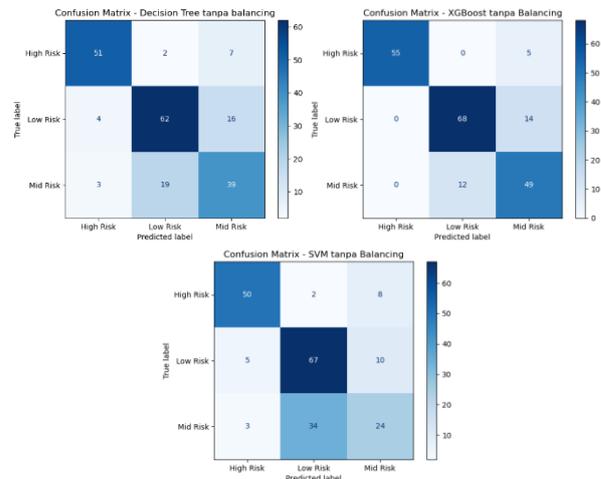


Gambar 8. Confusion Matrix Percobaan 2

Pada eksperimen 3 menggunakan data yang tidak seimbang dengan *random state* = 30, hasil evaluasi model XGB memiliki *accuracy* 0.85 kemudian diikuti model DT dengan memiliki *accuracy* 0.75, kemudian diikuti model SVM dengan memiliki *accuracy* 0.69.

Tabel 6. Hasil Evaluasi Percobaan 3

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.86      | 0.85   | 0.85     | 0.85     |
| SVM   | 0.69      | 0.68   | 0.68     | 0.69     |
| DT    | 0.75      | 0.75   | 0.75     | 0.75     |



Gambar 9. Confusion Matrix Percobaan 3

Berdasarkan hasil jumlah rata – rata evaluasi dari setiap percobaan menggunakan data asli, di posisi 1 model XGB memiliki hasil *accuracy* 0.83, setelah itu diposisi 2 ditempati model DT dengan memiliki *accuracy* 0.76 dan diposisi 3 ditempati model SVM dengan memiliki *accuracy* 0.70. Sehingga saat menggunakan data asli model XGB merupakan model yang paling unggul dibandingkan model DT dan SVM.

Tabel 7. Hasil Rata – Rata Evaluasi Data Asli

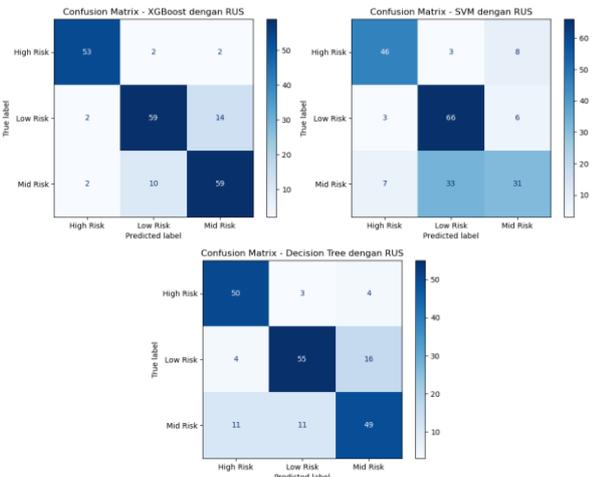
| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.84      | 0.84   | 0.8367   | 0.83     |
| SVM   | 0.71      | 0.70   | 0.69     | 0.70     |
| DT    | 0.76      | 0.75   | 0.75     | 0.76     |

### 3.2 Menggunakan *Random Undersampling* (RUS)

Pada eksperimen 4 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random undersampling* dengan *random state* = 10, hasil evaluasi model XGB memiliki *accuracy* 0.84 kemudian diikuti model DT dengan memiliki *accuracy* 0.76, kemudian diikuti model SVM dengan memiliki *accuracy* 0.70.

Tabel 8. Hasil Evaluasi Percobaan 4

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.85      | 0.85   | 0.85     | 0.84     |
| SVM   | 0.72      | 0.71   | 0.70     | 0.70     |
| DT    | 0.76      | 0.77   | 0.76     | 0.76     |

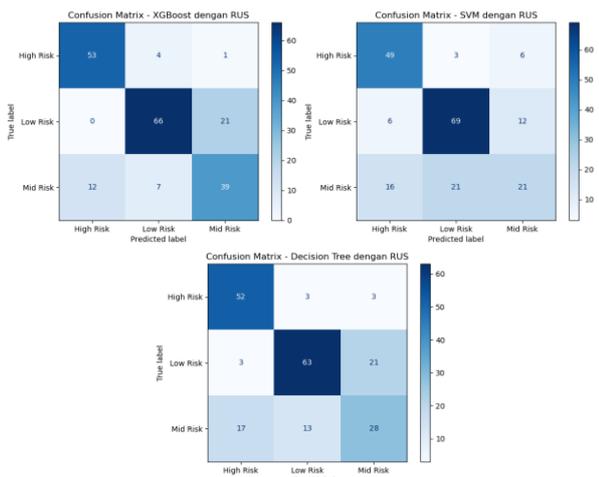


Gambar 10. Confusion Matrix Percobaan 4

Pada eksperimen 5 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random undersampling* dengan *random state* = 20, hasil evaluasi model XGB memiliki *accuracy* 0.78 kemudian diikuti model DT dengan memiliki *accuracy* 0.70, kemudian diikuti model SVM dengan memiliki *accuracy* 0.68.

Tabel 9. Hasil Evaluasi Percobaan 5

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.77      | 0.78   | 0.77     | 0.78     |
| SVM   | 0.66      | 0.67   | 0.65     | 0.68     |
| DT    | 0.69      | 0.70   | 0.69     | 0.70     |



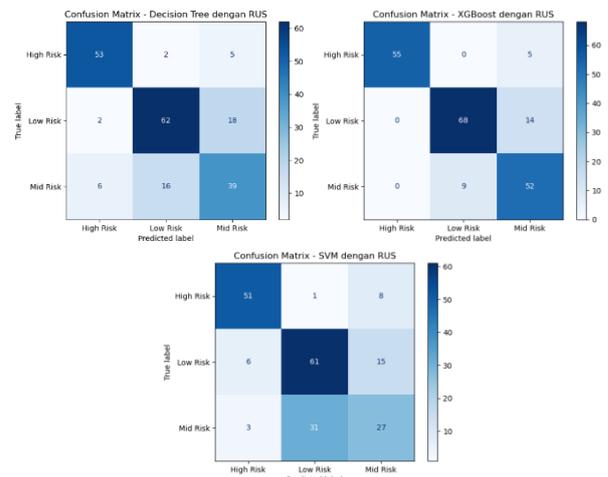
Gambar 11. Confusion Matrix Percobaan 5

Pada eksperimen 6 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random undersampling* dengan *random state* = 30, hasil evaluasi

model XGB memiliki *accuracy* 0.86 kemudian diikuti model DT dengan memiliki *accuracy* 0.76, kemudian diikuti model SVM dengan memiliki *accuracy* 0.68.

Tabel 10. Hasil Evaluasi Percobaan 6

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.87      | 0.87   | 0.87     | 0.86     |
| SVM   | 0.68      | 0.68   | 0.68     | 0.68     |
| DT    | 0.76      | 0.76   | 0.76     | 0.76     |



Gambar 12. Confusion Matrix Percobaan 6

Berdasarkan hasil jumlah rata – rata evaluasi dari setiap percobaan menggunakan data yang sudah di *resampling* menggunakan *random undersampling*, di posisi 1 model XGB memiliki hasil *accuracy* 0.82, setelah itu diposisi 2 ditempati model DT dengan memiliki *accuracy* 0.74, dan diposisi 3 ditempati model SVM dengan memiliki *accuracy* 0.68. Sehingga saat menggunakan teknik *random undersampling* model XGB merupakan model yang paling unggul dibandingkan model DT dan SVM.

Tabel 11. Hasil Rata – Rata Evaluasi Rus

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.83      | 0.83   | 0.83     | 0.82     |
| SVM   | 0.68      | 0.68   | 0.67     | 0.68     |
| DT    | 0.73      | 0.74   | 0.73     | 0.74     |

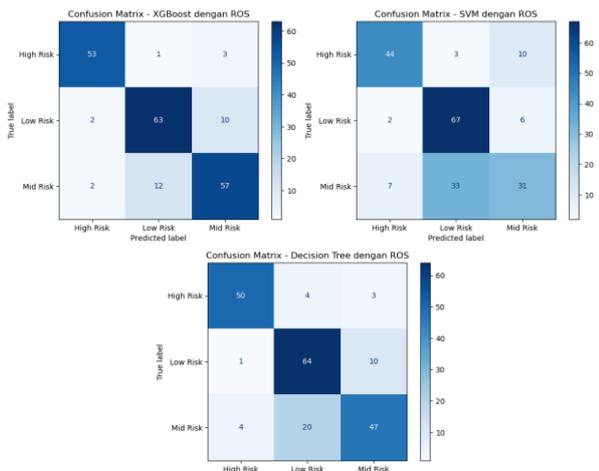
### 3.3 Menggunakan *Random Oversampling* (ROS)

Pada eksperimen 7 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random oversampling* dengan *random state* = 10, hasil evaluasi model XGB memiliki *accuracy* 0.85 kemudian diikuti model DT dengan memiliki *accuracy* 0.79, kemudian diikuti model SVM dengan memiliki *accuracy* 0.70.

Tabel 12. Hasil Evaluasi Percobaan 7

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.86      | 0.86   | 0.86     | 0.85     |
| SVM   | 0.71      | 0.70   | 0.69     | 0.70     |

|    |      |      |      |      |
|----|------|------|------|------|
| DT | 0.81 | 0.80 | 0.80 | 0.79 |
|----|------|------|------|------|

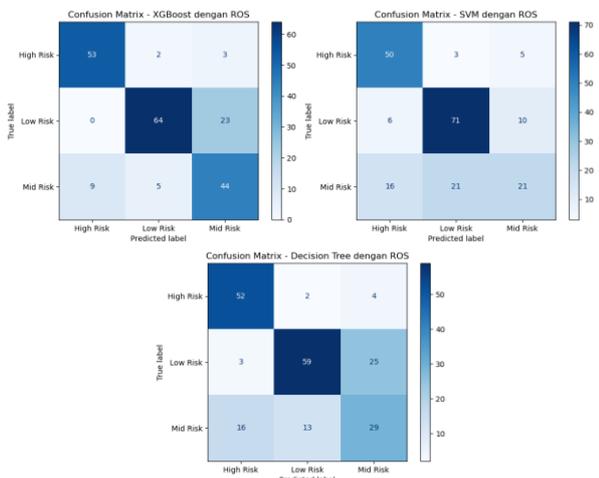


Gambar 13. Confusion Matrix Percobaan 7

Pada eksperimen 8 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random oversampling* dengan *random state* = 20, hasil evaluasi model XGB memiliki *accuracy* 0.79 kemudian diikuti model SVM dengan memiliki *accuracy* 0.70, kemudian diikuti model DT dengan memiliki *accuracy* 0.69.

Tabel 13. Hasil Evaluasi Percobaan 8

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.79      | 0.80   | 0.79     | 0.79     |
| SVM   | 0.68      | 0.68   | 0.67     | 0.70     |
| DT    | 0.68      | 0.69   | 0.68     | 0.69     |



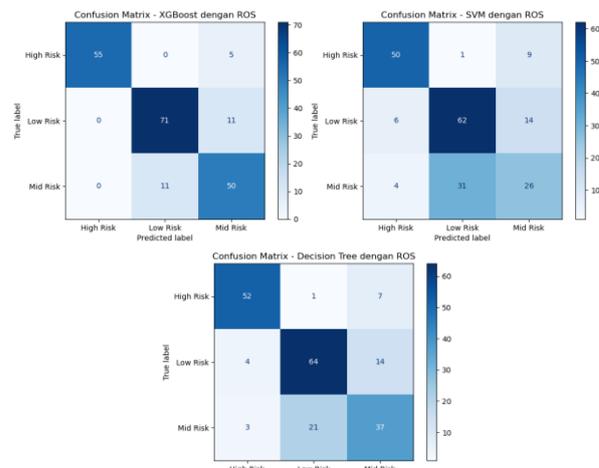
Gambar 14. Confusion Matrix Percobaan 8

Pada eksperimen 9 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *random oversampling* dengan *random state* = 30, hasil evaluasi model XGB memiliki *accuracy* 0.87 kemudian diikuti model DT dengan memiliki *accuracy* 0.75, kemudian diikuti model SVM dengan memiliki *accuracy* 0.68.

Tabel 14. Hasil Evaluasi Percobaan 9

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.87      | 0.87   | 0.87     | 0.87     |
| SVM   | 0.67      | 0.67   | 0.67     | 0.68     |
| DT    | 0.75      | 0.75   | 0.75     | 0.75     |

|     |      |      |      |      |
|-----|------|------|------|------|
| XGB | 0.87 | 0.87 | 0.87 | 0.87 |
| SVM | 0.67 | 0.67 | 0.67 | 0.68 |
| DT  | 0.75 | 0.75 | 0.75 | 0.75 |



Gambar 15. Confusion Matrix Percobaan 9

Berdasarkan hasil jumlah rata – rata evaluasi dari setiap percobaan menggunakan data yang sudah di *resampling* menggunakan *random oversampling*, di posisi 1 model XGB memiliki hasil *accuracy* 0.83, setelah itu diposisi 2 ditempati model DT dengan memiliki *accuracy* 0.74, dan diposisi 3 ditempati model SVM dengan memiliki *accuracy* 0.69. Sehingga saat menggunakan teknik *random oversampling* model XGB merupakan model yang paling unggul dibandingkan model DT dan SVM.

Tabel 15. Hasil Rata – Rata Evaluasi Ros

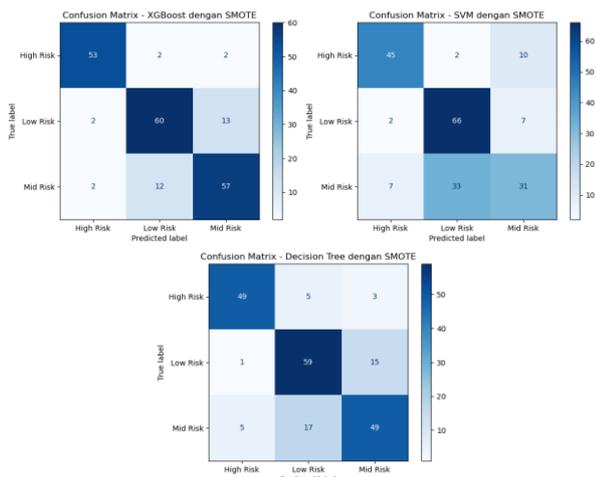
| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.84      | 0.84   | 0.84     | 0.83     |
| SVM   | 0.68      | 0.68   | 0.67     | 0.69     |
| DT    | 0.74      | 0.74   | 0.74     | 0.74     |

### 3.3 Menggunakan *Synthetic Minority Oversampling Technique* (SMOTE)

Pada eksperimen 10 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *synthetic minority oversampling technique* dengan *random state* = 10, hasil evaluasi model XGB memiliki *accuracy* 0.84 kemudian diikuti model DT dengan memiliki *accuracy* 0.77, kemudian diikuti model SVM dengan memiliki *accuracy* 0.70.

Tabel 16. Hasil Evaluasi Percobaan 10

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.84      | 0.84   | 0.84     | 0.84     |
| SVM   | 0.71      | 0.70   | 0.69     | 0.70     |
| DT    | 0.78      | 0.78   | 0.78     | 0.77     |

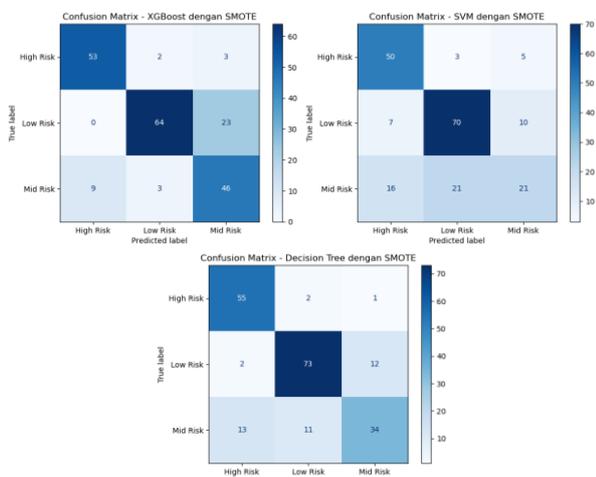


Gambar 16. Confusion Matrix Percobaan 10

Pada percobaan 11 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *synthetic minority oversampling technique* dengan *random state = 20*, hasil evaluasi model XGB memiliki *accuracy* 0.80 kemudian diikuti model DT dengan memiliki *accuracy* 0.80, kemudian diikuti model SVM dengan memiliki *accuracy* 0.69.

Tabel 14. Hasil Evaluasi Percobaan 11

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.81      | 0.81   | 0.80     | 0.80     |
| SVM   | 0.67      | 0.68   | 0.66     | 0.69     |
| DT    | 0.79      | 0.79   | 0.78     | 0.80     |



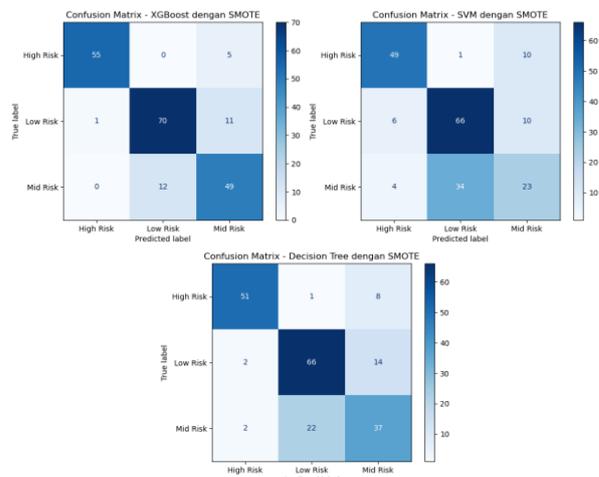
Gambar 17. Confusion Matrix Percobaan 11

Pada percobaan 12 menggunakan data yang sudah di seimbangkan dengan menggunakan teknik *Synthetic Minority Oversampling Technique* dengan *random state = 30*, hasil evaluasi model XGB memiliki *accuracy* 0.86 kemudian diikuti model DT dengan memiliki *accuracy* 0.76, kemudian diikuti model SVM dengan memiliki *accuracy* 0.68.

Tabel 17. Hasil Evaluasi Percobaan 12

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.86      | 0.86   | 0.86     | 0.86     |
| SVM   | 0.67      | 0.67   | 0.66     | 0.68     |
| DT    | 0.77      | 0.75   | 0.76     | 0.76     |

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.86      | 0.86   | 0.86     | 0.86     |
| SVM   | 0.67      | 0.67   | 0.66     | 0.68     |
| DT    | 0.77      | 0.75   | 0.76     | 0.76     |



Gambar 18. Confusion Matrix Percobaan 12

Berdasarkan hasil jumlah rata – rata evaluasi dari setiap percobaan menggunakan data yang sudah di *resampling* menggunakan *synthetic minority oversampling technique*, di posisi 1 model XGB memiliki hasil *accuracy* 0.83, setelah itu diposisi 2 ditempati model DT dengan memiliki *accuracy* 0.77, dan diposisi 3 ditempati model SVM dengan memiliki *accuracy* 0.69. Sehingga saat menggunakan teknik *synthetic minority oversampling technique* model XGB merupakan model yang paling unggul dibandingkan model DT dan SVM.

Tabel 18. Hasil Rata – Rata Evaluasi Smote

| model | precision | recall | f1-score | accuracy |
|-------|-----------|--------|----------|----------|
| XGB   | 0.83      | 0.83   | 0.83     | 0.83     |
| SVM   | 0.68      | 0.68   | 0.67     | 0.69     |
| DT    | 0.78      | 0.77   | 0.77     | 0.77     |

### 3.3 Hasil Evaluasi Akhir

Hasil rata – rata evaluasi model XGB pada sebelum dan sesudah menggunakan teknik *resampling* memberikan hasil evaluasi *accuracy* 0.827.

Tabel 19. Hasil Evaluasi Akhir XGB

| percobaan   | precision | recall | f1-score | accuracy |
|-------------|-----------|--------|----------|----------|
| Data Asli   | 0.84      | 0.84   | 0.8367   | 0.83     |
| RUS         | 0.83      | 0.83   | 0.83     | 0.82     |
| ROS         | 0.84      | 0.84   | 0.84     | 0.83     |
| SMOTE       | 0.83      | 0.83   | 0.83     | 0.83     |
| Rata - rata |           |        |          | 0.827    |

Kemudian, hasil rata – rata evaluasi model SVM ketika sebelum dan sesudah menggunakan teknik *resampling* memberikan hasil evaluasi *accuracy* 0.722.

Tabel 20. Hasil Evaluasi Akhir SVM

| percobaan   | precision | recall | f1-score | accuracy |
|-------------|-----------|--------|----------|----------|
| Data Asli   | 0.84      | 0.84   | 0.8367   | 0.83     |
| RUS         | 0.68      | 0.68   | 0.67     | 0.68     |
| ROS         | 0.68      | 0.68   | 0.67     | 0.69     |
| SMOTE       | 0.68      | 0.68   | 0.67     | 0.69     |
| Rata - rata |           |        |          | 0.722    |

Kemudian, hasil rata – rata evaluasi model DT pada sebelum dan sesudah menggunakan teknik *resampling* memberikan hasil evaluasi *accuracy* 0.767.

Tabel 21. Hasil Evaluasi Akhir DT

| percobaan   | precision | recall | f1-score | accuracy |
|-------------|-----------|--------|----------|----------|
| Data Asli   | 0.76      | 0.75   | 0.75     | 0.76     |
| RUS         | 0.73      | 0.74   | 0.73     | 0.74     |
| ROS         | 0.74      | 0.74   | 0.74     | 0.74     |
| SMOTE       | 0.83      | 0.83   | 0.83     | 0.83     |
| Rata - rata |           |        |          | 0.767    |

#### 4. Kesimpulan

Dari berbagai percobaan yang telah dilakukan terhadap setiap model XGB, SVM, DT dan setiap data yang telah dilakukan *resampling* dengan menggunakan RUS, ROS, SMOTE, berdasarkan hasil rata – rata dari setiap percobaan yang telah dilakukan model XGB mengalami hasil evaluasi yang stabil di *accuracy* 0.83 tetapi mengalami penurunan saat menggunakan *resampling* RUS dengan *accuracy* 0.82, pada model DT mengalami penurunan dari data asli ketika data di *resampling* dengan RUS dan ROS, tetapi mengalami peningkatan pada penggunaan SMOTE dengan *accuracy* 0.83, pada model SVM cenderung mengalami penurunan *accuracy* ketika menggunakan data yang telah di *resampling* dari data asli. Sehingga dari banyaknya percobaan yang telah dilakukan dapat disimpulkan bahwa teknik *resampling* data memberikan hasil evaluasi yang cukup baik untuk model XGB dan SMOTE, tetapi pada model SVM saat menggunakan teknik *resampling* memberikan hasil yang lebih buruk dari menggunakan data asli.

#### REFERENSI

[1] Ghimire N and Pandey N, “Knowledge and Practice of Mothers Regarding the Prevention of Anemia,” *J. Chitwan Med. Coll.*, vol. 3, no. 5, pp. 14–17, 2013.

[2] W. Gezimu, F. Bekele, and G. Habte, “Pregnant mothers’ knowledge, attitude, practice and its predictors towards nutrition in public hospitals of

Southern Ethiopia: A multicenter cross-sectional study,” *SAGE Open Med.*, vol. 10, 2022, doi: 10.1177/20503121221085843.

[3] R. D. Wulandari and A. D. Laksono, “Determinants of knowledge of pregnancy danger signs in Indonesia,” *PLoS One*, vol. 15, no. 5, pp. 1–11, 2020, doi: 10.1371/journal.pone.0232550.

[4] L. Darwati, V. Fatmawati, and I. Susila, “Pemberdayaan Deteksi Dini Risiko Tinggi pada Ibu Hamil di Desa Doyomulyo Kec. Kembangbahu Lamongan,” *J. Community Engagem. Heal.*, vol. 5, no. 2, pp. 186–190, 2022, doi: 10.30994/jceh.v5i2.410.

[5] F. Alahmari, “A Comparison of *Resampling* Techniques for Medical Data Using Machine Learning,” *J. Inf. Knowl. Manag.*, vol. 19, no. 1, pp. 1–13, 2020, doi: 10.1142/S021964922040016X.

[6] G. Gumelar, Q. Ain, R. Marsuciati, S. Agustanti Bambang, A. Sunyoto, and M. Syukri Mustafa, “Kombinasi Algoritma Sampling dengan Algoritma Klasifikasi untuk Meningkatkan Performa Klasifikasi Dataset Imbalance,” *SISFOTEK Sist. Inf. dan Teknol.*, pp. 250–255, 2021.

[7] M. S. Kraiem, F. Sánchez-Hernández, and M. N. Moreno-García, “Selecting the suitable *resampling* strategy for imbalanced data classification regarding dataset properties. An approach based on association models,” *Appl. Sci.*, vol. 11, no. 18, 2021, doi: 10.3390/app11188546.

[8] L. K. Xin and N. binti A. Rashid, “Prediction of depression among women using random oversampling and random forest,” *2021 Int. Conf. Women Data Sci. Taif Univ. WiDSTaif 2021*, 2021, doi: 10.1109/WIDSTAIF52235.2021.9430215.

[9] X. Zheng, S. Hasegawa, W. Gu, and K. Ota, “Addressing Class Imbalances in Video Time-Series Data for Estimation of Learner Engagement: ‘Over Sampling with Skipped Moving Average,’” *Educ. Sci.*, vol. 14, no. 6, 2024, doi: 10.3390/educsci14060556.

[10] R. Ridwan, E. H. Hermaliani, and M. Ernawati, “Penerapan: Penerapan Metode SMOTE Untuk Mengatasi Imbalanced Data Pada Klasifikasi Ujaran Kebencian,” *Comput. Sci.*, vol. 4, no. 1, pp. 80–88, 2024, [Online]. Available: <https://jurnal.bsi.ac.id/index.php/co-science/article/view/2990>

[11] R. Ubaidillah, M. Muliadi, D. T. Nugrahadi, M. R. Faisal, and R. Herteno, “Implementasi XGBoost Pada Keseimbangan Liver Patient Dataset dengan SMOTE dan Hyperparameter Tuning Bayesian Search,” *J. Media Inform. Budidarma*, vol. 6, no. 3, p. 1723, 2022, doi: 10.30865/mib.v6i3.4146.

[12] M. A. Khadija and N. A. Setiawan, “Detecting Liver Disease Diagnosis by Combining SMOTE, Information Gain Attribute Evaluation and Ranker,” *ITSMART J. Teknol. dan Inf.*, vol. 9, no. 1, pp. 13–17, 2020.

[13] W. Apriliah, I. Kurniawan, M. Baydhowi, and T. Haryati, “Prediksi Kemungkinan Diabetes pada Tahap Awal Menggunakan Algoritma Klasifikasi Random Forest,” *Sistemasi*, vol. 10, no. 1, p. 163, 2021, doi: 10.32520/stmsi.v10i1.1129.

[14] T. R. Mahesh, V. Vinoth Kumar, V. Muthukumar, H. K. Shashikala, B. Swapna, and S. Guluwadi, “Performance Analysis of XGBoost Ensemble Methods for Survivability with the Classification of Breast Cancer,” *J. Sensors*, vol. 2022, 2022, doi:

- 10.1155/2022/4649510.
- [15] S. Li and X. Zhang, "Research on orthopedic auxiliary classification and prediction model based on XGBoost algorithm," *Neural Comput. Appl.*, vol. 32, no. 7, pp. 1971–1979, 2020, doi: 10.1007/s00521-019-04378-4.
- [16] P. Liu, B. Fu, S. X. Yang, L. Deng, X. Zhong, and H. Zheng, "Optimizing Survival Analysis of XGBoost for Ties to Predict Disease Progression of Breast Cancer," *IEEE Trans. Biomed. Eng.*, vol. 68, no. 1, pp. 148–160, 2021, doi: 10.1109/TBME.2020.2993278.
- [17] P. Fremmuzar and A. Baita, "Uji Kernel SVM dalam Analisis Sentimen Terhadap Layanan Telkomsel di Media Sosial Twitter," *Komputika J. Sist. Komput.*, vol. 12, no. 2, pp. 57–66, 2023, doi: 10.34010/komputika.v12i2.9460.
- [18] K. Karthick, S. K. Aruna, R. Samikannu, R. Kuppasamy, Y. Teekaraman, and A. R. Thelkar, "Implementation of a Heart Disease Risk Prediction Model Using Machine Learning," *Comput. Math. Methods Med.*, vol. 2022, 2022, doi: 10.1155/2022/6517716.
- [19] N. Nurahman and S.- Aminah, "Klasifikasi Penerima Bantuan Sosial Di Desa Batuah Menggunakan Metode Algoritma C4.5," *J. Tek. Inf. dan Komput.*, vol. 5, no. 2, p. 271, 2022, doi: 10.37600/tekinkom.v5i2.516.
- [20] T. A. Q. Putri, A. Triayudi, and R. T. Aldisa, "Implementasi Algoritma Decision Tree dan Naïve Bayes Untuk Klasifikasi Sentimen Terhadap Kepuasan Pelanggan Starbucks," *J. Inf. Syst. Res.*, vol. 4, no. 2, pp. 641–649, 2023, doi: 10.47065/josh.v4i2.2949.

**Jefri Jaya**, mahasiswa S1, program studi Teknik Informatika  
Universitas Tarumanagara