

# Analisis Perbandingan Algoritma Decision Tree, Random Forest, dan XGBoost untuk Klasifikasi Penyakit Infeksi Gigi dan Mulut

Bernadus Anggo Seno Aji<sup>1</sup>, Yohanes Setiawan<sup>2</sup>, Sukma Dewi Anggraini<sup>3</sup>

<sup>1,2,3</sup>Jurusan Teknologi Informasi (Kampus Kota Surabaya), Direktorat Kampus Surabaya, Universitas Telkom

Email: <sup>1</sup>[bernadusanggosenoaji@telkomuniversity.ac.id](mailto:bernadusanggosenoaji@telkomuniversity.ac.id), <sup>2</sup>[yohanessetiawan@telkomuniversity.ac.id](mailto:yohanessetiawan@telkomuniversity.ac.id),  
<sup>3</sup>[sukmadew@student.ittelkom-sby.ac.id](mailto:sukmadew@student.ittelkom-sby.ac.id)

**Abstract.** *Untreated dental diseases can lead to dental and oral infections. Dental and oral infections can lead to various complications, thus they must be appropriately treated according to the type of disease. The main issue in this study is the high prevalence of dental and oral infections in Indonesia and the lack of effective early detection systems. Various methods from artificial intelligence technology can rapidly detect dental and oral infections and accurately classify the types of infections. The objective of this study is to compare the performance of tree-based classification models for dental and oral infections, such as Decision Tree, Random Forest, and XGBoost. Tree-based methods are among algorithms suitable for categorical input data. In addition, class imbalance was addressed using the SMOTE technique. Each algorithm was evaluated using performance metrics such as accuracy, recall, precision, and F1-score. A comparison of the computational time (running time) of each model was also conducted to assess model efficiency. The classification results using Decision Tree, Random Forest, and XGBoost achieved accuracies of 87.5%, 91.7%, and 93.1% with training data without SMOTE, and accuracies of 88.9%, 93.1%, and 97.2% with training data using SMOTE for class imbalance handling. The best-performing model in this study is XGBoost with SMOTE-applied training data.*

**Keywords:** *Decision Tree, Random Forest, XGBoost, Classification, Smote.*

**Abstrak.** *Penyakit gigi yang tidak segera ditangani menyebabkan penyakit infeksi gigi dan mulut. Penyakit infeksi gigi dan mulut dapat menyebabkan berbagai komplikasi sehingga harus ditangani dengan tepat sesuai dengan jenis penyakitnya. Permasalahan utama dalam penelitian ini adalah tingginya prevalensi penyakit infeksi gigi dan mulut di Indonesia serta kurangnya sistem deteksi dini yang efektif. Beragam metode dari teknologi kecerdasan buatan dapat melakukan deteksi dini penyakit infeksi gigi dan mulut secara cepat dan secara akurat dapat melakukan klasifikasi penyakit infeksinya. Tujuan dari penelitian ini adalah membandingkan performa model klasifikasi penyakit infeksi gigi dan mulut berbasis tree, seperti Decision tree, Random Forest dan XGBoost. Metode berbasis tree merupakan salah satu algoritma kecerdasan buatan yang dapat digunakan untuk data input kategorikal. Selain itu dilakukan penanganan ketidakseimbangan kelas menggunakan Teknik SMOTE. Masing-masing algoritma dievaluasi menggunakan matrik evaluasi seperti akurasi, recall, presisi dan f1-score. Selain itu juga dilakukan perbandingan waktu komputasi (running time) dari setiap model untuk menilai efisiensi model. Hasil klasifikasi menggunakan metode Decision Tree, Random Forest dan XGBoost memiliki akurasi 87.5%, 91.7% dan 93.1% dengan data latih tidak menggunakan smote serta memiliki akurasi 88.9%, 93.1% dan 97.2%. untuk data latih menggunakan penanganan ketidakseimbangan kelas smote. Model terbaik berdasarkan penelitian ini adalah xgboost dengan data latih menggunakan penanganan ketidakseimbangan data smote.*

**Kata Kunci:** *Decision Tree, Random Forest, XGBoost, Klasifikasi, Smote.*

## 1. Pendahuluan

Kesehatan gigi dan mulut adalah salah satu indikator kesehatan tubuh secara keseluruhan. Kondisi kesehatan gigi dan mulut yang buruk dapat menyebabkan berbagai masalah. Kesehatan pada organ tubuh lain serta rasa tidak nyaman (Pratiwi et al., 2020). Menurut Riskesdes tahun 2018, sebanyak 45% memiliki masalah dengan gigi rusak/berlubang/sakit (Riskesdas, 2018). Menurut data dari Riskesdes 2018 disebutkan bahwa 57,6% dari populasi Indonesia mengalami masalah kesehatan gigi dan mulut (Riskesdas, 2018). Penderita sakit gigi biasanya mengeluhkan rasa sakit, ngilu, nyeri pada gigi maupun sekitarnya. Rasa sakit tersebut bisa terjadi karena masalah pada gigi itu sendiri atau

bisa terjadi karena masalah rahang. Banyak kategori penyakit gigi dan mulut, salah satunya adalah infeksi gigi dan mulut (Elsenterisi et al., 2024).

Beberapa penyebab penyakit infeksi gigi dan mulut termasuk kebiasaan merokok dan konsumsi alkohol. Merokok yang berlebihan menyebabkan masalah pada gigi seperti timbulnya patologi pada rongga mulut. Merokok dapat menyebabkan peningkatan bakteri didalam rongga mulut sehingga rongga mulut rentan terserang infeksi. Kerusakan akibat rokok dapat terjadi pada gigi dan jaringan lunak rongga mulut. Beberapa kasus yang sering timbul akibat merokok seperti penyakit periodontitis, gingivitis dan lainnya (Andina Rizkia Putri Kusuma, 2011). Selain merokok, kebiasaan minum alkohol juga dapat menyebabkan penyakit infeksi gigi. Minum alkohol berlebihan menyebabkan iritasi gingiva dan meningkatkan terjadinya infeksi sehingga terjadinya resiko periodontitis (Syahriell & Dewi Haryani, 2020). Selain merokok dan alkohol, penyakit infeksi gigi juga dipengaruhi oleh kurangnya menjaga kebersihan mulut, sehingga banyak bakteri dan jamur yang berkembang biak serta jarang memeriksa kondisi gigi ke dokter gigi.

Penanganan penyakit infeksi gigi dan mulut harus dilakukan sedini mungkin, hal ini guna mempercepat proses penanganan. Jika proses penanganan tidak segera dilakukan, akan menyebabkan komplikasi penyakit yang menjalar ke organ lain. Penyakit infeksi gigi dan mulut memiliki banyak jenis dan gejala yang berbeda-beda. Berdasarkan hal tersebut, mengetahui jenis penyakit gigi dan mulut sangat membantu dalam menentukan pengobatan yang akan dilakukan. Melakukan deteksi awal jenis penyakit gigi secara manual dapat dilakukan dengan membandingkan gejala dengan jenis-jenis penyakit gigi dan mulut yang terdapat di Internet. Namun, hal itu membuang waktu dalam perihal proses pencarian dan perbandingannya. Teknologi kecerdasan buatan melalui pembelajaran mesin dengan komputer dapat mengotomatisasi deteksi dini terkait klasifikasi jenis penyakit gigi secara lebih cepat. Oleh karena itu, diperlukan sebuah sistem untuk membantu mendeteksi jenis penyakit infeksi gigi dan mulut berdasarkan gejala yang dialami oleh pasien. Sistem ini diharapkan dapat membantu pengguna, terutama tim medis, dalam mengidentifikasi jenis penyakit dan memberikan rekomendasi untuk langkah awal penanganan infeksi gigi dan mulut.

Sudah ada beberapa penelitian terkait penyakit gigi dan mulut. Beberapa penelitian terkait deteksi penyakit gigi dan mulut menggunakan pendekatan machine learning. Salah satu penelitian untuk mendeteksi penyakit gigi dan mulut yang dilakukan oleh Yuliana dkk pada tahun 2019 menggunakan metode *Naïve Bayes* (Yuliyana & Sinaga, 2019). Penelitian tersebut bertujuan membuat sistem pakar untuk mendeteksi penyakit gigi dan mulut dengan mencari probabilitas tertinggi berdasarkan gejala-gejala yang diderita. Nilai probabilitas diperoleh dari pengalaman seorang pakar. Penelitian lainnya terkait deteksi penyakit gigi dan mulut dilakukan oleh Ana Mariyam Puspitasari dkk tahun 2018. Penelitian tersebut menggunakan metode *Support Vector Machine* untuk mengklasifikasikan penyakit gigi dan mulut (Puspitasari et al., 2018). Penelitian tersebut menggunakan kernel RBF dan strategi One-Against-All untuk model klasifikasi. Penelitian ini menunjukkan rata-rata akurasi sebesar 94,442% dengan menggunakan dataset yang terdiri dari 122 data.

Berdasarkan masalah dan penelitian yang telah dilakukan, penelitian ini berfokus pada deteksi penyakit infeksi gigi dan mulut menggunakan metode *machine learning*. Tidak semua algoritma machine learning dapat menangani data input kategorikal. Metode berbasis Tree merupakan salah satu algoritma yang dapat digunakan untuk data input kategorikal maupun kontinu (Charbuty & Abdulazeez, 2021). Berdasarkan kelebihan metode berbasis Tree, metode yang digunakan pada penelitian ini adalah *Decision Tree*, *Random Forest* dan *XGBoost (eXtreme Gradient Boosting)*.

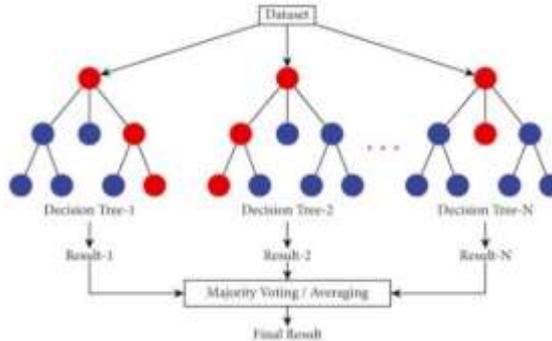
## 2. Tinjauan Pustaka

### 2.1 Decision Tree

Decision tree merupakan salah satu metode klasifikasi yang populer karena mudah diimplementasikan. Decision tree merepresentasikan klasifikasi seperti sekumpulan aturan dalam pohon keputusan. Setiap node di decision tree merupakan atribut atau fitur yang digunakan, untuk setiap cabang merepresentasikan cabang keputusan untuk setiap kondisi, leaf (daun) merepresentasikan kelas atau hasil klasifikasi (Hidayat et al., 2024).

## 2.2 Random Forest

Random Forest adalah bagian dari algoritma Decision Tree. Algoritma ini membentuk pohon keputusan (Decision Tree) secara acak, termasuk pemilihan fiturnya. Karena menghasilkan banyak pohon keputusan, algoritma ini disebut sebagai "forest" atau hutan. Gambaran arsitektur random forest dapat dilihat pada Gambar 1. Dataset akan masuk kedalam semua pohon keputusan kemudian dilakukan majority voting untuk memutuskan hasil klasifikasi (Nur Aprilia et al., 2024).



Gambar 1. Gambaran Umum Random Forest

## 2.4 XGBoost

XGBoost merupakan singkatan dari Extreme Gradient Boosting. Merupakan salah satu metode klasifikasi yang efektif dalam machine learning. Xgboost menggunakan teknik ensemble learning. XGBoost membangun pohon dengan proses menambahkan pohon keputusan secara berurutan. Pohon keputusan akan diperbaiki setiap penambahan pohon dengan mempertimbangkan kesalahan prediksi yang dilakukan oleh model sebelumnya. XGBoost melakukan proses regularisasi yang berguna untuk mencegah overfitting. Selain itu XGBoost juga memiliki kemampuan untuk melihat fitur penting dalam pembuatan model (Salsabil et al., 2024).

## 2.5 SMOTE

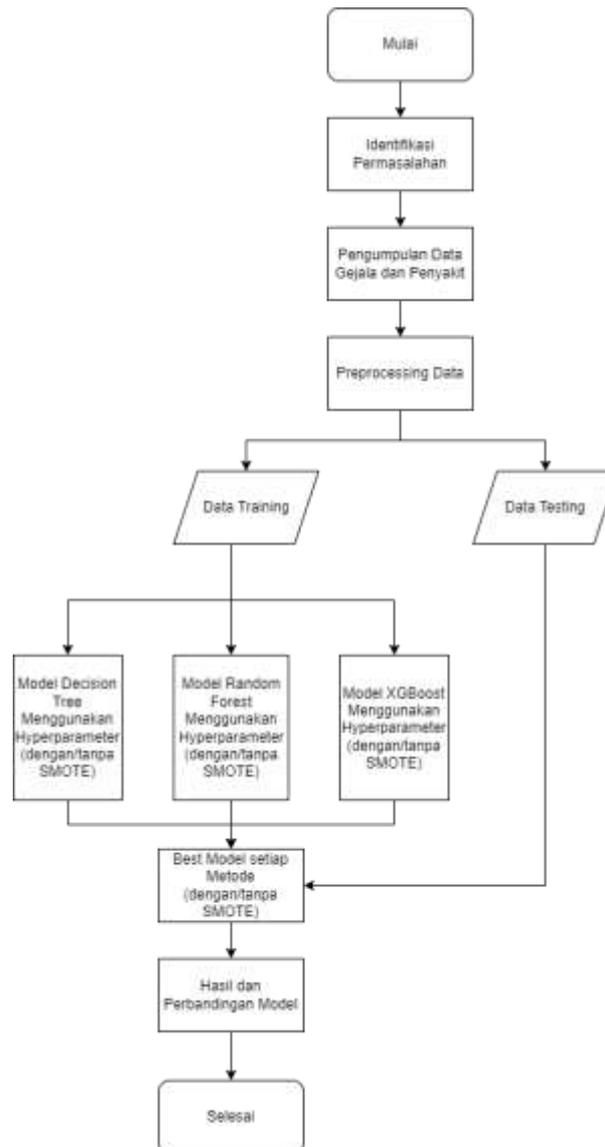
SMOTE (*Synthetic Minority Oversampling Technique*) adalah metode yang digunakan untuk mengatasi ketidakseimbangan pada data target atau kelas (Kaewwiset et al., 2021). Ketidakseimbangan terjadi ketika salah satu kelas mempunyai jumlah yang jauh lebih sedikit daripada kelas lainnya. Ketidakseimbangan data biasanya menyebabkan pembiasan model klasifikasi. Smote merupakan salah satu metode oversampling data dengan menghasilkan data sintetik untuk kelas minor, tidak hanya menduplikat sampel yang ada (Wang et al., 2021). *SMOTE* membuat data sintetik dengan rumus 1.

$$P_{ij} = x_i + \mathit{rand}(0, 1) \times (x_{ij} - x_i) \quad (1)$$

$P_{ij}$  = titik baru yang dihasilkan,  $x_i$  = sampel asli dari kelas minoritas yang dipilih,  $x_{ij}$  = salah satu tetangga terdekat dari  $x_i$ ,  $\mathit{rand}(0,1)$  = bilangan acak dari 0 sampai 1.

## 3. Metode Penelitian

Penelitian ini menggunakan metode komparatif. Penelitian ini terdiri dari proses pengumpulan data, pembagian data menjadi data latih dan data uji, pembuatan model dengan metode decision tree, random forest dan XGBoost, pada saat pembuatan model menggunakan dua skenario percobaan yaitu menggunakan SMOTE dan tidak menggunakan SMOTE untuk penanganan ketidakseimbangan data. Rincian tahapan penelitian dapat dilihat pada Gambar 2:



**Gambar 2. Diagram Alur Penelitian**

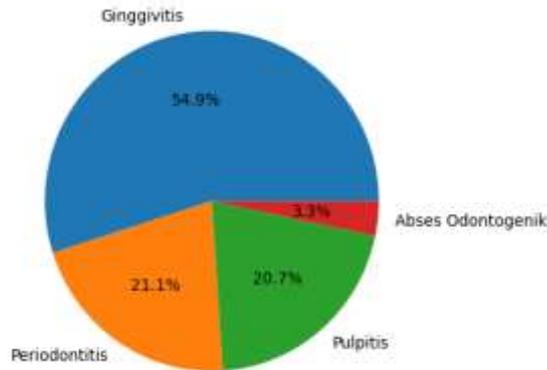
### 3.1 Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data primer hasil dari kuesioner terhadap pasien yang sedang menderita penyakit infeksi gigi dan mulut. Sumber data diperoleh pada salah satu Faskes tingkat pertama di kota Malang. Pertanyaan kuesioner berupa gejala-gejala pada pasien penderita penyakit infeksi gigi dan mulut. Pertanyaan yang diajukan merupakan pertanyaan yang sering dokter tanyakan untuk mengetahui diagnosa awal kondisi pasien. Pertanyaan, gejala-gejala serta hasil diagnosa yang digunakan sebagai kelas klasifikasi sudah divalidasi oleh pakar. Berikut pertanyaan yang diajukan kepada pasien:

1. Apakah merasakan nyeri saat terkena panas atau dingin?
2. Apakah saat mengunyah menimbulkan rasa nyeri?
3. Apakah rasa nyeri datang tiba-tiba tanpa rangsangan?
4. Apakah merasa bau nafas anda tidak sedap?
5. Apakah saat sakit gigi disertai dengan demam?
6. Apakah Gusi anda mudah berdarah?
7. Apakah Gusi anda mengalami pembengkakan dan kemerahan?
8. Apakah terdapat penumpukan karang gigi?

9. Apakah sisa makanan sering terselip disela-sela gigi?
10. Apakah ada gigi yang berlubang?
11. Apakah mengalami pembengkakan di bagian wajah?
12. Apakah pada bagian gigi yang mengalami pembengkakan terdapat cairan berbau?

Total data pada penelitian ini sebanyak 285 data pasien. Hasil diagnosa oleh pakar digunakan sebagai target kelas dimana terdapat 4 jenis penyakit infeksi gigi dan mulut yang dideteksi. 4 penyakit tersebut terdiri dari Pulpitis, Gingivitis, Periodontitis, dan Abses Odontogenic. Berikut prosentase setiap penyakit gigi dan mulut sesuai dengan Gambar 3.



**Gambar 3. Prosentase Data Pasien Infeksi Gigi dan Mulut**

Detail banyaknya data pasien seperti pada Tabel 1:

**Tabel 1. Jumlah Data Pasien Infeksi Gigi dan Mulut**

No	Jenis Penyakit	Banyak Data
1	Gingivitis	156
2	Pulpitis	65
3	Periodontitis	54
4	Abses Odontogenik	10

Berdasarkan hasil pengumpulan data dibuat menjadi matriks yang akan digunakan untuk proses permodelan.

**Tabel 2. Matriks Data**

Nama	Pertanyaan												Class
	1	2	3	4	5	6	7	8	9	10	11	12	
Pasien 1	1	1	1	1	0	1	1	0	0	1	1	1	PP
Pasien 2	0	1	0	0	1	0	1	0	1	1	1	1	PD
Pasien 3	0	1	1	0	1	0	1	0	0	1	1	1	AO
Pasien 4	1	1	1	1	0	0	1	0	0	1	1	1	PP
Pasien 5	0	0	1	1	1	1	1	0	1	1	1	1	GG

Berdasarkan Tabel 2, nilai 1 berarti Ya dan 0 berarti tidak, nilai tersebut berdasarkan pertanyaan gejala yang dialami. Untuk nilai Class merupakan hasil pemeriksaan pakar, Pulpitis (PP), Periodontitis (PD), Gingivitis (GG), dan Abses Odontogenic (AO).

### 3.2 Preprocessing Data

#### A. Split Data

Data pasien dibagi menjadi dua yaitu data latih dan data uji. Pembagian data menggunakan proporsi 75% data latih dan 25% data uji. Berikut detail banyaknya data latih serta prosentasenya pada Tabel 3:

**Tabel 3. Jumlah Data Latih Pasien Infeksi Gigi dan Mulut**

No	Jenis Penyakit	Banyak Data
1	Ginggivitis	117
2	Pulpitis	45
3	Periodontitis	44
4	Abses Odontogenik	7

Data uji mempunyai detail jumlah dan prosentase seperti pada Tabel 4:

**Tabel 4. Jumlah Data Uji Pasien Infeksi Gigi dan Mulut**

No	Jenis Penyakit	Banyak Data
1	Ginggivitis	39
2	Pulpitis	20
3	Periodontitis	10
4	Abses Odontogenik	3

#### B. SMOTE

SMOTE (*Synthetic Minority Oversampling Technique*) adalah salah satu metode yang digunakan untuk mengatasi ketidakseimbangan pada data target atau kelas (Kaewwiset et al., 2021). Data target pada penelitian ini mempunyai proporsi data yang tidak seimbang seperti pada Gambar 2. Metode SMOTE dapat digunakan untuk penanganan imbalanced data dengan multiclass (Dash et al., 2020). Metode ini mensintesis data dari kelas minoritas dengan cara mencari instance yang berdekatan lalu membuat *convex* kombinasinya. Metode SMOTE menghasilkan data yang seimbang yang tidak overfit (Istighfar et al., 2023). Data yang dilakukan SMOTE hanya data training, hal ini untuk menjaga keaslian data testing. Berikut detail banyaknya data setiap jenis penyakit dan prosentase data latih pasien infeksi gigi dan mulut setelah dilakukan proses SMOTE terlihat pada Gambar 2:

```

oversample = SMOTE()

X_train_smote, y_train_smote = oversample.fit_resample(X_train, y_train)

y_train_smote.value_counts()
    
```

	count
Hasil Diagnosa	
Ginggivitis	117
Pulpitis	117
Periodontitis	117
Abses Odontogenik	117

**Gambar 4. Proses SMOTE pada data latih**

Setelah dilakukan SMOTE, jumlah data memiliki prosentase yang sama. Data yang minoritas memiliki jumlah yang sama dengan kelas mayoritas. Penggunaan SMOTE dilakukan dengan mengimplementasikan SMOTE hanya pada data training sehingga data uji tetap terjaga kualitasnya sebagai data real yang diuji dalam situasi yang sebenarnya dan menghindari leaking, yakni kebocoran data sehingga hasil pengujian seolah-olah terlihat baik

tetapi telah “bocor” pada data latih. Gambar 4 memperlihatkan hasil eksekusi kode program ketika SMOTE diimplementasikan. Secara umum, seluruh algoritma (Decision Tree, Random Forest, dan XGBoost) menggunakan `x_train_smote` dan `y_train_smote` yang sama ketika diimplementasikan dengan SMOTE.

### 3.3 Model Klasifikasi

#### A. Model berbasis Tree

Penelitian ini menggunakan tiga model algoritma berbasis tree yaitu:

- 1) Decision Tree, model klasifikasi yang berbentuk struktur pohon / tree yang memilih berdasarkan atribut terbaik untuk setiap cabang. Metode ini memiliki kelebihan mudah untuk diinterpretasikan dan dipahami
- 2) Random Forest, model klasifikasi yang termasuk metode ensemble learning berbasis decision tree. Dalam pengambilan keputusan dilakukan pemungutan suara (voting) mayoritas.
- 3) XGBoost, merupakan metode boosting berbasis gradient tree yang mempunyai kelebihan dalam mengatasi overfitting dengan memanfaatkan proses regularisasi.

Setiap algoritma diimplementasikan menggunakan bahasa pemrograman python dengan library Scikit-learn dan XGBoost. Pengujian menggunakan skenario dengan dan tanpa penyeimbangan data SMOTE.

#### B. Hyperparameter dan training Model

Dalam model machine learning parameter merupakan nilai penting yang menentukan keberhasilan suatu model klasifikasi. Kombinasi parameter yang tepat akan menghasilkan model klasifikasi yang memiliki kinerja yang baik. Untuk menemukan kombinasi yang terbaik salah satu caranya adalah dengan menggunakan *Hyperparameter tuning* (Michael et al., 2023). Untuk setiap model, menggunakan 5-Fold cross validation (Turska et al., 2021). *Hyperparameter* untuk setiap metode Decision Tree, Random Forest dan XGBoost sebagai berikut :

Untuk decision Tree, tuning hyperparameter sebagai berikut (Rhys, 2020):

1. `min_samples_split` – Jumlah sampel minimum yang dibutuhkan untuk membagi simpul.: [5 – 20]
2. `max_depth` – Maksimum kedalaman dari Tree : [3 – 10].
3. `ccp_alpha` – Parameter kompleksitas untuk pruning : [0.01, 0.1]
4. `min_samples_leaf` – Jumlah sampel minimum untuk membuat simpul daun : [3 – 10].

Untuk Random Forest, tuning hyperparameter sebagai berikut (Rhys, 2020):

1. `n_estimators` – Jumlah tree di forest : [5 – 30]
2. `max_features` – Jumlah maksimum fitur untuk setiap sampel : [6 – 12]
3. `min_samples_leaf` – Jumlah sampel minimum yang dibutuhkan untuk berada di simpul daun : [1,5].
4. `max_leaf_nodes` – Jumlah maksimum daun yang diperbolehkan. [5 – 20]

Untuk XGBoost, tuning hyperparameter sebagai berikut (Rhys, 2020) :

1. `eta` – Learning rate : [0,1]
2. `gamma` – Minimum pengurangan loss : [0 – 5]
3. `max_depth` – Maksimum kedalaman Tree : [1 – 5]
4. `min_child_weight` – Jumlah bobot minimum : [1 – 10]
5. `param_scale_pos_weight` – bobot untuk mengontrol keseimbangan bobot positif dan negatif imbalanced data : [1, 5, 10]

### 3.4 Evaluasi kinerja

Evaluasi setiap model dalam penelitian ini dilakukan dengan menggunakan nilai akurasi. Nilai akurasi data latih diperoleh dengan membandingkan hasil prediksi model dengan data target. Akurasi yang dilihat pada setiap model cross validation adalah rata-rata akurasi dari 5-Fold. Untuk data uji, evaluasi menggunakan akurasi, recall, presisi dan F1-score. Recall, presisi dan f1-score digunakan untuk melihat seberapa baik model dalam mengklasifikasikan, terutama berkaitan dengan *imbalanced class* (Cahyana et al., 2019). Recall digunakan untuk mengevaluasi cakupan suatu model dalam memprediksi kelas tertentu, sedangkan precision digunakan untuk menilai ketepatan model dalam memprediksi kelas tersebut. Sedangkan f1-score merupakan kombinasi antara recall dan precision. Selain evaluasi menggunakan matrik seperti akurasi, recall dan presisi, dilakukan pula pengukuran waktu komputasi (*running time*) untuk masing-masing algoritma saat proses pelatihan dan pengujian. Pengukuran waktu komputasi menggunakan fungsi *time()* untuk setiap model.

## 4. Hasil dan Pembahasan

Proses pelatihan menggunakan hyperparameter pada data latih mendapatkan model terbaik berdasarkan parameter hasil tuning. Model dengan parameter terbaik tersebut diuji menggunakan data uji. Berikut hasil parameter terbaik serta hasil uji pada masing-masing metode.

### 4.1 Decision Tree

Bagian ini menjelaskan hasil tuning parameter *decision tree* menggunakan *cross validation* didapatkan parameter dan model terbaik pada data latih tanpa proses smote dan menggunakan smote, hasil klasifikasi pada data uji serta performansinya sebagai berikut:

#### A. Model Decision Tree Tanpa smote

Pada bagian ini proses pelatihan tidak dilakukan penanganan ketidakseimbangan data. Tabel 5 menunjukkan parameter decision tree terbaik dari proses tuning menggunakan hyperparameter.

**Tabel 5. Hasil Tuning Parameter Decision Tree Menggunakan Hyperparameter**

Min samples split	Max depth	Ccp alpha	Min samples leaf
9	7	0.01	3

Model dengan parameter terbaik tersebut kemudian diuji menggunakan data uji didapatkan hasil Nilai recall, precision dan f1-score dihitung sesuai kelas masing-masing. Rincian nilai precision, recall, dan f1-score masing-masing dapat dilihat pada Tabel 6:

**Tabel 6. Precision, Recall dan F1-Score Decision Tree tanpa SMOTE**

Kelas	precision	recall	f1-score	support
Abses Odontogenik	0.750	1.000	0.857	3
Ginggivitis	0.919	0.872	0.895	39
Periodontitis	0.800	0.800	0.800	10
Pulpitis	0.857	0.900	0.878	20
accuracy	0.875			72
Macro avg	0.832	0.893	0.857	72
Weighted avg	0.878	0.875	0.875	72

Hasil *precision*, *recall* dan *f1-score* cukup baik untuk semua kelas. Model ini mampu mengenali kelas Abses Odontogenik dengan baik walaupun hanya memiliki 3 sampel tetap terdapat kesalahan prediksi dalam mengklasifikasikan penyakit abses odontogenik. Untuk kelas Ginggivitis model cukup baik dengan nilai recall

87% artinya cukup baik dalam mendeteksi kasus gingivitis dan Sebagian besar prediksi akurat dengan nilai precision 91%. Pada kelas Periodontitis model cukup seimbang dalam mengklasifikasikan, tetapi memiliki akurasi paling kecil diantara kelas lainnya. Kelas Pulpitis memiliki recall yang tinggi yaitu 90%, artinya model mampu mendeteksi kasus pulpitis dengan baik, tetapi mempunyai precision 85% hal ini menunjukkan bahwa ada beberapa kasus pulpitis yang salah prediksi. Karena kasus penyakit sehingga diharapkan tidak melewatkan penyakit sehingga perlu menaikkan recall untuk kasus gingivitis dan periodontitis. Berdasarkan hal tersebut, model decision tree tanpa penanganan data imbalanced mampu mengklasifikasikan dengan cukup baik.

## B. Model decision tree menggunakan SMOTE

Pada bagian ini proses pelatihan dilakukan penanganan ketidakseimbangan data. Tabel 7 menunjukkan parameter decision tree dari proses tuning menggunakan hyperparameter.

**Tabel 7. Hasil Tuning Parameter Decision Tree Menggunakan Hyperparameter dengan SMOTE**

Min samples split	Max depth	Ccp alpha	Min samples leaf
5	5	0.01	3

Berdasarkan proses pelatihan pada data latih hasil SMOTE, parameter terbaik untuk model decision tree yang diperoleh adalah: jumlah minimum sampel untuk membagi simpul sebanyak 5, kedalaman maksimum setiap pohon adalah 5, jumlah minimum sampel untuk membentuk simpul daun adalah 3, dan parameter kompleksitas pemangkasan adalah 0.01.

Berdasarkan parameter terbaik tersebut diuji pada data uji mendapatkan hasil detail nilai *precision*, *recall* dan *f1-score* masing-masing seperti pada Tabel 8:

**Tabel 8. Precision, Recall, dan F1-Score Decision Tree dengan SMOTE**

Kelas	precision	recall	f1-score	support
Abses Odontogenik	1.000	1.000	1.000	3
Gingivitis	0.878	0.923	0.900	39
Periodontitis	0.800	0.800	0.800	10
Pulpitis	0.944	0.850	0.895	20
accuracy	0.889			72
Macro avg	0.906	0.893	0.899	72
Weighted avg	0.891	0.889	0.889	72

Hasil *precision*, *recall* dan *f1-score* cukup baik untuk semua kelas. Jika melihat akurasinya, decision tree menggunakan SMOTE terdapat kenaikan dibandingkan tidak menggunakan SMOTE. Model dengan SMOTE mampu mengenali kelas Abses Odontogenik dengan baik walaupun hanya memiliki 3 sampel. Untuk kelas Gingivitis model cukup baik dengan nilai recall 92% artinya hampir semua kasus gingivitis terdeteksi. Pada kelas Periodontitis model cukup seimbang dalam mengklasifikasikan, tetapi memiliki akurasi paling kecil diantara kelas lainnya. Kelas Pulpitis memiliki recall yang tinggi yaitu 94%, artinya prediksi positif lebih akurat, tetapi mempunyai recall yang cukup rendah yaitu 85% hal ini menunjukkan bahwa ada beberapa kasus pulpitis yang terlewatkan. Karena kasus penyakit sehingga diharapkan tidak melewatkan penyakit sehingga perlu menaikkan recall untuk kelas periodontitis dan pulpitis.

## 4.2 Random Forest

Bagian ini menjelaskan hasil tuning parameter random forest menggunakan hyperparameter, hasil klasifikasi model pada data uji serta performansinya.

- 1) Model Random Forest tanpa SMOTE

Tabel 9 menunjukkan hasil tuning parameter random forest menggunakan hyperparameter tanpa penanganan keseimbangan data mendapatkan parameter dan model terbaik seperti Tabel 9. Hasil Tuning Parameter Random Forest menggunakan Hyperparameter tanpa SMOTE

**Tabel 9. Hasil Tuning Parameter Random Forest menggunakan Hyperparameter tanpa SMOTE**

N estimators	Max features	Min samples leaf	Max leaf nodes
19	7	1	11

Berdasarkan proses pelatihan pada data tanpa penanganan imbalanced data, didapatkan parameter model terbaik random forest yaitu jumlah tree di forest adalah 19, jumlah maksimal fitur untuk setiap sampel adalah 7, jumlah minimum sampel yang diperlukan untuk berada di simpul daun adalah 1 dan jumlah maksimum daun yang diperbolehkan adalah 11.

Model dengan parameter terbaik tersebut kemudian diuji menggunakan data uji, didapatkan hasil evaluasi matriksnya pada Tabel 10 :

**Tabel 10. Matriks Evaluasi Random Forest Tanpa SMOTE**

Kelas	precision	recall	f1-score	support
Abses Odontogenik	1.000	1.000	1.000	3
Gingivitis	0.923	0.923	0.923	39
Periodontitis	0.900	0.900	0.900	10
Pulpitis	0.900	0.900	0.900	20
accuracy	0.917			72
Macro avg	0.931	0.931	0.931	72
Weighted avg	0.917	0.917	0.917	72

Melihat tabel *precision*, *recall* dan *f1-score* menggunakan metode random forest pada Tabel 10, menunjukan model ini mampu mendeteksi dengan sempurna kasus abses odontogenik walaupun datanya hanya 3. Untuk penyakit gingivitis menunjukan model random forest akurat dalam mengenali kasus gingivitis dengan keseimbangan precision dan recall yang tinggi yaitu sebesar 92%. Untuk kasus periodontitis dan pulpitis menunjukan model mampu mendeteksi penyakit periodontitis dan pulpitis dengan baik dan memiliki keseimbangan recall maupun presisi dengan nilai 90%. Untuk nilai akurasi menggunakan random forest tanpa SMOTE juga mengalami peningkatan dibandingkan menggunakan decision tree.

## 2) Model Random Forest menggunakan SMOTE

Hasil tuning parameter random forest menggunakan hyperparameter dengan penanganan keseimbangan data mendapatkan parameter dan model terbaik seperti pada Tabel 11.

**Tabel 11. Hasil Tuning Parameter Random Forest menggunakan Hyperparameter dengan SMOTE**

N estimators	Max features	Min samples leaf	Max leaf nodes
17	7	1	17

Berdasarkan proses pelatihan pada data dengan penanganan imbalanced data menggunakan SMOTE, didapatkan parameter model terbaik random forest yaitu jumlah tree di forest adalah 17, jumlah maksimal fitur untuk setiap sampel adalah 7, jumlah minimum sampel yang diperlukan untuk berada di simpul daun adalah 1 dan jumlah maksimum daun yang diperbolehkan adalah 17.

Model dengan parameter terbaik tersebut kemudian diuji menggunakan data uji, didapatkan hasil evaluasi seperti pada Tabel 12 :

**Tabel 12. Matriks Evaluasi Random Forest dengan SMOTE**

Kelas	precision	recall	f1-score	support
Abses Odontogenik	1.000	1.000	1.000	3

<b>Gingivitis</b>	0.925	0.949	0.937	39
<b>Periodontitis</b>	1.000	0.900	0.947	10
<b>Pulpitis</b>	0.900	0.900	0.900	20
<b>accuracy</b>	0.931			72
<b>Macro avg</b>	0.956	0.937	0.946	72
<b>Weighted avg</b>	0.932	0.931	0.931	72

Model random forest menggunakan SMOTE mengalami peningkatan akurasi dibandingkan tidak menggunakan SMOTE. Meningkatnya akurasi menunjukkan bahwa SMOTE membantu meningkatkan keseimbangan klasifikasi. Pada kelas Abses Ondotogenik model ini mampu mendeteksi dengan sempurna tetapi hanya memiliki 3 sampel. Untuk kelas gingivitis, terdapat peningkatan dalam recall maupun precision. Untuk kelas gingivitis, model lebih baik dalam mengenali kelas ini setelah dilakukan oversampling SMOTE. Untuk kelas periodontitis lebih berhati-hati dalam memprediksi kelas ini, ditunjukkan dengan peningkatan nilai precision dibanding tanpa menggunakan oversampling. Pada kasus pulpitis tidak terdapat perubahan antara sebelum dan sesudah dilakukan oversampling SMOTE. Berdasarkan nilai precision, recall dan f1-score masing-masing kelas menunjukkan mengalami peningkatan dibandingkan model tanpa SMOTE maupun juga decision tree.

### 4.3 XGBoost

Pada bagian ini akan dijelaskan tuning parameter menggunakan hyperparameter untuk metode XGBoost. Selain itu juga dijelaskan hasil klasifikasi menggunakan metode XGBoost pada data latih tanpa dan dengan penanganan ketidakseimbangan data menggunakan SMOTE.

#### 1) Model XGBoost tanpa SMOTE

Pada sub bab ini dijelaskan hasil tuning parameter menggunakan hyperparameter dengan data latih tanpa penanganan ketidakseimbangan data. Berikut parameter terbaik hasil tuning parameter terlihat pada Tabel 13:

**Tabel 13. Hasil Tuning Parameter XGBOOST menggunakan Hyperparameter tanpa SMOTE**

<b>eta</b>	<b>Gamma</b>	<b>Max depth</b>	<b>Min child weight</b>	<b>scale_pos_weight</b>
1	0	1	1	6

Tuning parameter terbaik XGBoost menggunakan data latih tanpa proses SMOTE yaitu Learning rate sebesar 1, minimum pengurangan loss adalah 0, maksimum kedalaman Tree adalah 1, jumlah bobot minimum adalah 1, jumlah minimum daun yang diperbolehkan adalah 1 dan bobot imbalanced data adalah 6.

Model dengan parameter terbaik tersebut kemudian diuji menggunakan data uji didapatkan hasil akurasi, recall, precision dan f1-score seperti Tabel 14:

**Tabel 14. Precision, Recall, dan F1-Score XGBOOST tanpa SMOTE**

<b>Kelas</b>	<b>precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
<b>Abses Odontogenik</b>	1.000	0.333	0.500	3
<b>Gingivitis</b>	1.000	0.974	0.987	39
<b>Periodontitis</b>	1.000	0.900	0.947	10
<b>Pulpitis</b>	0.833	1.000	0.909	20
<b>accuracy</b>	0.944			72
<b>Macro avg</b>	0.958	0.802	0.936	72
<b>Weighted avg</b>	0.954	0.944	0.940	72

Akurasi model XGBoost tanpa penanganan ketidakseimbangan data lebih tinggi dibanding model decision tree maupun random forest. Jika hanya melihat akurasi, model ini sangat bagus, tetapi disisi lain terdapat recall yang sangat rendah untuk kelas abses odontogenic artinya model sering melewatkan deteksi kelas

ini. Untuk kelas lain sudah cukup baik dilihat dari F1-Scorenya, tetapi karena kasus penyakit sehigga diharapkan tidak melewatkan penyakit sehingga perlu menaikkan recall untuk kasus abses odontogenik.

2) Model XGBoost menggunakan SMOTE

Pada sub bab ini dijelaskan hasil tuning parameter menggunakan hyperparameter dengan data latih dengan penanganan ketidakseimbangan data menggunakan SMOTE. Berikut parameter terbaik hasil tuning parameter :

**Tabel 15. Hasil Tuning Hyperparameter XGBOOST dengan SMOTE**

eta	Gamma	Max depth	Min child weight	scale_pos_weight
1	0	2	1	1

Tuning parameter terbaik XGBoost menggunakan data latih tanpa proses SMOTE yaitu Learning rate sebesar 1, minimum pengurangan loss adalah 0, maksimum kedalaman Tree adalah 2, jumlah bobot minimum adalah 1, jumlah minimum daun yang diperbolehkan adalah 1 dan bobot imbalanced data adalah 1.

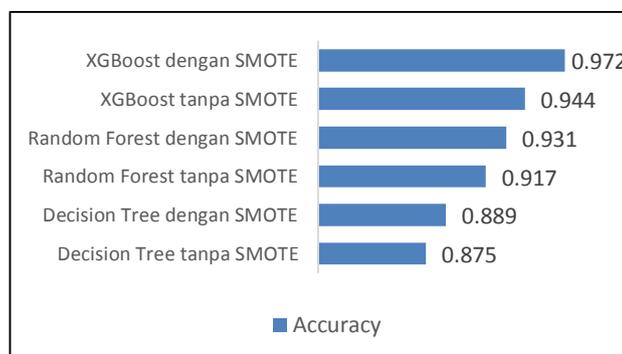
Model dengan parameter terbaik tersebut kemudian diuji menggunakan data uji didapatkan hasil akurasi, recall, precision dan f1-score seperti Tabel 16:

**Tabel 16. Precision, Recall dan F1-Score XGBOOST dengan SMOTE**

Kelas	precision	recall	f1-score	support
Abses Odontogenik	1.000	1.000	1.000	3
Gingivitis	0.974	0.974	0.974	39
Periodontitis	1.000	0.900	0.947	10
Pulpitis	0.952	1.000	0.976	20
accuracy	0.972			72
Macro avg	0.982	0.969	0.974	72
Weighted avg	0.973	0.972	0.972	72

Mengacu pada tabel diatas, model XGBoost menggunakan SMOTE memiliki akurasi lebih besar daripada model XGBoost tanpa SMOTE. Selain itu, model ini juga memiliki akurasi lebih tinggi dari model decision tree maupun random forest. Melihat nilai recall, precision dan f1-score model XGBoost dengan SMOTE juga memiliki nilai lebih besar dibandingkan model decision tree maupun random forest. Berdasarkan data tersebut, model XGBoost dengan penanganan ketidakseimbangan kelas merupakan model terbaik.

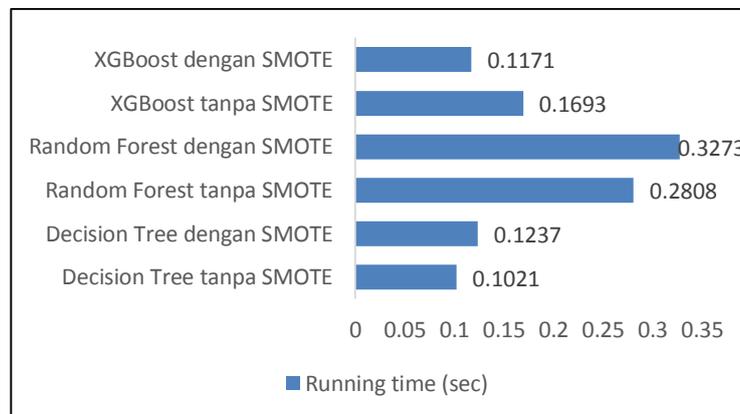
Perbandingan akurasi untuk semua mode yang digunakan dapat dilihat pada Gambar 5.



**Gambar 5. Perbandingan Akurasi Model yang digunakan**

Berdasarkan data perbandingan akurasi pada Gambar 5 dapat dilihat penanganan ketidakseimbangan kelas menggunakan SMOTE dapat meningkatkan akurasi model. Selain evaluasi akurasi, recall, presisi dan f1-score, dilakukan juga pengukuran waktu komputasi atau *running time* untuk masing-

masing skenario percobaan. Pengukuran dilakukan menggunakan fungsi *time()*. Berikut hasil waktu komputasi berdasarkan pelatihan dan pengujian menggunakan parameter terbaik untuk masing-masing model dapat dilihat pada Gambar 6:



**Gambar 6. Perbandingan Waktu Komputasi (running time)**

Berdasarkan Gambar 6 dapat dilihat bahwa XGBoost tidak hanya baik dalam akurasi tetapi juga memiliki waktu komputasi yang relatif cepat, hanya sedikit lebih lama daripada decision tree namun dapat digantikan dengan akurasi yang jauh lebih baik daripada decision tree. Random forest memiliki waktu komputasi paling lama disebabkan karena harus membentuk banyak pohon untuk proses ensemble.

## 5. Kesimpulan

Berdasarkan hasil penelitian yang sudah dilakukan dan dijelaskan menggunakan Metode berbasis tree seperti decision tree, random forest dan XGBoost dapat digunakan untuk klasifikasi data penyakit infeksi gigi dan mulut dengan nilai akurasi diatas 80%. Ketiga metode yang digunakan, yaitu decision tree, random forest, dan XGBoost, masing-masing memperoleh akurasi sebesar 87.5%, 91.7%, dan 93.1% pada data latih tanpa menggunakan SMOTE. Untuk akurasi klasifikasi menggunakan data latih dengan SMOTE didapatkan akurasi masing-masing 88.9%, 93.1% dan 97.2%. Penanganan ketidakseimbangan data kelas dapat ditangani menggunakan SMOTE. Data latih menggunakan SMOTE terbukti mampu meningkatkan akurasi klasifikasi. Selain itu, penggunaan SMOTE juga meningkatkan nilai recall dan presisi. Algoritma XGBoost menjadi algoritma terbaik dari ketiga model yang dipilih ketika SMOTE diterapkan, XGBoost nyaris mendekati 100% (97.2%) karena bias dan varians dari ketidakseimbangan data berhasil diatasi. Selain nilai akurasi, nilai recall, precision dan f1-score menunjukkan model XGBoost dengan SMOTE menunjukkan nilai yang tinggi. Selain itu XGBoost juga memiliki waktu komputasi yang relatif cepat sehingga menunjukkan bahwa XGBoost tidak hanya akurat tetapi juga cukup efisien untuk mendeteksi penyakit infeksi gigi dan mulut.

## Referensi

- Andina Rizkia Putri Kusuma. (2011). *Pengaruh Merokok Terhadap Kesehatan Gigi Dan Rongga Mulut*.  
 Cahyana, N., Khomsah, S., & Aribowo, A. S. (2019). *Improving Imbalanced Dataset Classification Using Oversampling and Gradient Boosting*. IEEE.  
 Charbuty, B., & Abdulazeez, A. (2021). Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28. <https://doi.org/10.38094/jastt20165>  
 Dash, P. B., Nayak, J., Naik, B., Oram, E., & Islam, S. H. (2020). Model based IoT security framework using multiclass adaptive boosting with SMOTE. *Security and Privacy*, 3(5). <https://doi.org/10.1002/spy2.112>

- Elsenterisi, H. M., Alsatravi, M. A., Zidan, K., Alqahtani, L., & Temsah, M.-H. (2024). Pediatric Mandibular Langerhans Cell Histiocytosis with Upper Airway Compromise: A Case Report. In *The Egyptian Journal of Hospital Medicine* (Vol. 96). <https://ejhm.journals.ekb.eg/>
- Hidayat, F., Sarwani, M. Z., Hariyanto, R., & Penulis Korespondensi, E. (2024). *Hidayat, Rekomendasi Pengobatan Pada Penyakit Kucing Menggunakan Metode Decision Tree 155 Rekomendasi Pengobatan Pada Penyakit Kucing Menggunakan Metode Decision Tree (Studi Kasus : Klinik Drh Panti Absari)*.
- Istighfar, F., Bijaksana Putra Negara, A., & Hadari Nawawi, J. H. (2023). *Klasifikasi Bidang Keahlian Mahasiswa Menggunakan Algoritma Naive Bayes*. 11(1). <https://doi.org/10.26418/justin.v11i1.52402>
- Kaewwiset, T., Temdee, P., & Yooyativong, T. (2021). Employee Classification for Personalized Professional Training Using Machine Learning Techniques and SMOTE. *2021 Joint 6th International Conference on Digital Arts, Media and Technology with 4th ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering, ECTI DAMT and NCON 2021*, 376–379. <https://doi.org/10.1109/ECTIDAMTNCN51128.2021.9425754>
- Michael, A., Palelleng, S., Devi Damayanti, I., & Rusman, J. (2023). Kombinasi Pretrained Model dan Random Forest Pada Klasifikasi Bakso Mengandung Boraks dan Non-Boraks Berbasis Citra. *Teknika*, 12(1), 27–32. <https://doi.org/10.34148/teknika.v12i1.591>
- Nur Aprilia, Y., Ahkam Sani, D., & Martyan Anggadimas, N. (2024). *Klasifikasi Status Penderita Gizi Stunting Pada Balita Menggunakan Metode Random Forest (Studi Kasus di Kelurahan Petamanan Kota Pasuruan)*.
- Pratiwi, D., Putri Ariyani, A., Sari, A., Wirahadikusumah, A., Nofrizal, R., Tjandrawinata, R., Gani Soulisha, A., Wijaya, H., Sandra, F., Kedokteran Gigi, J., & Kedokteran Gigi, F. (2020). *Penyuluhan Peningkatan Kesadaran Dini Dalam Menjaga Kesehatan Gigi dan Mulut Pada Masyarakat Tegal Alur, Jakarta*.
- Puspitasari, A. M., Ratnawati, D. E., & Widodo, A. W. (2018). *Klasifikasi Penyakit Gigi Dan Mulut Menggunakan Metode Support Vector Machine* (Vol. 2, Issue 2). <http://j-ptiik.ub.ac.id>
- Rhys, H. I. (2020). *Machine Learning with R, the tidyverse, and mlr*.
- Riskesdas, T. (2018). *Laporan Nasional RKD2018 FINAL*.
- Salsabil, M., Azizah, N. L., & Eviyanti, A. (2024). Implementasi Data Mining Dalam Melakukan Prediksi Penyakit Diabetes Menggunakan Metode Random Forest Dan Xgboost. *Jurnal Ilmiah Komputasi*, 23(1). <https://doi.org/10.32409/jikstik.23.1.3507>
- Syahrieh, D., & Dewi Haryani, I. (2020). Gambaran Status Kebersihan Gigi dan Mulut Serta Kebutuhan Perawatan Periodontal Pada Remaja Yang Mengonsumsi Alkohol. *Jurnal Bakti Saraswati*, 09(02).
- Turska, E., Jurga, S., & Piskorski, J. (2021). Mood disorder detection in adolescents by classification trees, random forests and xgboost in presence of missing data. *Entropy*, 23(9). <https://doi.org/10.3390/e23091210>
- Wang, S., Dai, Y., Shen, J., & Xuan, J. (2021). Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-03430-5>
- Yuliyana, Y., & Sinaga, A. S. R. M. (2019). Sistem Pakar Diagnosa Penyakit Gigi Menggunakan Metode Naive Bayes. *Fountain of Informatics Journal*, 4(1), 19. <https://doi.org/10.21111/fij.v4i1.3019>