

## Penerapan Algoritma K-Nearest Neighbors (K-NN) untuk Prediksi Status Gizi Balita dengan Penyeimbangan Kelas Menggunakan SMOTE, SMOTEENN, dan SMOTETomek

Ramadhan<sup>1</sup>,

<sup>1</sup>Teknik Informatika, Fakultas Teknik, Universitas Islam Syekh-Yusuf, Jl. Maulana Yusuf No.10, Babakan, Kec. Tangerang, Kota Tangerang, Banten 15118

[2104030082@students.unis.ac.id](mailto:2104030082@students.unis.ac.id)<sup>1</sup>

### Abstrak

*Ketidakseimbangan data (imbalanced data) merupakan salah satu permasalahan utama dalam machine learning yang dapat menyebabkan bias terhadap kelas mayoritas, sehingga mengurangi akurasi prediksi pada kelas minoritas. Penelitian ini bertujuan untuk mengatasi ketidakseimbangan data dalam prediksi status gizi balita dengan menggunakan algoritma K-Nearest Neighbors (K-NN) dan teknik penyeimbangan kelas, yaitu SMOTE, SMOTEENN, dan SMOTETomek. Dataset yang digunakan merupakan data status gizi balita dari Puskesmas Legok, yang terdiri atas 3.555 data dengan parameter usia, berat badan, tinggi badan, dan status gizi. Proses penelitian meliputi tahapan pengumpulan data, preprocessing, penerapan teknik penyeimbangan kelas, serta evaluasi kinerja model menggunakan confusion matrix. Hasil penelitian menunjukkan bahwa teknik SMOTE, SMOTEENN, dan SMOTETomek berhasil meningkatkan kinerja model secara signifikan. Teknik SMOTEENN dan SMOTETomek memberikan akurasi tertinggi sebesar 99%, dengan distribusi prediksi yang lebih seimbang pada setiap kelas. Hal ini membuktikan bahwa penerapan teknik penyeimbangan kelas mampu mengatasi bias terhadap kelas mayoritas dan meningkatkan kemampuan model dalam memprediksi kelas minoritas. Penelitian ini menunjukkan bahwa kombinasi algoritma K-NN dan teknik penyeimbangan kelas dapat menjadi solusi efektif dalam menangani ketidakseimbangan data. Implementasi hasil penelitian ini diharapkan dapat membantu dalam proses pengambilan keputusan yang lebih baik dalam pemantauan status gizi balita.*

**Kata kunci:** Balita, Status Gizi, K-NN

### A. Pendahuluan

Data Mining, atau yang juga disebut sebagai Knowledge Discovery in Database (KDD), merupakan rangkaian proses yang mengintegrasikan berbagai cabang ilmu, seperti sistem basis data, machine learning, statistika, visualisasi, dan pengetahuan informasi, untuk menganalisis dataset berukuran besar guna menemukan pola atau karakteristik data yang berguna. Data Mining telah memberikan kontribusi signifikan di berbagai bidang ilmu, termasuk bisnis, bioinformatika, genetika, kedokteran, dan pendidikan (Sulistiyono et al., 2021).

Machine learning adalah bidang ilmu komputer yang berfokus pada pengembangan algoritma yang dapat mempelajari atau menyesuaikan diri dengan pola data tanpa harus diprogram secara langsung. Machine learning menggunakan

berbagai metode komputasi untuk meningkatkan kinerjanya dengan memanfaatkan pengetahuan yang diperoleh dari pengalaman selama proses pembelajaran (Kurniawan et al., 2023).

Dalam machine learning, salah satu permasalahan umum yang paling sering ditemui adalah data yang tidak seimbang (imbalanced data) (Pramayasa et al., 2023). Data tidak seimbang, atau yang lebih dikenal sebagai imbalanced data, adalah keadaan di mana rasio antara satu kelas dengan kelas lainnya tidak seimbang, sehingga terdapat kelas mayoritas (dengan jumlah data lebih banyak) dan kelas minoritas (dengan jumlah data lebih sedikit) (Haryawan & Ardhana, 2023).

Ketidakseimbangan data ini berpotensi menyebabkan kesalahan dalam mengklasifikasikan kelas minoritas. Hal ini disebabkan oleh jumlah data yang ada pada kelas minoritas yang jauh lebih sedikit, sehingga dalam proses pengklasifikasian data cenderung bias terhadap kelas mayoritas. Dengan pengklasifikasian yang tidak bekerja dengan baik karna data yang tidak seimbang, maka diperlukan pemecahan masalah ini (Ghorbani & Ghousi, 2020).

Teknik resampling adalah pendekatan yang paling umum digunakan untuk menangani masalah ini. Ada tiga metode utama untuk mengatasi underclassification: menambah sampel pada kelas minoritas, mengurangi sampel pada kelas mayoritas, atau menggunakan metode hybrid yang mengombinasikan keduanya. Teknik ini bertujuan untuk menyesuaikan distribusi kelas minoritas saat melatih data pada algoritma machine learning, sehingga kelas tersebut tidak lagi menjadi minoritas. Metode pemodelan ini telah terbukti efektif dalam menyelesaikan permasalahan klasifikasi yang kompleks (Jayadi et al., 2024).

Berdasarkan hasil penelitian (Yunus & Pratiwi, 2023), diketahui bahwa hasil penelitian tersebut menggunakan indeks berat badan menurut umur untuk mengevaluasi status gizi balita dan mendapatkan akurasi sebesar 88.06% tanpa menggunakan teknik penyeimbang data, berbeda dengan penelitian yang penulis lakukan tidak hanya menggunakan teknik penyeimbangan data yaitu SMOTE, SMOTE-ENN, SMOTETOMEK sebagai perbandingan hasil yang akan di dapatkan, tetapi juga menambahkan parameter tambahan yaitu usia, berat badan, tinggi badan, dan status gizi berdasarkan parameter tersebut.


Penelitian yang penulis lakukan akan memfokuskan pada permasalahan ketidakseimbangan data (imbalanced data) yang dapat menyebabkan bias dalam proses klasifikasi status gizi balita. Ketidakseimbangan ini mengakibatkan performa klasifikasi menjadi kurang akurat. Berdasarkan hipotesis awal, penggunaan teknik penyeimbangan kelas seperti SMOTE, SMOTEENN, dan SMOTETomek akan meningkatkan akurasi prediksi pada dataset yang tidak seimbang, terutama dalam mengklasifikasikan kelas minoritas. Dengan membandingkan ketiga teknik tersebut, diharapkan dapat diperoleh nilai akurasi yang lebih baik dan hasil yang lebih seimbang pada setiap kelas gizi.

Dengan permasalahan yang ada mengenai ketidakseimbangan data, maka penelitian ini dilakukan dengan tujuan Mengatasi permasalahan ketidakseimbangan

kelas dalam prediksi status gizi balita dengan menerapkan teknik penyeimbangan kelas seperti SMOTE, SMOTEENN, dan SMOTETomek. Membandingkan efektivitas ketiga teknik penyeimbangan kelas dalam meningkatkan hasil prediksi menggunakan algoritma K-Nearest Neighbors (K-NN). Mengevaluasi kinerja algoritma K-Nearest Neighbors (K-NN) pada prediksi status gizi balita setelah dilakukan penyeimbangan kelas.

## B. Metode

Pada penelitian ini, data yang digunakan adalah data tidak seimbang dari dataset status gizi balita Puskesmas Legok. Data yang tidak seimbang ini akan diolah dengan menggunakan metode SMOTE, SMOTEENN dan SMOTETOMEK. Dalam penelitian ini akan dilakukan beberapa tahap seperti yang digambarkan pada Gambar 1.



Gambar 1. Metode penelitian

### Pengumpulan Data

Pertama tahapan pengumpulan data yaitu bertujuan untuk mengumpulkan data/informasi yang mendukung proses penelitian. Data yang digunakan oleh penulis pada penelitian ini adalah kumpulan dataset balita yang terdapat pada Puskesmas Legok dengan jumlah 3555 data, dengan parameter pengukuran usia, berat badan, tinggi badan dan variabel status gizi untuk label klasifikasi, seperti yang tertera pada tabel 1.

Tabel 1  
 Dataset Gizi Balita Puskesmas Legok

Nik	Nama	Usia	Berat Badan	Tinggi Badan	Status Gizi
3603200209228942	MUHAMMAD RAFKA RAFARDHAN	23	9.23	80	Normal
3603606309191208	CHEROLLINE	58	17.13	102.2	Normal
3603172708190004	MUHAMMAD AZRIEL SAPUTRA	59	14.98	109	Gizi Kurang
3603600510198210	M. ALZAM	58	16.2	102	Normal
3603202909190002	MUHAMMAD RAFFASYA ADITYA	58	15.55	103	Normal
.....	.....	.....	.....	.....	.....
3603606401203828	NADIA ZAFIRAH LATIFAH	54	22.1	106.8	Gizi Lebih
3603202409190001	MUHAMAD DANISH SETIABUDI	58	18.15	107	Normal
3603201809840001	MUHAMAD FAIZZAN AZRIL MUSYARI	57	18.45	110.8	Normal
3603204508190003	ALYA KHOIRIYAH FAJRINA	60	14.35	102.4	Normal
3603200305900004	ALESHA SHAQUIEENA	57	13.2	100	Normal

### Pre-Processing

Dalam tahap preprocessing data, langkah pertama yang dilakukan adalah memahami data yang ada. Selanjutnya, membersihkan data dengan menangani nilai yang hilang dan menghapus baris yang memiliki nilai nol atau tidak relevan. Setelah itu, melakukan transformasi data dengan mengubah nilai kategorikal menjadi angka

dan menormalkan data agar berada dalam skala yang sama.

## SMOTE

Metode SMOTE digunakan untuk membuat representatif dari data minoritas untuk mengatasi masalah yang terdapat pada ketidakseimbangan data (Yulian Pamuji & Dwi Arma Putri, 2023). Data sintetis ini akan membantu pengklasifikasian dalam membangun batas keputusan yang lebih umum, sehingga dapat mengurangi dampak dari overfitting (Lin et al., 2021). Selanjutnya dataset yang sudah di resampling, masing-masing di split dengan perbandingan 80% data training dan 20% data testing sebelum dieksekusi ke model klasifikasi K-NN.

## Klasifikasi

K-Nearest Neighbor (K-NN) merupakan algoritma supervised learning yang menentukan klasifikasi instance baru berdasarkan mayoritas kategori dari k-tetangga terdekat. Algoritma ini memanfaatkan prinsip kedekatan (neighbor) untuk memprediksi kelas data baru (Cahyanti et al., 2021).

Penelitian ini menggunakan fungsionalitas klasifikasi data, yang merupakan proses untuk menemukan sebuah model atau fungsi yang menjelaskan serta membedakan antara kelas-kelas data dan konsep-konsepnya (Putri & Wijayanto, 2022). Rumus K-NN menggunakan persamaan sebagai berikut:

$$d(x, y) = \sum_{k=0}^n (x_i - y_i)^2$$

Di mana:

$p_i$  adalah nilai fitur dari titik data  $p$ .

$q_i$  adalah nilai fitur dari titik data  $q$ .

$n$  adalah jumlah dimensi fitur.

## Evaluasi

Kinerja algoritma klasifikasi dalam penelitian ini dievaluasi menggunakan confusion matrix. Confusion matrix memberikan gambaran tentang jumlah prediksi yang benar dan salah dengan membandingkannya terhadap data sebenarnya. (Imamah & Rachman, 2020). Hasil klasifikasi bisa dihitung tingkat akurasi berdasarkan kinerja matriks. Untuk menghitung berapa tingkat akurasi pada matriks digunakan rumus:

**Tabel 2**  
**Confusion Matrix**

Actual Class	Predict Class	
	Positive (P)	Negative (N)
Positive (P)	True Positive (TP)	False Positive (FP)
Negative (N)	False Negative (FN)	True Negative (TN)

Dari nilai-nilai yang terdapat dalam confusion matrix, selanjutnya dapat dihitung nilai-nilai yang digunakan untuk mengevaluasi metode klasifikasi, yaitu accuracy, precision, recall, dan f1-score. Nilai accuracy, precision, recall, dan f1-score dapat dihitung melalui Persamaan berikut:

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

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

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

$$\text{F1-score} = \frac{2TP}{2TP + FN + FP}$$

### C. Hasil dan Pembahasan

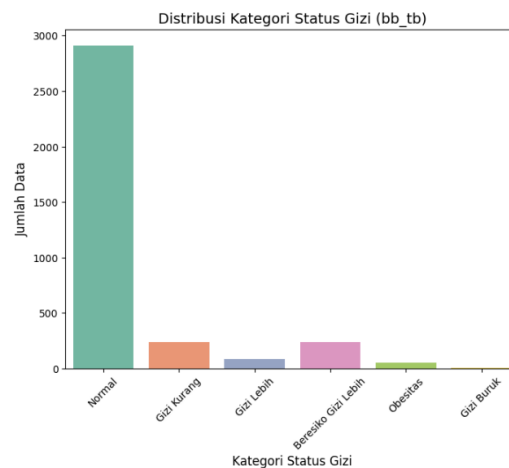
Pada penelitian ini, dilakukan implementasi tahapan penelitian mulai dari pengumpulan data balita dari Puskesmas Legok sampai pada tahap evaluasi model menggunakan perhitungan confusion matrix.

#### 1). Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan melalui observasi langsung di Puskesmas Legok dengan meminta data yang tersedia. Dataset yang digunakan terdiri dari 3.555 data balita, mencakup parameter pengukuran seperti usia, berat badan, tinggi badan, serta variabel status gizi sebagai label untuk klasifikasi.

#### 2). Pre-Processing

Pada tahap preprocessing data, langkah pertama yang dilakukan adalah memahami data yang ada. Selanjutnya, data dibersihkan dengan mengatasi nilai yang hilang dan menghapus baris yang mengandung nilai nol atau dianggap tidak relevan. Setelah itu, dilakukan transformasi data dengan mengubah nilai kategorikal menjadi numerik dan menormalisasi data agar berada dalam skala yang sama. Sebelum proses SMOTE dilakukan, visualisasi data digunakan untuk memahami spesifikasinya dan mengamati perubahan yang terjadi sebelum dan setelah penerapan SMOTE, SMOTENN, SMOTETomek seperti pada gambar 2, 3, 4 dan 5.

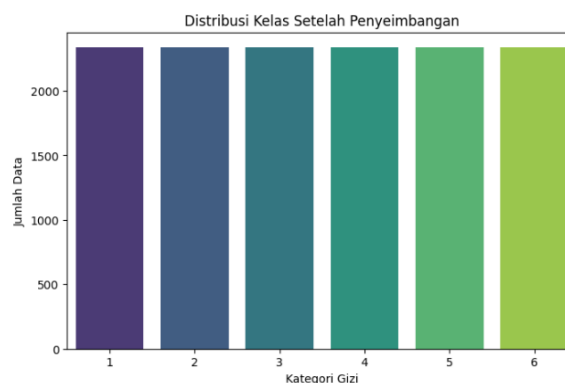


**Gambar 2. Distribusi Data Sebelum SMOTE**


Berdasarkan gambar yang tertera, Grafik ini mencerminkan ketidakseimbangan data (imbalanced data), di mana kategori mayoritas (Normal) mendominasi dataset, sedangkan kategori lainnya termasuk dalam kelas minoritas. Langkah selanjutnya adalah mengatasi ketidakseimbangan data ini dengan teknik seperti SMOTE, SMOTEENN, atau SMOTETomek agar performa klasifikasi lebih optimal untuk semua kategori.

### 3). SMOTE

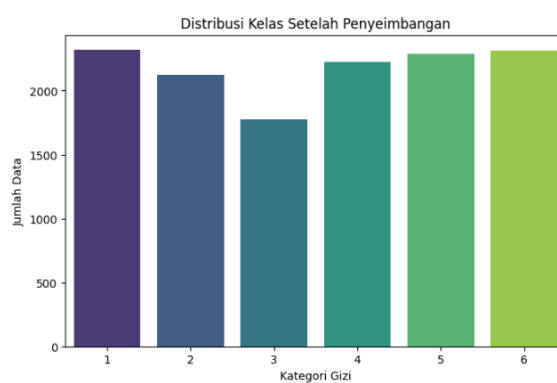
Metode SMOTE digunakan untuk menghasilkan representasi data sintesis pada kelas minoritas. Setelah itu, dataset dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian sebelum diimplementasikan ke model klasifikasi K-NN. Berikut adalah representasi data setelah di SMOTE.



**Gambar 3. Distribusi Data Setelah Dilakukan Teknik SMOTE**



Gambar 4. Distribusi Data Setelah Dilakukan Teknik SMOTEENN



Gambar 5. Distribusi Data Setelah Dilakukan Teknik SMOTETomek

Tabel 3  
 Distribusi data Sebelum dan Sesudah di SMOTE

Kelas Gizi	Distribusi Data			
	Sebelum SMOTE	SMOTE	SMOTEENN	SMOTETomek
Gizi Kurang (1)	9	2338	2319	2319
Gizi Kurang (2)	238	2338	2125	2125
Normal (3)	2911	2338	1776	1776
Beresiko Gizi Lebih (4)	240	2338	2222	2222
Gizi Lebih (5)	87	2338	2285	2285
Obesitas (6)	55	2338	2314	2314
Jumlah	3540	14.028	13.041	13.041

Tabel di atas menunjukkan distribusi data status gizi sebelum dan sesudah diterapkan teknik penyeimbangan data, yaitu SMOTE, SMOTEENN, dan SMOTETomek. Distribusi data status gizi sebelum dan sesudah diterapkannya teknik penyeimbangan data menunjukkan perubahan yang signifikan.

#### 4). Klasifikasi

Proses klasifikasi dimulai dengan membagi dataset menjadi dua bagian, yaitu 80% untuk data pelatihan (training) dan 20% untuk data pengujian (testing). Selanjutnya, model K-Nearest Neighbors (K-NN) dengan jumlah tetangga  $K = 3$  diterapkan untuk melakukan klasifikasi status gizi balita berdasarkan fitur-fitur yang tersedia dalam dataset. Data pelatihan digunakan untuk melatih model Klasifikasi, sementara data pengujian digunakan untuk mengukur kinerja model dalam memprediksi status gizi balita yang belum diketahui kategorinya. Hasil dari pengujian model bisa dilihat pada tabel 4 dan 5.

**Tabel 4**  
**Klasifikasi Dengan K-NN Sebelum di SMOTE**

	Accuracy	Precision	Recall	F1-Score
Tanpa SMOTE	0.89	0.88	0.89	0.88

**Tabel 5**  
**Klasifikasi Dengan K-NN Sesudah di SMOTE**

	Accuracy	Precision	Recall	F1-Score
SMOTE	0.97	0.97	0.97	0.97
SMOTEENN	0.99	0.99	0.99	0.99
SMOTETomek	0.99	0.99	0.99	0.99

Setelah melakukan implementasi algoritma K-Nearest Neighbors (K-NN). Tabel diatas menggambarkan hasil yang diperoleh setelah mengaplikasikan teknik-teknik tersebut pada dataset yang tidak seimbang dari Puskesmas Legok mengalami kenaikan persentasi baik dari segi accuracy, precision, recall dan f1-score.


#### 5). Evaluasi

Langkah Selanjutnya evaluasi dilakukan dengan menggunakan confusion matrix. Confusion matrix merupakan matriks yang digunakan untuk mengukur kinerja model klasifikasi dengan membandingkan prediksi yang dihasilkan model terhadap label sebenarnya pada data pengujian.







Gambar 6. Confusion Matrix K-NN Tanpa SMOTE



Gambar 7. Confusion Matrix Teknik SMOTE



Gambar 8. Confusion Matrix Teknik SMOTEENN



**Gambar 9. Confusion Matrix Teknik SMOTETomek**

Pada gambar confusion matrix, terlihat hasil distribusi prediksi model untuk setiap metode penyeimbangan data yang diterapkan, yaitu SMOTE, SMOTEENN, dan SMOTETomek. Gambar tersebut menunjukkan bahwa setelah menggunakan teknik penyeimbangan kelas, jumlah True Positive (TP) dan True Negative (TN) mengalami peningkatan yang signifikan, menandakan bahwa model dapat melakukan klasifikasi data dengan lebih akurat.

Sebagai ilustrasi, penerapan metode SMOTE mampu mengurangi jumlah False Positive (FP) dan False Negative (FN), yang pada akhirnya meningkatkan akurasi keseluruhan model. Demikian pula, teknik SMOTEENN dan SMOTETomek menghasilkan distribusi yang lebih merata di antara semua kelas dalam confusion matrix. Hal ini menunjukkan bahwa model memiliki kemampuan lebih baik untuk memprediksi data dari kelas minoritas, sehingga mengurangi bias terhadap kelas mayoritas yang sebelumnya mendominasi.

Evaluasi ini membuktikan bahwa penggunaan teknik penyeimbangan data tidak hanya meningkatkan akurasi model tetapi juga memperbaiki metrik evaluasi lainnya, seperti precision, recall, dan F1-score, sebagaimana tercermin dalam hasil pengujian yang tercantum pada tabel kinerja model.

#### D. Kesimpulan

Penelitian ini berhasil menunjukkan efektivitas penerapan algoritma K-Nearest Neighbors (K-NN) dalam memprediksi status gizi balita, terutama pada dataset dengan ketidakseimbangan kelas. Ketidakseimbangan data, yang sebelumnya menjadi kendala dalam proses klasifikasi, berhasil diatasi melalui penggunaan teknik penyeimbangan kelas seperti SMOTE, SMOTEENN, dan SMOTETomek.

Hasil evaluasi menunjukkan bahwa penerapan teknik-teknik tersebut secara

signifikan meningkatkan kinerja model K-NN dalam hal akurasi, precision, recall, dan F1-score. Teknik SMOTEENN dan SMOTETomek menghasilkan kinerja terbaik dengan nilai akurasi mencapai 99%, yang menunjukkan peningkatan signifikan dibandingkan pengujian tanpa penyeimbangan data. Selain itu, teknik penyeimbangan data juga mampu meningkatkan kemampuan model dalam mengklasifikasikan data dari kelas minoritas, sehingga bias terhadap kelas mayoritas dapat diminimalkan.

Dengan demikian, penelitian ini membuktikan bahwa penggunaan metode penyeimbangan kelas dalam algoritma K-NN merupakan solusi efektif untuk mengatasi permasalahan ketidakseimbangan data dalam prediksi status gizi balita. Hasil penelitian ini diharapkan mampu memberikan kontribusi dalam pengembangan sistem klasifikasi berbasis machine learning yang lebih akurat dan adil, terutama dalam bidang kesehatan masyarakat.

### Daftar Pustaka

- Cahyanti, F. L. D., Gata, W., & Sarasati, F. (2021). Implementasi Algoritma Naïve Bayes dan K-Nearest Neighbor Dalam Menentukan Tingkat Keberhasilan Immunotherapy Untuk Pengobatan Penyakit Kanker Kulit. *Jurnal Ilmiah Universitas Batanghari Jambi*, 21(1), 259. <https://doi.org/http://dx.doi.org/10.33087/jiubj.v21i1.1189>
- Ghorbani, R., & Ghousi, R. (2020). Comparing Different Resampling Methods in Predicting Students' Performance Using Machine Learning Techniques. *IEEE*, 8, 67899–67911. <https://doi.org/https://doi.org/10.1109/ACCESS.2020.2986809>
- Haryawan, C., & Ardhana, Y. M. K. (2023). Analisa Perbandingan Teknik Oversampling SMOTE Pada Imbalance Data. *Jurnal Informatika & Rekayasa Elektronika*, 6(1). <https://doi.org/https://www.e-journal.stmiklombok.ac.id/index.php/jire/issue/view/25>
- Imamah, & Rachman, F. H. (2020). Twitter sentiment analysis of Covid-19 using term weighting TF-IDF and logistic regresion. *Proceeding - 6th Information Technology International Seminar, ITIS 2020*, 238–242. <https://doi.org/https://doi.org/10.1109/ITIS50118.2020.9320958>
- Jayadi, Rachmat Raharja, A., Pramudianto, A., & Muchsam, Y. (2024). Application of Naïve Bayes Classifier Algorithm for Classification of Scholarship Recipients at SMA PGRI 2 Bandung. *Mechanical Computational And Manufacturing Research*, 13(2), 33–41. <https://doi.org/https://doi.org/10.35335/computational.v13i2.169>
- Kurniawan, R., Wintoro, P. B., Mulyani, Y., & Komarudin, M. (2023). Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(2), 233–236. <https://doi.org/http://dx.doi.org/10.23960/jitet.v11i2.3034>
- Lin, M., Zhu, X., Hua, T., Tang, X., Tu, G., & Chen, X. (2021). Detection of ionospheric scintillation based on xgboost model improved by smote-enn technique. *Remote Sensing*, 13(13), 1–22. <https://doi.org/https://doi.org/10.3390/rs13132577>
- Pramayasa, K., Maysanjaya, I. M. D., & Indradewi, I. G. A. A. D. (2023). Analisis Sentimen Program MbkM Pada Media Sosial Twitter Menggunakan KNN Dan SMOTE. *SINTECH Journal Edition*, 6. <https://doi.org/https://doi.org/10.31598/sintechjournal.v6i2.1372>
- Putri, N. B., & Wijayanto, A. W. (2022). Analisis Komparasi Algoritma Klasifikasi Data

- Mining Dalam Klasifikasi Website Phishing. *Komputika : Jurnal Sistem Komputer*, 11(1), 59–66. <https://doi.org/http://dx.doi.org/10.34010/komputika.v11i1.4350>
- Sulistiyono, M., Pristyanto, Y., Adi, S., & Gumelar, G. (2021). Implementasi Algoritma Synthetic Minority Over-Sampling Technique untuk Menangani Ketidakseimbangan Kelas pada Dataset Klasifikasi. *SISTEMASI: Jurnal Sistem Informasi*, 10(2), 445–459. <https://doi.org/http://dx.doi.org/10.32520/stmsi.v10i2.1303>
- Yulian Pamuji, F., & Dwi Arma Putri, S. (2023). Komparasi Metode SMOTE dan ADASYN Untuk Penanganan Data Tidak Seimbang MultiClass. *JIP (Jurnal Informatika Polinema)*, 9(3), 331–338. <https://doi.org/https://doi.org/10.33795/jip.v9i3.1330>
- Yunus, M., & Pratiwi, N. K. A. (2023). Prediksi Status Gizi Balita Dengan Algoritma K-Nearest Neighbor (KNN) di Puskesmas Cakranegara. *JTIM : Jurnal Teknologi Informasi Dan Multimedia*, 4(4), 221–231. <https://doi.org/10.35746/jtim.v4i4.328>