

**IMPLEMENTASI SMOTE DAN PERBANDINGAN KINERJA
ALGORITMA KLASIFIKASI PADA KASUS IMBALANCE CLASS**

SKRIPSI

Diajukan untuk memenuhi salah satu syarat mencapai derajat Sarjana

Program Studi Informatika



disusun oleh

MUHAMMAD FATHUR RIZQI

19.11.2757

Kepada

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2022

**IMPLEMENTASI SMOTE DAN PERBANDINGAN KINERJA
ALGORITMA KLASIFIKASI PADA KASUS IMBALANCE CLASS**

SKRIPSI

untuk memenuhi salah satu syarat mencapai derajat Sarjana

Program Studi Informatika



disusun oleh

MUHAMMAD FATHUR RIZQI

19.11.2757

Kepada

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2022

HALAMAN PERSETUJUAN

SKRIPSI

IMPLEMENTASI SMOTE DAN PERBANDINGAN KINERJA ALGORITMA KLASIFIKASI PADA KASUS IMBALANCE CLASS



Yoga Pristyanto, S.Kom, M.Eng

NIK. 190302412

HALAMAN PENGESAHAN
SKRIPSI
IMPLEMENTASI SMOTE DAN PERBANDINGAN KINERJA
ALGORITMA KLASIFIKASI PADA KASUS IMBALANCE CLASS

yang disusun dan diajukan oleh

Muhammad Fathur Rizqi

19.11.2757

Telah dipertahankan di depan Dewan Pengaji
pada tanggal 23 desember 2022

Susunan Dewan Pengaji

Nama Pengaji

Majid Rahardi, S.Kom, M.Eng

NIK. 190302393

Tanda Tangan

Ikmah, M.Kom
NIK. 190302282

Yoga Pristyanto, S.Kom, M.Eng
NIK. 190302412

Skripsi ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Sarjana Komputer
Tanggal 23 desember 2022

DEKAN FAKULTAS ILMU KOMPUTER

Hanif Al Fatta,S.Kom., M.Kom.
NIK. 190302096

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Yang bertandatangan di bawah ini,

**Nama mahasiswa : Muhammad Fathur Rizqi
NIM : 19.11.2757**

Menyatakan bahwa Skripsi dengan judul berikut:

IMPLEMENTASI SMOTE DAN PERBANDINGAN KINERJA ALGORITMA KLASIFIKASI PADA KASUS IMBALANCE CLASS

Dosen Pembimbing : Yoga Pristyanto, S.Kom, M.Eng

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

Yogyakarta, 23 Desember 2022

Yang Menyatakan,



Muhammad Fathur Rizqi

KATA PENGANTAR

Dengan memanajatkan puja dan puji syukur kehadirat Allah Subhanahu Wata'ala, yang telah memberikan nikmat ilmu, kesehatan dan kecukupan rezeki sehingga penulis mampu dalam menyelesaikan skripsi ini yang berjudul “Implementasi SMOTE dan Perbandingan Kinerja Algoritma Klasifikasi Pada Kasus Imbalance Class”, sebagai salah satu syarat dalam menyelesaikan Program Sarjana (S1) Jurusan Informatika.

Penulis sadar bahwa jika tanpa bantuan dan dukungan dari berbagai pihak penyusunan skripsi ini tidak akan berjalan lancar, oleh karena itu penulis ingin menyampaikan rasa terima kasih sebesar-besarnya kepada seluruh pihak terkait yang telah memberikan dukungan dan motivasi dalam penyusunan skripsi ini. Pada kesempatan ini penulis ingin menyampaikan terima kasih kepada:

1. Kedua orang tua di rumah yang selalu memberikan dukungan baik secara material maupun doa.
2. Bapak Yoga Pristiyanto, S.Kom., M.Eng selaku dosen pembimbing yang telah memberikan arahan dan bimbingan dalam penggerjaan skripsi ini.
3. Serta teman-teman kelas informatika 03 yang saling berbagi ilmu pengetahuan selama perkuliahan berlangsung.

Selain itu penulis juga menyadari bahwa dalam skripsi ini masih banyak terdapat kekurangan, oleh karenanya peneliti ingin meminta maaf dan mengharapkan saran dan kritik dari para pembaca agar peneliti dapat membuat karya yang lebih baik di masa depan. Penulis berharap skripsi ini bisa bermanfaat bagi para pembaca.

Yogyakarta, 30 November 2022

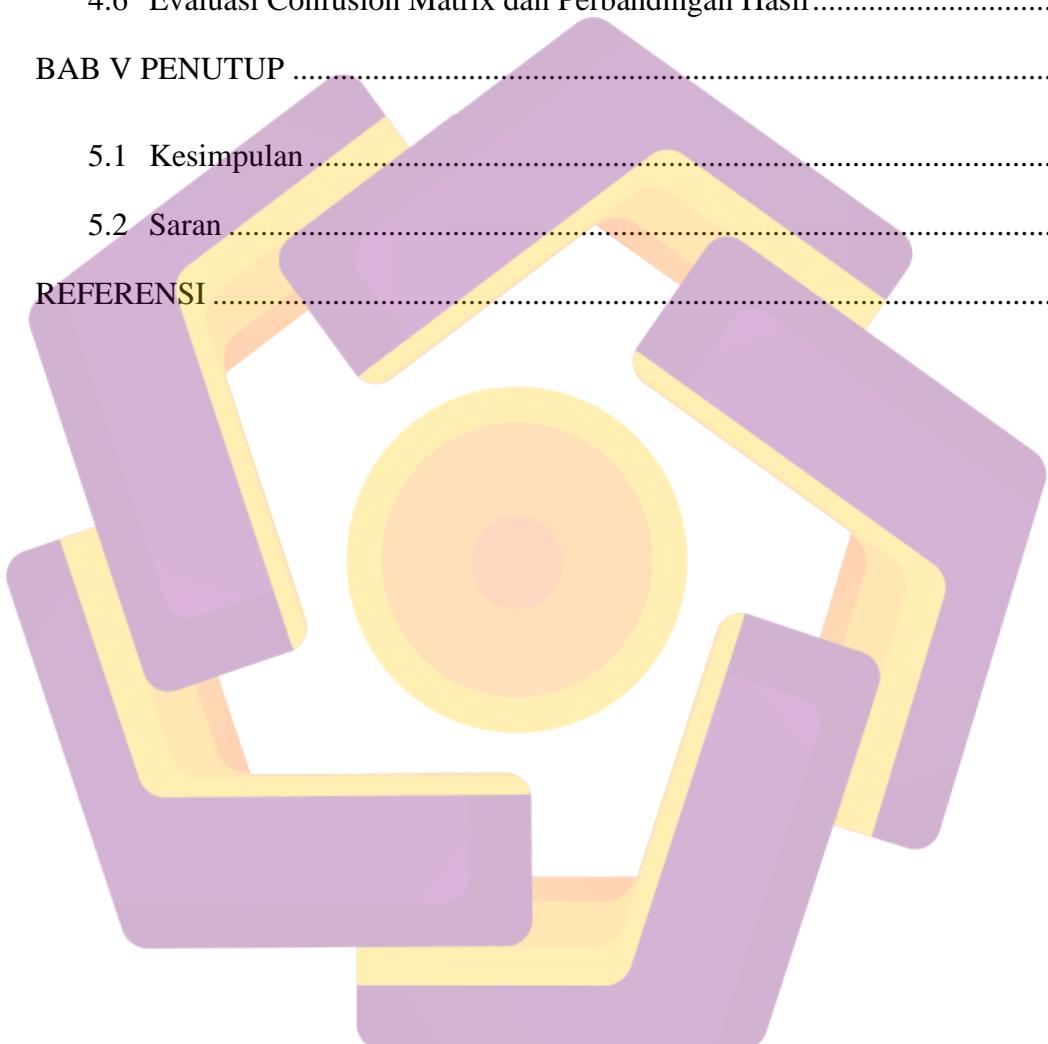
Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERNYATAAN KEASLIAN SKRIPSI	iv
KATA PENGANTAR	v
DAFTAR ISI	vi
DAFTAR TABEL	ix
DAFTAR GAMBAR	x
DAFTAR LAMBANG DAN SINGKATAN	xi
DAFTAR ISTILAH	xii
INTISARI	xiv
ABSTRACT	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tujuan Penelitian	2
1.3 Rumusan Masalah	2
1.4 Batasan Masalah	2
1.5 Manfaat Penelitian	3
1.6 Sistematika Penulisan	3
BAB II TINJAUAN PUSTAKA	4

2.1 Studi Literatur	4
2.2 Dasar Teori	11
2.2.1 Data Mining	11
2.2.2 Klasifikasi	12
2.2.3 SMOTE	12
2.2.4 Naïve Bayes Classifier	13
2.2.5 K-Nearest Neighbors.....	14
2.2.6 Decision Tree C4.5	15
2.2.7 Confusion Matrix	16
BAB III METODE PENELITIAN	19
3.1 Alur Penelitian	19
3.2 Alat dan Bahan.....	21
3.3 Perhitungan Manual Algoritma Klasifikasi	22
3.3.1 Algoritma Naïve Bayes Classifier.....	22
3.3.2 Algoritma K-Nearest Neigbor.....	26
3.3.3 Algoritma Decision Tree C4.5	28
BAB IV HASIL DAN PEMBAHASAN	34
4.1 Akuisisi Data.....	34
4.2 Pre-processing.....	36
4.3 Split Data	39
4.4 Implementasi oversampling SMOTE	39
4.5 Implementasi Algoritma Klasifikasi	41

4.5.1	Algoritma Naïve Bayes Classifier.....	41
4.5.2	Algoritma K-Nearest Neighbor.....	42
4.5.3	Algoritma Decision Tree C4.5	43
4.6	Evaluasi Confusion Matrix dan Perbandingan Hasil.....	43
BAB V PENUTUP		48
5.1	Kesimpulan	48
5.2	Saran	49
REFERENSI		50



DAFTAR TABEL

Tabel 2.1 Keaslian Penelitian	8
Tabel 2.2 Confusion Matrix	17
Tabel 3.1 Sampel Data Training	22
Tabel 3.2 Data Testing NBC	24
Tabel 3.3 Hasil Rata-rata dan Standar Deviasi Attribut Bmi	25
Tabel 3.4 Hasil Rata-rata dan Standar Deviasi Attribut Age	26
Tabel 3.5 Data Training Hasil Konversi	27
Tabel 3.6 Data Testing Hasil Konversi	28
Tabel 3.7 Hasil Perhitungan dengan Rumus Euclidean	29
Tabel 3.8 Data Age	30
Tabel 3.9 Data Gain Ratio	32
Tabel 4.1 Confusion Matrix Algoritma C4.5 Sebelum SMOTE	45
Tabel 4.2 Confusion Matrix Algoritma C4.5 Setelah SMOTE	45
Tabel 4.3 Hasil Evaluasi Confusion Matrix	46

DAFTAR GAMBAR

Gambar 3.1. Alur Penelitian	20
Gambar 3.2. Root Node Dataset Stroke Prediction	33
Gambar 3.2. Pohon Keputusan Dataset Stroke Prediction	34
Gambar 4.1. Dataset Stroke Prediction	35
Gambar 4.2 Grafik Komposisi Kelas	36
Gambar 4.3. Perhitungan Jumlah Null Values	37
Gambar 4.4. Kode Python Pengisian Nilai Null	37
Gambar 4.5. Attribut Bmi Sebelum Pengisian Null	37
Gambar 4.6. Attribut Bmi Setelah Pengisian Null	38
Gambar 4.7. Kode Python Transformasi Data	39
Gambar 4.8. Dataset Sebelum Transformasi Data	39
Gambar 4.9. Dataset Setelah Transformasi Data	39
Gambar 4.10. Split Data	40
Gambar 4.11. Diagram Bar Data Sebelum Implementasi SMOTE	41
Gambar 4.12. Diagram Bar Data Setelah Implementasi SMOTE	41
Gambar 4.13. Kode Python Naïve Bayes dengan SMOTE	42
Gambar 4.14. Kode Python Naïve Bayes tanpa SMOTE	43
Gambar 4.15. Kode Pyhton K-Nearest Neigbor dengan SMOTE	43
Gambar 4.16. Kode Pyhton K-Nearest Neigbor tanpa SMOTE	43
Gambar 4.17. Kode Pyhton Decision Tree C4.5 dengan SMOTE	44
Gambar 4.18. Kode Pyhton Decision Tree C4.5 tanpa SMOTE	44
Gambar 4.19 Grafik Perbandingan Kinerja Algoritma Klasifikasi	47

DAFTAR LAMBANG DAN SINGKATAN

σ Standar Deviasi

μ Rata-rata

SVM Support Vector Machines

NBC Naïve Bayes Classifier

KNN K-Nearest Neighbor

TP True Positive

TN True Negative

FP False Positive

FN False Negative

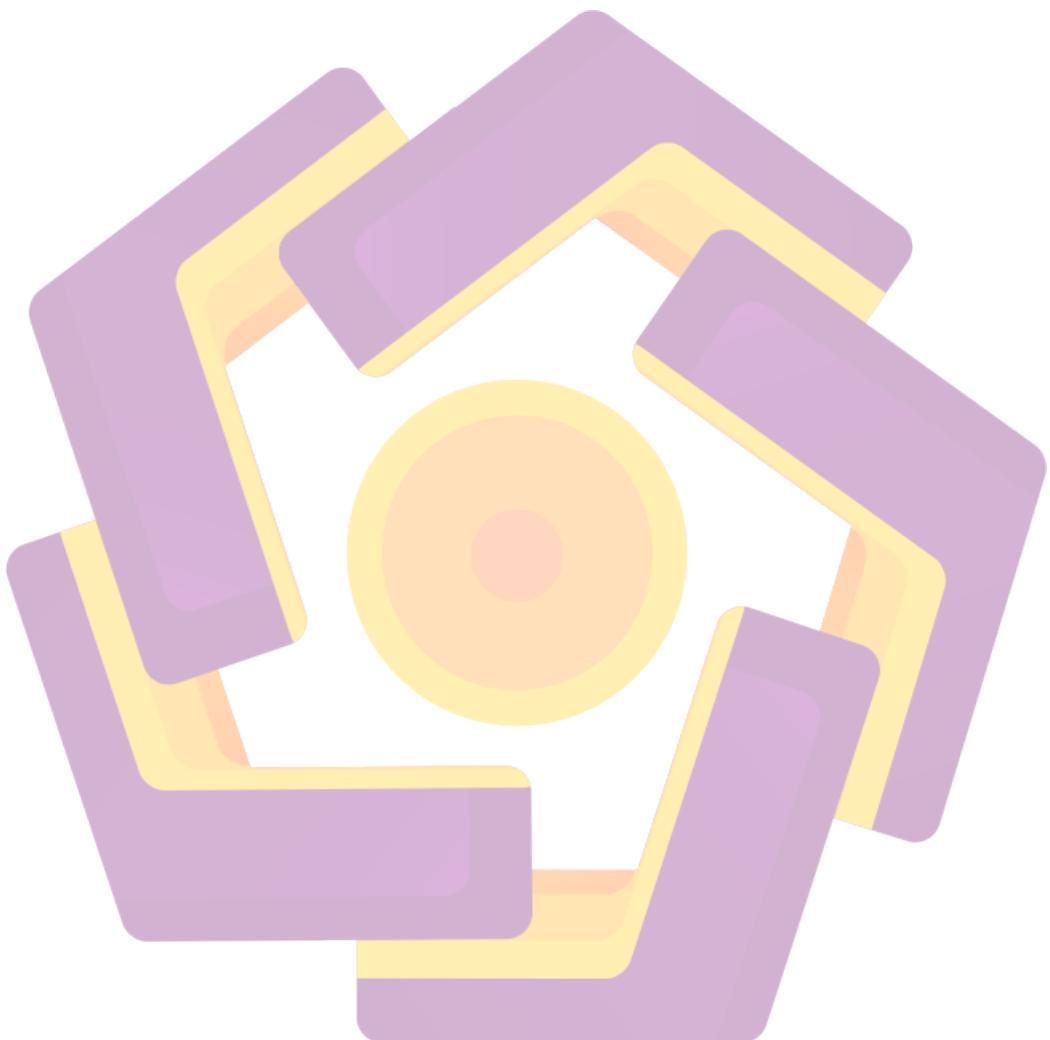
SMOTE Synthetic Minority Oversampling Technique

DAFTAR ISTILAH

Akurasi	Total akumulasi data yang diklasifikasi benar oleh classifier
Classifier	Model machine learning yang berfungsi mengklasifikasi data
Data Testing	Data yang digunakan untuk pengetesan model
Data Training	Data yang digunakan untuk pelatihan model
G-mean	Hasil evaluasi akurasi pada kelas positif dan negatif
Library	Sebuah modul yang menyimpan banyak fungsi untuk dipakai saat melakukan pemrograman
Precision	Banyaknya data yang benar positif pada data yang diprediksi sebagai positif
Sensitivity	Proporsi data positif yang diklasifikasi benar sebagai positif
Sklearn	Salah satu library pada bahasa pemrograman python
Specificity	Proporsi data negatif yang diklasifikasi benar sebagai negative
Imbalance Class	Ketidakseimbangan proporsi kelas pada suatu dataset
Resampling	Penyeimbangan proporsi kelas pada suatu dataset
Undersampling	Penyeimbangan proporsi kelas dengan mengurangi jumlah data kelas mayoritas

Oversampling

Penyeimbangan proporsi kelas dengan menambah jumlah data kelas minoritas



INTISARI

Permasalahan pada kasus klasifikasi data mining yang cukup sering terjadi yaitu adanya imbalance class pada suatu dataset yang dapat mempengaruhi kualitas klasifikasi pada model machine learning sehingga model tidak dapat memprediksi dengan benar kedua kelas secara seimbang.

Penelitian ini bertujuan mengaplikasikan algoritma SMOTE *oversampling* untuk menangani permasalahan *imbalance class* pada dataset *stroke prediction* dan melakukan perbandingan hasil pada algoritma klasifikasi yang diimplementasikan SMOTE dan tanpa SMOTE. Algoritma yang digunakan yakni Naïve Bayes Classifier, C4.5 dan K-Nearest Neighbor. Uji evaluasi dilakukan menggunakan *g-mean*, *confusion matrix* dan akurasi.

Hasil yang didapatkan dari penelitian ini adalah SMOTE mempengaruhi penurunan nilai akurasi pada tiap algoritma klasifikasi seperti pada algoritma C4.5 terjadi penurunan nilai akurasi sebesar 3%, KNN dengan penurunan nilai akurasi sebesar 12% dan NBC turun sebesar 16%. Namun disisi lain nilai g-mean pada algoritma klasifikasi yang telah dilakukan SMOTE mengalami peningkatan seperti pada algoritma C4.5 mengalami peningkatan nilai g-mean setelah diimplementasikan SMOTE sebesar 13%, KNN dengan peningkatan yang cukup tinggi yakni 45% dan NBC dengan peningkatan yang sedikit yaitu 4%.

Kata kunci: Data Mining, Imbalance Class, Klasifikasi, Oversampling, Synthetic Minority Over-sampling Technique (SMOTE)

ABSTRACT

The problem in the data mining classification case that occurs quite frequently is the imbalance class in a dataset which can affect the classification quality of the machine learning model so that the model cannot correctly predict both classes in a balanced way.

This study aims to apply the SMOTE oversampling algorithm to address the class imbalance problem in the stroke prediction dataset and to compare the results of the classification algorithm implemented with SMOTE and without SMOTE. The algorithms used are Naïve Bayes Classifier, C4.5 and K-Nearest Neighbor. Evaluation test is carried out using g-mean, confusion matrix and accuracy.

The results obtained from this study are that SMOTE affects the decrease in the accuracy value of each classification algorithm as in the C4.5 algorithm there is a decrease in the accuracy value of 3%, KNN with a decrease in the accuracy value of 12% and NBC decreases by 16%. But on the other hand the g-mean value of the classification algorithm that has been carried out by SMOTE has increased as in the C4.5 algorithm the g-mean value has increased after implementing SMOTE by 13%, KNN with a fairly high increase of 45% and NBC with a slight increase which is about 4%.

Keyword: Data Mining, Imbalance Class, Classification, Oversampling, Synthetic Minority Over-sampling Technique (SMOTE)