

**IMPLEMENTASI METODE OVER SAMPLING UNTUK
MENINGKATKAN PERFORMA RANDOM FOREST
CLASSIFICATION PADA DATA YANG TIDAK SEIMBANG**

SKRIPSI

Diajukan untuk memenuhi salah satu syarat mencapai derajat Sarjana
Program Studi S1 Informatika



disusun oleh

CHERFLY KAOPE

19.11.3012

Kepada

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2022

**IMPLEMENTASI METODE OVER SAMPLING UNTUK
MENINGKATKAN PERFORMA RANDOM FOREST
CLASSIFICATION PADA DATA YANG TIDAK SEIMBANG**

SKRIPSI

untuk memenuhi salah satu syarat mencapai derajat Sarjana
Program Studi S1 Informatika



disusun oleh

CHERFLY KAOPE

19.11.3012

Kepada

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2022**

HALAMAN PERSETUJUAN

SKRIPSI

IMPLEMENTASI METODE OVER SAMPLING UNTUK MENINGKATKAN PERFORMA RANDOM FOREST CLASSIFICATION PADA DATA YANG TIDAK SEIMBANG

yang disusun dan diajukan oleh

Cherfly Kaope

19.11.3012

telah disetujui oleh Dosen Pembimbing Skripsi
pada tanggal 24 November 2022

Dosen Pembimbing,

Anna Balta, M.Kom.

NIK. 190302290

HALAMAN PENGESAHAN

SKRIPSI

IMPLEMENTASI METODE OVER SAMPLING UNTUK MENINGKATKAN PERFORMA RANDOM FOREST CLASSIFICATION PADA DATA YANG TIDAK SEIMBANG

yang disusun dan diajukan oleh

Cherfly Kaope

19.11.3012

Telah dipertahankan di depan Dewan Penguji
pada tanggal 24 November 2022

Susunan Dewan Penguji

Nama Penguji

Tanda Tangan

Mardhiya Hayatv, S.T., M.Kom.
NIK. 190302108

Yuli Astuti, M.Kom
NIK. 190302146

Anna Balta, M.Kom.
NIK. 190302290

Skrripsi ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Sarjana Komputer
Tanggal 24 November 2022

DEKAN FAKULTAS ILMU KOMPUTER

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

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Yang bertandatangan di bawah ini,

Nama mahasiswa : Cherfly Kaope
NIM : 19.11.3012

Menyatakan bahwa Skripsi dengan judul berikut:

IMPLEMENTASI METODE OVER SAMPLING UNTUK MENINGKATKAN PERFORMA RANDOM FOREST CLASSIFICATION PADA DATA YANG TIDAK SEIMBANG.

Dosen Pembimbing : Anna Batta, M.Kom

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, 24 November 2022

Yang Menyatakan,

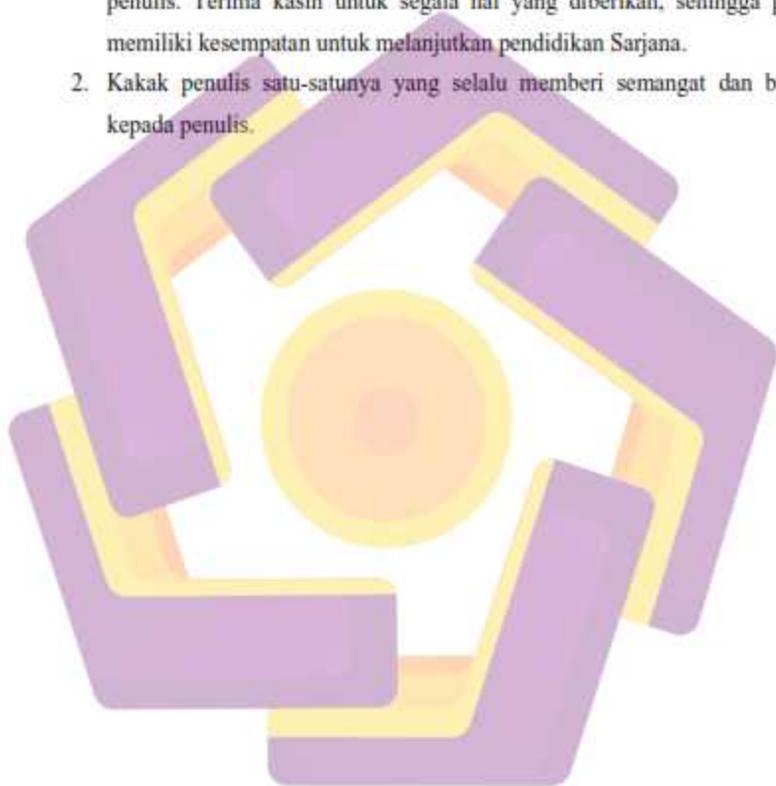


Cherfly Kaope

HALAMAN PERSEMBAHAN

Segala puji syukur ke hadirat Tuhan Yang Maha Esa yang telah memberikan berkat dan pertolongan-Nya, sehingga penulis dapat menyelesaikan skripsi ini dengan baik. Skripsi ini penulis persembahkan kepada:

1. Ayah dan ibu tercinta yang senantiasa memberikan dukungan dan doa kepada penulis. Terima kasih untuk segala hal yang diberikan, sehingga penulis memiliki kesempatan untuk melanjutkan pendidikan Sarjana.
2. Kakak penulis satu-satunya yang selalu memberi semangat dan bantuan kepada penulis.



KATA PENGANTAR

Segala puji syukur ke hadirat Tuhan Yang Maha Esa atas kasih dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan judul “Implementasi Metode Over Sampling untuk Meningkatkan Performa Random Forest Classification pada Data yang Tidak Seimbang”.

Dalam menyusun skripsi ini, penulis memperoleh banyak arahan, saran, dan kritik, sehingga penulis dapat menyelesaikan skripsi ini dengan baik. Oleh karena itu, penulis ingin mengucapkan terima kasih kepada:

1. Ibu Anna Baita, M. Kom. selaku dosen pembimbing atas waktu, saran, dan bimbingannya dalam penyusunan skripsi ini.
2. Seluruh dosen penguji atas saran yang diberikan, sehingga skripsi ini menjadi lebih baik.
3. Keluarga penulis khususnya orang tua dan kakak penulis yang selalu memberikan dukungan dan doa kepada penulis.
4. Rekan-rekan penulis kelas Informatika 07 angkatan 2019.
5. Seluruh pihak yang telah membantu penulis dan tidak bisa penulis sebutkan satu persatu.

Penulis menyadari skripsi ini masih memiliki keterbatasan. Untuk itu penulis menerima segala kritik dan saran yang bersifat membangun. Penulis berharap skripsi ini dapat memberi manfaat untuk pembaca dan khususnya sebagai referensi untuk penelitian terkait.

Yogyakarta, 24 November 2022

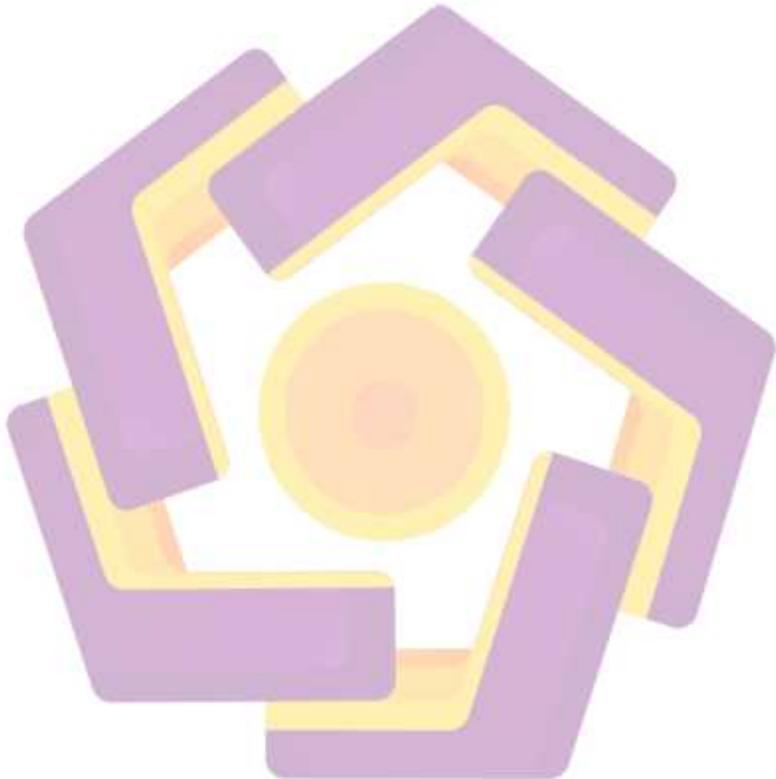
Penulis

DAFTAR ISI

SAMPUL	I
HALAMAN JUDUL	II
HALAMAN PERSETUJUAN	III
HALAMAN PENGESAHAN	IV
HALAMAN PERNYATAAN KEASLIAN SKRIPSI	V
HALAMAN PERSEMBAHAN	VI
KATA PENGANTAR	VII
DAFTAR ISI	VIII
DAFTAR TABEL	XI
DAFTAR GAMBAR	XII
INTISARI	XIII
ABSTRACT	XIV
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	2
1.3 Batasan Masalah.....	2
1.4 Tujuan Penelitian.....	3
1.5 Manfaat Penelitian.....	3
1.5.1 Manfaat Teoritis.....	3
1.5.2 Manfaat Praktis.....	3
1.6 Sistematika Penulisan.....	3
BAB II TINJAUAN PUSTAKA	5
2.1 Studi Literatur.....	5
2.2 Dasar Teori.....	17
2.2.1 Klasifikasi.....	17

2.2.2	Random Forest	18
2.2.3	Imbalanced Data.....	20
2.2.4	Preprocessing	22
2.2.5	Seleksi Fitur.....	22
2.2.6	Recursive Feature Elimination (RFE).....	23
2.2.7	Data Splitting.....	23
2.2.8	GridSearchCV	23
2.2.9	Adaptive Synthetic Sampling (ADASYN)	23
2.2.10	Synthetic Minority Oversampling Technique (SMOTE).....	25
2.2.11	Borderline-SMOTE.....	27
2.2.12	Evaluasi.....	30
BAB III METODE PENELITIAN		32
3.1	Tahapan Penelitian.....	32
3.2	Preprocessing Data.....	33
3.3	Data Splitting.....	34
3.4	Oversampling Data	34
3.5	Hyperparameter Tuning.....	35
3.6	Klasifikasi	35
3.7	Evaluasi.....	36
BAB IV HASIL DAN PEMBAHASAN		37
4.1	Deskripsi Dataset	37
4.2	Hasil Preprocessing.....	40
4.3	Pembagian Data	40
4.4	Proses Oversampling.....	41
4.5	Hasil Hyperparameter Tuning.....	42
4.6	Evaluasi Kinerja Klasifikasi.....	43
4.5.1	Perbandingan Nilai Recall dan G-mean.....	44

4.5.2 Persentase Kenaikan Performa Setelah Oversampling	47
BAB V KESIMPULAN	46
5.1 Kesimpulan	46
5.2 Saran.....	46
DAFTAR PUSTAKA.....	49



DAFTAR TABEL

Tabel 2.1 Keaslian Penelitian	9
Tabel 2.2 <i>Confusion Matrix</i>	30
Tabel 3.1 Fitur Glass1	33
Tabel 3.2 Fitur Page-blocks0	34
Tabel 3.3 Fitur Yeast1	34
Tabel 3.4 Fitur Yeast6	34
Tabel 3.5 Parameter <i>classifier</i> 80:20	35
Tabel 3.6 Parameter <i>classifier</i> 70:30	35
Tabel 4.1 Deskripsi Dataset	37
Tabel 4.2 Dataset Setelah Preprocessing	40
Tabel 4.3 Data Splitting	40
Tabel 4.4 Parameter Metode Oversampling	41
Tabel 4.5 Proporsi Data Sebelum Oversampling	41
Tabel 4.6 Proporsi Data Setelah Oversampling	41
Tabel 4.7 Akurasi Sebelum Hyperparameter Tuning	42
Tabel 4.8 Akurasi Setelah Hyperparameter Tuning	42
Tabel 4.9 Hasil Klasifikasi Data 80:20	43
Tabel 4.10 Hasil Klasifikasi Data 70:30	44
Tabel 4.11 Persentase Kenaikan Performa Setelah Oversampling	47

DAFTAR GAMBAR

Gambar 2.1 Tahapan Klasifikasi	17
Gambar 2.2 Random Forest Classifier.....	20
Gambar 2.3 Skema metode Synthetic Minority Oversampling Technique	26
Gambar 2.4 Kategori Data Tidak Seimbang pada Borderline-SMOTE	28
Gambar 3.1 Tahapan Penelitian.....	32
Gambar 4.1 Distribusi Dataset Glass1	37
Gambar 4.2 Distribusi Dataset Page-blocks0	38
Gambar 4.3 Distribusi Dataset Yeast1	39
Gambar 4.4 Distribusi Dataset Yeast6	39
Gambar 4.5 Recall 80:20	45
Gambar 4.6 Recall 70:30	45
Gambar 4.7 G-mean 80:20.....	46
Gambar 4.8 G-mean 70:30.....	47

INTISARI

Ketidakeimbangan data merupakan tantangan dalam pembelajaran mesin. Masalah data yang tidak seimbang menyebabkan pengklasifikasi bias terhadap kelas mayoritas dalam melakukan proses klasifikasi, sehingga hasil klasifikasi tidak dapat dipercaya.

Pada penelitian ini, metode SMOTE, ADASYN, dan Borderline-SMOTE diimplementasikan untuk meningkatkan jumlah sampel pada kelas minoritas, sehingga kelas dalam keadaan yang seimbang. Kemudian, data yang dihasilkan dari proses oversampling digunakan untuk membangun model klasifikasi. Fokus penelitian ini adalah untuk meningkatkan kinerja klasifikasi Random Forest dengan menerapkan beberapa metode oversampling pada data yang tidak seimbang dan menemukan metode oversampling terbaik untuk mengatasi masalah ketidakseimbangan data dalam klasifikasi Random Forest.

Kinerja klasifikasi diukur menggunakan *accuracy*, *recall*, *f1-score*, dan *g-mean* dengan dua skenario pembagian data. Hasil penelitian menunjukkan metode oversampling dapat membantu meningkatkan performa klasifikasi Random Forest dengan rata-rata peningkatan *recall* pada metode SMOTE 42,57%, ADASYN 50,6%, dan Borderline-SMOTE 53,28%. Kemudian, peningkatan *g-mean* pada metode SMOTE 19,08%, ADASYN 20,04%, dan Borderline-SMOTE 21,21%. Berdasarkan pengujian kinerja pada keempat dataset, metode yang menghasilkan performa klasifikasi paling baik ditunjukkan oleh integrasi metode Borderline-SMOTE dan Random Forest, dengan hasil klasifikasi yang lebih tinggi dibandingkan dengan metode SMOTE dan ADASYN.

Kata Kunci: Ketidakeimbangan Data, Klasifikasi, Oversampling, Random Forest

ABSTRACT

Data imbalances are a challenge in machine learning. The problem of imbalanced data causes the classifier to be biased towards the majority class in carrying out the classification process, so the classification results are not reliable.

In this study, the SMOTE, ADASYN, and Borderline-SMOTE methods were implemented to increase the number of samples in the minority class, so that the classes were in a balanced state. Then, the data generated from the oversampling process is used to build the classification model. The focus of this study is to improve the classification performance of the Random Forest by applying several oversampling methods to imbalanced data and finding the best oversampling method to deal with data imbalance problems in the Random Forest classification.

Classification performance was measured using accuracy, recall, f1-score, and g-mean in two data splitting scenarios. The results showed that the oversampling method could help improve the performance of Random Forest classification with an average increase in recall using the SMOTE method of 42.57%, ADASYN 50.6%, and Borderline-SMOTE 53.28%. Then, the g-mean increase in the SMOTE method was 19.08%, ADASYN 20.04%, and Borderline-SMOTE 21.21%. Based on performance testing on four datasets, the method that produces the best classification performance is demonstrated by the integration of Borderline-SMOTE and Random Forest methods, with higher classification results compared to the SMOTE and ADASYN methods.

Keyword: *Imbalanced data, Classification, Oversampling, Random Forest*