

**ALGORITMA XGBOOST UNTUK MENINGKATKAN KINERJA MODEL
MACHINE LEARNING PADA MULTICLASS IMBALANCED DATASET**

SKRIPSI



disusun oleh :

Zulfikar Murakabiman

18.11.2474

**PROGRAM SARJANA
PROGRAM STUDI INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2022**

ALGORITMA XGBOOST UNTUK MENINGKATKAN KINERJA MODEL MACHINE LEARNING PADA MULTICLASS IMBALANCED DATASET

SKRIPSI

untuk memenuhi sebagian persyaratan
mencapai gelar Sarjana
pada Program Studi Informatika



disusun oleh :

Zulfikar Murakabiman

18.11.2474

**PROGRAM SARJANA
PROGRAM STUDI INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2022**

PERSETUJUAN

SKRIPSI

ALGORITMA XGBOOST UNTUK MENINGKATKAN KINERJA MODEL MACHINE LEARNING PADA MULTICLASS IMBALANCED DATASET

yang dipersiapkan dan disusun oleh

Zulfikar Murakabiman

18.11.2474

telah disetujui oleh Dosen Pembimbing Skripsi
pada tanggal 9 Februari 2022

Dosen Pembimbing,

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

NIK. 190302412

PENGESAHAN
SKRIPSI

**ALGORITMA XGBOOST UNTUK MENINGKATKAN KINERJA
MODEL MACHINE LEARNING PADA MULTICLASS IMBALANCED
DATASET**

yang dipersiapkan dan disusun oleh
Zulfikar Murakabiman

18.11.2474

telah dipertahankan di depan Dewan Pengaji
pada tanggal 17 Februari 2022

Susunan Dewan Pengaji

Nama Pengaji

Tanda Tangan

Arif Akbarul Huda, S.Si, M.Eng
NIK. 190302287

Uyock Anggoro Saputro, M.Kom
NIK. 190302419

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

Skripsi ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Sarjana Komputer
Tanggal 21 April 2022

DEKAN FAKULTAS ILMU KOMPUTER

Hanif Al Fatta, M.Kom
NIK. 190302096

PERNYATAAN

Saya yang bertandatangan dibawah ini menyatakan bahwa, skripsi ini merupakan karya saya sendiri (ASLI), dan isi dalam skripsi ini tidak terdapat karya yang pernah diajukan oleh orang lain untuk memperoleh gelar akademis di suatu institusi pendidikan tinggi manapun, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis dan/atau diterbitkan oleh orang lain, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Segala sesuatu yang terkait dengan naskah dan karya yang telah dibuat adalah menjadi tanggungjawab saya pribadi.

Yogyakarta, 19 April 2022

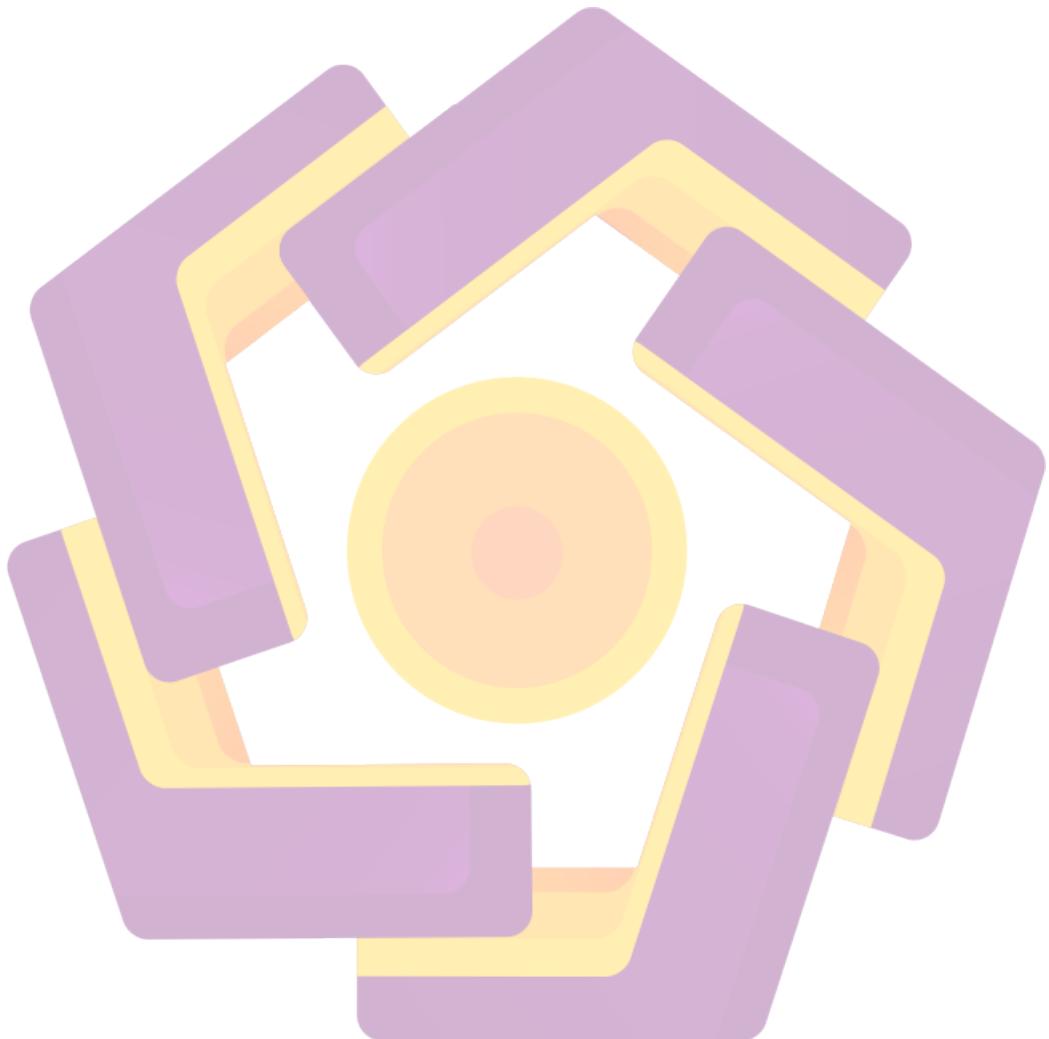


Zulfikar Murakabiman
NIM. 18.11.2474

MOTTO

Luck is what happens when preparation meets opportunity

(Seneca)



PERSEMBAHAN

Alhamdulillah penulis panjatkan pujisyukur kepada Allah SWT atas segala rahmat, taufiq, serta hidayah-Nya, sehingga diberi kesempatan untuk dapat menyelesaikan skripsi ini dengan sebaik-baiknya dengan segala kekurangan penulis. Segala syukur penulis ucapkan kepada-Mu karena telah menghadirkan mereka yang memberikan semangat dan doa disaat menjalani proses pembuatan skripsi ini. Dengan segala kerendahan hati saya persembahkan skripsi ini kepada semua orang yang terlibat dan mendukung saya dalam pengerjaan skripsi ini.

Saya ucapkan terima kasih yang sebesar-besarnya untuk kalian semua. Mohon maaf jika ada salah kata atau perbuatan baik yang disengaja maupun tidak disengaja selama ini. Sukses untuk kalian semua, semoga Allah SWT memberikan rahmat dan hidayah-Nya kepada kita semua. Dan semoga skripsi ini dapat bermanfaat dan berguna untuk kemajuan ilmu pengetahuan kedepannya.

KATA PENGANTAR

Alhamdulillah penulis panjatkan puji syukur kepada Allah SWT atas segala rahmat, taufiq, serta hidayah-Nya kepada penulis sehingga dapat menyelesaikan skripsi yang berjudul “Algoritma XGBoost Untuk Meningkatkan Kinerja Model Machine Learning pada Multiclass Imbalanced Dataset”.

Selama prosespengerjaan skripsi ini penulis menyadari bahwa dalam proses penulisan skripsi ini banyak mengalami kendala, namun berkat bantuan, bimbingan, kerjasama dari berbagai pihak dan berkah dari Allah SWT sehingga kendala-kendala tersebut bisa diatasi. Selanjutnya ucapan terima kasih penulis sampaikan kepada :

1. Bapak Prof. Dr. M. Suyanto, M.M selaku Rektor Universitas Amikom Yogyakarta.
2. Bpk. Yoga Pristyanto, S.Kom, M.Eng selaku dosen pembimbing yang telah memberikan banyak masukkan yang membantu membimbing dalam menyelesaikan skripsi ini.
3. Kedua orang tua dan keluarga yang selalu memberikan doa, dukungan dan semangat.
4. Serta semua pihak yang tidak bisa penulis sebutkan satu-persatu yang telah membantu dalam penyusunan skripsi ini.

Penulis Menyadari bahwa masih banyak terdapat kekurangan-kekurangan dalam mengerjakan skripsi ini, sehingga penulis mengharapkan adanya saran dan kritik yang membangun demi kesempurnaan skripsi ini.

Yogyakarta, 10 Februari 2022

Zulfikar Murakabiman

NIM. 18.11.2474

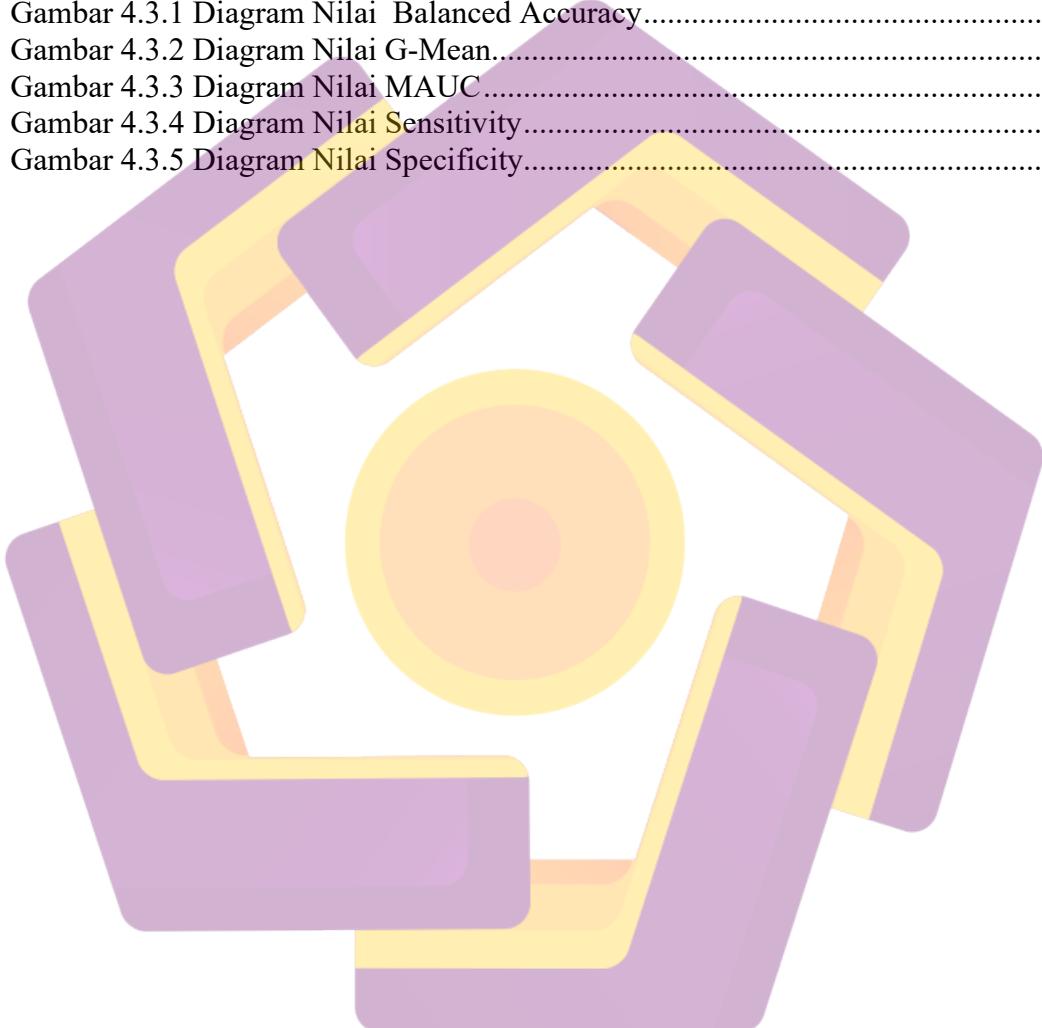
DAFTAR ISI

| | |
|---|------|
| HALAMAN SAMPUL | i |
| HALAMAN JUDUL..... | ii |
| PERSETUJUAN | iii |
| PENGESAHAN | iv |
| PERNYATAAN..... | v |
| MOTTO | vi |
| PERSEMBAHAN..... | vii |
| KATA PENGANTAR | viii |
| DAFTAR ISI..... | ix |
| DAFTAR GAMBAR | xi |
| DAFTAR TABEL..... | xii |
| INTISARI..... | xiii |
| ABSTRACT..... | xiv |
| BAB I | 1 |
| PENDAHULUAN | 1 |
| 1.1 Latar Belakang Masalah | 1 |
| 1.2 Rumusan Masalah | 6 |
| 1.3 Batasan Penelitian | 6 |
| 1.4 Tujuan Penelitian..... | 7 |
| 1.5 Manfaat Penelitian..... | 7 |
| 1.6 Metode Penelitian..... | 8 |
| 1.6.1 Metode Pengumpulan Data..... | 8 |
| 1.6.2 Metode Klasifikasi dan Penanganan Ketidakseimbangan Kelas. | 8 |
| 1.6.3 Metode Evaluasi..... | 8 |
| 1.7 Sistematika Penulisan..... | 9 |
| BAB II..... | 11 |
| TINJUAN PUSTAKA DAN LANDASAN TEORI..... | 11 |
| 2.1 Tinjauan Pustaka | 11 |
| 2.2 Landasan Teori | 22 |

| | | |
|-----------------------------------|---|-----------|
| 2.2.1 | Data Mining | 22 |
| 2.2.2 | Boosting | 22 |
| 2.2.3 | XGBoost..... | 24 |
| 2.2.4 | Data Preprocessing..... | 26 |
| 2.2.5 | Evaluasi Model..... | 27 |
| BAB III | | 31 |
| METODOLOGI PENELITIAN..... | | 31 |
| 3.1 | Gambaran Umum | 31 |
| 3.2 | Alat dan Bahan | 31 |
| 3.2.1 | Alat..... | 31 |
| 3.2.2 | Bahan..... | 32 |
| 3.3 | Jalannya Penelitian..... | 40 |
| 3.4 | Pra Pemrosesan Data | 41 |
| 3.5 | Klasifikasi dan Penanganan Ketidakseimbangan Kelas..... | 41 |
| 3.6 | Evaluasi | 43 |
| BAB IV | | 45 |
| HASIL DAN PEMBAHASAN..... | | 45 |
| 4.1 | Dataset | 45 |
| 4.2 | Pra Pemrosesan Data | 47 |
| 4.3 | Implementasi Algoritma Klasifikasi..... | 48 |
| 4.3.1 | Nilai Balanced Accuracy..... | 48 |
| 4.3.2 | Nilai G-Mean | 50 |
| 4.3.3 | Nilai MAUC..... | 52 |
| 4.3.4 | Nilai Sensitivity..... | 54 |
| 4.3.5 | Nilai Specificity | 56 |
| BAB V..... | | 59 |
| KESIMPULAN DAN SARAN..... | | 59 |
| 5.1 | Kesimpulan..... | 59 |
| 5.2 | Saran | 59 |
| DAFTAR PUSTAKA | | 61 |

DAFTAR GAMBAR

| | |
|---|----|
| Gambar 3.3.1 Alur Penelitian | 40 |
| Gambar 3.5.1 Gambaran Model XGBoost..... | 42 |
| Gambar 4.1.1 Grafik Distribusi Kelas Dataset..... | 47 |
| Gambar 4.3.1 Diagram Nilai Balanced Accuracy..... | 49 |
| Gambar 4.3.2 Diagram Nilai G-Mean..... | 51 |
| Gambar 4.3.3 Diagram Nilai MAUC..... | 53 |
| Gambar 4.3.4 Diagram Nilai Sensitivity..... | 55 |
| Gambar 4.3.5 Diagram Nilai Specificity..... | 57 |



DAFTAR TABEL

| | |
|--|----|
| Tabel 2.2.1 Contoh Missing Value | 27 |
| Tabel 2.2.2 Confusion Matrix | 28 |
| Tabel 3.2.1 Karakteristik Dataset..... | 32 |
| Tabel 3.2.2 car..... | 34 |
| Tabel 3.2.3 contraceptive | 34 |
| Tabel 3.2.4 glass..... | 35 |
| Tabel 3.2.5 hayes-roth..... | 35 |
| Tabel 3.2.6 new-thyroid | 36 |
| Tabel 3.2.7 pageblocks..... | 37 |
| Tabel 3.2.8 winequality-red | 37 |
| Tabel 3.2.9 winequality-white..... | 38 |
| Tabel 3.2.10 yeast | 39 |
| Tabel 3.6.1 XGBoost Confusion Matrix | 43 |
| Tabel 4.2.1 Hasil Dataset yang Menunjukan Nilai Missing Value..... | 47 |
| Tabel 4.3.1 Tabel Nilai Balanced Accuracy | 50 |
| Tabel 4.3.2 Tabel Nilai G-Mean | 52 |
| Tabel 4.3.3 Tabel Nilai MAUC..... | 54 |
| Tabel 4.3.4 Tabel Nilai Sensitivity | 56 |
| Tabel 4.3.5 Tabel Nilai Specificity | 57 |

INTISARI

Permasalahan ketidakseimbangan kelas pada dataset (*imbalanced dataset*) merupakan kondisi dimana nilai dari kelas minoritas sangat jauh lebih kecil dengan kelas mayoritas atau sangat kurang memadai sehingga model lebih mengenali pola pada kelas mayoritas dibanding kelas minoritas. Permasalahan tersebut merupakan salah satu tantangan yang sangat penting dalam penelitian *machine learning*, sehingga telah dikembangkan beberapa metode untuk mengatasinya. Namun metode-metode tersebut mayoritas hanya terfokus pada *binary dataset*, sehingga masih belum banyak metode yang terfokus pada *multiclass dataset*.

Penanganan *multiclass* tentu lebih sulit daripada *binary* karena melibatkan kelas yang lebih banyak. Untuk itu diperlukan algoritma yang memiliki fitur yang dapat mendukung penyesuaian terhadap kesulitan-kesulitan yang muncul pada *multiclass imbalanced dataset*, salah satu algoritma *ensemble* yang memiliki fitur-fitur untuk penyesuaian adalah algoritma XGBoost.

Pada 8 dari 9 dataset dengan metrik evaluasi *balanced accuracy*, *g-mean*, MAUC, *sensitivity*, dan *specificity*, algoritma XGBoost mampu mengungguli algoritma klasifikasi dan algoritma *ensemble* lain. Bahkan menyentuh nilai sempurna yaitu 1.00 pada dataset *new-thyroid*.

Kata Kunci: *Boosting*, XGBoost, Ketidakseimbangan Kelas, *Multiclass*, Klasifikasi.

ABSTRACT

Dataset imbalance problem is a condition where the number minority class is way smaller than the majority class or insufficient that the model recognizes patterns in the majority class more than the minority class. This problem is one of the most important challenges in machine learning research, so several methods have been developed to overcome it. However, the majority of these methods only focus on binary datasets, so there are still not many methods that focus on multiclass datasets.

Handling multiclass is certainly more difficult than binary because it involves more classes. For this reason, we need an algorithm that has features that can support adjustments to the difficulties that arise in multiclass imbalanced datasets, one of the ensemble algorithms that has features for adjustment is the XGBoost algorithm.

In 8 out of 9 datasets with evaluation metrics of balanced accuracy, g-mean, MAUC, sensitivity, and specificity, the XGBoost algorithm is able to outperform other classification algorithms and ensemble algorithms. It even hits a perfect score of 1.00 on the new-thyroid dataset.

Keywords: Boosting, XGBoost, Class Imbalance, Multiclass, Classification.