



Perbandingan Kinerja Naïve Bayes dengan dan Tanpa SMOTE untuk Klasifikasi Gangguan Kecemasan Mahasiswa pada Data Tidak Seimbang

Nurhadi Surojudin*, Sufajar Butsianto, Andri Firmansyah

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

Email: ^{1,*}nurhadi@pelitabangsa.ac.id, ²sufajar@pelitabangsa.ac.id, ³andrifirmansyah@pelitabangsa.ac.id

Email Penulis Korespondensi: nurhadi@pelitabangsa.ac.id

Abstrak—Gangguan kecemasan merupakan salah satu masalah kesehatan mental yang cukup umum terjadi pada mahasiswa dan dapat memengaruhi konsentrasi belajar serta performa akademik. Analisis data survei psikologis menggunakan teknik machine learning dapat membantu dalam proses deteksi dini kondisi kecemasan mahasiswa. Namun, salah satu tantangan dalam analisis data kesehatan mental adalah ketidakseimbangan distribusi kelas pada dataset. Penelitian ini bertujuan untuk menganalisis pengaruh penerapan Synthetic Minority Oversampling Technique (SMOTE) terhadap kinerja algoritma Naïve Bayes dalam klasifikasi multi-kelas tingkat kecemasan mahasiswa yang terdiri dari tiga kategori, yaitu No Stress, Eustress, dan Distress. Dataset yang digunakan berasal dari data kuesioner mahasiswa yang telah melalui tahap preprocessing, meliputi pembersihan data, transformasi atribut, serta pembagian dataset menggunakan metode hold-out dengan rasio 80% data training dan 20% data testing. Evaluasi model dilakukan menggunakan confusion matrix dengan metrik accuracy, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model Naïve Bayes tanpa SMOTE menghasilkan nilai accuracy sebesar 0.84, precision 0.78, recall 0.41, dan F1-score 0.54. Setelah penerapan SMOTE, model menghasilkan accuracy 0.82, precision 0.74, recall 0.69, dan F1-score 0.71. Hasil ini menunjukkan bahwa penerapan SMOTE membantu meningkatkan kemampuan model dalam mengenali kelas minoritas pada kasus klasifikasi multi-kelas meskipun terjadi sedikit penurunan pada nilai akurasi keseluruhan.

Kata Kunci: Naïve Bayes; SMOTE; Multi-Class Classification; Gangguan Kesehatan Mahasiswa; Data Tidak Seimbang

Abstract—Anxiety disorders are one of the most common mental health problems experienced by university students and may affect learning concentration and academic performance. The analysis of psychological survey data using machine learning techniques can support early detection of student anxiety conditions. However, one of the main challenges in mental health data analysis is the presence of class imbalance within the dataset. This study aims to analyze the effect of applying the Synthetic Minority Oversampling Technique (SMOTE) on the performance of the Naïve Bayes algorithm for multi-class classification of student anxiety levels, which are categorized into three classes: No Stress, Eustress, and Distress. The dataset used in this research was obtained from student questionnaire data and underwent several preprocessing steps including data cleaning, feature transformation, and dataset splitting using the hold-out method with a ratio of 80% training data and 20% testing data. Model performance was evaluated using a confusion matrix with evaluation metrics including accuracy, precision, recall, and F1-score. The results show that the Naïve Bayes model without SMOTE achieved an accuracy of 0.84, precision 0.78, recall 0.41, and F1-score 0.54. After applying SMOTE, the model achieved an accuracy of 0.82, precision 0.74, recall 0.69, and F1-score 0.71. These results indicate that SMOTE improves the model's ability to detect minority classes in multi-class classification problems, although a slight decrease in overall accuracy is observed.

Keywords: Naïve Bayes; SMOTE; Multi-Class Classification; Student Mental Health; Imbalanced Dataset

1. PENDAHULUAN

Mahasiswa berada pada fase perkembangan dewasa awal yang sering dihadapkan pada berbagai tuntutan akademik, sosial, dan psikologis [1]. Tekanan akademik, seperti penyelesaian tugas, ujian, dan tuntutan penyelesaian studi [4] [5], dapat memicu munculnya kondisi stres dan kecemasan yang memengaruhi konsentrasi belajar, performa akademik, serta kesejahteraan psikologis mahasiswa [6] [7]. Berbagai penelitian menunjukkan bahwa gangguan kecemasan merupakan salah satu masalah kesehatan mental yang cukup umum terjadi pada mahasiswa di berbagai perguruan tinggi [8]. Beberapa studi melaporkan bahwa prevalensi kecemasan pada mahasiswa dapat mencapai lebih dari 30% hingga 50%, bergantung pada karakteristik responden, konteks pendidikan, serta metode pengukuran yang digunakan. Oleh karena itu, deteksi dini terhadap kondisi kecemasan mahasiswa menjadi penting guna mendukung upaya pencegahan dan intervensi yang lebih efektif.

Seiring dengan meningkatnya ketersediaan data survei psikologis mahasiswa, pendekatan data mining dan machine learning mulai dimanfaatkan untuk menganalisis kondisi kesehatan mental secara lebih sistematis [9]. Teknik klasifikasi dalam machine learning memungkinkan identifikasi pola yang tersembunyi pada data psikologis mahasiswa sehingga dapat membantu dalam proses deteksi dini gangguan kecemasan. Salah satu algoritma yang sering digunakan dalam tugas klasifikasi adalah Naïve Bayes [10], yang bekerja berdasarkan prinsip probabilitas Bayes dengan asumsi independensi antar fitur [11]. Algoritma ini dikenal memiliki keunggulan dalam hal kesederhanaan implementasi, efisiensi komputasi, serta kemampuan yang cukup baik dalam menangani dataset dengan jumlah fitur yang relatif banyak [12]. Oleh karena itu, Naïve Bayes banyak digunakan dalam berbagai penelitian klasifikasi pada bidang kesehatan, pendidikan, maupun analisis perilaku manusia [13] [14].

Meskipun demikian, salah satu tantangan utama dalam analisis data psikologis adalah ketidakseimbangan distribusi kelas (imbalanced dataset) [15]. Pada dataset kesehatan mental mahasiswa, jumlah data pada setiap kategori kondisi psikologis sering kali tidak merata. Dalam penelitian ini, tingkat kecemasan mahasiswa diklasifikasikan ke dalam tiga kategori utama, yaitu *No Stress*, *Eustress*, dan *Distress*. Ketidakseimbangan distribusi data pada ketiga kelas tersebut dapat menyebabkan model klasifikasi cenderung bias terhadap kelas mayoritas dan kurang mampu mendeteksi kelas



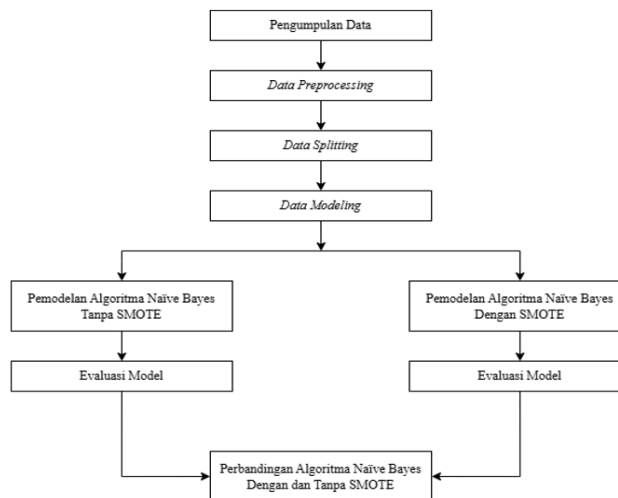
dengan jumlah data lebih sedikit. Kondisi ini menjadi permasalahan penting dalam pengembangan model klasifikasi yang akurat dan representatif.

Untuk mengatasi permasalahan ketidakseimbangan data, salah satu teknik yang banyak digunakan adalah Synthetic Minority Oversampling Technique (SMOTE) [16]. Teknik ini bekerja dengan menghasilkan sampel sintetis pada kelas minoritas berdasarkan kedekatan antar data dalam ruang fitur, sehingga distribusi kelas menjadi lebih seimbang tanpa mengurangi jumlah data pada kelas mayoritas. Berbagai penelitian menunjukkan bahwa penerapan SMOTE dapat meningkatkan performa model klasifikasi pada dataset tidak seimbang, khususnya dalam meningkatkan kemampuan model dalam mengenali kelas minoritas [17]. Namun demikian, sebagian besar penelitian sebelumnya lebih banyak berfokus pada kasus klasifikasi biner, sedangkan penerapan teknik penyeimbangan data pada kasus klasifikasi multi-kelas, khususnya dalam konteks analisis tingkat kecemasan mahasiswa, masih relatif terbatas dan memerlukan evaluasi lebih lanjut [18].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis pengaruh penerapan SMOTE terhadap kinerja algoritma Naïve Bayes dalam klasifikasi multi-kelas tingkat kecemasan mahasiswa pada dataset tidak seimbang [19]. Penelitian ini membandingkan performa model Naïve Bayes dengan dan tanpa penerapan SMOTE menggunakan metrik evaluasi yang lebih representatif untuk dataset tidak seimbang, yaitu precision, recall, F1-score, dan AUC-ROC [20], serta akurasi sebagai indikator performa umum [21]. Melalui pendekatan ini, penelitian diharapkan dapat memberikan pemahaman yang lebih komprehensif mengenai efektivitas teknik penyeimbangan data dalam meningkatkan kemampuan model klasifikasi dalam mendeteksi berbagai tingkat kecemasan mahasiswa secara lebih seimbang dan akurat [22].

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan klasifikasi berbasis machine learning untuk menganalisis tingkat kecemasan mahasiswa. Proses penelitian meliputi beberapa tahapan utama, yaitu pengumpulan data, pra-pemrosesan data, pembagian dataset, penerapan teknik penyeimbangan data menggunakan Synthetic Minority Oversampling Technique (SMOTE), pelatihan model menggunakan algoritma Naïve Bayes, serta evaluasi dan perbandingan kinerja model.



Gambar 2. Tahapan Penelitian

2.1. Pengumpulan Data

Pengumpulan data dalam penelitian ini menggunakan data sekunder berupa dataset kuesioner mahasiswa yang disimpan dalam format CSV. Setiap baris data merepresentasikan satu responden, sedangkan setiap kolom merepresentasikan variabel penelitian yang telah dikodekan secara numerik.

NO	GENDER	AGE	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15	P16	P17	P18	P19	P20	P21	P22	P23	CLASS	
1	0	18	5	5	3	4	4	3	2	1	1	4	1	1	3	5	5	5	5	5	5	1	4	3	2	Eustress	
2	0	20	2	3	2	1	1	1	1	1	4	2	1	2	1	2	4	3	2	1	1	3	2	1	4	2	Eustress
3	1	21	4	4	2	4	5	5	4	5	4	4	4	4	4	3	4	3	4	4	3	3	2	5	2	Distress	
4	1	19	4	4	3	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	2	2	3	3	Distress	
5	0	20	3	3	3	2	2	4	4	4	4	1	1	1	2	1	2	3	1	2	2	4	2	2	2	Eustress	
6	0	18	3	2	2	3	2	3	4	1	1	1	1	2	3	1	4	2	1	3	5	4	4	1	2	Eustress	
7	1	19	2	1	2	4	3	3	2	2	4	3	1	1	2	2	1	1	1	1	1	1	2	3	1	No Stress	
8	0	20	5	5	5	2	4	2	1	1	2	2	4	1	2	1	1	4	2	4	3	1	1	1	5	Eustress	
9	1	20	3	2	1	5	3	5	1	1	2	3	2	3	3	4	4	4	2	4	4	3	1	5	1	Eustress	
10	1	21	3	4	2	1	1	2	1	2	3	4	3	2	2	1	1	1	1	1	1	1	2	4	2	No Stress	
...
842	1	21	4	4	2	4	5	5	4	5	4	4	4	4	4	3	4	3	4	4	3	3	2	5	2	Distress	
843	0	20	5	2	2	2	3	2	1	1	1	1	1	5	2	2	3	2	2	1	1	1	1	4	1	Eustress	

Gambar 3. Struktur Dataset Gangguan Kecemasan Mahasiswa.



Dataset ditampilkan dalam format tabular, di mana setiap baris merepresentasikan satu responden dan setiap kolom (P1–P26) merepresentasikan variabel penelitian. Variabel P1–P25 merupakan variabel fitur, sedangkan P26 digunakan sebagai variabel target (kelas) dalam proses klasifikasi.

2.2. Preprocessing Data

Tahap *preprocessing data* bertujuan untuk meningkatkan kualitas dataset agar siap digunakan dalam proses pemodelan klasifikasi. Tahapan ini meliputi pembersihan data, penyamaan skala fitur numerik, serta pengodean fitur kategorikal ke dalam bentuk numerik.

2.2.1. Cleaning Data

a. Pemeriksaan missing value

Tabel 1. Cek Missing Value

Keterangan	Nilai
Jumlah atribut	26
Atribut dengan nilai kosong	0
Total missing value	0

Hasil pemeriksaan menunjukkan bahwa seluruh atribut pada dataset tidak memiliki nilai kosong sehingga tidak diperlukan proses penanganan missing value.

b. Penghapusan data duplikat

Tabel 2. Penghapusan Data Duplikat

Keterangan	Jumlah Data
Total dataset awal	843
Data duplikat terdeteksi	27
Dataset setelah penghapusan duplikat	816
Data duplikat setelah pembersihan	0

Tabel 2 menunjukkan hasil pemeriksaan dan penghapusan data duplikat pada dataset penelitian. Dari total 843 data awal, ditemukan 27 data duplikat yang memiliki nilai atribut identik. Data duplikat tersebut kemudian dihapus untuk memastikan bahwa setiap data yang digunakan dalam analisis bersifat unik dan tidak menimbulkan bias pada proses pemodelan. Setelah proses penghapusan dilakukan, dataset yang digunakan dalam penelitian berjumlah 816 data dan tidak ditemukan lagi data duplikat.

c. Penyaringan dataset berdasarkan usia

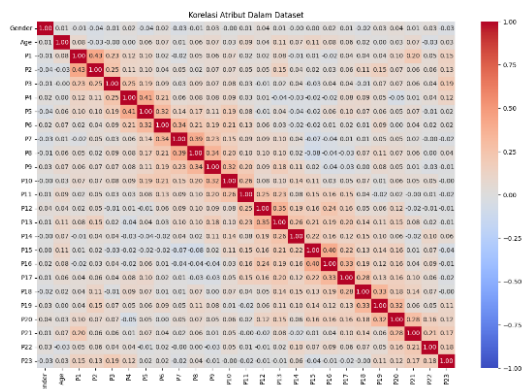
Tabel 3. Penyaringan Dataset Berdasarkan Usia

Keterangan	Jumlah Data
Dataset awal	843
Data di luar rentang usia 18–24	60
Dataset setelah penyaringan	783

Hasil penyaringan dataset berdasarkan rentang usia 18–24 tahun yang menghasilkan dataset akhir sebanyak 783 data dari total 843 data awal.

2.2.2. Korelasi Dataset

Heatmap korelasi antar atribut pada dataset gangguan kecemasan mahasiswa untuk melihat hubungan antar variabel sebelum proses pemodelan dilakukan.



Gambar 4. Heatmap Korelasi Antar Atribut Dataset



Gambar 4 menunjukkan visualisasi heatmap korelasi antar atribut pada dataset gangguan kecemasan mahasiswa. Korelasi dihitung menggunakan metode Pearson correlation untuk melihat hubungan antar variabel seperti Gender, Age, serta indikator kuesioner P1 hingga P23. Nilai korelasi berada pada rentang -1 hingga 1, dimana nilai yang mendekati 1 menunjukkan hubungan positif yang kuat, nilai yang mendekati -1 menunjukkan hubungan negatif yang kuat, sedangkan nilai yang mendekati 0 menunjukkan hubungan yang lemah atau tidak signifikan. Visualisasi ini membantu dalam memahami keterkaitan antar atribut sebelum dilakukan proses pemodelan klasifikasi menggunakan algoritma machine learning.

2.2.3. Transformasi Data

Tabel 4. Transformasi Data

Tahap	Hasil
Rename kolom	P1–P23
Label mapping	No Stress, Eustress, Distress

Transformasi data dilakukan dengan menyederhanakan nama atribut dataset menjadi format yang lebih ringkas, yaitu Gender, Age, P1 hingga P23, dan Class. Selain itu dilakukan pemetaan label pada variabel target untuk mengelompokkan tingkat stres mahasiswa menjadi tiga kategori utama, yaitu No Stress, Eustress, dan Distress. Proses transformasi ini bertujuan untuk menyesuaikan struktur dataset sehingga lebih mudah digunakan dalam proses analisis data dan pemodelan klasifikasi.

2.3. Data Splitting

Data splitting merupakan proses pembagian dataset menjadi dua bagian utama, yaitu data training dan data testing. Pembagian ini bertujuan untuk melatih model klasifikasi serta mengevaluasi kinerja model terhadap data yang belum pernah digunakan pada proses pelatihan.

Tabel 5. Jumlah *Splitting* Data Tanpa SMOTE

	Persentase	Jumlah x	Jumlah y
<i>Data Training</i>	80%	626	626
<i>Data Testing</i>	20%	157	157

Tabel 3 menunjukkan pembagian dataset pada proses data splitting sebelum penerapan metode SMOTE. Dataset dibagi menjadi dua bagian, yaitu data training sebesar 80% dan data testing sebesar 20% dari total dataset. Data training digunakan untuk melatih model klasifikasi Naïve Bayes, sedangkan data testing digunakan untuk mengevaluasi kinerja model. Hasil pembagian menunjukkan bahwa terdapat 626 data training dan 157 data testing, dengan jumlah atribut fitur (x) dan label kelas (y) yang sama pada masing-masing bagian dataset.

2.4. Data Modeling

Data modeling merupakan tahap pembangunan model klasifikasi menggunakan algoritma Naïve Bayes. Model diinisialisasi menggunakan metode GaussianNB() dan dilatih menggunakan data training melalui fungsi fit(x_train, y_train) untuk mempelajari pola hubungan antara atribut dataset dan label kelas. Model yang dihasilkan kemudian digunakan pada proses evaluasi kinerja klasifikasi.

2.4.1. Pemodelan Data Tanpa SMOTE

Pemodelan data tanpa SMOTE dilakukan dengan melatih algoritma Naïve Bayes menggunakan dataset asli. Model diinisialisasi menggunakan GaussianNB() dan dilatih dengan data training melalui fungsi fit(x_train, y_train) untuk mempelajari pola hubungan antara atribut dan label kelas.

Tabel 6. Proses Pemodelan Naïve Bayes Tanpa SMOTE

Tahap	Proses	Keterangan
Inisialisasi model	GaussianNB()	Membuat model klasifikasi Naïve Bayes
Pelatihan model	fit(x_train, y_train)	Melatih model menggunakan data training tanpa SMOTE

Pemodelan dilakukan menggunakan algoritma Gaussian Naïve Bayes dengan data training yang belum melalui proses penyeimbangan kelas menggunakan metode SMOTE.

2.4.2. Pemodelan Data Dengan SMOTE

Pemodelan data dengan SMOTE dilakukan dengan terlebih dahulu menerapkan metode Synthetic Minority Oversampling Technique (SMOTE) untuk menyeimbangkan distribusi kelas pada dataset.

Tabel 7. Distribusi Dataset Sebelum dan Sesudah SMOTE

Kelas	Sebelum SMOTE	Sesudah SMOTE
No Stress	38	715



Kelas	Sebelum SMOTE	Sesudah SMOTE
Eustress	715	715
Distress	30	715

Tabel 7 menunjukkan perbandingan distribusi jumlah data pada setiap kelas sebelum dan sesudah penerapan metode Synthetic Minority Oversampling Technique (SMOTE). Sebelum penerapan SMOTE, dataset memiliki ketidakseimbangan kelas dimana jumlah data pada kelas Eustress jauh lebih besar dibandingkan kelas No Stress dan Distress. Setelah proses SMOTE dilakukan, jumlah data pada setiap kelas menjadi lebih seimbang karena metode ini menghasilkan data sintesis pada kelas minoritas. Penyeimbangan dataset ini bertujuan untuk meningkatkan kemampuan model klasifikasi dalam mengenali seluruh kelas secara lebih proporsional.

2.4.3. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja algoritma Naïve Bayes dalam mengklasifikasikan tingkat gangguan kecemasan mahasiswa. Proses evaluasi dilakukan menggunakan data testing yang sebelumnya telah dipisahkan pada tahap data splitting. Kinerja model dianalisis menggunakan confusion matrix, yang kemudian digunakan untuk menghitung beberapa metrik evaluasi klasifikasi, yaitu accuracy, precision, recall, dan F1-score. Metrik tersebut digunakan untuk menilai kemampuan model dalam memprediksi kelas secara tepat, khususnya pada kondisi dataset yang tidak seimbang. Confusion matrix menggambarkan perbandingan antara hasil prediksi model dengan nilai aktual pada dataset. Berdasarkan confusion matrix tersebut, nilai evaluasi model dihitung menggunakan rumus sebagai berikut. Accuracy digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi terhadap seluruh data.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Precision menunjukkan tingkat ketepatan model dalam memprediksi suatu kelas tertentu.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall menunjukkan kemampuan model dalam mendeteksi seluruh data yang termasuk dalam suatu kelas.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

F1-score merupakan rata-rata harmonik dari nilai precision dan recall.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Hasil evaluasi model kemudian digunakan untuk membandingkan kinerja model Naïve Bayes tanpa SMOTE dan Naïve Bayes dengan SMOTE sehingga dapat diketahui pengaruh penerapan SMOTE terhadap performa klasifikasi.

2.5. Perbandingan Kinerja Model

Perbandingan kinerja model dilakukan untuk mengetahui pengaruh penerapan metode SMOTE terhadap performa algoritma Naïve Bayes dalam klasifikasi gangguan kecemasan mahasiswa. Evaluasi dilakukan dengan membandingkan nilai accuracy, precision, recall, dan F1-score antara model Naïve Bayes tanpa SMOTE dan Naïve Bayes dengan SMOTE berdasarkan hasil pengujian pada data testing. Hasil perbandingan ini digunakan untuk menilai model yang memiliki kinerja klasifikasi yang lebih baik.

Tabel 8. Perbandingan Kinerja Model Naïve Bayes dengan dan tanpa SMOTE

Model	Accuracy	Precision	Recall	F1-Score
Naïve Bayes (Tanpa SMOTE)	0.84	0.78	0.41	0.54
Naïve Bayes + SMOTE	0.82	0.74	0.69	0.71

Tabel 8 menunjukkan perbandingan kinerja model klasifikasi menggunakan algoritma Naïve Bayes tanpa SMOTE dan Naïve Bayes dengan SMOTE. Model tanpa SMOTE memiliki nilai accuracy yang lebih tinggi, namun nilai recall dan F1-score lebih rendah karena model cenderung memprediksi kelas mayoritas.

Setelah penerapan metode SMOTE, nilai recall dan F1-score meningkat, yang menunjukkan bahwa model menjadi lebih mampu mendeteksi kelas minoritas pada dataset. Hal ini menunjukkan bahwa penerapan SMOTE dapat membantu meningkatkan keseimbangan performa model dalam klasifikasi data yang tidak seimbang.

3. HASIL DAN PEMBAHASAN

3.1. Distribusi Dataset

Pada tahap awal dilakukan analisis distribusi dataset untuk mengetahui keseimbangan jumlah data pada setiap kelas. Dataset yang digunakan dalam penelitian ini terdiri dari tiga kategori tingkat kecemasan mahasiswa yaitu No Stress,



Eustress, dan Distress. Hasil analisis menunjukkan bahwa dataset memiliki ketidakseimbangan kelas (imbalanced dataset) dimana jumlah data pada kelas Eustress jauh lebih banyak dibandingkan kelas No Stress dan Distress.

Tabel 9. Distribusi Dataset Sebelum SMOTE

Kelas	Jumlah Data
No Stress	38
Eustress	715
Distress	30
Total	783

Ketidakseimbangan dataset ini dapat mempengaruhi performa model klasifikasi karena algoritma cenderung memprediksi kelas mayoritas.

3.2. Distribusi Dataset Setelah SMOTE

Untuk mengatasi ketidakseimbangan dataset, penelitian ini menerapkan metode Synthetic Minority Oversampling Technique (SMOTE). Metode ini menghasilkan data sintesis pada kelas minoritas sehingga jumlah data pada setiap kelas menjadi lebih seimbang.

Tabel 10. Distribusi Dataset Setelah SMOTE

Kelas	Jumlah Data
No Stress	715
Eustress	715
Distress	715
Total	2145

Setelah penerapan SMOTE, distribusi dataset menjadi lebih seimbang sehingga model dapat mempelajari pola dari setiap kelas secara lebih optimal.

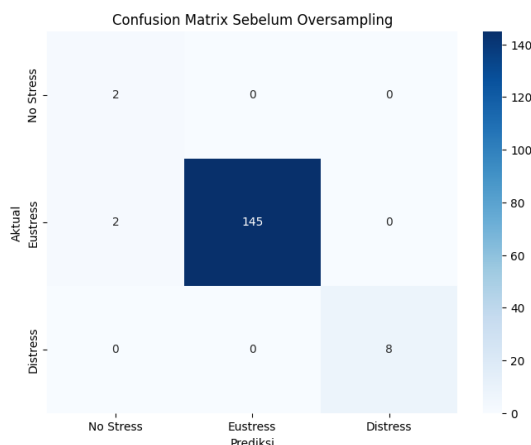
3.3. Hasil Pemodelan Naïve Bayes Tanpa SMOTE

Pemodelan pertama dilakukan menggunakan algoritma **Naïve Bayes tanpa penerapan SMOTE**. Model dilatih menggunakan dataset asli yang masih memiliki ketidakseimbangan kelas. Model kemudian diuji menggunakan data testing untuk mengetahui performa klasifikasi.

Tabel 11. Hasil Evaluasi Model Naïve Bayes Tanpa SMOTE

Metrik Evaluasi	Nilai
Accuracy	0.84
Precision	0.78
Recall	0.41
F1-score	0.54

Hasil evaluasi menunjukkan bahwa model memiliki nilai accuracy yang cukup tinggi, namun nilai recall masih rendah karena model kurang mampu mendeteksi kelas minoritas pada dataset yang tidak seimbang.



Gambar 5. Confusion Matrix Tanpa SMOTE

Gambar 5 menunjukkan confusion matrix hasil klasifikasi Naïve Bayes sebelum penerapan SMOTE. Model mampu mengklasifikasikan sebagian besar data pada kelas Eustress dengan benar, namun performa pada kelas No Stress dan Distress masih rendah. Hal ini menunjukkan bahwa model cenderung memprediksi kelas mayoritas, sehingga



diperlukan metode SMOTE untuk menyeimbangkan dataset dan meningkatkan kemampuan model dalam mengenali kelas minoritas.

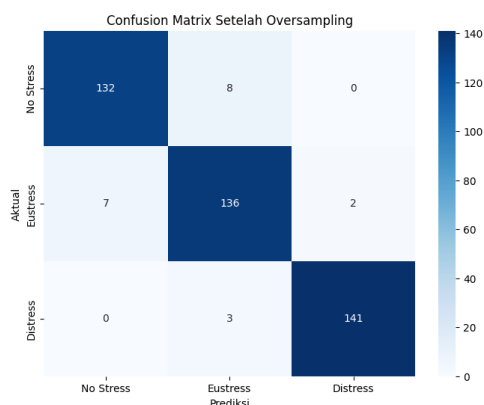
3.4. Hasil Pemodelan Naïve Bayes Dengan SMOTE

Pada tahap berikutnya dilakukan pemodelan menggunakan algoritma Naïve Bayes dengan penerapan metode SMOTE untuk menyeimbangkan dataset. Dataset hasil oversampling kemudian digunakan untuk melatih model klasifikasi.

Tabel 12. Hasil Evaluasi Model Naïve Bayes Dengan SMOTE

Metrik Evaluasi	Nilai
Accuracy	0.82
Precision	0.74
Recall	0.69
F1-score	0.71

Hasil evaluasi menunjukkan bahwa nilai recall dan F1-score meningkat secara signifikan setelah penerapan SMOTE.



Gambar 6. Confusion Matrix Dengan SMOTE

Gambar 6 menunjukkan confusion matrix hasil klasifikasi Naïve Bayes setelah penerapan SMOTE. Sebagian besar data berhasil diklasifikasikan dengan benar pada setiap kelas, yaitu No Stress, Eustress, dan Distress. Hasil ini menunjukkan bahwa penerapan SMOTE membantu meningkatkan kemampuan model dalam mengenali kelas minoritas sehingga performa klasifikasi menjadi lebih seimbang.


3.5. Perbandingan Kinerja Model

Perbandingan kinerja model dilakukan untuk mengetahui pengaruh penerapan metode SMOTE terhadap performa algoritma Naïve Bayes.

Tabel 13. Perbandingan Kinerja Model

Model	Accuracy	Precision	Recall	F1-score
Naïve Bayes (Tanpa SMOTE)	0.84	0.78	0.41	0.54
Naïve Bayes + SMOTE	0.82	0.74	0.69	0.71

Berdasarkan hasil evaluasi, model tanpa SMOTE memiliki accuracy lebih tinggi, namun model dengan SMOTE memiliki nilai recall dan F1-score yang lebih baik.



Gambar 7. Grafik Kinerja Model



Gambar 7 menunjukkan perbandingan performa model Naïve Bayes sebelum dan setelah penerapan metode SMOTE berdasarkan metrik precision, recall, dan F1-score pada masing-masing kelas yaitu No Stress, Eustress, dan Distress.

Pada kondisi sebelum oversampling, model menunjukkan performa yang sangat tinggi pada kelas mayoritas seperti No Stress dan Eustress, namun performa pada kelas Distress relatif lebih rendah terutama pada nilai precision (0.50) dan F1-score (0.67). Hal ini terjadi karena dataset memiliki ketidakseimbangan kelas sehingga model lebih cenderung memprediksi kelas mayoritas.

Setelah dilakukan oversampling menggunakan SMOTE, distribusi dataset menjadi lebih seimbang sehingga performa model pada seluruh kelas menjadi lebih stabil. Nilai precision, recall, dan F1-score pada setiap kelas berada pada kisaran 0.93–0.99, yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang lebih seimbang dalam mengenali seluruh kelas pada dataset.

3.6. Pembahasan

Hasil penelitian menunjukkan bahwa ketidakseimbangan dataset dapat mempengaruhi performa model klasifikasi. Model Naïve Bayes tanpa SMOTE cenderung memprediksi kelas mayoritas sehingga nilai recall pada kelas minoritas menjadi rendah. Setelah penerapan metode SMOTE, distribusi dataset menjadi lebih seimbang sehingga model dapat mempelajari pola dari setiap kelas dengan lebih baik. Hal ini terlihat dari peningkatan nilai recall dan F1-score, yang menunjukkan bahwa model menjadi lebih mampu mendeteksi kelas minoritas. Dengan demikian, penerapan metode SMOTE terbukti efektif dalam meningkatkan performa model klasifikasi pada dataset yang tidak seimbang, khususnya dalam meningkatkan kemampuan model dalam mengenali kelas minoritas.

4. KESIMPULAN

Penelitian ini bertujuan untuk menganalisis pengaruh penerapan metode Synthetic Minority Oversampling Technique (SMOTE) terhadap kinerja algoritma Naïve Bayes dalam klasifikasi multi-kelas tingkat kecemasan mahasiswa yang terdiri dari tiga kategori, yaitu No Stress, Eustress, dan Distress, pada dataset yang tidak seimbang. Hasil penelitian menunjukkan bahwa dataset awal memiliki ketidakseimbangan distribusi kelas yang cukup signifikan, dimana kelas Eustress mendominasi jumlah data dibandingkan kelas No Stress dan Distress. Kondisi ini mempengaruhi kinerja model klasifikasi, dimana model Naïve Bayes tanpa SMOTE menghasilkan nilai accuracy sebesar 0.84, precision sebesar 0.78, recall sebesar 0.41, dan F1-score sebesar 0.54. Nilai recall yang relatif rendah menunjukkan bahwa model masih kurang optimal dalam mendeteksi kelas minoritas pada dataset yang tidak seimbang. Setelah penerapan metode SMOTE, distribusi dataset menjadi lebih seimbang sehingga model dapat mempelajari pola dari setiap kelas secara lebih proporsional. Hasil evaluasi menunjukkan bahwa model Naïve Bayes dengan SMOTE menghasilkan nilai accuracy sebesar 0.82, precision sebesar 0.74, recall sebesar 0.69, dan F1-score sebesar 0.71. Peningkatan nilai recall dan F1-score menunjukkan bahwa penerapan SMOTE membantu meningkatkan kemampuan model dalam mengenali kelas minoritas pada kasus klasifikasi multi-kelas. Secara keseluruhan, hasil penelitian menunjukkan bahwa penerapan SMOTE pada dataset yang tidak seimbang dapat memberikan peningkatan pada metrik evaluasi yang berkaitan dengan kemampuan deteksi kelas minoritas, meskipun nilai akurasi keseluruhan sedikit menurun. Oleh karena itu, penggunaan teknik penyeimbangan data seperti SMOTE dapat menjadi pendekatan yang bermanfaat dalam pengembangan model klasifikasi pada kasus analisis kesehatan mental mahasiswa yang memiliki distribusi kelas yang tidak merata. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi algoritma klasifikasi lain seperti Random Forest, Support Vector Machine, atau Gradient Boosting, serta menerapkan teknik evaluasi yang lebih robust seperti k-fold cross-validation, guna memperoleh pemahaman yang lebih komprehensif mengenai performa model pada kasus klasifikasi multi-kelas dengan dataset tidak seimbang.

REFERENCES

- [1] T. Anjarsari, I. R. I. Astutik, and U. Indahyanti, "Deteksi Dini Gangguan Kecemasan Menggunakan Metode Naive Bayes," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 4, pp. 1198–1210, Nov. 2022, doi: 10.29100/jupi.v7i4.3197.
- [2] M. Sun, M. Piao, and Z. Jia, "The impact of alexithymia, anxiety, social pressure, and academic burnout on depression in Chinese university students: an analysis based on SEM," *BMC Psychol.*, vol. 12, no. 1, p. 757, Dec. 2024, doi: 10.1186/s40359-024-02262-y.
- [3] Y. Wang *et al.*, "Stressors in university life and anxiety symptoms among international students: a sequential mediation model," *BMC Psychiatry*, vol. 23, no. 1, p. 556, Aug. 2023, doi: 10.1186/s12888-023-05046-7.
- [4] S. Fisher and B. Hood, "The stress of the transition to university: A longitudinal study of psychological disturbance, absent-mindedness and vulnerability to homesickness," *British Journal of Psychology*, vol. 78, no. 4, pp. 425–441, Nov. 1987, doi: 10.1111/j.2044-8295.1987.tb02260.x.
- [5] E. Kroshus, M. Hawrilenko, and A. Browning, "Stress, self-compassion, and well-being during the transition to college," *Soc. Sci. Med.*, vol. 269, p. 113514, Jan. 2021, doi: 10.1016/j.socscimed.2020.113514.
- [6] W. Amalia, H. Abdilah, and K. Tarwati, "Gambaran Tingkat Kecemasan Mahasiswa Tingkat Akhir Program Studi Pendidikan Profesi Ners," *MAHESA: Malahayati Health Student Journal*, vol. 3, no. 10, pp. 3326–3337, Oct. 2023, doi: 10.33024/mahesa.v3i10.11298.
- [7] A. Poots and T. Cassidy, "Academic expectation, self-compassion, psychological capital, social support and student wellbeing," *Int. J. Educ. Res.*, vol. 99, p. 101506, 2020, doi: 10.1016/j.ijer.2019.101506.



- [8] A. F. Akhnaf, R. P. Putri, A. Vaca, N. P. Hidayat, R. I. Az-Zahra, and A. Rusdi, "Self Awareness Dan Kecemasan Pada Mahasiswa Tingkat Akhir," *Jurnal Muara Ilmu Sosial, Humaniora, dan Seni*, vol. 6, no. 1, pp. 107–118, Apr. 2022, doi: 10.24912/jmishumsen.v6i1.13201.2022.
- [9] M. Z. A. Rustam and L. Nurlela, "Gangguan Kecemasan dengan Menggunakan Self Reporting Questionnaire (SRQ-29) di Kota Surabaya," *Jurnal Kesehatan Masyarakat Mulawarman (JKMM)*, vol. 3, no. 1, p. 39, Aug. 2021, doi: 10.30872/jkmm.v3i1.5752.
- [10] M. N. Sulistyani and W. S. Hertinjung, "Memahami Kecemasan Mahasiswa di Solo Raya: Kontribusi Kepribadian, Dukungan Sosial, dan Gender," *JURNAL Al-AZHAR INDONESIA SERI HUMANIORA*, vol. 9, no. 3, p. 230, Dec. 2024, doi: 10.36722/sh.v9i3.3454.
- [11] D. A. Punkastyo, F. Septian, and A. Syaripudin, "Implementasi Data Mining Menggunakan Algoritma Naïve Bayes Untuk Prediksi Kelulusan Siswa," *Journal of System and Computer Engineering (JSCE)*, vol. 5, no. 1, pp. 24–35, Jan. 2024, doi: 10.61628/jsce.v5i1.1073.
- [12] T. Anjarsari, I. R. I. Astutik, and U. Indahyanti, "Deteksi Dini Gangguan Kecemasan Menggunakan Metode Naive Bayes," *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 4, pp. 1198–1210, Nov. 2022, doi: 10.29100/jipi.v7i4.3197.
- [13] N. J. Fauziyah, F. Rahmania, M. Daniyal, and N. F. A. T. Sari, "Analisis dan Optimalisasi Performa Algoritma Gaussian Naive Bayes pada Prediksi Metabolic Syndrome Menggunakan SMOTE," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 9, no. 2, pp. 112–122, May 2024, doi: 10.14421/jiska.2024.9.2.112-122.
- [14] K. Rahayu, V. Fitria, D. Septhya, R. Rahmadden, and L. Efrizoni, "Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: 10.57152/malcom.v3i2.780.
- [15] W. L. Ku and H. Min, "Evaluating Machine Learning Stability in Predicting Depression and Anxiety Amidst Subjective Response Errors," *Healthcare*, vol. 12, no. 6, p. 625, Mar. 2024, doi: 10.3390/healthcare12060625.
- [16] M. Vaz, T. Summavielle, R. Sebastião, and R. P. Ribeiro, "Multimodal Classification of Anxiety Based on Physiological Signals," *Applied Sciences*, vol. 13, no. 11, p. 6368, May 2023, doi: 10.3390/app13116368.
- [17] R. Gelar Guntara, "Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55–60, Feb. 2023, doi: 10.47233/jteksis.v5i1.750.
- [18] K. Rahayu, V. Fitria, D. Septhya, R. Rahmadden, and L. Efrizoni, "Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: 10.57152/malcom.v3i2.780.
- [19] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, Jun. 2002, doi: 10.1613/jair.953.
- [20] B. Z. Ramadhan, R. I. Adam, and I. Maulana, "Analisis Sentimen Ulasan pada Aplikasi E-Commerce dengan Menggunakan Algoritma Naïve Bayes," *Journal of Applied Informatics and Computing*, vol. 6, no. 2, pp. 220–225, Dec. 2022, doi: 10.30871/jaic.v6i2.4725.
- [21] M. A. Hermawan, A. Faqih, and G. Dwilestari, "Implementasi Akurasi Model Naive Bayes Menggunakan SMOTE dalam Analisis Sentimen Pengguna Aplikasi Brimo," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, Jan. 2025, doi: 10.23960/jitet.v13i1.5748.
- [22] D. Nurfitriana, T. Ridwan, and A. Voutama, "Analisis Opini Terhadap Aplikasi Rilis di Twitter Menggunakan Algoritma Naïve Bayes dan Random Forest," *Jurnal SAINTEKOM*, vol. 14, no. 1, pp. 26–37, Mar. 2024, doi: 10.33020/saintekom.v14i1.526.
- [23] C. B. Handoko and C. S. K. Aditya, "Penerapan Teknik SMOTE Dalam Mengatasi Imbalance Data Penyakit Diabetes Menggunakan Algoritma ANN," *Smart Comp: Jurnalnya Orang Pintar Komputer*, vol. 14, no. 1, Jan. 2025, doi: 10.30591/smartcomp.v14i1.7045.
- [24] M. I. Fikri, T. S. Sabrila, and Y. Azhar, "Perbandingan Metode Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Twitter," *SMATIKA JURNAL*, vol. 10, no. 02, pp. 71–76, Dec. 2020, doi: 10.32664/smatika.v10i02.455.
- [25] V. Oktaviani, N. Rosmawarni, and M. P. Muslim, "Perbandingan Kinerja Random Forest Dan Smote Random Forest Dalam Mendeteksi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir," *Informatik : Jurnal Ilmu Komputer*, vol. 20, no. 1, pp. 43–49, Apr. 2024, doi: 10.52958/iftk.v20i1.9158.
- [26] Y. Yunita, M. Fahmi, and S. Salmon, "Penerapan Algoritma K-Means Data Mining Pada Clustering Kelayakan Penerima UKT Dengan Normalisasi Data Model Z-Score," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1977–1986, Dec. 2024, doi: 10.47065/bits.v6i3.6475.