



Analisis Sentimen: Pengaruh Jam Kerja Terhadap Kesehatan Mental Generasi Z

Muhammad Daffa Al Fahreza¹, Ardytha Luthfiarta², Muhammad Rafid³, Michael Indrawan⁴, Adhitya Nugraha⁵

^{1,2,3,4,5}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Semarang, Indonesia

¹11202012812@mhs.dinus.ac.id, ²ardytha.luthfiarta@dsn.dinus.ac.id, ³11202012803@mhs.dinus.ac.id,

⁴11202012434@mhs.dinus.ac.id, ⁵adhitya@dsn.dinus.ac.id

Abstract

Mental health is a significant concern in society today, particularly for Generation Z, who are vulnerable to experiencing mental health problems that can disrupt daily productivity. The influence of working hours also contributes to the mental health of this generation. To assess public opinion on this issue, sentiment analysis is needed on social media, especially twitter. This research uses the Gaussian Naïve Bayes algorithm and Support Vector Machine with various stemming algorithms such as Nazief-Adriani, Arifin Setiono, and Sastrawi. The sentiment analysis method is used to assess positive, negative, and neutral sentiment in related tweets. The research results show that the Sastrawi stemming algorithm on the Gaussian Naïve Bayes model achieves 84% precision, 84% recall, and 84% f1-score, with 84% accuracy. Meanwhile, Support Vector Machine achieved 91% precision, 90% recall, 90% f1-score, and 91% accuracy. The Nazief-Adriani stemming algorithm on the Gaussian Naïve Bayes model has 80% precision, 80% recall, and 80% f1-score, with 80% accuracy. Meanwhile, on the Support Vector Machine, precision is 87%, recall is 85%, f1-score is 86%, and accuracy is 85%. Arifin Setiono's stemming algorithm on the Gaussian Naïve Bayes model achieved 81% precision, 81% recall, 81% f1-score, with 82% accuracy, while on Support Vector Machine, 88% precision, 86% recall, 86% f1-score, with 86% accuracy. Public opinion was recorded as 33% positive, 9% neutral, and 58% negative. This research aims to increase public awareness of the importance of mental health, especially regarding the influence of working hours, to create a healthy work environment for Generation Z and society in general, as well as improving the quality of mental health.

Keywords: Sentiment Analysis, Gaussian Naïve Bayes, Support Vector Machine, Stemming Algorithm, Mental Health, Generation Z.

Abstrak

Kesehatan mental menjadi sorotan utama di tengah masyarakat saat ini dikarenakan rentannya masyarakat untuk mengalami masalah kesehatan mental yang berpotensi mengganggu produktivitas sehari-hari terutama Generasi Z. Pengaruh jam kerja turut berkontribusi terhadap kesehatan mental generasi ini. Untuk mengetahui pandangan masyarakat mengenai masalah tersebut, diperlukan analisis sentimen pada opini masyarakat di media sosial, khususnya di twitter. Penelitian ini menggunakan algoritma *Gaussian Naïve Bayes* dan *Support Vector Machine* dengan beragam algoritma *stemming* seperti Nazief-Adriani, Arifin Setiono, dan Sastrawi. Metode analisis sentimen digunakan untuk menilai sentimen positif, negatif, dan netral dalam tweet terkait. Hasil penelitian menunjukkan bahwa algoritma *stemming* Sastrawi pada model *Gaussian Naïve Bayes* mencapai presisi 84%, *recall* 84%, dan *f1-score* 84%, dengan akurasi 84%. Sementara itu, *Support Vector Machine* mencapai presisi 91%, *recall* 90%, *f1-score* 90%, dan akurasi 91%. Algoritma *stemming* Nazief-Adriani pada model *Gaussian Naïve Bayes* memiliki presisi 80%, *recall* 80%, dan *f1-score* 80%, dengan akurasi 80%. Sementara pada *Support Vector Machine*, presisi 87%, *recall* 85%, *f1-score* 86%, dan akurasi 85%. Algoritma *stemming* Arifin Setiono pada model *Gaussian Naïve Bayes* mencapai presisi 81%, *recall* 81%, *f1-score* 81%, dengan akurasi 82%, sementara pada *Support Vector Machine*, presisi 88%, *recall* 86%, *f1-score* 86%, dengan akurasi 86%. Opini masyarakat tercatat 33% sebagai sentimen positif, 9% netral, dan 58% negatif. Penelitian ini bertujuan untuk meningkatkan kesadaran masyarakat akan pentingnya kesehatan mental terutama terkait pengaruh jam kerja, guna menciptakan lingkungan kerja yang sehat bagi Generasi Z dan masyarakat umumnya, serta meningkatkan kualitas kesehatan mental.

Kata kunci: Analisis Sentimen, *Gaussian Naïve Bayes*, *Support Vector Machine*, Algoritma *Stemming*, Kesehatan Mental, Generasi Z.

1. Pendahuluan

Generasi Z adalah kelompok individu yang lahir antara tahun 1997-2012 dan tumbuh di era teknologi. Mereka

memiliki akses mudah ke informasi dan sering berkomunikasi melalui media sosial. Generasi Z disebut juga sebagai generasi internet dikarenakan mereka lahir pada era teknologi. Namun, mereka juga rentan



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

mengalami masalah kesehatan mental karena ketergantungan terhadap teknologi dan pengaruh media sosial. Terdapat sebuah penelitian yang menunjukkan bahwa generasi Z rentan mengalami depresi, kecemasan, *self-harm*, dan gangguan makan. Faktor-faktor seperti penggunaan sosial media dan jam kerja berkontribusi pada masalah kesehatan mental mereka [1], [2], [3].

Kesehatan mental menjadi sorotan di era modern ini seiring dengan perubahan gaya hidup, tekanan sosial, dan perkembangan teknologi yang menimbulkan tantangan baru bagi kesehatan mental masing-masing individu [2]. Saat ini kebutuhan untuk hidup bermasyarakat semakin tinggi sejak inflasi yang kian menaik di Indonesia, hal ini mengakibatkan banyak orang termasuk dari kalangan Generasi Z yang cenderung memilih untuk mencari uang tambahan dengan kerja lembur ataupun mencari kerja sampingan untuk memenuhi kebutuhan kehidupan mereka. Tentu hal ini mengakibatkan bertambahnya jam kerja dalam sehari pada aktivitas sehari-hari mereka. Penelitian yang dilakukan oleh Kapo Wong menjelaskan bahwa jam kerja yang panjang dalam satu hari mempunyai dampak negatif terhadap kesehatan pekerja. Kesehatan pekerja disini termasuk kesehatan secara fisik dan mental pekerja. Kapo Wong menjelaskan bahwa ketika kesehatan mental terganggu dampaknya lebih parah terhadap pekerja dibandingkan kesehatan fisik yang terganggu. Hal ini dikarenakan kesehatan mental berkaitan dengan *burnout*, stres, depresi, dan kecemasan seseorang. Dengan meningkatnya jam kerja terhadap pekerja dapat meningkatkan risiko terhadap dampak kesehatan mental pekerja, hingga ketika hal ini tidak dapat ditangani dengan baik, maka tingkat seseorang untuk mengakhiri hidupnya akan semakin meningkat [3].

Terdapat sebuah penelitian yang dilakukan oleh Sungjin Park dengan melibatkan sekitar 3332 responden mengungkapkan bahwa pekerja muda Korea yang bekerja dalam jangka waktu yang lama cenderung mengalami tingkat stres dan depresi yang lebih tinggi. Hasil penelitian menunjukkan bahwa risiko stres dan depresi lebih tinggi pada peserta yang bekerja lebih dari 60 jam per minggu dibandingkan dengan mereka yang bekerja 31 hingga 40 jam per minggu. Oleh karena itu, studi Sungjin Park menyimpulkan bahwa mengurangi jam kerja dapat menjadi strategi yang efektif untuk meningkatkan kesehatan mental pekerja muda di Korea [4].

Sentimen analisis dapat digunakan sebagai alat untuk penelitian terkait, karena dapat membantu mengidentifikasi dan menganalisis perasaan dan opini yang terkait dengan topik tersebut di media sosial. Dengan menggunakan sentimen analisis, penelitian menjadi lebih mudah dengan memahami bagaimana masyarakat merespons topik kesehatan mental dan faktor pengaruh jam kerja terhadap kesehatan mental mereka dengan lebih cepat. Oleh karena itu, sentimen

analisis dapat menjadi alat yang sangat efektif untuk melakukan penelitian terkait kesehatan mental Generasi Z.

Salah satu penelitian yang dilakukan oleh Karina et al. dengan menggunakan metode *data mining*, analisis sentimen, dan algoritma *Naive Bayes* untuk mengklasifikasikan sentimen dan emosi dari tweet. Hasil eksperimen menunjukkan sentimen positif yang mendominasi. Hasil klasifikasi menunjukkan sentimen positif mendominasi dengan lebih dari 40.000 tweet, diikuti oleh sentimen negatif dengan lebih dari 25.000 tweet dan netral dengan lebih dari 10.000 tweet. Meskipun hasil yang diberikan cukup baik, data penelitian yang digunakan hanya mengambil kalimat yang berbahasa Inggris sehingga opini-opini dari data tersebut belum bisa mewakili kesehatan mental masyarakat Indonesia khususnya generasi Z [5]. Pada penelitian Rahayu dan kawan-kawan melakukan penelitian terkait komparasi algoritma SVM, *Decision Tree*, KNN dan *Naive Bayes* untuk klasifikasi tingkat depresi pada masyarakat twitter, hasilnya SVM menghasilkan akurasi sebesar 91% [6]. Pada penelitian yang dilakukan oleh Lickha dan Reisa terkait dengan komparasi tiga metode pada algoritma *Naive Bayes* yakni, Multinomial, Gaussian, dan Bernoulli pada analisis sentimen gangguan depresi di media sosial twitter, hasil yang diperoleh GNB menghasilkan akurasi sebesar 88.38% [7].

Berdasarkan penelitian Rahayu penggunaan SVM sebagai algoritma klasifikasi analisis sentimen mampu memberikan tingkat performa yang baik untuk kasus klasifikasi teks. Efektivitas teknik klasifikasi ini dapat dievaluasi dan dicapai akurasi hingga lebih dari 80%. *Naive Bayes* juga dapat dijadikan alternatif kedua sebagai algoritma klasifikasi teks, dikarenakan algoritma ini mampu memberikan tingkat akurasi yang hampir mendekati dengan SVM. *Naive Bayes* biasa digunakan dalam masalah klasifikasi, karena *Naive Bayes* memiliki fitur independensi prediktor. Fitur ini, mampu memodelkan hubungan antara masing-masing fitur dengan kelas tanpa dipengaruhi fitur yang lain [6], [7].

Pada penelitian yang dilakukan oleh Agastya menjelaskan bahwa algoritma *stemming* juga dapat mempengaruhi akurasi dari model yang diuji. Penelitian yang dilakukan yakni membandingkan model yang *disstemming* dan tanpa *stemming*. Artha menyimpulkan bahwa pengujian menggunakan *stemming* Nazief Adriani dapat memperoleh akurasi sebesar 81% dibandingkan tanpa *stemming* yang hanya mampu menghasilkan akurasi sebesar 80% dengan algoritma klasifikasi SVM. Pada penelitiannya, Artha menjelaskan bahwa penelitian ini dapat dikembangkan lebih jauh lagi yakni dengan membandingkan algoritma *stemming* berbahasa Indonesia lainnya seperti Porter, dan Sastrawi [8].

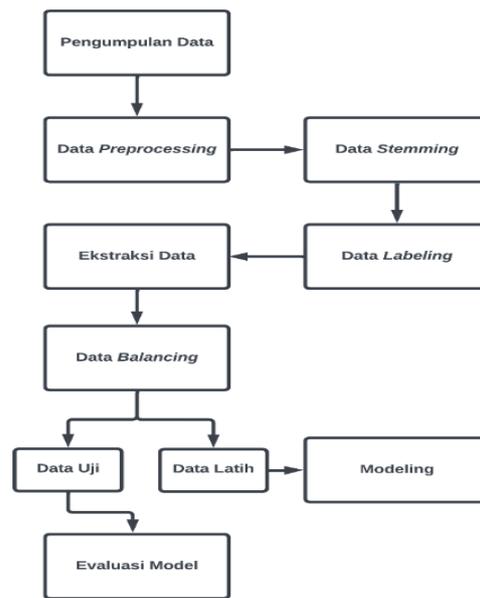
Penelitian ini akan menggunakan teknik *oversampling* *SMOTE* untuk menangani data yang tidak seimbang pada tiap label. Pada penelitian yang dilakukan oleh Utami menjelaskan bahwa *oversampling* sangat cocok digunakan ketika data yang tidak seimbang jumlahnya sangat jauh dari kelas minoritas. *Oversampling* akan menyeimbangkan jumlah data pada kelas minoritas dengan kelas mayoritas. Sehingga hal ini akan meningkatkan tingkat akurasi pada kelas minoritasnya. Herni juga menjelaskan bahwa penggunaan *undersampling* bisa dilakukan ketika jumlah data pada kelas mayoritas tidak terlalu jauh perbedaannya dengan kelas minoritas. Namun, penggunaan *undersampling* bisa jadi tidak dapat meningkatkan tingkat akurasi model ketika jumlah data besar dan ketidakseimbangannya yang signifikan, dikarenakan *undersampling* bekerja dengan cara menyeimbangkan jumlah data kelas mayoritas pada kelas minoritas. Adapun hasil dari penelitian ini memang menunjukkan bahwa dengan menggunakan teknik *oversampling* *SMOTE* dapat meningkatkan tingkat akurasi hingga 80% [9].

Berdasarkan penelitian terkait, penelitian ini akan melakukan komparasi model terhadap SVM dan GNB dalam analisis sentimen pengaruh jam kerja terhadap kesehatan mental. SVM dan GNB dijadikan acuan utama dalam model komparasi penelitian ini karena kedua algoritma tersebut mampu menangani data teks yang jumlah klasifikasinya lebih dari dua kelas seperti pada kasus ini terdapat tiga kelas sentimen yakni positif, negatif, dan netral. Pada penelitian terkait, juga dijelaskan bahwa GNB merupakan algoritma yang ringan, cepat dan mampu menghasilkan akurasi yang tinggi dalam klasifikasi teks. Sedangkan SVM memiliki teknik yang pemecahan masalah yang kompleks, yang umum disebut *kernel*. *Kernel* yang akan digunakan pada penelitian ini yakni *kernel* "poly" dikarenakan kernel ini mampu mengatasi klasifikasi teks dengan jumlah kelas yang banyak, sehingga tingkat akurasi yang dihasilkan memiliki tingkat yang lebih baik dibandingkan konfigurasi *kernel* lainnya [6], [7]. Penelitian ini menggunakan dua model algoritma klasifikasi yang berbeda untuk mengetahui perbandingan performa dari kedua model tersebut dari segi akurasi, presisi, *recall*, dan *f1-score*. Penelitian ini menerapkan tiga teknik algoritma *stemmer* yakni Sastrawi, Nazief Adriani, dan Arifin Setiono untuk mengetahui pengaruh *stemming* pada model akurasi SVM dan GNB. Berdasarkan penelitian yang dilakukan oleh Dyah dan kawan kawan algoritma *stemming* Sastrawi menghasilkan akurasi yang baik dibandingkan dengan Nazief Adriani dan Arifin Setiono, dimana Sastrawi menghasilkan tingkat akurasi sebesar 95.2% disusul dengan Nazief Adriani sebesar 92,4%, dan Arifin Setiono sebesar 89% [10]. Penelitian yang dilakukan Dharmendra menunjukkan hasil sebaliknya, dimana penelitian ini terkait dengan analisis sentimen Bahasa Indonesia pada opini alumni PT dengan model SVM dan *Maximum Entropy* dengan algoritma *stemming* Sastrawi. Hasilnya menunjukkan

bahwa SVM dengan algoritma *stemming* Sastrawi menghasilkan akurasi sebesar 71.21% [11]. Pada Penelitian yang dilakukan Haris terkait analisis sentimen terhadap kebijakan pemerintah. Haris menjelaskan bahwa dengan menggunakan algoritma *stemming* Nazief Adriani dan Arifin Setiono, mampu menghasilkan tingkat akurasi sebesar 97,9% dan 92% dimana akurasi yang dihasilkan jauh lebih baik dibandingkan algoritma Vega dan Tala. Oleh karena itu penelitian ini menggunakan algoritma algoritma diatas untuk mengetahui apakah dengan menggunakan teknik yang sama pada kasus yang berbeda mampu menghasilkan tingkat akurasi yang sama baiknya dengan penelitian sebelumnya [12].

Penelitian ini dilakukan dengan tujuan untuk mengetahui opini masyarakat terhadap pengaruh jam kerja pada kesehatan mental Generasi Z. Hasil analisa dari opini masyarakat tersebut diharapkan memberikan pengetahuan terkait pengaruh jam kerja bagi kualitas kesehatan mental, sehingga kedepannya akan tercipta kualitas lingkungan kerja yang lebih sehat dan baik.

2. Metode Penelitian



Gambar 1. Tahapan Alur penelitian

Pada penelitian ini, alur penelitian dibagi menjadi beberapa tahapan, dimulai dari data diambil dari tweet untuk dijadikan kumpulan data. Data tersebut kemudian dilakukan pemrosesan data dengan menghilangkan atribut yang tidak penting pada teks seperti emoji, mengubah kalimat menjadi *lower-case text*, menghapus *link reference*, dan lain-lain. Setelah itu, data tersebut akan dilakukan *stemming* guna mengubah suatu kata menjadi ke kata dasar atau *root word*. Kemudian data tweet akan dilabeli berdasarkan bobot katanya, pelabelan ini menggunakan tiga jenis kelas berbeda yakni positif, negatif, dan netral. Data akan diekstraksi menggunakan *term frequency-inverse document*

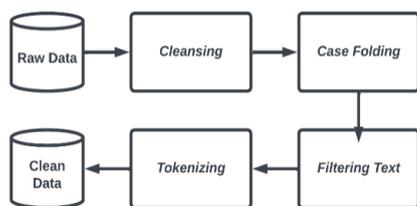
frequency (TF-IDF) dan diubah menjadi tipe data numerik untuk dilakukan *data balancing* dengan metode *oversampling* menggunakan SMOTE (*Synthetic Minority Over-sampling Technique*) untuk mengatasi ketidakstabilan data. Data hasil dari *oversampling* inilah yang akan digunakan untuk dimasukkan kedalam data latih dan data uji, dimana data latih sendiri nantinya akan dimasukkan kedalam pemodelan mesin sedangkan data uji akan dimasukkan ke pengujian dan evaluasi dari tingkat keakuratan dan akurasi model. Adapun tahapan yang dimaksud dapat dilihat pada Gambar 1.

2.1. Pengumpulan Data

Proses pengumpulan data dilakukan dengan teknik *crawling* dengan menggunakan alat Tweet Harvest v2.6.8 yang dibuat oleh Helmi Satria. *Crawling* data twitter adalah pengunduhan data dengan bantuan API twitter [13]. Proses *crawling* ini melibatkan kata kunci “jam kerja generasi z”, “kesehatan mental generasi z”, dan “tingkat stress kerja gen z”. Proses ini membutuhkan waktu tiga hari dimulai pada tanggal 10 Oktober hingga 13 Oktober 2023 dengan menggunakan dua akun twitter yang berbeda dan didapatkan total data sebanyak 2956 data tweet. (<https://helimisatria.com/blog/crawl-data-twitter-menggunakan-tweet-harvest>)

2.2. Pra-pemrosesan Data

Pra-pemrosesan data merupakan langkah penting dalam penelitian yang bertujuan untuk membersihkan, merapikan, dan mengubah data mentah ke dalam format yang lebih sesuai untuk analisis lebih lanjut. Pra-pemrosesan data dimaksudkan untuk membersihkan data teks dengan cara yang relevan untuk dianalisis kedepannya [14]. Adapun tahapan alur pra-pemrosesan dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Alur Preprocessing

Pertama pada proses *cleansing*, karakter yang tidak penting seperti tanda baca, emoji, URL, *hashtag*, dan angka dihapus untuk menghapus data dari item yang tidak relevan. Hal ini membuat data lebih bersih dan lebih mudah diproses pada langkah selanjutnya [2]. Tujuan dari tahap *cleansing* ini yakni untuk membersihkan data dari *noise*, informasi yang tidak relevan, dan kesalahan, sehingga data yang digunakan dalam analisis lebih bersih, akurat, dan dapat diandalkan dalam analisis.

Tahapan selanjutnya yakni *Case Folding*, *Case Folding* adalah proses mengubah seluruh huruf dalam suatu teks menjadi huruf kecil atau besar, berdasarkan aturan yang

telah ditentukan. Tujuannya adalah untuk memastikan konsistensi dalam analisis teks, sehingga kata-kata serupa dengan huruf berbeda (misalnya “Data” dan “data”) dianggap sama [15].

Tokenisasi adalah tahapan ketiga dimana proses ini akan membagi teks menjadi token, seperti kata atau kalimat. Hal ini memudahkan pemrosesan lebih lanjut. Misalnya, kalimat “Saya suka makanan Italia” akan dibagi menjadi tag “Saya”, “suka”, “makanan”, “Italia” [16]. Adapun *library* yang digunakan yakni menggunakan NLTK (*Natural Language Toolkit*).

Proses *Stemming* digunakan untuk mengubah kata-kata ke bentuk dasar atau kata kerja infinitif. Misalnya, kata “berlari,” “berlari-lari,” dan “lari” dapat diubah menjadi “lari.” Ini membantu mengurangi variasi kata yang memiliki arti yang sama [13]. *Stemming* sendiri sebetulnya masuk ke dalam proses preprocessing data hanya saja dalam penelitian ini, eksperimen dilakukan dengan menggunakan beberapa teknik algoritma *stemming*. Algoritma yang pertama adalah Sastrawi. Sastrawi merupakan sebuah kamus atau *library* yang digunakan untuk melakukan *stemming* pada kata-kata dalam bahasa Indonesia. *Library* ini dapat mengubah kata-kata berimbuhan dalam bahasa Indonesia menjadi bentuk kata dasar [17]. Adapun cara kerja dari Algoritma ini pertama algoritma sastrawi akan melakukan proses pra-pemrosesan data dengan mentransformasi semua huruf menjadi huruf kecil, menghapus bentuk URL, menghapus karakter-karakter yang tidak penting, dan lain-lain. Setelah proses pra-pemrosesan selesai, algoritma Sastrawi melakukan proses *stemming* pada kata-kata dalam teks dengan mengidentifikasi dan menghapus awalan, akhiran, dan imbuhan pada kata-kata tersebut. Terakhir, setelah semua awalan, akhiran, dan imbuhan yang relevan dihapus, kata tersebut akan dikembalikan dalam bentuk dasar atau akar.

Algoritma kedua yakni Nazief dan Adriani. NA merupakan salah satu metode *stemming* berbahasa Indonesia yang digunakan dalam *Natural Language Processing* untuk mengubah kata menjadi bentuk dasar atau *stem*-nya [18]. Adapun cara kerja dari algoritma ini yakni, pertama algoritma akan mencoba mengidentifikasi kata apakah kalimat memiliki awalan seperti “me-”, “di-”, “ke-”, “se-”, atau “te-”. Jika iya maka kata awalan tersebut akan dihapus, sebagai contoh “makan” akan menjadi “akan”, dan “melakukan” menjadi “lakukan”. Kemudian kata akan dicek apakah kalimat memiliki akhiran seperti “-kan”, “-i”, “-mu”, “-kah”. Jika iya maka kata akhiran akan dihapus, sebagai contoh “melakukan” menjadi “melaku” dan “makanan” = “makan”. Jika dalam kalimat terdapat kata imbuhan seperti “-nya” dan “-ku” maka imbuhannya akan dihapus, sebagai contoh “kucingnya” menjadi “kucing” dan “permainanku” = “permainan”. Proses pemeriksaan ini akan dilakukan secara berurutan, dengan algoritma memeriksa setiap kemungkinan aturan pemotongan

untuk kata tersebut. Sehingga hasil akhir dari proses ini kata-kata tersebut akan kembali ke bentuk dasar.

Algoritma terakhir yang digunakan yakni Arifin Setiono. Algoritma ini merupakan salah satu algoritma *stem* bahasa Indonesia yang digunakan untuk mengubah kata dalam bentuk infleksi menjadi kata dasar atau akar kata. Algoritma ini mengelompokkan dokumen, menggunakan konsep kemiripan atau *similarity* antar dokumen berdasarkan kemiripan antar dokumen. Penghitungan tingkat kemiripan dilakukan menggunakan metode *cosine similarity* [19]. Adapun cara kerja dari algoritma ini yang pertama algoritma Arifin Setiono akan mengasumsikan bahwa setiap kata memiliki dua awalan dan tiga akhiran. Algoritma ini mengikuti pola berikut: Prefix1 + Prefix2 + Root Words + Suffix3 + Suffix2 + Suffix1. Jika sebuah kata memiliki awalan atau akhiran yang kurang dari itu, maka untuk awalan kosong ditandai dengan x dan xx untuk akhiran kosong. Kemudian *stemming* akan dilakukan secara berurut dengan urutan Prefix1 akan dihapus dan disimpan kedalam p1, kemudian Prefix2 akan dihapus dan disimpan kedalam p2, lalu Suffix3 akan dihapus dan disimpan kedalam s3, dan seterusnya hingga Suffix1 disimpan kedalam s1. Terakhir, setiap kata hasil *stemming* akan diperiksa terhadap kamus untuk memastikan bahwa kata tersebut telah kembali ke bentuk dasar atau akar kata. Jika iya maka proses pencarian berhenti, jika tidak maka proses dilanjutkan.

2.3. Pelabelan

Pelabelan adalah proses memberikan label atau klasifikasi pada data yang telah terkumpul. Pada tahap ini, data diberikan label untuk menentukan apakah setiap kalimat dalam kumpulan data tersebut memiliki makna yang positif, negatif, atau netral. Dalam proses pelabelan, setiap kalimat diberikan label berdasarkan makna yang terkandung dalam kalimat tersebut. Hal ini dilakukan untuk memudahkan analisis data dan pengambilan keputusan [2]. Metode pelabelan pada penelitian ini menggunakan kamus Inset *Lexicon* dimana kamus ini menggunakan basis berdasarkan *lexicon-based* dengan menggunakan berbagai kata yang akan dinilai dan diberi bobot berdasarkan skor polaritas untuk mengetahui tanggapan masyarakat dari suatu topik [20].

2.4. Ekstraksi Fitur

Ekstraksi fitur pada penelitian ini menggunakan term *frequency-inverse document frequency*. TF-IDF merupakan salah satu metode untuk mengekstrak fitur dari teks yang akan dianalisis. Metode ini bekerja dengan cara menghitung frekuensi kemunculan kata dalam sebuah dokumen dan membandingkannya dengan frekuensi kemunculan kata tersebut dalam seluruh dokumen yang ada [21]. Semakin sering kata tersebut muncul dalam dokumen, semakin tinggi bobotnya dalam analisis sentimen. Untuk mengetahui perhitungan TF-IDF dapat dilihat pada rumus 1.

$$TF.IDF(t) = tf_d^t \times \log \frac{N}{df^t} \quad (1)$$

Dimana $tf_d^t \times \log \frac{N}{df^t}$ merupakan jumlah kemunculan istilah t pada dokumen d. Nilai N menunjukkan jumlah total dokumen pada korpus, sedangkan df^t merujuk kepada jumlah dokumen dimana istilah TF.IDF(t) muncul.

2.5. Data Balancing

Data balancing adalah proses untuk menyeimbangkan jumlah data pada setiap kelas dalam kumpulan data. Salah satu metode yang digunakan untuk melakukan data balancing adalah *Synthetic Minority Over-sampling Technique* (SMOTE).

Metode ini bekerja dengan cara membuat sampel sintetis dari kelas minoritas dengan cara mengambil sampel dari kelas minoritas dan membuat sampel sintetis baru dengan menggabungkan sampel tersebut dengan tetangga terdekatnya [22].

2.6. Modeling

Modeling dalam analisis sentimen adalah proses pembuatan model atau algoritma yang digunakan untuk mengklasifikasikan teks ke dalam kategori sentimen tertentu, seperti positif, negatif, atau netral. Proses ini melibatkan ekstraksi fitur dari teks, seperti kata-kata atau frasa, dan penggunaan algoritma machine learning untuk mempelajari pola dalam data dan membuat prediksi sentimen [2]. Pada penelitian ini, model yang digunakan yakni *Gaussian Naïve Bayes* dan *Support Vector Machine*. GNB adalah salah satu variasi dari algoritma *Naïve Bayes* yang digunakan dalam klasifikasi teks. Algoritma ini mengasumsikan bahwa setiap fitur (kata) dalam teks independen satu sama lain dan memiliki distribusi normal [23]. Oleh karena itu, algoritma ini cocok digunakan pada data yang memiliki kategori atau pelabelan teks lebih dari tiga seperti pada kasus penelitian ini dimana terdapat tiga kategori yakni positif, negatif dan netral. Untuk mengetahui nilai kalkulasi *Gaussian Naïve Bayes* dapat dilihat pada rumus 2.

$$P(C|Z) = \frac{P(Z|C) \times P(C)}{P(Z)} \quad (2)$$

Dimana C pada $P(C|Z)$ merupakan kelas dari label, dan nilai Z yang merupakan atribut yang akan diterapkan. Kemudian $\frac{P(Z|C) \times P(C)}{P(Z)}$ merupakan probabilitas dari kelas sebelumnya yakni $P(C)$, dan $P(Z)$ adalah probabilitas yang terjadi pada atribut yang diterapkan.

Support Vector Machine merupakan salah satu algoritma yang biasa digunakan untuk melakukan regresi dan klasifikasi, dimana kategori ini mampu untuk menganalisis data dan mengidentifikasi pola dengan cukup akurat [24]. Pada analisis sentimen SVM mampu memberikan hasil yang cukup akurat dikarenakan model ini dapat dikonfigurasi secara fleksibel. Adapun

konfigurasi SVM yang digunakan pada penelitian ini yakni menggunakan *kernel* “poly” dikarenakan *kernel* “poly” dapat menghasilkan model yang lebih kompleks dan dapat menangani data yang tidak linear dibandingkan dengan konfigurasi *kernel* lainnya [15]. Adapun perhitungan nilai SVM dengan *kernel* “poly” dapat dilihat pada rumus 3.

$$K(X, X_i) = 1 + \sum(X * X_i)^d \quad (3)$$

Dimana *d* merupakan nilai optimal pada setiap kumpulan data, nilai *X* dan *X_i* adalah vektor sampel.

2.7. Evaluasi Model

Pada tahap evaluasi, sistem dianalisis untuk mengevaluasi kinerja klasifikasi yang telah dilakukan. Proses ini melibatkan perhitungan nilai *accuracy*, *precision*, *recall*, dan *f1-score*. Nilai *precision* digunakan untuk mengukur seberapa akurat model dalam memprediksi data positif, sedangkan nilai *recall* digunakan untuk menghitung seberapa baik model dalam menemukan data positif, dan *f1-score* digunakan untuk mengukur *harmonic* mean atau keseimbangan antara nilai *precision* dan *recall* [25]. Evaluasi kinerja ini digunakan sebagai parameter untuk mengukur seberapa akurat implementasi metode yang digunakan.

3. Hasil dan Pembahasan

3.1. Pra-pemrosesan Data

Tahapan ini, kumpulan data yang akan diolah menjadi sebuah data baru yang dapat dianalisis. Tahapan ini mencakup *case folding*, *cleansing*, dan *tokenizing*.

Tabel 1. Tabel Proses Processing Data

Tahapan	Raw Data	Hasil
Cleansing	@txttarikopi engga juga, di tempat gue ada beberapa anak gen z yg tahan banting wkwk, lagian kalo emang apa apa kena mental ya gausah kerja ðŸ˜,	Ah Ah engga juga di tempat gue ada beberapa anak gen z yg tahan banting wkwk lagian kalo emang apa apa kena mental ya gausah kerja
Case Folding	ah engga juga di tempat gue ada beberapa anak gen z yg tahan banting wkwk lagian kalo emang apa apa kena mental ya gausah kerja	ah engga juga di tempat gue ada beberapa anak gen z yg tahan banting wkwk lagian kalo emang apa apa kena mental ya gausah kerja
Tokenizing	ah engga juga di tempat gue ada beberapa anak gen z yg tahan banting wkwk lagian kalo emang apa apa kena	Ah, engga, juga, Di, Tempat, gue, ada, beberapa anak, gen, z, yg, tahan, banting, wkwk, lagian, kalo, emang, apa, apa, kena, mental, ya, gausah, kerja

Pada proses ini data yang semula berjumlah 2956 data mentah setelah dilakukan preprocessing dan dilakukan pengecekan apakah ada duplikasi pada kumpulan data

menghasilkan 2620 clean data yang siap untuk diproses ke tahap selanjutnya.

3.2. Stemming

Pada tahapan ini data yang telah dibersihkan akan dimasukkan kedalam proses *stemming* dengan menggunakan tiga jenis algoritma *stemming* yang berbeda untuk mengetahui performa *stemming* mana yang sekiranya terbaik ketika dimasukkan kedalam tahap pengujian dan evaluasi. Sebagai contoh tabel 2. dibawah mengilustrasikan 5 jenis kata yang ada pada kumpulan data.

Tabel 2. Komparasi Tiga Algoritma Stemming

Kata	Sastrawi	Nazief Adriani	Arifin Setiono
bagusan	bagus	bagus	bagus
pendongeng	dongeng	ndongeng	dongeng
santai	santai	santa	santa
lingkungan	lingkung	lingkung	lingkung
pemikiran	pikir	mikiran	ikir

Pada tabel tersebut dapat dilihat bahwa algoritma sastrawi memiliki hasil yang baik dimana dari kelima contoh kata pada kumpulan data, sastrawi mampu mengubah semua kata berimbuhan dengan tepat. Kemudian untuk kedua algoritma Nazief dan Arifin memiliki algoritma yang cukup baik. Algoritma Nazief sendiri masih memiliki kelemahan dimana seperti pada contoh kata pada tabel kata “pemikiran” yang diturunkan seharusnya menjadi “pikir” bukan “mikiran”. Hal ini disebabkan karena algoritma ini hanya mengelompokkan imbuhan ke dalam beberapa kategori tertentu, sehingga masih terdapat kesalahan dalam menentukan kata dasar dari kata-kata berimbuhan. Kemudian pada algoritma Arifin juga masih terdapat kesalahan yang sama dimana kata “pemikiran” di-*stemming* menjadi “ikir”. Hal ini dikarenakan proses *stemming* berdasarkan pemeriksaan kamus akar, mengembalikan afiks ke kata dasar dalam urutan pertama, sehingga kata “pemikiran” akan dikembalikan sebagai kata dasar “ikir”.

3.3. Pelabelan Data

Tahapan Pelabelan akan membagi data clean text kedalam tiga kelas kategori yakni negatif, netral, positif dari hasil tahapan preprocessing sebelumnya. Pelabelan ini berdasarkan kamus Inset *Lexicon* sehingga proses ini telah dilakukan oleh sistem. Dari proses diatas dihasilkan 1575 kelas negatif, 888 positif, dan 233 netral dimana proses ini dilakukan dengan menggunakan algoritma *stemming* sastrawi. Kemudian untuk algoritma *stemming* Nazief Adriani menghasilkan 1405 label negatif, 1023 label positif, dan 268 label netral. Terakhir untuk algoritma *stemming* Adriani menghasilkan 1438 label negatif, 989 label positif, dan 269 label netral. Dari ketiga jenis algoritma *stemming* tersebut pelabelan data menghasilkan data yang tidak seimbang atau imbalancing data sehingga kedepannya akan mempengaruhi performa dan akurasi dari model mesin.

Adapun hasil dari label sentimen yang dilakukan dapat dilihat pada Tabel 3.

Tabel 3. Pelabelan Berdasarkan Kamus Lexicon

Kata	Sastrawi	Nazief Adriani	Arifin Setiono
gen z itu bukan berdasarkan tahun kelahiran tapi lebih ke perilaku z itu artinya zombie zahiliyah di kantor gw dl ada kelahiran an kerjanya ngerokok pd saat jam kerja dlm intensitas x atau lebih	Positif	Positif	Positif
generasi z peduli kesehatan mental ini buktinya	Netral	Netral	Netral
saya ada anak buah gen z tiap malam begadang siangnya pas jam kerja jadi ndak fokus diajari cara kerja lemot dibilangin baik baik malah membantah jujur awal awal mereka masuk bikin stress di tempat kerja	Negatif	Negatif	Negatif

3.4. Ekstraksi Fitur

Pada tahap ini dikarenakan data yang dilabelkan menghasilkan *imbalance data* maka perlu dilakukan *handling data*, namun dikarenakan data berupa tipe data untaian atau string perlu dilakukan ekstraksi data menjadi tipe data numerik. TF-IDF menjadi metode pilihan untuk melakukan ekstraksi data menjadi tipe data numerik dikarenakan TF-IDF ini mengubah data teks menjadi vektor numerik dengan menghitung frekuensi kemunculan kata dalam dokumen dan mengurangi bobot kata yang sering muncul dalam seluruh dokumen. Tabel 4 menunjukkan beberapa contoh hasil perhitungan TF-IDF terhadap suatu kata pada dokumen, dan perhitungan tersebut juga menghitung bobot katanya, semakin tinggi nilainya maka kata tersebut penting atau berpengaruh terhadap kalimat pada dokumen.

Tabel 4. Hasil TF-IDF

Kata	TF			IDF	TF*IDF		
	t1	t2	t3		t1	t2	t3
jam	1	2	1	0.195	0.195	0.399	0.195
kerja	1	2	2	0.209	0.209	0.418	0.418
salah	1	0	0	0.112	0.112	0	0
satu	1	0	0	0.118	0.118	0	0
pemicu	1	0	0	0.191	0.191	0	0
meningkatnya	1	0	0	0.251	0.251	0	0
angka	1	0	0	0.176	0.176	0	0
kematian	1	0	0	0.275	0.275	0	0
dan	1	0	0	0.127	0.127	0	0
bunuh	1	0	0	0.172	0.172	0	0
diri	1	0	0	0.105	0.105	0	0
genz	1	1	1	0.287	0.287	0.287	0.287
gak	0	1	0	0.138	0	0.138	0
masuk	0	1	0	0.148	0	0.148	0
akal	0	1	0	0.180	0	0.180	0
kayak	0	1	0	0.222	0	0.222	0
aku	0	1	0	0.189	0	0.189	0
keluarga	0	1	0	0.157	0	0.157	0
bergantung	0	1	0	0.200	0	0.200	0
banget	0	1	0	0.178	0	0.178	0
sama	0	1	0	0.122	0	0.122	0
ini	0	0	1	0.139	0	0	0.139
kalo	0	0	1	0.162	0	0	0.162
rajin	0	0	1	0.221	0	0	0.221

hampir	0	0	1	0.150	0	0	0.150
sampe	0	0	1	0.127	0	0	0.127
malem	0	0	1	0.160	0	0	0.160

3.5. Oversampling dengan SMOTE

Pada Tahapan ini dikarenakan pelabelan data menghasilkan ketidakstabilan data atau imbalancing data maka untuk menghindari performa dan akurasi model yang buruk maka perlu dilakukan *oversampling* data. Dikarenakan pada ketiga algoritma *stemming* yang digunakan, semuanya menghasilkan nilai label negatif yang sangat tinggi, maka dari itu perlu peningkatan tiap kelas positif dan netral hingga mendekati atau sama dengan nilai kelas negatif. Hasil *oversampling* dapat dilihat pada Tabel 5 dan Tabel 6, dan Gambar 3.

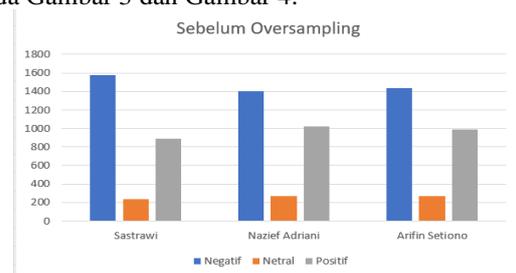
Tabel 5. Jumlah Data Label Sebelum Oversampling

Label	Sebelum Oversampling SMOTE		
	Sastrawi	Nazief Adriani	Arifin Setiono
Negatif	1606	1371	1404
Netral	168	264	265
Positif	846	985	951

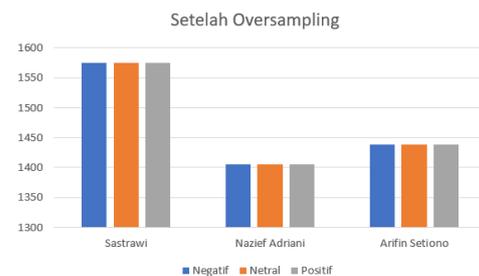
Tabel 6. Jumlah Data Label Setelah Oversampling

Label	Setelah Oversampling SMOTE		
	Sastrawi	Nazief Adriani	Arifin Setiono
Negatif	1606	1371	1404
Netral	1606	1371	1404
Positif	1606	1371	1404

Setelah dilakukan teknik *oversampling data* dengan menggunakan SMOTE dapat dilihat bahwa jumlah data yang ada pada label netral dan positif berjumlah sama dengan label negatif. Hal ini dilakukan untuk mencegah kesalahan kinerja model dalam memprediksi kelas minoritas, karena jumlah data yang dihasilkan pada masing-masing label tidak seimbang dan lebih condong ke hasil negatif. Adapun perbandingan grafik hasil sebelum dan setelah *oversampling* SMOTE dapat dilihat pada Gambar 3 dan Gambar 4.



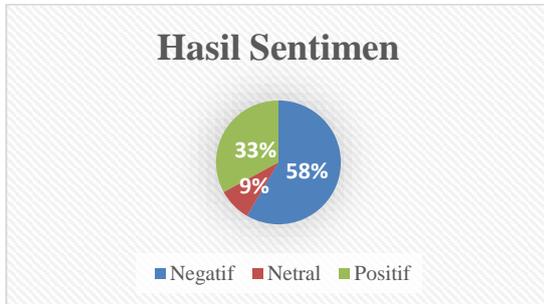
Gambar 3. Grafik Perbandingan Sebelum Oversampling



Gambar 4. Grafik Perbandingan Sesudah Oversampling

3.6. Hasil Sentimen

Berdasarkan sentimen masyarakat di media sosial twitter pada pengaruh jam kerja terhadap kesehatan mental generasi Z. Sentimen masyarakat cenderung menghasilkan 58% sentimen negatif, 33% sentimen positif dan 9% sentimen netral. Adapun hasil dari keseluruhan sentimen dapat dilihat pada Gambar 5.



Gambar 5. Hasil sentimen

Adapun kata kata pendukung sentimen dapat dilihat pada Gambar 6 dan Gambar 7.



Gambar 6. Word Cloud untuk Sentimen Negatif



Gambar 7. Word Cloud untuk Sentimen Positif

Pada *Word Cloud* dapat dilihat bahwa frekuensi kata yang paling sering muncul baik untuk sentimen negatif maupun positif dapat dilihat dengan ketebalan warna dan besar pada kata. Semakin tebal dan besar warnanya maka semakin sering frekuensi kata tersebut muncul. Diketahui kata untuk sentimen negatif yang paling sering muncul yakni kerja, stress, dan dari. Sedangkan kata untuk sentimen positif yang sering muncul sendiri kerja, tingkat, jam, dan stress.

Dari *Word Cloud* ini dapat dilihat bahwa pengaruh jam kerja dapat mempengaruhi kesehatan mental Generasi Z, yang dapat dilihat dari sentimen positif yang muncul. Hal ini dapat diinterpretasikan dengan, banyaknya

masyarakat yang beropini bahwa pengaruh jam kerja dapat meningkatkan tingkat stress mereka terutama pada kalangan Generasi Z. Sedangkan untuk sentimen negatif dapat diinterpretasikan bahwa masyarakat cenderung menolak bahwa jam kerja dapat mempengaruhi kualitas kesehatan mental mereka, dan kebanyakan juga masyarakat banyak yang menyinggung kualitas kerja dari Generasi Z di perusahaan tempat mereka bekerja.

3.7. Evaluasi Model

Pada proses ini, klasifikasi evaluasi model dilakukan dengan membagi data menjadi 30% data uji dan 70% data latih. Dari total data untuk algoritma Sastrawi sebesar 4818 data, 4113 untuk algoritma Nazief Adriani, dan 4212 untuk algoritma Arifin Setiono. Dari total 4818 data pengklasifikasian model menggunakan SVM dan GNB untuk algoritma *stemming* Sastrawi menghasilkan 3372 data latih dan 1446 data uji. Kemudian 2879 data latih dan 1234 data uji dari total 4113 data untuk model SVM dan GNB algoritma *stemming* Nazief Adriani. Terakhir untuk model GNB dan SVM algoritma *stemming* Arifin Setiono menghasilkan 2948 data latih dan 1264 data uji dari total 4212 data. Kemudian data-data tersebut dari ketiga algoritma *stemming* akan diuji dan dievaluasi untuk mengetahui nilai *precision*, *recall*, *f1-score* dan *accuracy*. Adapun rumus untuk menghitung ketiga nilai *precision*, *recall*, *f1-score* dan *accuracy* dapat dilihat pada rumus 4, rumus 5, rumus 6, dan rumus 7.

$$Precision = \frac{TP}{(TP+FP)} \quad (4)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (5)$$

$$F1 = \frac{2*Recall*Precision}{(Recall+Precision)} \quad (6)$$

$$Accuracy = \frac{TP+TN}{(TP + TN + FP + FN)} \quad (7)$$

Dengan TP merupakan jumlah data benar yang terdeteksi benar oleh model, TN merupakan jumlah data salah, yang terdeteksi salah oleh model, FP merupakan jumlah data yang salah, namun terdeteksi benar oleh model, dan FN merupakan jumlah yang terdeteksi benar, namun terdeteksi salah oleh model. Dari pengujian penelitian didapatkan bahwa model yang menggunakan algoritma *stemming* sastrawi menghasilkan nilai yang sangat baik dibanding dua algoritma lainnya.

Hasil evaluasi menunjukkan bahwa pada kategori “negatif”, menggunakan algoritma *stemming* Sastrawi dengan model *Gaussian Naïve Bayes* dan *Support Vector Machine* (dengan *kernel* “poly”) menghasilkan tingkat presisi antara 0.82 hingga 0.87, *recall* antara 0.67 hingga 0.93, dan *f1-score* antara 0.74 hingga 0.87. Sedangkan dengan algoritma *stemming* Nazief dan Adriani, tingkat presisi berkisar antara 0.70 hingga 0.75, *recall* antara 0.68 hingga 0.94, dan *f1-score* antara 0.71 hingga 0.84. Pada penggunaan algoritma *stemming* Arifin Setiono, tingkat presisi berkisar antara 0.72

hingga 0.76, *recall* antara 0.73 hingga 0.93, dan *f1-score* antara 0.74 hingga 0.81.

Sementara untuk label “netral”, dengan menggunakan algoritma *stemming* Sastrawi dan model GNB serta SVM (dengan kernel “poly”) menghasilkan tingkat presisi antara 0.97 hingga 0.99, *recall* antara 1.00 hingga 0.99, dan *f1-score* masing-masing 0.99. Sementara Nazief Adriani tingkat presisi yang dihasilkan berkisar 0.92 hingga 1.00, *recall* 0.98 dan 0.96, dan *f1-score* sebesar 0.95 hingga 0.98. Terakhir pada Arifin Setiono tingkat presisi yang diperoleh sejumlah 0.91 hingga 1.00, *recall* sebesar 0.99 dan 0.96 dan, *f1-score* sebesar 0.94 hingga 0.98.

Kemudian untuk label “positif”, dengan menggunakan algoritma *stemming* Sastrawi dengan model *Gaussian Naïve Bayes* dan *Support Vector Machine* (dengan kernel “poly”) menghasilkan tingkat presisi antara 0.73 hingga 0.93, *recall* sebesar 0.84 dan 0.79, dan *f1-score* antara 0.78 hingga 0.85. Sedangkan dengan algoritma *stemming* Nazief dan Adriani, tingkat presisi berkisar antara 0.72 hingga 0.92, *recall* sebesar 0.74 dan 0.64, dan *f1-score* antara 0.73 hingga 0.76. Selanjutnya pada algoritma *stemming* Arifin Setiono, tingkat presisi berkisar antara 0.76 hingga 0.91, *recall* sebesar 0.72 dan 0.68, dan *f1-score* antara 0.74 hingga 0.78.

Secara keseluruhan, model *Support Vector Machine* cenderung memberikan kinerja yang lebih baik daripada *Gaussian Naïve Bayes*, dengan akurasi berkisar antara 0.85 hingga 0.91 dibandingkan dengan 0.80 hingga 0.84. Adapun perbandingan hasil pengujian dapat dilihat pada tabel 7.

Tabel 7. Perbandingan Hasil Pengujian

Algoritma Stemming	Model	Precision	Recall	F1-Score	Accuracy
Sastrawi	GNB	84%	84%	84%	84%
	SVM	91%	90%	90%	91%
Nazief	GNB	80%	80%	80%	80%
Adriani	SVM	87%	85%	86%	85%
Arifin	GNB	81%	81%	81%	82%
Setiono	SVM	88%	86%	86%	86%

4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, metode algoritma *Gaussian Naïve Bayes* dan *Support Vector Machine* dengan tiga algoritma *stemming* yang berbeda, yaitu Sastrawi, Nazief Adriani, dan Arifin Setiono. Penggunaan metode ini dilakukan dalam analisis terhadap kumpulan data sebanyak 2620 *clean data*. Evaluasi dilakukan terhadap beberapa model algoritma dan metode *stemming* yang menghasilkan perbandingan yang signifikan.

Hasil evaluasi menunjukkan bahwa pada algoritma *stemming* Sastrawi, model *Gaussian Naïve Bayes* (GNB) menghasilkan tingkat presisi, *recall*, *f1-score*, dan akurasi sebesar 84%. Sementara untuk model *Support Vector Machine* (SVM) pada algoritma

stemming yang sama, menghasilkan tingkat presisi dan akurasi sebesar 91%, dengan *recall* dan *f1-score* masing-masing sebesar 90%. Kemudian, pada algoritma *stemming* Nazief Adriani, model GNB memperoleh tingkat presisi, *recall*, *f1-score*, dan akurasi sebesar 80%. Sedangkan untuk SVM, tingkat presisi yang diperoleh adalah 87%, dengan *recall* dan akurasi sebesar 85% dan *f1-score* sebesar 86%. Selanjutnya, pada algoritma *stemming* Arifin Setiono, model GNB memperoleh tingkat presisi hingga *f1-score* sebesar 81%, sementara untuk akurasi diperoleh hasil sebesar 82%. Sedangkan untuk SVM, tingkat presisi sebesar 86% diperoleh, dengan *recall*, akurasi, dan *f1-score* sebesar 86%.

Dari hasil tersebut, dapat disimpulkan bahwa model *Gaussian Naïve Bayes* dan *Support Vector Machine* dengan algoritma *stemming* Sastrawi memberikan hasil yang lebih baik dibandingkan dengan algoritma *stemming* Nazief dan Adriani serta Arifin Setiono. Selain itu, penelitian ini juga mengungkapkan bahwa masyarakat di twitter cenderung memiliki sentimen negatif terhadap pengaruh jam kerja terhadap kesehatan mental Generasi Z, yang tercermin dari dominasi dan ketebalan kata-kata pada *Word Cloud*.

Ucapan Terimakasih

Terima kasih kepada Fakultas Ilmu Komputer Universitas Dian Nuswantoro atas segala dukungannya serta Helmi Satria atas alat tweet-harvestnya yang sangat membantu dalam pengumpulan data tweet untuk dijadikan kumpulan data dalam penelitian ini.

Daftar Rujukan

- [1] Resekiani Mas Bakar and A. Putri Maharani Usmar, “Growth Mindset dalam Meningkatkan Mental Health bagi Generasi Zoomer,” 2022.
- [2] Ahmad Ilham and Wahyu Pramusinto, “Analisis Sentimen Masyarakat Terhadap Kesehatan Mental Pada Twitter Menggunakan Algoritma K-nearest Neighbor,” Sep. 2023.
- [3] Kapo Wong, Alan H.S. Chan, and S. C. Ngan, “The Effect of Long Working Hours and Overtime on Occupational Health: A Meta-Analysis of Evidence from 1998 to 2018,” 2019.
- [4] Sungjin Park *et al.*, “The negative impact of long working hours on mental health in young Korean workers,” Aug. 2020.
- [5] Karina Aulia and Lia Amelia, “Analisis Sentimen Twitter Pada Isu Mental Health Dengan Algoritma Klasifikasi Naive Bayes,” 2020.
- [6] K. Rahayu, V. Fitria, D. Septhya, R. Rahmaddeni, and L. Efrizoni, “Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: 10.57152/malcom.v3i2.780.
- [7] N. L. Lavenia and R. Permatasari, “Sentiment Analysis on Twitter Social Media Regarding Depression Disorder Using the Naive Bayes Method,” *CoreID J.*, vol. 1, no. 2, pp. 66–74, Jul. 2023, doi: 10.60005/coreid.v1i2.14.
- [8] I. M. A. Agastya, “Pengaruh Stemmer Bahasa Indonesia Terhadap Peforma Analisis Sentimen Terjemahan Ulasan Film,” *J. Tekno Kompak*, vol. 12, no. 1, p. 18, Feb. 2018, doi: 10.33365/jtk.v12i1.70.
- [9] H. Utami, “Analisis Sentimen dari Aplikasi Shopee Indonesia Menggunakan Metode Recurrent Neural Network,” *Indones. J. Appl. Stat.*, vol. 5, no. 1, p. 31, May 2022, doi:

- 10.13057/ijas.v5i1.56825.
- [10] Davriwan Dzaky Muttaqien, Tibyani, and Pitoyo Peter Hartono, "Implementasi Support Vector Machine pada Analisis Sentimen mengenai Bantuan Sosial di Era Pandemi Covid-19 pada Pengguna Twitter," 2022.
- [11] I. K. Dharmendra, N. N. U. Januhari, I. P. Ramayasa, and I. Putra, "Uji Komparasi Sentiment Analysis Pada Opini Alumni Terhadap Perguruan Tinggi," *J. Tek. Inform. UNIKA St. Thomas*, pp. 1–6, 2022.
- [12] M. H. AL Farisi, "Analisis Sentimen Komentar Masyarakat Terhadap Kebijakan Pemerintah Tentang Sistem Zonasi Sekolah Menggunakan Algoritma K-Means dan Algoritma Levensthein Distance," 2019.
- [13] Dyah Mustikasari, Ida Widaningrum, Rizal Arifin, and Wahyu Henggal Eka Putri, "Comparison of Effectiveness of Stemming Algorithms in Indonesian Documents," 2020.
- [14] Edo Priyono Mualim, "Pendekatan Oversampling SMOTE Untuk Imbalanced Dataset Aksara Lampung Dan Klasifikasi Menggunakan Svm," 2022.
- [15] Anab Maulana Barik, Rahmad Mahendra, and Mirna Adrian, "Normalization of Indonesian-English Code-Mixed Twitter Data," 2019.
- [16] J Jumadi, D S Maylawati, L D Pratiwi, and M A Ramdhani, "Comparison of Nazief-Adriani and Paice-Husk algorithm for Indonesian text stemming process," 2021.
- [17] Jian Budiarto, "Identifikasi Kebutuhan Masyarakat Nusa Tenggara Barat pada Pandemi Covid-19 di Media Sosial dengan Metode Crawling," Feb. 2021.
- [18] D. Jurafsky and J. H. Martin, "Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition," 2019.
- [19] Khusnul Khotimah Sirajuddin, Ahmad, and Dian Novita Siswanti, "Hubungan Harga Diri Dengan Kepuasan Hidup Generasi Z Pengguna Media Sosial Instagram," 2023.
- [20] Desi Musfiroh, Ulfa Khaira, Pradita Eko Prasetyo Utomo, and Tri Suratno, "Analisis Sentimen terhadap Perkuliahan Daring di Indonesia dari Twitter Dataset Menggunakan InSet Lexicon," Apr. 2021.
- [21] Afian Syafaadi Rizki, Aris Tjahyanto, and Rahmat Trialih, "Comparison of stemming algorithms on Indonesian text processing," Feb. 2019.
- [22] Merinda Lestandy, Abdurrahim Abdurrahim, and Lailis Syafa'ah, "Analisis Sentimen Tweet Vaksin COVID-19 Menggunakan Recurrent Neural Network dan Naïve Bayes," 2021.
- [23] Ngunah Indra Purnayasa, I Made Agus Dwi Suarjaya, and I Putu Arya Dharmadadia, "Analysis of Cyberbullying Level using Support Vector Machine Method," Aug. 2022.
- [24] Nur Ghaniaviyanto Ramadhan and Faisal Dharm Adhinata, "Sentiment analysis on vaccine COVID-19 using word count and Gaussian Naïve Bayes," 2022.
- [25] Setyo Adji Pratomo, Said Al Faraby, and Mahendra Dwifebri Purbolaksono, "Analisis Sentimen Pengaruh Kombinasi Ekstraksi Fitur TF-IDF dan Lexicon Pada Ulasan Film Menggunakan Metode KNN," 2021.