

Komparasi Berbagai Metode Klasifikasi Teks untuk Sentimen Pengguna Gawai di Usia Dini

Yovi Meliana¹, Ryan Randy Suryono²

yovi_meliana@teknokrat.ac.id¹, ryan@teknokrat.ac.id²

¹Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia.

²Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia.

Informasi Artikel

Diterima : 15 Okt 2024
Direvisi : 21 Okt 2024
Disetujui : 30 Okt 2024

Kata Kunci

Penggunaan gawai,
Sentimen, Support
Vector Machine (SVM),
Naïve Bayes, Decision
Tree .

Abstrak

Dalam konteks perkembangan digital yang pesat, penggunaan perangkat gawai di kalangan anak-anak Indonesia menjadi topik yang sangat penting untuk diteliti. Penelitian ini bertujuan untuk menganalisis sentimen terkait penggunaan gawai dengan menerapkan metode klasifikasi seperti *Support Vector Machine* (SVM), *Naïve Bayes*, dan *Decision Tree*. Untuk mengatasi ketidakseimbangan data, Setelah penerapan teknik SMOTE, hasil penelitian mengungkapkan bahwa SVM memperoleh akurasi tertinggi sebesar 99% dengan SMOTE, diikuti oleh *Decision Tree* yang mencapai 98% dan *Naïve Bayes* yang memperoleh 94% saat SMOTE diterapkan. Selain itu, penerapan teknik preprocessing seperti *tokenisasi*, *stemming*, dan *filtering* berkontribusi pada peningkatan kualitas data. Temuan ini menekankan pentingnya pemilihan metode yang tepat dalam analisis sentimen untuk memahami dampak penggunaan gawai terhadap perkembangan anak-anak. Penelitian ini memberikan wawasan yang berarti bagi pengembangan kebijakan dan praktik yang lebih baik terkait penggunaan perangkat digital oleh anak-anak.

Keywords

Device usage, Sentiment, Support Vector Machine (SVM), Naïve Bayes, Decision Tree.

Abstract

In the context of rapid digital development, the use of gadgets among Indonesian children has become a very important topic to study. This study aims to analyze sentiments related to gadget use by applying classification methods such as Support Vector Machine (SVM), Naïve Bayes, and Decision Tree. To overcome data imbalance, After applying the SMOTE technique, the results of the study revealed that SVM obtained the highest accuracy of 99% with SMOTE, followed by Decision Tree which reached 98% and Naïve Bayes which obtained 94% when SMOTE was applied. In addition, the application of preprocessing techniques such as tokenization, stemming, and filtering contributed to improving data quality. These findings emphasize the importance of choosing the right method in sentiment analysis to understand the impact of gadget use on children's development. This study provides meaningful insights for the development of better policies and practices related to children's digital device use.

A. Pendahuluan

Pada era globalisasi yang sedang berlangsung, telah terjadi kemajuan pesat dalam teknologi dan informasi. Selama beberapa tahun terakhir, perhatian terhadap penggunaan perangkat digital di kalangan anak-anak semakin meningkat. Hal ini disebabkan potensi kecanduan yang berdampak negatif pada perkembangan fisik, mental, dan sosial mereka. Menurut informasi dari Badan Pusat Statistik (BPS), hampir separuh anak usia dini di Indonesia telah mampu menggunakan perangkat elektronik dan mengakses internet pada tahun 2022. Secara keseluruhan, 33,44% anak-anak usia dini di Indonesia telah menggunakan perangkat digital, dengan 24,96% di antaranya memiliki akses ke internet [1].

Berdasarkan informasi Asosiasi Penyelenggara Jasa Internet Indonesia (APJI), tingkat peetrasi internet di Indonesia telah mencapai 77,02% pada tahun 2021-2022, dengan Kalimantan memiliki tingkat penetrasi tertinggi sebesar 79,09% (APJII, 2022). Data dari BPS juga menunjukkan bahwa 67,88% penduduk Indonesia berusia 5 tahun ke atas memiliki gawai pada tahun 2022. Kepemilikan tertinggi tercatat di Kalimantan Timur, mencapai 82,37% (BPS, 2022). Di Kota Samarinda, menurut laporan APJII, sebesar 76,7% penduduknya telah menggunakan internet dari tahun 2019 sampai kuartal II 2020. Publikasi Statistik Kesejahteraan Rakyat oleh BPS Kota Samarinda menunjukkan bahwa 72,33% anggota rumah tangga berusia 5 tahun ke atas telah menggunakan internet atau media sosial dalam tiga bulan terakhir Tahun 2020 [2].

Masalah ini tidak hanya terbatas di Indonesia, tetapi juga merupakan tantangan global. Laporan dari Common Sense Media tahun 2019 menemukan bahwa anak-anak di seluruh dunia menghabiskan rata-rata 7 jam setiap hari di depan layar digital, seperti televisi, komputer, tablet, dan ponsel pintar. Selain itu, 53% anak-anak memiliki ponsel pribadi pada usia 11 tahun, dan angka ini naik menjadi 84% pada usia 14 tahun. Oleh karena itu, penting untuk memahami cara anak-anak mengungkapkan pendapat mereka tentang perangkat digital melalui analisis teks.

Analisis sentimen berkaitan dengan cara individu mengekspresikan perasaan positif atau negatif, terutama di media sosial. Di samping polaritas positif dan negatif, polaritas juga bisa dianggap sebagai rentang di mana dokumen bisa berisi pernyataan dengan polaritas campuran (Mejova, 2009). Metode ini sangat relevan dalam konteks media sosial, di mana pengguna aktif menyampaikan pendapat mereka tentang berbagai isu, termasuk penggunaan perangkat digital [3].

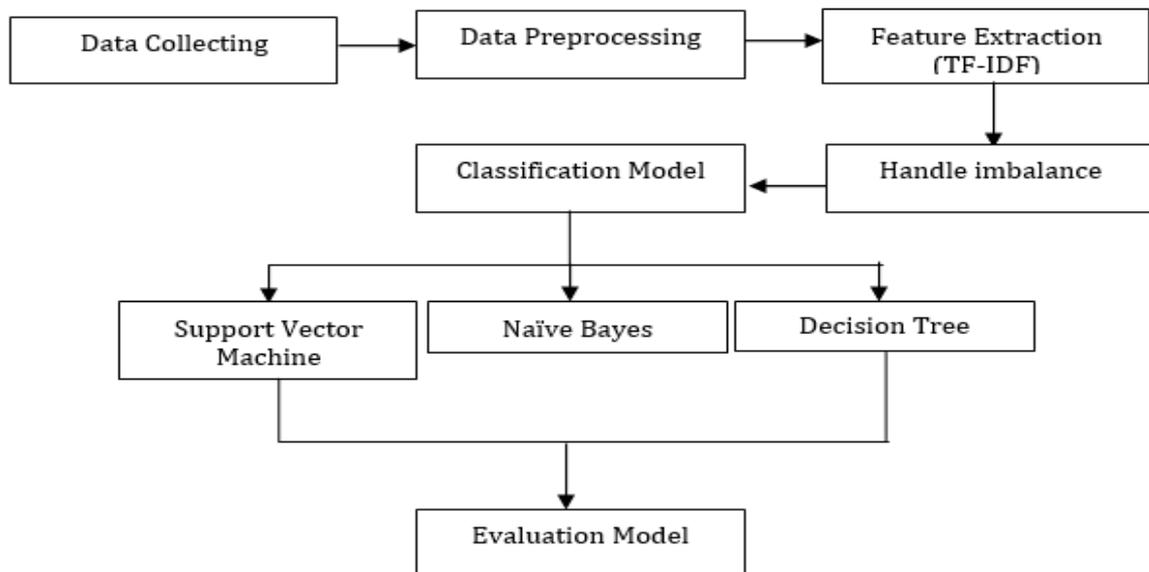
Penelitian sebelumnya menunjukkan bahwa penggunaan perangkat digital dapat memberikan dampak positif pada perkembangan anak, seperti meningkatkan kreativitas, kemampuan komunikasi, dan keterampilan sosial. Namun Chaidiman dkk. Penelitian (2019) menunjukkan bahwa remaja yang menggunakan perangkat digital dalam durasi 6-8 jam per hari mengalami gangguan pola tidur karena penggunaan yang tidak teratur dan sulit melepaskan perangkat, yang dapat menyebabkan kecanduan [4].

Dengan demikian, tujuan dari penelitian ini adalah untuk melakukan membandingkan efektivitas metode analisis sentimen yang berbeda di kalangan anak-anak pengguna perangkat digital. Platform X sangat penting dalam pengumpulan data untuk menganalisis sentimen masyarakat. Sebagai platform populer, X memberikan akses ke berbagai data dari berbagai sudut pandang. Dalam

studi ini, kualitas data yang digunakan sangat penting, data dari *Twitter* harus dibersihkan dan diolah dengan baik agar analisis dapat akurat. Algoritma yang digunakan seperti *SVM*, *Naïve Bayes*, dan *Decision Tree* namun untuk metode yang akan digunakan termasuk dalam proses tokenisasi, stemming, dan penghapusan kata umum untuk menciptakan dataset yang akurat dan mewakili.

B. Metode Penelitian

Alur penelitian ini terdiri dari 6 tahapan utama. Pertama, dilakukan pengumpulan data (*Data Collection*) yang berfungsi sebagai dasar untuk proses lebih lanjut. Setelah itu, data yang terkumpul akan melalui tahap preprocessing untuk membersihkan dan mempersiapkan data tersebut. Langkah selanjutnya adalah melakukan ekstraksi fitur menggunakan metode TF-IDF (Term-Frekuensi-Inverse Document) untuk mengkonversi teks ke dalam format numerik. Kemudian, untuk mengatasi masalah ketidakseimbangan data (*Handle Imbalance*), digunakan teknik SMOTE (*Synthetic Minority Over-sampling Technique*). Setelah proses penyeimbangan data, langkah selanjutnya adalah klasifikasi model. Proses klasifikasi ini menggunakan *support vector machine (SVM)*, *Naïve Bayes*, dan *Decision Tree*. Langkah terakhir adalah evaluasi model, yang dilakukan dengan menggunakan berbagai metrik, presisi, recal, skor f1. Matrik ini digunakan untuk mengevaluasi kinerja. Tiga algoritma digunakan untuk menganalisis sentimen mengenai pengguna awal platform x. Gambar 1. menunjukkan tahapan penelitian.



Gambar 1. Tahapan Penelitian

1. Data Collecting

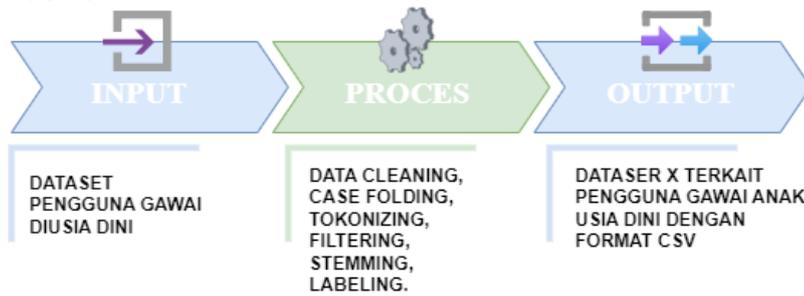
Data dikumpulkan dari platform media sosial *Twitter* dengan teknik web *crawling*, memanfaatkan bahasa pemrograman python. Proses ini dilakukan dengan menggunakan perpustakaan Harvest untuk mengekstrak tweet yang mengandung kata kunci “efek gawai anak” sebanyak 8073 tweet berhasil dikumpulkan, dengan seluruh teks dalam bahasa Indonesia. Setelah pengumpulan, data disimpan dalam format CSV untuk keperluan analisis lebih lanjut. Berikut alur pengumpulan data dapat dilihat pada Gambar 2.



Gambar 2. Alur Pengumpulan Data

2. Data Preprocessing

Selanjutnya, dilakukan Pre-processing data. Tahap ini adalah proses dalam data mining yang merubah data mentah ke dalam format yang lebih mudah dimengerti, dengan menghapus komentar yang tidak mengandung opini, seperti nilai yang hilang, data yang tidak valid, dan informasi yang berlebihan.



Gambar 3. Alur Preprocessing

Berbagai teknik *preprocessing* yang diterapkan dalam penelitian ini meliputi:

2.1 Data Cleaning

Data Cleaning adalah proses menilai kualitas data dengan mengoreksi, mengubah, atau menghapus informasi dalam database yang dianggap tidak relevan, tidak lengkap, tidak akurat, atau format salah. Tujuan dari proses ini adalah untuk menghasilkan data yang berkualitas tinggi [5].

2.2 Case Folding

Case folding merupakan proses mengubah huruf besar menjadi huruf kecil. Langkah ini memungkinkan komputer bisa membedakan antara huruf besar dan huruf kecil, memastikan konsistensi dalam pengolahan kata [6].

2.3 Tokenizing

Tokenizing adalah proses yang bertujuan untuk memecah kalimat atau paragraf menjadi kata atau token individual. Proses ini menggunakan spasi sebagai pembatas untuk memotong setiap kata dalam kalimat atau pragraf [7].

2.4 Filtering (Stopword Removal)

Setelah tahap *tokenizing* selesai, langkah berikutnya adalah *filtering*. *Filtering* adalah proses dalam pengolahan data teks yang menghilangkan kata-kata yang tergolong sebagai *stopword*, yaitu kata-kata yang dianggap tidak memberikan kontribusi signifikan dalam analisis sentimen. [8].

2.5 Stemming

Proses *stemming* adalah tahap yang bertujuan untuk menemukan bentuk dasar dari sebuah token. Dalam langkah ini, dibuat aturan untuk menghapus imbuhan atau menentukan akar kata dalam suatu teks.

Hasil *preprocessing* dapat dilihat pada Tabel 1. berikut ini.

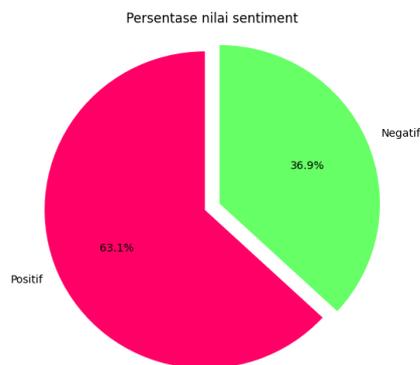
Tabel 1. Hasil *Preprocessing*

Tahapan	Hasil <i>Preprocessing</i>
<i>Dataset</i>	Pihak Dinas Pendidikan Cianjur telah berkomunikasi
<i>Cleaning</i>	Pihak Dinas Pendidikan cianjur telah berkomunikasi
<i>Case Folding</i>	Pihak dinas Pendidikan cianjur telah berkomunikasi
<i>Tokenizing</i>	`pihak`, `dimas`, `Pendidikan`, `cianjur`, `telah`, `berkomunikasi`,
<i>Filtering</i>	`dimas`, `pendidikan`, `cianjur`, `berkomunikasi`
<i>Stemming</i>	dimas pendidikan cianjur berkomunikasi

2.6 Labelling

Proses *labelling* adalah langkah yang mengelompokkan data teks berdasarkan sentimen, seperti positif dan negatif, dalam analisis sentiment. Pada tahap ini, setiap teks dianalisis untuk menentukan perasaan atau opini yang terkandung di dalamnya. Label ini membantu dalam memahami bagaimana suatu topik diterima oleh publik dan merupakan dasar untuk analisis lebih lanjut [9].

Berdasarkan hasil pelabelan, sebanyak 5.096 tweet diidentifikasi sebagai sentimen positif, sedangkan 2.977 tweet diklasifikasikan sebagai sentimen negatif. Persentase dari kedua kategori tersebut dapat dilihat pada Gambar 4.



Gambar 4. Persentase Nilai Sentiment

3. Feature Extraction (TF - IDF)

Ekstraksi fitur adalah metode yang umum digunakan untuk menyederhanakan kompleksitas data. Hal ini melibatkan konversi data dalam jumlah besar menjadi fungsionalitas yang dapat dikelola tanpa kehilangan nilai informasi. Menambahkan fitur ini secara signifikan meningkatkan kinerja model. Istilah frekuensi kemunculan (TF) dan frekuensi dokumen terbalik (IDF) digunakan untuk menilai seberapa sering sebuah kata muncul dalam sebuah dokumen dibandingkan dengan jumlah total kata yang ada [10].

$$idf d = \log \frac{\text{Number of document}}{\text{Total Number of tern n document}} \quad (1)$$

IDF mengukur seberapa sering atau jarangny suatu istilah muncul di seluruh kumpulan dokumen.

$$TF - IDF = tf(t. d \times IDF (d)) \quad (2)$$

TF-IDF merupakan hasil dari pengalian nilai TF dan IDF. Dengan Megintegrasikan informasi tentang frekuensi istilah dalam dokumen (TF) dan distribusi istilah di seluruh kumpulan dokumen (IDF), TF-IDF menghasilkan skor yang lebih akurat serta memberikan bobot yang lebih baik pada setiap istilah.

4. **Handle Imbalance (SMOTE) Synthetic**

Handle Imbalance (SMOTE), atau yang disebut dengan teknik *syntetic minority oversampling* merupakan salah satu metode untuk mengatasi masalah ketidakseimbangan kelas pada kumpulan data [11]. Ketidakseimbangan kelas terjadi ketika jumlah contoh di satu kelas jauh lebih rendah dibandingkan jumlah contoh di kelas lain, sehingga dapat menyebabkan model pembelajaran mesin lebih mengutamakan kelas mayoritas. Dengan menerapkan SMOTE, diharapkan model tidak hanya memperhatikan kelas mayoritas, tetapi juga dapat mengidentifikasi pola dalam kelas minoritas. Hal ini bertujuan untuk meningkatkan kinerja keseluruhan sistem.

5. **Model Classification (Klasifikasi Model)**

Modeling merupakan proses klasifikasi yang bertujuan untuk menentukan tingkat akurasi dari berbagai algoritma yang diterapkan [12]. Setelah itu, hasil dari setiap algoritma akan dibandingkan untuk mengevaluasi kinerjanya secara menyeluruh. Penerapan model klasifikasi melibatkan pengguna algoritma *Support Vector Machine (SVM)*, *Naïve Bayes*, dan *Decision Tree*.

5.1 *Support Vector Machine (SVM)*

Support Vector Machine (SVM) adalah algoritma klasifikasi yang digunakan untuk menemukan *hyperplane*, yaitu garis pemisah yang memiliki jarak maksimum antara kelas data yang berbeda. Jarak ini mencerminkan seberapa jauh titik data berada dari *hyperplane*. Titik-titik yang terdekat dengan *hyperplane* dikenal sebagai vektor pendukung [13].

SVM bertujuan untuk meningkatkan akurasi klasifikasi dan generalisasi model dengan memaksimalkan margin ini. Margin yang lebih besar antara *hyperplane* dan titik data dari masing-masing kelas membantu SVM dalam mengurangi risiko *overfitting*, yaitu kondisi di mana model terlalu sesuai dengan data pelatihan sehingga kinerjanya menurun pada data baru. Dalam konteks ini, SVM tidak hanya berfokus pada klasifikasi yang benar dari data pelatihan, tetapi juga pada penciptaan model yang dapat beradaptasi dengan baik terhadap variasi dalam data yang tidak terlihat. Dengan cara ini, SVM menjadi efektif dalam berbagai aplikasi, seperti pengenalan pola, pengolahan bahasa alami, dan analisis sentimen

5.2 *Naïve Bayes*

Metode *Naive Bayes* diterapkan untuk klasifikasi dengan menerapkan aturan Bayes melalui perhitungan probabilitas. Proses klasifikasi dilakukan dengan mengelompokkan data berdasarkan nilai probabilitas tertinggi. Banyak peneliti yang menggunakan metode *Naive Bayes* karena dianggap efektif dalam mencapai tingkat akurasi yang tinggi [14].

5.3 Decision Tree

Salah satu metode umum untuk klasifikasi dan prediksi adalah *Decision Tree*. Struktur pohon ini membantu dalam menentukan konsekuensi dari setiap keputusan yang diambil. Hasil dari proses ini adalah variabel yang dapat digunakan untuk memprediksi respons atau keluaran. Dengan pendekatan ini, kita bisa mempertajam pemahaman dari data pelatihan dan labelnya, menebak kategori atau label kelas, dan mengklasifikasikan data baru. Tersedia beberapa algoritma klasifikasi dalam machine learning, dan konsep dasar algoritma pohon keputusan akan dijelaskan dalam konteks ini [15].

6. Model Evaluation (Evaluasi Model)

Dalam penelitian ini, evaluasi terhadap metode yang digunakan sangat penting untuk menentukan apakah metode tersebut telah mencapai tingkat akurasi yang memadai. Kemampuan prediksi diukur menggunakan *Confusion Matrix*, yang mencakup metrik seperti Akurasi, Precision, Recall, dan F1-Score. Gambar *Confusion Matrix* pada Tabel 2. sebagai berikut.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+PN} \times 100 \quad (3)$$

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

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

$$F1 - Score = \frac{2 \times Presisi \times Recall}{Presisi \times Recal} \quad (6)$$

Tabel 2. Confusion Matrix

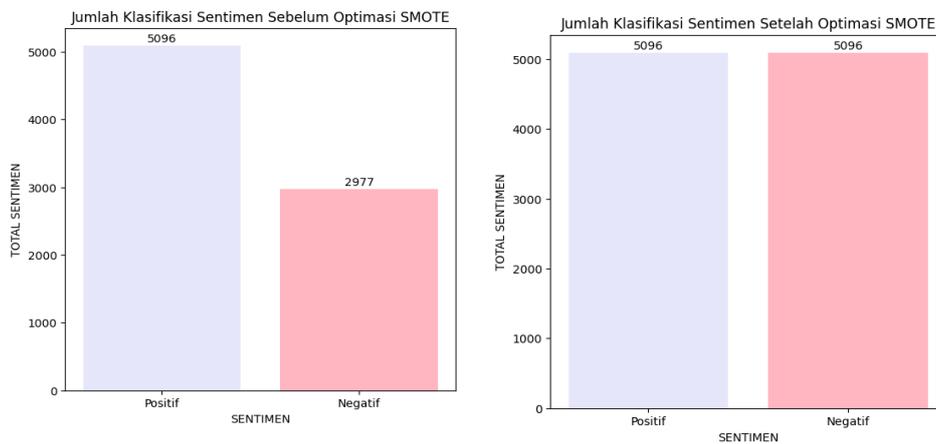
Class	Classified as positive	Classified as negative
Positif	True Positive (TP)	False Negative (FN)
Negatif	False Positive (FP)	True Negative (TN)

Dalam mengevaluasi model klasifikasi, terdapat empat metrik utama yang digunakan untuk mengukur kinerjanya *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Metrik-metrik ini berperan dalam menilai akurasi model. TP merujuk pada jumlah data yang berhasil diidentifikasi dengan benar sebagai positif. FP adalah jumlah data yang keliru diidentifikasi sebagai positif, sedangkan TN menunjukkan jumlah data yang diidentifikasi dengan akurat sebagai negatif. Di sisi lain, FN adalah jumlah data yang salah dikategorikan sebagai positif. Dengan memanfaatkan kombinasi keempat metrik ini dapat menghitung ukuran evaluasi tambahan, seperti presisi, recall, dan akurasi, untuk memahami seberapa baik model dalam memprediksi kelas berdasarkan data yang tersedia.

C. Hasil dan Pembahasan

1. Dataset

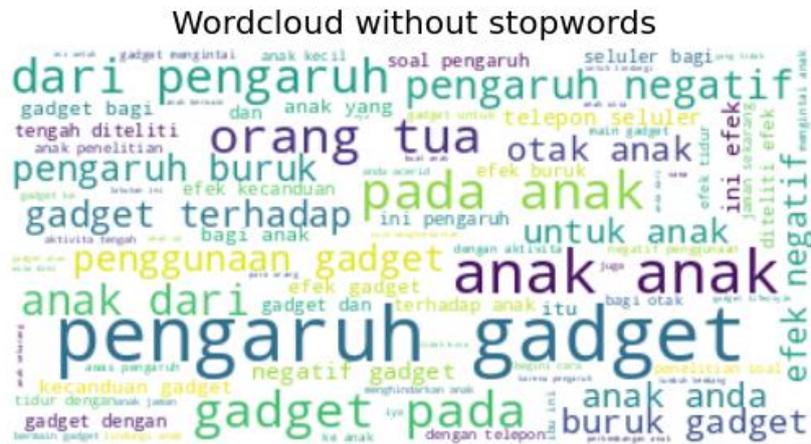
Peneliti telah mengumpulkan jumlah seluruh data yang dianalisis 8073 tweet. Dataset yang didapat dari proses crawling menunjukkan bahwa terdapat 5096 data sentimen positif dan 2977 data sentimen negatif. Ketidakseimbangan antara kedua kelas tersebut diatasi melalui optimasi menggunakan metode Synthetic Minority Oversampling Technique (SMOTE) untuk menyeimbangkan jumlah data antara kelas positif dan negatif. Setelah penerapan SMOTE, jumlah data emosi positif dan negatif menjadi sama 5096 untuk setiap kelas. SMOTE membuat sampel sintetik dari kelas minoritas (dalam hal ini, kelas negatif) untuk memastikan keseimbangan dalam kumpulan data. Keseimbangan ini membantu model belajar kedua kelas secara lebih baik, sehingga meningkatkan performa model dalam mengklasifikasikan data sentimen. Penerapan sebelum SMOTE dan sesudah SMOTE dapat dilihat di gambar 5 .



Gambar 5. Jumlah klasifikasi sentimen sebelum dan setelah SMOTE

2. Tahap Visualisasi *Word Cloud*

Word Cloud adalah representasi visual dari sekumpulan kata yang paling sering muncul dalam teks atau dokumen. Tujuannya adalah untuk menampilkan data secara grafis sehingga dapat dengan mudah mengidentifikasi istilah yang paling sering muncul. Proses pembuatan *Word Cloud* dilakukan dengan menggunakan library *matplotlib* dalam bahasa pemrograman Python. Hasil visualisasi *Word Cloud* ditunjukkan pada Gambar 6. Kata-kata yang berukuran lebih besar menunjukkan frekuensi kemunculan yang lebih tinggi, seperti "Pengaruh gadget".



Gambar 6. Visualisasi Word Cloud

3. Tahap Pengujian

Setelah beberapa tahap, dilakukan evaluasi dengan menguji tiga algoritma klasifikasi *Support Vector Machine*, *Naïve Bayes*, dan *Decision Tree*. 80% data digunakan untuk pelatihan, dan 20% sisanya dipakai untuk pengujian. Performa ketiga model dievaluasi menggunakan berbagai metrik seperti matriks konfusi, akurasi, presisi, recall dan skor f1. Metrik-metrik ini memberikan analisis menyeluruh mengenai efektivitas masing-masing model dalam mengklasifikasikan data secara akurat dan efisien.

3.1 Nilai Accuracy, Precision, Recall, F1-Score

Tabel 3. menampilkan tingkat akurasi antar *Support Vector Machine*, *Naïve Bayes*, dan *Decision Tree*.

Tabel 3. Hasil Nilai Accuracy

Metode	Accuracy score	
	Sebelum Smote	Setelah Smote
SVM	0.97	0.99
Naïve Bayes	0.92	0.94
Decision Tree	0.98	0.98

Tabel 3 menunjukkan pengaruh metode *Decision Tree* terhadap akurasi, dengan SMOTE atau tanpa SMOTE mencapai 98%. Di sisi lain, kinerja metode *Naive Bayes* meningkat saat digunakan bersama metode SMOTE, mencapai tingkat akurasi 94% dibandingkan tanpa SMOTE. Saat ini, SVM mencapai tingkat akurasi 99% dengan menggunakan SMOTE dan 97% tanpa SMOTE. Maka, dari ketiga metode tersebut. Metode SVM memiliki keunggulan dalam menangani ketidakseimbangan kelas pada data sentimen pengguna gawai di usia dini dibandingkan metode lain.

Dalam studi ini, selain mengukur akurasi, juga digunakan F1-score, presisi, dan recall. Hasil klasifikasi dilihat pada Tabel 4 dan Tabel 5.

Tabel 4. Hasil Klasifikasi Sebelum Smote

<i>Modelling</i>	<i>Sentimen</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>SVM</i>	Positif	0.98	0.99	0.98
	Negatif	0.98	0.96	0.97
<i>Naïve Bayes</i>	Positif	0.93	0.96	0.94
	Negatif	0.93	0.87	0.98
<i>Decision Tree</i>	Positif	0.99	0.99	0.99
	Negatif	0.98	0.98	0.98

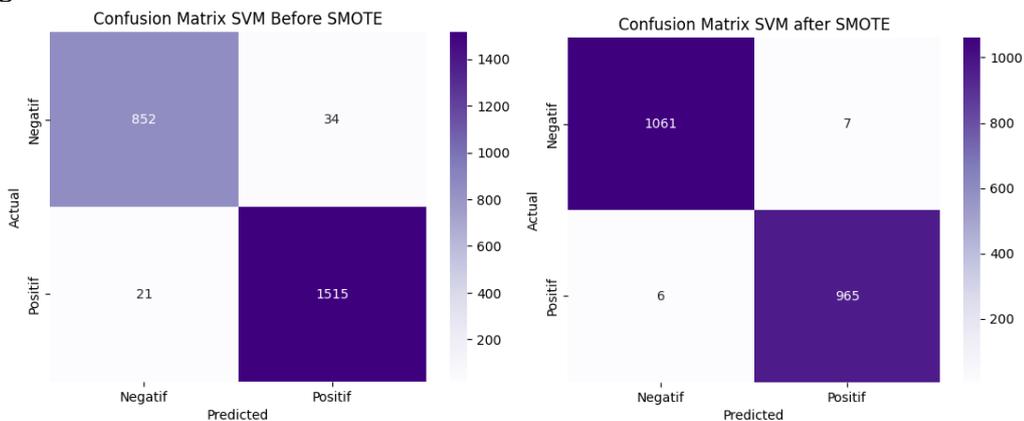
Tabel 5. Hasil Klasifikasi Setelah Smote

<i>Modelling</i>	<i>Sentimen</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>SVM</i>	Positif	0.99	0.99	0.99
	Negatif	0.99	0.99	0.99
<i>Naïve Bayes</i>	Positif	0.97	0.91	0.94
	Negatif	0.92	0.94	0.94
<i>Decision Tree</i>	Positif	0.98	0.99	0.98
	Negatif	0.98	0.97	0.97

Setelah penerapan SMOTE, algoritma SVM menunjukkan peningkatan pada nilai presisi, recall, dan F1-score. Untuk metode *Naive Bayes*, nilai presisi pada sentimen positif meningkat setelah menggunakan SMOTE, namun nilai recall mengalami penurunan pada sentimen positif setelah menggunakan SMOTE, sementara F1-score tetap stabil. Di sisi lain, dalam metode *Decision Tree*, nilai presisi meningkat namun sentimen positif mengalami penurunan. Sementara itu, nilai recall mengalami penurunan untuk sentimen negatif, meskipun sentimen positif menunjukkan peningkatan, dan F1-score juga menurun secara keseluruhan.

4. Hasil Confusion Matrix

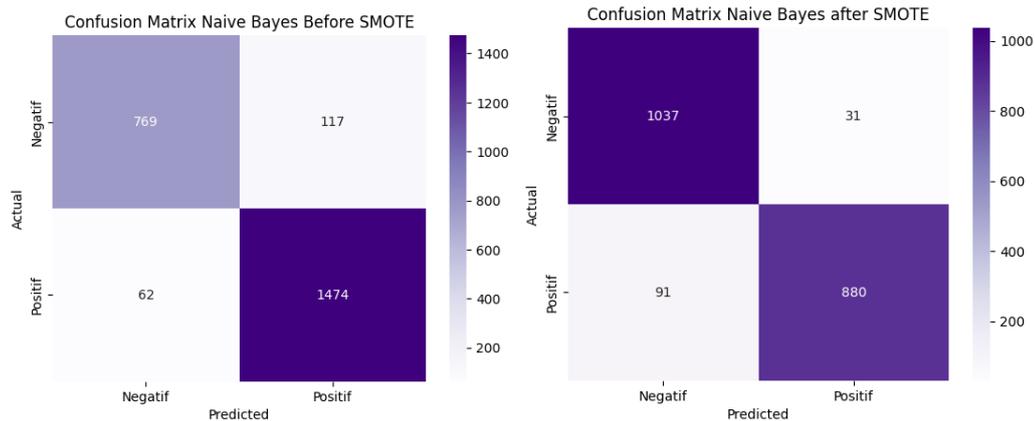
Selain itu, penelitian ini juga membandingkan matriks konfusi ketiga algoritma. Tujuan dari perbandingan ini adalah untuk mempertimbangkan indikator-indikator seperti true positive (TP), false positive, true negative (TN), dan false negative (FN) untuk mengidentifikasi emosi positif dan negatif setiap algoritma.



Gambar 7. Confusion Matrix SVM Sebelum dan Setelah SMOTE

Dari *confusion matriks* SVM, dapat dilihat bahwa model menunjukkan performa yang cukup baik dalam mengidentifikasi sentimen positif (1515 TP) dan negatif (852 TN). Namun, terdapat beberapa kesalahan, di mana sejumlah sentimen negatif diidentifikasi sebagai positif (34 FP), dan beberapa sentimen positif diidentifikasi sebagai negatif (21 FN). Setelah penerapan SMOTE, terdapat peningkatan signifikan dalam kemampuan model untuk mengidentifikasi sentimen positif, dengan jumlah *True Positive* (TP) mencapai 965 dan hanya sedikit kesalahan pada *False Negative* (FN), yang berkurang menjadi 6. Model juga menunjukkan peningkatan dalam mengenali sentimen negatif, dengan *True Negative* (TN) mencapai 1061 dan hanya 7 *False Positives* (FP).

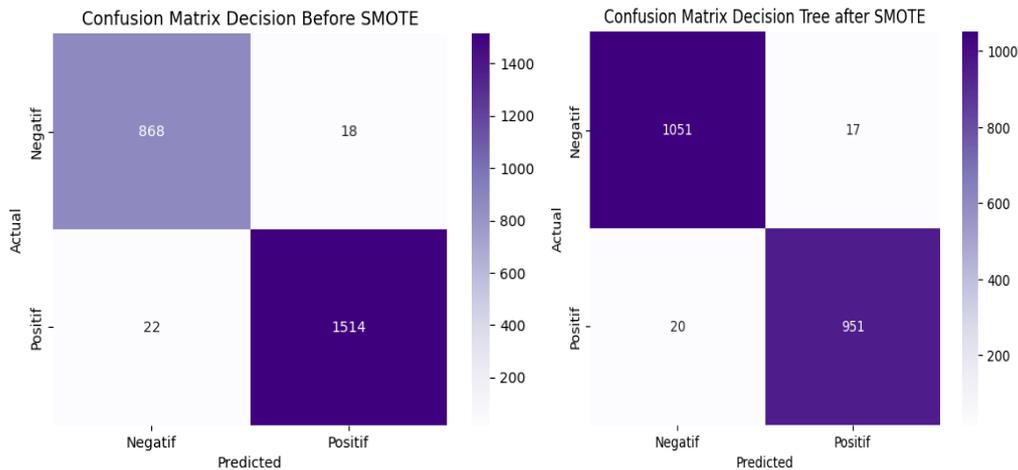
Penerapan SMOTE terbukti sangat efektif dalam meningkatkan kinerja model dalam mengenali kedua jenis sentimen tersebut. Model ini jauh lebih handal dalam mengidentifikasi sentimen positif tanpa banyak mengorbankan kemampuan untuk mendeteksi sentimen negatif.



Gambar 8. *Confusion Matrix Naïve Bayes* Sebelum dan Setelah SMOTE

Dalam *confusion matrix Naïve Bayes*, model menunjukkan kemampuan yang efektif dalam mengenali sentimen positif, seperti yang terlihat dari 1474 *True Positive* (TP). Namun, terdapat 62 *False Negative* (FN), yang menunjukkan bahwa model salah mengklasifikasikan 62 sentimen positif sebagai negatif. Selain itu, ada 117 *False Positive* (FP), yang mengindikasikan kesalahan dalam mengidentifikasi beberapa sentimen negatif sebagai positif. Model juga berhasil mencatat 769 *True Negatives* (TN).

Setelah penerapan SMOTE, model menunjukkan peningkatan dalam pengenalan *True Negatives* (TN), mencapai 1037, lebih tinggi dibandingkan dengan hasil sebelumnya. Jumlah *False Positive* (FP) menurun secara signifikan menjadi 31, yang mencerminkan peningkatan akurasi dalam mengenali sentimen negatif. Namun, untuk pengenalan sentimen positif, terdapat sedikit penurunan pada *True Positive* (TP), yang kini menjadi 880, dan peningkatan pada *False Negative* (FN) menjadi 91, menunjukkan bahwa beberapa sentimen positif telah salah diidentifikasi sebagai negatif.



Gambar 9. *Confusion Matrix Decision Tree* Sebelum dan Setelah SMOTE

Model berhasil secara akurat mengidentifikasi 868 data negatif. Namun, ada 18 data negatif yang salah diklasifikasikan sebagai positif. Selain itu, model salah mengenali 22 data positif sebagai negatif. Di sisi lain, data positif sebanyak 1528 berhasil diklasifikasikan dengan benar. Secara keseluruhan, model ini menunjukkan kinerja yang baik dalam mendeteksi sentimen positif, ditandai dengan jumlah *False Negative* (FN) yang sangat minim. Meskipun demikian, masih terdapat beberapa kesalahan dalam mendeteksi sentimen negatif, seperti yang ditunjukkan oleh 18 *False Positive* (FP).

Setelah menggunakan SMOTE, model menunjukkan peningkatan dalam mengenali data negatif, dengan jumlah *True Negative* (TN) yang meningkat menjadi 1051. Kesalahan klasifikasi negatif sebagai positif juga berkurang, dengan jumlah *False Positive* (FP) turun menjadi 17. Meskipun demikian, jumlah *False Negative* (FN) tetap sama, yaitu 20, menunjukkan bahwa kesalahan dalam mengidentifikasi sentimen positif tidak berubah. Namun, jumlah *True Positives* (TP) menurun menjadi 951 setelah penerapan SMOTE.

D. Simpulan

Penelitian ini membahas isu penting tentang pemanfaatan gawai oleh anak-anak di Indonesia dan dampaknya pada perkembangan mereka dengan menganalisis sentimen dari 8073 tweet, menemukan bahwa metode klasifikasi svm memberikan performa terbaik akurasi mencapai 99% setelah menerapkan teknik smote yang efektif dalam menyeimbangkan data antara sentimen positif dan negatif metode *decision tree* dan juga menunjukkan hasil yang memuaskan dengan akurasi masing-masing 98% dan 94% setelah penerapan smote. Temuan ini menekankan efektivitas teknik smote dalam meningkatkan akurasi model dan pentingnya *preprocessing* data untuk analisis yang lebih tepat. Temuan dari penelitian ini dapat dijadikan landasan untuk mengembangkan kebijakan yang lebih baik terkait penggunaan teknologi di kalangan anak-anak. Selain itu, Hasil penelitian ini juga memberikan peluang untuk penelitian lebih lanjut yang dapat menyelidiki dampak jangka panjang dari penggunaan metode analisis dan teknologi digital lainnya.

E. Ucapan Terima Kasih

Saya mengucapkan terima kasih yang sebesar-besarnya kepada pembimbing yg telah memberikan dukungan, dan kontribusinya yang sangat berharga dalam penelitian ini. Tanpa arahan dan saran yang konstruktif dari beliau, penelitian ini tidak akan dapat diselesaikan dengan baik.

Saya juga ingin menyampaikan rasa terima kasih kepada Universitas Teknokrat Indonesia atas dukungan dan fasilitas yang diberikan selama proses penelitian ini.

F. Referensi

- [1] L. Aviva, D. H. Muhammad, and H. R. Halili, "Upaya Guru PAI dalam Mengatasi Dampak Negatif Kecanduan Gadget Terhadap Siswa SMP Islam Hikmatul Hasanah Kecamatan Tegalsiwalan," *J. Pendidik. dan Konseling*, vol. 4, no. 1, pp. 478–489, 2022.
- [2] J. N. Hidayat, A. Prasetyarini, K. Anam, R. Wahyuni, and P. S. Kebidanan, "Hubungan Peran Pengawasan OrangTua Dengan Penggunaan Gagdet Pada Anak Usia Prasekolah di TK Kartika V-11, Melatih," *E-Jurnal Penelit.*, vol. 01, no. 05, pp. 1038–1044, 2023.
- [3] J. Supriyanto, D. Alita, and A. R. Isnain, "Penerapan Algoritma K-Nearest Neighbor (K-NN) Untuk Analisis Sentimen Publik Terhadap Pembelajaran Daring," *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 4, no. 1, pp. 74–80, 2023.
- [4] L. Siwi, "Jurnal Interdisiplin Sosiologi Agama (JINSA) Jurnal Interdisiplin Sosiologi Agama (JINSA)," *J. Interdisiplin Sociol. Agama*, vol. 03, no. 4, pp. 23–30, 2022.
- [5] A. R. Raharja, Jayadi, A. Pramudianto, and Y. Muchsam, "Penerapan Algoritma Decision Tree dalam Klasifikasi Data 'Framingham' Untuk Menunjukkan Risiko Seseorang Terkena Penyakit Jantung dalam 10 Tahun Mendatang," *Technol. J.*, vol. 1, no. 1, 2024.
- [6] I. Artikel and A. Info, "Komparasi Analisis Sentimen Ulasan Film Avengers : Endgame di IMDB Menggunakan Metode Naive Bayes dan SVM," vol. 3, no. 3, pp. 156–166, 2024.
- [7] B. Ramadhani and R. R. Suryono, "Komparasi Algoritma Naïve Bayes dan Logistic Regression Untuk Analisis Sentimen Metaverse," *J. Media Inform. Budidarma*, vol. 8, no. 2, p. 714, 2024.
- [8] L. Rofiqi and M. Akbar, "Analisis Sentimen Terkait RUU Perampasan Aset dengan Support Vector Machine," *JEKIN - J. Tek. Inform.*, vol. 4, no. 3, pp. 529–538, 2024.
- [9] K. Cyberbullying and D. I. Instagram, "Komparasi metode algoritma klasifikasi pada analisis sentimen komentar cyberbullying di instagram," vol. 7, pp. 466–472, 2024.
- [10] Y. Setiawan, D. Gunawan, and R. Efendi, "Feature Extraction TF-IDF to Perform Cyberbullying Text Classification: A Literature Review and Future Research Direction," *2022 Int. Conf. Inf. Technol. Syst. Innov. ICITSI 2022 - Proc.*, no. May, pp. 283–288, 2022.
- [11] C. Bintang, G. Allo, N. Roona Paranoan, W. Ade Fitriya B, and S. Rosnafi'an Sumardi, "Perbandingan Metode Klasifikasi Kegagalan Simulasi Model Iklim

- Perbandingan Metode Klasifikasi Kegagalan Simulasi Model Iklim,” *Koloni*, vol. 2, no. 1, pp. 242–249, 2023.
- [12] A. Sentimen, K. Pelatih, and T. Indonesia, “Komparasi berbagai model klasifikasi teks untuk analisis sentimen kinerja pelatih timnas indonesia,” vol. 8, no. 3, pp. 110–118, 2019.
- [13] U. Khaira, R. Aryani, and R. W. Hardian, “Komparasi Algoritma Naïve Bayes Dan Support Vector Machine (SVM) Pada Analisis Sentimen Kebijakan Kemdikbudristek Mengenai Kuota Internet Selama Covid-19,” *J. Process.*, vol. 18, no. 2, pp. 272–285, 2023.
- [14] K. V. S. Toy, Y. A. Sari, and I. Cholissodin, “Analisis Sentimen Twitter menggunakan Metode Naive Bayes dengan Relevance Frequency Feature Selection (Studi Kasus: Opini Masyarakat mengenai Kebijakan New Normal),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 11, pp. 5068–5074, 2021.
- [15] A. Setiawan, R. Febrio Waleska, M. Adji Purnama, Rahmadden, and L. Efrizoni, “Komparasi algoritma K-Nearest Neighbor (K-Nn), Support Vector Machine (Svm), Dan Decision Tree dalam Klasifikasi Penyakit Stroke,” *J. Inform. Rekayasa Elektron.*, vol. 7, no. 1, pp. 107–114, 2024.