

Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen Komentar Instagram Laga El Clásico Barcelona vs Real Madrid

Muhammad Irvan Maulana¹, Savana Putra Aditama², Harun Al Rosyid³

^{1,2,3}Pendidikan Teknologi Informasi, Universitas Negeri Surabaya

e-mail: 1muhammadirvan.22107@mhs.unesa.ac.id ,

2savana.22100@mhs.unesa.ac.id, 3harunrosyid@unesa.ac.id

Intisari

Perkembangan teknologi informasi dan komunikasi mendorong media sosial menjadi sarana utama bagi masyarakat dalam mengekspresikan opini terhadap berbagai peristiwa, termasuk pertandingan sepak bola bergengsi seperti El Clásico antara Barcelona dan Real Madrid. Tingginya interaksi pengguna Instagram menghasilkan komentar dalam jumlah besar dengan karakteristik teks tidak terstruktur dan beragam sentimen, sehingga diperlukan analisis sentimen secara otomatis untuk memahami kecenderungan opini publik. Penelitian ini bertujuan untuk menganalisis sentimen komentar pengguna Instagram terhadap laga El Clásico Barcelona vs Real Madrid dengan membandingkan algoritma Naive Bayes dan Support Vector Machine (SVM). Dataset yang digunakan terdiri dari 1.526 komentar dengan distribusi kelas sentimen yang tidak seimbang. Tahapan penelitian meliputi *preprocessing* teks, pembobotan kata menggunakan Term Frequency–Inverse Document Frequency (TF-IDF), serta proses klasifikasi sentimen. Hasil pengujian menunjukkan bahwa algoritma SVM memiliki performa yang lebih baik dibandingkan Naive Bayes, dengan nilai akurasi sebesar 62,88% dan *weighted F1-score* sebesar 0,62, sedangkan Naive Bayes memperoleh akurasi 59,53% dan *weighted F1-score* sebesar 0,52. Hasil tersebut menunjukkan bahwa SVM lebih efektif dalam menangani data berdimensi tinggi dan distribusi kelas tidak seimbang pada analisis sentimen media sosial.

Kata kunci— Analisis Sentimen, El Clasico, , Instagram, Naive Bayes, SVM, TF-IDF.

Abstract

The rapid development of information and communication technology has driven social media to become a primary platform for users to express opinions on various events, including prestigious football matches such as El Clásico between Barcelona and Real Madrid. The high level of interaction among Instagram users generates a large volume of comments with unstructured text characteristics and diverse sentiments, making automatic sentiment analysis necessary to understand public opinion trends. This study aims to analyze the sentiment of Instagram user comments related to the El Clásico match by comparing the Naive Bayes and Support Vector Machine (SVM) algorithms. The dataset consists of 1,526 comments with an imbalanced sentiment class distribution. The research stages include text preprocessing, term weighting using Term Frequency–Inverse Document Frequency (TF-IDF), and sentiment classification. The experimental results show that the SVM algorithm outperforms Naive Bayes, achieving an accuracy of 62.88% and a weighted F1-score of 0.62, while Naive Bayes achieves an accuracy of 59.53% and a weighted F1-score of 0.52. These results indicate that SVM is more effective in handling high-dimensional data and imbalanced class distributions in social media sentiment analysis.

Keywords— Sentiment Analysis, El Clasico, Instagram, Naive Bayes, SVM, TF-IDF.

PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi telah mendorong pertumbuhan media sosial sebagai salah satu sarana utama bagi masyarakat untuk menyampaikan pendapat, perasaan, dan reaksi terhadap berbagai peristiwa. Media sosial tidak hanya digunakan sebagai alat komunikasi, tetapi juga sebagai sumber data yang kaya akan opini publik [1]. Salah satu platform media sosial yang memiliki tingkat interaksi tinggi adalah Instagram, khususnya pada unggahan yang berkaitan dengan peristiwa populer seperti olahraga. Sepak bola merupakan salah satu cabang olahraga yang memiliki basis penggemar terbesar di dunia. Salah satu pertandingan sepak bola yang selalu menarik perhatian publik global adalah El Clásico, yaitu laga antara Barcelona dan Real Madrid. Pertandingan ini tidak hanya menjadi tontonan olahraga, tetapi juga menjadi fenomena sosial yang memicu reaksi emosional dari para penggemar [2]. Hal tersebut tercermin dari banyaknya komentar yang muncul di media sosial, terutama Instagram, baik dalam bentuk dukungan, kritik, maupun opini netral.

Komentar-komentar pengguna Instagram tersebut mengandung sentimen yang beragam, seperti sentimen positif, negatif, dan netral. Jumlah komentar yang besar dan sifat data yang tidak terstruktur menyebabkan analisis manual menjadi tidak efisien. Oleh karena itu, diperlukan pendekatan otomatis untuk mengolah dan mengklasifikasikan sentimen dari data teks tersebut. Analisis sentimen merupakan salah satu teknik dalam text mining dan information retrieval yang bertujuan untuk mengekstraksi informasi subjektif dari teks guna mengetahui kecenderungan opini publik terhadap suatu topik atau peristiwa [3].

Dalam analisis sentimen, proses representasi teks menjadi data numerik memiliki peran penting. Metode Term Frequency–Inverse Document Frequency (TF-IDF) sering digunakan karena mampu memberikan bobot pada kata berdasarkan tingkat kepentingannya dalam dokumen. Selanjutnya, hasil pembobotan tersebut dapat digunakan sebagai input untuk algoritma klasifikasi guna menentukan sentimen dari setiap komentar [4].

Berbagai algoritma klasifikasi telah digunakan dalam penelitian analisis sentimen, di antaranya Naive Bayes dan Support Vector Machine (SVM). Naive Bayes dikenal sebagai algoritma yang sederhana dan efisien, namun memiliki keterbatasan karena asumsi independensi antar fitur [5]. Di sisi lain, Support Vector Machine (SVM) memiliki kemampuan yang baik dalam menangani data berdimensi tinggi, seperti data hasil pembobotan TF-IDF, sehingga sering menghasilkan performa yang lebih stabil [6].

Berdasarkan latar belakang tersebut, penelitian ini dilakukan untuk menganalisis sentimen komentar pengguna Instagram terhadap laga El Clásico Barcelona vs Real Madrid dengan membandingkan performa algoritma Naive Bayes dan Support Vector Machine (SVM). Perbandingan ini bertujuan untuk mengetahui algoritma yang paling efektif dalam mengklasifikasikan sentimen komentar Instagram. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan analisis sentimen berbasis media sosial serta pemanfaatannya dalam memahami opini publik di bidang olahraga.

TINJAUAN PUSTAKA

1. Analisis Sentimen (*Sentiment Analysis*)

Sebagai bagian dari ranah *Text Mining*, analisis sentimen menitikberatkan pada upaya penggalian informasi guna mengidentifikasi opini maupun emosi subjektif yang tersirat dalam sebuah dokumen teks. Pengategorian data menjadi kelas sentimen positif, negatif, dan netral merupakan target utama dilakukannya proses analisis ini. Dalam konteks media sosial, khususnya platform X (sebelumnya Twitter), analisis sentimen menjadi krusial karena platform ini menyediakan data yang sangat besar (*high volume*) dan bersifat *real-time*. Data ini merefleksikan reaksi instan pengguna terhadap suatu peristiwa, seperti kinerja Timnas Indonesia, sehingga dapat digunakan untuk mengukur tingkat kepuasan, kekecewaan, maupun harapan publik secara terukur. Karena data teks di media sosial seringkali tidak terstruktur, diperlukan metode klasifikasi otomatis agar pemrosesan informasi bisa dilaksanakan secara efektif dan optimal.

2. Algoritma *Naïve Bayes Classifier*

Algoritma *Naive Bayes* merepresentasikan salah satu pendekatan *Machine Learning* berbasis probabilitas yang mengadopsi Teorema Bayes dalam melakukan suatu klasifikasi teks. Algoritma ini termasuk dalam kategori *Supervised Learning* dan dikenal karena kesederhanaannya namun memiliki performa yang tinggi dalam menangani klasifikasi teks [7].

Keunggulan utama *Naive Bayes* terletak pada kecepatan komputasinya dan efektivitasnya dalam memproses data berskala besar, menjadikannya metode klasifikasi yang paling banyak digunakan untuk penelitian analisis sentimen. Algoritma ini bekerja dengan mengestimasi probabilitas kejadian di masa depan dengan memanfaatkan data historis, di mana setiap fitur (kata) dianggap independen satu sama lain. Secara matematis, persamaan teorema Bayes dapat dituliskan sebagai berikut:

$$P(X) = \frac{P(C) \cdot P(C)}{P(X)} \quad (1)$$

3. Algoritma Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma klasifikasi yang bekerja dengan mencari sebuah *hyperplane* optimal yang berfungsi untuk memisahkan data ke dalam kelas-kelas tertentu dengan margin terbesar. Prinsip utama SVM adalah memaksimalkan jarak antara *hyperplane* dan titik data terdekat dari masing-masing kelas (*support vectors*), sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik terhadap data baru [8].

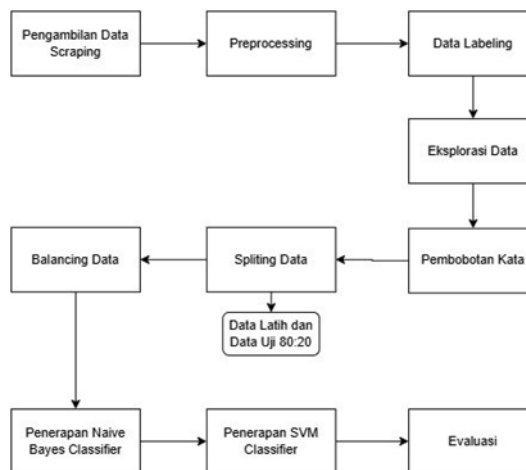
SVM dikenal sangat efektif dalam menangani data berdimensi tinggi, seperti data teks hasil pembobotan TF-IDF, di mana setiap dokumen direpresentasikan sebagai vektor dengan jumlah fitur yang besar. Kemampuan ini menjadikan SVM banyak digunakan pada tugas klasifikasi teks, termasuk analisis sentimen, karena mampu mengelola kompleksitas fitur tanpa

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Laga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

mengalami penurunan performa yang signifikan. Selain itu, SVM relatif tahan terhadap masalah *overfitting*, terutama ketika jumlah fitur lebih besar dibandingkan jumlah data. Oleh karena itu, SVM sering memberikan performa yang lebih stabil dan akurat dalam mengklasifikasikan sentimen positif, negatif, maupun netral pada data komentar media sosial.

METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen kuantitatif dengan pendekatan text mining untuk menganalisis sentimen komentar pengguna Instagram terhadap laga El Clásico antara Barcelona dan Real Madrid. Metode yang digunakan meliputi tahapan pengumpulan data, preprocessing teks, pembobotan fitur menggunakan Term Frequency–Inverse Document Frequency (TF-IDF), serta klasifikasi sentimen menggunakan algoritma Naive Bayes dan Support Vector Machine (SVM) [9]. Kedua algoritma tersebut dibandingkan untuk mengetahui performa terbaik dalam mengklasifikasikan sentimen komentar.



Gambar 1. Alur Analisis Sentimen


1. Pengumpulan Data (*Data Scraping*)

Data penelitian ini diperoleh dari komentar pengguna Instagram pada dua akun media olahraga, yaitu @bola_bini dan @faktabola, yang mempublikasikan unggahan terkait pertandingan El Clásico antara Barcelona dan Real Madrid. Kedua akun tersebut dipilih karena memiliki jumlah pengikut yang besar serta tingkat interaksi yang tinggi, sehingga komentar yang dihasilkan mencerminkan opini publik yang beragam terhadap pertandingan tersebut. Pengambilan data dilakukan dengan cara mengumpulkan seluruh komentar yang terdapat pada masing-masing unggahan yang membahas laga El Clásico. Seluruh komentar yang diperoleh kemudian digabungkan menjadi satu dataset dan dilakukan proses seleksi untuk menghilangkan komentar duplikat, komentar kosong, serta komentar yang tidak relevan dengan topik penelitian. Dari proses tersebut diperoleh total 1.526 komentar yang digunakan sebagai dataset penelitian. Dataset yang telah terkumpul selanjutnya dibagi menjadi dua bagian, yaitu data latih (training data) dan data uji (testing data) dengan

perbandingan 80% data latih dan 20% data uji. Data latih digunakan untuk melatih model klasifikasi sentimen, sedangkan data uji digunakan untuk mengevaluasi performa model dalam mengklasifikasikan sentimen komentar ke dalam tiga kelas, yaitu positif, negatif, dan netral.

2. *Pre-processing*

Preprocessing adalah serangkaian langkah yang dilakukan pada teks mentah untuk membersihkan, memformat, dan mengubah teks menjadi bentuk yang lebih terstruktur dan siap analisis [10]. *Text Preprocessing* penting untuk menghilangkan *noise* dan meningkatkan kualitas data, sehingga model dapat bekerja lebih baik dan menghasilkan *output* yang lebih akurat[11], Sebagaimana diilustrasikan pada Gambar 2, penelitian ini menerapkan rangkaian prosedur pra-pemrosesan yang sistematis, meliputi tahapan *cleansing*, *case-folding*, *normalization*, *tokenization*, *stop-word removal*, dan *stemming*.



Gambar 2. Tahapan *Preprocessing*

Tahap *cleansing* dilakukan untuk menghilangkan *noise* yang terdapat pada komentar Instagram. Pada tahap ini, komentar yang mengandung URL, mention pengguna (@), hashtag (#), angka, tanda baca, emoji, serta karakter non-alfanumerik dihapus. Selain itu, spasi ganda dan karakter tidak perlu juga dihilangkan agar setiap komentar berada dalam format teks yang bersih dan konsisten.

Selanjutnya dilakukan *case folding*, yaitu mengubah seluruh teks komentar menjadi huruf kecil (*lowercase*). Proses ini bertujuan untuk menyamakan bentuk kata sehingga perbedaan penulisan huruf kapital tidak memengaruhi proses pembobotan dan klasifikasi sentimen.

Tahap *normalization* diterapkan untuk mengubah kata tidak baku yang umum digunakan dalam komentar Instagram menjadi bentuk baku. Normalisasi dilakukan dengan memetakan singkatan, kata gaul, dan variasi ejaan ke dalam bentuk kata yang sesuai dengan Kamus Besar Bahasa Indonesia (KBBI). Langkah ini bertujuan untuk meningkatkan konsistensi kosakata dalam dataset.

Setelah proses normalisasi, dilakukan *tokenization*, yaitu memecah setiap komentar menjadi token berupa kata tunggal berdasarkan pemisahan spasi. Hasil tokenisasi ini digunakan sebagai dasar representasi teks dalam proses pembobotan kata menggunakan metode TF-IDF.

Tahap berikutnya adalah *stop-word removal*, yaitu menghapus kata-kata umum dalam bahasa Indonesia yang tidak memiliki kontribusi signifikan terhadap penentuan sentimen, seperti “dan”, “yang”, “di”, dan “adalah”. Penghapusan stopword bertujuan untuk mengurangi dimensi fitur dan meningkatkan fokus model pada kata-kata yang mengandung informasi sentimen.

Tahap terakhir adalah *stemming*, yang bertujuan untuk mengubah kata berimbuhan menjadi bentuk kata dasar. Proses *stemming* dilakukan menggunakan algoritma *stemming* bahasa Indonesia sehingga variasi kata yang

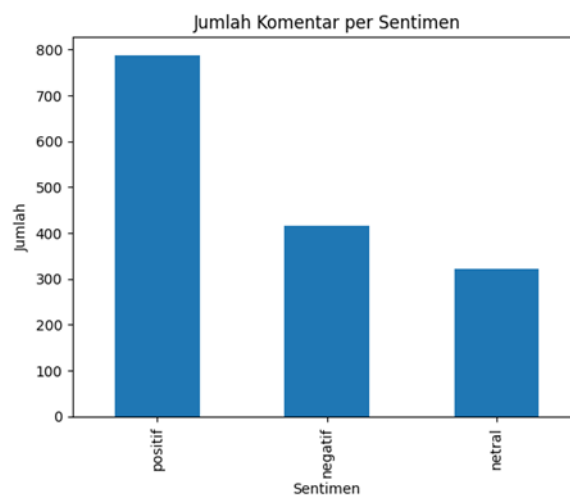
**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Laga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

memiliki makna sama dapat direduksi menjadi satu bentuk dasar. Dengan demikian, jumlah fitur menjadi lebih terkontrol dan proses klasifikasi dapat berjalan lebih efektif.

3. Data Labeling

Tahap berikutnya adalah pelabelan data sentimen menggunakan pendekatan *keyword-based labeling*. Metode ini memberikan label sentimen pada setiap komentar berdasarkan kemunculan kata kunci tertentu yang merepresentasikan sentimen positif maupun negatif. Komentar yang memiliki dominasi kata kunci positif diberi label positif, komentar dengan dominasi kata kunci negatif diberi label negatif, sedangkan komentar yang tidak mengandung kecenderungan emosional yang kuat dikategorikan sebagai netral [12]. Daftar kata kunci sentimen negatif mencakup kata-kata seperti “buruk”, “kacau”, “jelek”, “kecewa”, dan “hancur”, sementara kata kunci positif meliputi “keren”, “mantap”, “bagus”, “hebat”, dan “menang”. Komentar yang bersifat informatif atau objektif, seperti membahas jalannya pertandingan atau fakta skor, diklasifikasikan sebagai netral.

Hasil pelabelan menunjukkan bahwa distribusi sentimen komentar didominasi oleh sentimen positif sebanyak sekitar 790 komentar, diikuti oleh sentimen negatif sebanyak sekitar 410 komentar, dan sentimen netral sebanyak sekitar 326 komentar. Distribusi ini mengindikasikan bahwa mayoritas pengguna Instagram memberikan respons positif terhadap laga El Clásico, baik dalam bentuk pujian terhadap performa tim maupun apresiasi terhadap jalannya pertandingan. Meskipun metode keyword labeling relatif sederhana dan cepat diterapkan, pendekatan ini memiliki keterbatasan dalam menangani komentar yang bersifat ambigu, seperti sarkasme atau ironi. Oleh karena itu, pada tahap selanjutnya digunakan metode klasifikasi berbasis *machine learning* untuk meningkatkan akurasi analisis sentimen.



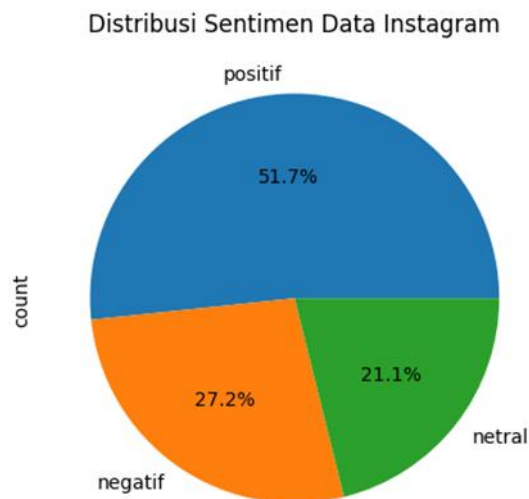
Gambar 3. Jumlah Data Sentimen

4. Data Exploration

Tahap eksplorasi data dilakukan untuk memperoleh gambaran awal mengenai karakteristik komentar pengguna Instagram terhadap laga El Clásico

Barcelona vs Real Madrid. Eksplorasi ini bertujuan untuk memahami pola distribusi sentimen serta kata-kata yang paling sering digunakan oleh pengguna sebelum dilakukan proses pemodelan lebih lanjut. Pada penelitian ini, eksplorasi data dilakukan melalui visualisasi distribusi jumlah sentimen dan Word Cloud [13].

Berdasarkan visualisasi distribusi sentimen yang ditunjukkan pada Gambar 3, dapat diketahui bahwa mayoritas komentar pengguna termasuk dalam kategori sentimen positif dengan persentase sebesar 51,7%. Hal ini menunjukkan bahwa sebagian besar pengguna Instagram memberikan respons yang bersifat apresiatif terhadap jalannya laga El Clásico, baik terhadap performa pemain maupun kualitas pertandingan secara keseluruhan. Selanjutnya, sentimen negatif menempati urutan kedua dengan persentase sebesar 27,2%, yang merepresentasikan adanya kritik, ketidakpuasan, atau kekecewaan terhadap tim maupun pemain tertentu. Sementara itu, sentimen netral memiliki persentase sebesar 21,1%, yang umumnya berisi komentar bersifat informatif, deskriptif, atau tidak mengandung muatan emosional yang kuat.



Gambar 4. Diagram Data Sentimen

Visualisasi *Word Cloud* pada Gambar 5 memberikan gambaran mengenai kata-kata yang paling sering muncul dalam keseluruhan komentar pengguna. Kata-kata seperti “madrid”, “barca”, “gol”, “menang”, “main”, “keren”, dan “lawan” tampak dominan, yang menunjukkan bahwa fokus utama komentar pengguna tertuju pada jalannya pertandingan, performa tim, serta hasil akhir laga. Selain itu, kemunculan nama pemain seperti “Yamal” dan “Pedri” mengindikasikan tingginya perhatian pengguna terhadap kontribusi individu pemain dalam pertandingan tersebut.

Secara keseluruhan, hasil eksplorasi data menunjukkan bahwa dataset komentar Instagram memiliki variasi sentimen yang cukup seimbang dengan dominasi sentimen positif. Pola kata yang muncul juga relevan dengan konteks pertandingan El Clásico, sehingga data yang digunakan dinilai representatif dan

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Liga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

layak untuk digunakan pada tahap analisis sentimen menggunakan metode klasifikasi berbasis *machine learning*.



Gambar 5. *Word Cloud* Komentar

Metode *Term Frequency-Inverse Document Frequency* (TF-IDF) diterapkan untuk memetakan data teks menjadi format angka agar dapat diproses lebih lanjut. Pendekatan ini akan memberikan pembobotan pada tiap - tiap istilah menurut frekuensi kemunculannya dalam dokumen spesifik, yang kemudian dinormalisasi terhadap frekuensinya di seluruh korpus data [14]. Mekanisme ini memungkinkan model untuk mengidentifikasi signifikansi setiap kata, di mana istilah yang relevan secara kontekstual akan memperoleh bobot lebih tinggi dibandingkan kata-kata umum yang muncul secara masif. Formulasi matematis pembobotan ini ditunjukkan pada Persamaan 2:

$$W_{t,d} = t_{ft,d} \times \log \frac{N}{d_{ft}} \quad (2)$$

Keterangan:

- $w_{t,d}$ = bobot TF-IDF
- $t_{ft,d}$ = banyaknya t dalam dokumen d
- N = frekuensi dokumen
- d_{ft} = frekuensi dokumen yang mengandung kata t

Pada tahap perhitungan bobot, proses TF-IDF diimplementasikan menggunakan *TfidfVectorizer* dari *library scikit-learn*. Modul ini menyediakan berbagai pengaturan, seperti normalisasi dan pembatasan jumlah fitur, sehingga hasil pembobotan dapat disesuaikan dengan kebutuhan analisis. Karena komponen IDF menurunkan nilai kata yang terlalu sering muncul pada banyak dokumen, metode ini efektif untuk mengurangi dominasi kata-kata umum dan meningkatkan fokus pada kata yang lebih representatif. Hasil TF-IDF adalah sebagai berikut :

	tfidf_value
bosan	0.439482
oper	0.421999
carreas	0.397359
sengaja	0.355236
lamine yamal	0.334069
bola	0.330595
lamine	0.315699
yamal	0.155321
ngukur	0.000000
ngocok	0.000000
ngk	0.000000
nggk	0.000000
nggak main	0.000000
nggak	0.000000
ngga main	0.000000

Gambar 6. Hasil TF – IDF

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Laga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

5. *Data Splitting*

Dalam pengembangan model machine learning, data splitting adalah langkah fundamental untuk mencegah bias evaluasi. Jika sebuah model diuji menggunakan data yang sama dengan yang dipelajarinya, model akan mengalami suatu kondisi di mana model hanya "menghafal" jawaban tanpa memahami pola sebenarnya (overfitting). Oleh karena itu, dataset harus dipisahkan menjadi training set (data latih) untuk pembelajaran dan testing set (data uji) untuk evaluasi performa. Pemilihan rasio pembagian data sangat krusial. Rasio data latih yang terlalu kecil membuat model kurang belajar, sedangkan rasio data uji yang terlalu kecil membuat evaluasi akurasi menjadi tidak representatif [15].

6. *Data Balancing*

Salah satu tantangan utama dalam analisis sentimen komentar media sosial adalah ketidakseimbangan kelas (*class imbalance*). Pada penelitian ini, berdasarkan hasil eksplorasi data yang ditunjukkan pada Gambar 4, distribusi sentimen komentar pengguna Instagram terhadap laga El Clásico Barcelona vs Real Madrid menunjukkan ketidakseimbangan jumlah data antar kelas. Sentimen positif mendominasi dengan persentase sebesar 51,7%, diikuti oleh sentimen negatif sebesar 27,2%, dan sentimen netral sebesar 21,1%. Kondisi ini berpotensi memengaruhi kinerja model klasifikasi, karena algoritma cenderung lebih akurat dalam memprediksi kelas dengan jumlah data yang lebih besar. Ketidakseimbangan data dapat menyebabkan model menghasilkan performa yang bias terhadap kelas mayoritas dan memiliki nilai recall yang lebih rendah pada kelas minoritas. Hal ini berisiko mengurangi kemampuan model dalam mengidentifikasi sentimen negatif dan netral secara optimal, meskipun nilai akurasi secara keseluruhan terlihat cukup baik. Oleh karena itu, diperlukan upaya penanganan ketidakseimbangan data agar model dapat mempelajari pola dari setiap kelas sentimen secara lebih seimbang.

Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan metode *Synthetic Minority Over-sampling Technique* (SMOTE) dengan memanfaatkan pustaka *imblearn*. Metode SMOTE bekerja dengan cara menghasilkan sampel sintesis baru pada kelas minoritas, yaitu sentimen negatif dan netral, berdasarkan kedekatan data dalam ruang fitur hasil pembobotan TF-IDF. Berbeda dengan metode oversampling konvensional yang hanya menduplikasi data, SMOTE menciptakan data baru dengan melakukan interpolasi antara data minoritas dan tetangga terdekatnya (*k-nearest neighbors*) [16]. Dengan penerapan metode ini, distribusi data antar kelas menjadi lebih seimbang sehingga diharapkan dapat meningkatkan performa model klasifikasi pada seluruh kelas sentimen.

7. Perbandingan Algoritma Naïve Bayes dan Support Vector Machine (SVM)

Pada penelitian ini, proses klasifikasi sentimen komentar Instagram terhadap laga El Clásico Barcelona vs Real Madrid dilakukan dengan menerapkan dua algoritma pembelajaran mesin, yaitu Naïve Bayes dan Support Vector Machine (SVM). Kedua algoritma tersebut dipilih untuk

dibandingkan karena memiliki karakteristik dan pendekatan yang berbeda dalam melakukan klasifikasi teks, sehingga diharapkan dapat memberikan gambaran yang komprehensif mengenai performa masing-masing metode dalam analisis sentimen.

Algoritma Naïve Bayes diterapkan sebagai pengklasifikasi probabilistik yang berlandaskan pada Teorema Bayes dengan asumsi bahwa setiap fitur bersifat saling independen. Dalam penelitian ini digunakan varian Multinomial Naïve Bayes, karena algoritma ini efektif dalam menangani data teks yang direpresentasikan dalam bentuk frekuensi atau bobot kata hasil ekstraksi TF-IDF (Term Frequency–Inverse Document Frequency). Proses klasifikasi dilakukan dengan menghitung probabilitas posterior suatu dokumen terhadap masing-masing kelas sentimen dan memilih kelas dengan nilai probabilitas tertinggi[17]. Untuk mengatasi permasalahan nilai probabilitas nol akibat karakteristik data teks yang jarang (*sparse*), diterapkan teknik Laplace Smoothing sehingga proses estimasi probabilitas dapat berjalan secara stabil.

Sementara itu, algoritma Support Vector Machine (SVM) digunakan sebagai metode klasifikasi berbasis margin yang bekerja dengan mencari *hyperplane* optimal untuk memisahkan data ke dalam kelas sentimen positif, negatif, dan netral. SVM dikenal memiliki kemampuan yang baik dalam menangani data berdimensi tinggi, seperti vektor TF-IDF, serta mampu memberikan performa yang stabil meskipun jumlah fitur jauh lebih besar dibandingkan jumlah data[8]. Dalam penelitian ini, SVM diharapkan dapat menangkap pola pemisahan antar kelas sentimen secara lebih optimal dibandingkan pendekatan probabilistik Naïve Bayes.

Untuk meningkatkan kinerja kedua algoritma dan mengurangi bias akibat ketidakseimbangan kelas, sebelum proses pelatihan dilakukan penerapan Synthetic Minority Over-sampling Technique (SMOTE). Pendekatan ini digunakan untuk menyeimbangkan distribusi data sentimen sehingga baik Naïve Bayes maupun SVM dapat mempelajari pola dari setiap kelas secara proporsional[18]. Hasil klasifikasi dari kedua algoritma kemudian dievaluasi dan dibandingkan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* guna menentukan algoritma yang memiliki performa terbaik dalam analisis sentimen komentar Instagram.

8. Evaluasi

Pada tahap akhir, validasi performa model dilakukan melalui instrumen *confusion matrix*. Teknik ini berfungsi sebagai tabel evaluasi untuk menilai efektivitas algoritma klasifikasi (seperti Naive Bayes) dengan cara menyandingkan hasil prediksi sistem melawan data aktual (*ground truth*) [19]. Dengan menggunakan tabel ini, peneliti tidak hanya mengetahui berapa banyak data yang diprediksi benar, tetapi juga dapat melihat secara detail jenis kesalahan yang dilakukan oleh model, apakah model cenderung salah memprediksi kelas positif sebagai negatif atau sebaliknya.

Untuk menghitung nilai evaluasi model, dapat menggunakan rumus perhitungan *accuracy*, *precision*, *recall* dan *f1-score* [20].

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Laga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

Metrik pertama ialah Akurasi (Accuracy), yang berfungsi mengukur rasio total prediksi yang benar (baik positif maupun negatif) terhadap keseluruhan data. Rumus perhitungan akurasi adalah sebagai berikut :

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

Selanjutnya, evaluasi difokuskan pada Presisi (Precision) untuk mengukur tingkat ketepatan prediksi pada kelas positif. Semakin tinggi nilai presisi, semakin sedikit kesalahan *False Positive* yang dihasilkan oleh model. Rumus perhitungan *precision* terdapat pada persamaan berikut :

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

Untuk melengkapi presisi, digunakan metrik *Recall* (Sensitivitas) yang mengukur keberhasilan model dalam menemukan kembali informasi positif yang sebenarnya ada dalam dataset. Tingginya nilai recall mengindikasikan minimnya kesalahan *False Negative*. Rumus perhitungan *recall* adalah sebagai berikut :

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

F1-Score, yang didefinisikan sebagai *harmonic mean* dari presisi dan *recall*, menjadi indikator evaluasi krusial saat menghadapi data yang tidak seimbang. Penggunaan metrik ini bertujuan untuk menjembatani celah antara presisi dan *recall*. Perhitungan nilainya mengacu pada persamaan di bawah ini:

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

Penerapan serangkaian metrik evaluasi ini memungkinkan analisis kinerja model yang lebih komprehensif pada tiap kategori sentimen. Temuan yang diperoleh tidak hanya menyoroti keunggulan algoritma, tetapi juga mendeteksi kelemahan spesifik melalui pemetaan pola misklasifikasi yang terjadi.

HASIL DAN PEMBAHASAN

Berdasarkan hasil pengujian model klasifikasi sentimen terhadap komentar Instagram laga El Clasico, algoritma Support Vector Machine (SVM) menunjukkan performa yang lebih baik dibandingkan Naive Bayes. SVM memperoleh nilai akurasi sebesar 62,88%, dengan nilai weighted F1-score sebesar 0,62, yang menandakan bahwa model cukup konsisten dalam mengklasifikasikan data dengan distribusi kelas yang tidak seimbang. Secara per kelas, SVM mampu mengklasifikasikan sentimen positif dengan baik, ditunjukkan oleh nilai precision 0,71, recall 0,76, dan F1-score 0,73, yang berarti sebagian besar komentar positif dapat dikenali secara tepat. Namun, performa SVM pada kelas netral masih relatif rendah, terutama pada nilai recall 0,40, yang menunjukkan bahwa cukup banyak komentar netral yang masih salah diklasifikasikan ke kelas lain. Kelas negatif menunjukkan performa sedang dengan F1-score 0,54, yang mengindikasikan bahwa model masih mengalami kesulitan membedakan sentimen negatif dengan sentimen lain yang memiliki kata-kata ambigu.

Sementara itu, algoritma Naive Bayes menghasilkan akurasi yang lebih rendah, yaitu 59,53%, dengan weighted F1-score sebesar 0,52. Meskipun Naive

Bayes memiliki precision yang cukup baik pada kelas negatif (0,63) dan netral (0,62), nilai recall untuk kedua kelas tersebut sangat rendah, masing-masing hanya 0,22 dan 0,15. Hal ini menunjukkan bahwa Naive Bayes cenderung gagal mengenali sebagian besar komentar negatif dan netral, meskipun prediksi yang dihasilkan relatif tepat ketika model yakin. Sebaliknya, Naive Bayes sangat baik dalam mengenali sentimen positif, dengan nilai recall yang sangat tinggi yaitu 0,96, namun precision yang lebih rendah (0,59), yang berarti model cenderung mengklasifikasikan banyak komentar sebagai positif meskipun tidak semuanya benar-benar positif.

```
*** === HASIL SVM ===  
Accuracy: 0.6287625418060201  
      precision    recall  f1-score   support  
  
negatif      0.52      0.55      0.54        76  
netral       0.53      0.40      0.46        65  
positif      0.71      0.76      0.73       158  
  
accuracy                    0.63       299  
macro avg      0.59      0.57      0.58       299  
weighted avg   0.62      0.63      0.62       299
```

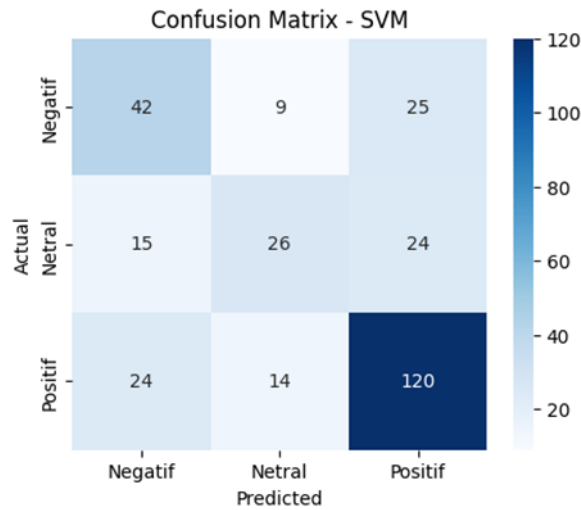
Gambar 7. Hasil Evaluasi SVM

```
*** === HASIL NAIVE BAYES ===  
Accuracy: 0.5953177257525084  
      precision    recall  f1-score   support  
  
negatif      0.63      0.22      0.33        76  
netral       0.62      0.15      0.25        65  
positif      0.59      0.96      0.73       158  
  
accuracy                    0.60       299  
macro avg      0.61      0.44      0.44       299  
weighted avg   0.61      0.60      0.52       299
```

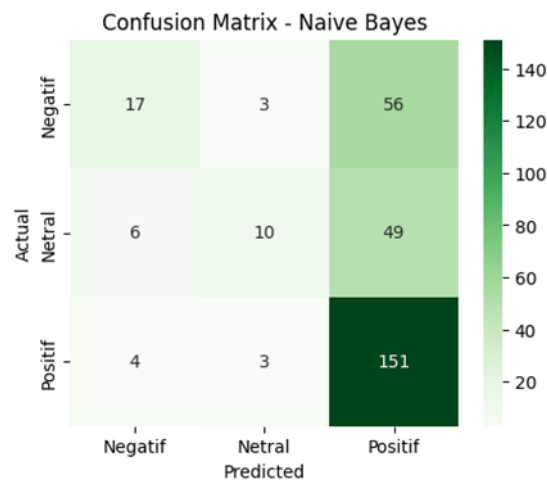
Gambar 8. Hasil Evaluasi Naïve Bayes

Selain evaluasi tabel tersebut, evaluasi juga dilakukan menggunakan confusion matrix untuk melihat distribusi hasil prediksi model terhadap kelas sentimen positif, negatif, dan netral. Confusion matrix membantu dalam mengidentifikasi kesalahan klasifikasi yang terjadi pada masing-masing kelas. Seluruh hasil evaluasi dari algoritma Naive Bayes dan SVM kemudian dibandingkan untuk menentukan algoritma yang memiliki performa terbaik dalam analisis sentimen komentar Instagram.

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Liga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**



Gambar 9. Confusion Matrix SVM



Gambar 10. Confusion Matrix Naïve Bayes

Secara keseluruhan, hasil ini menunjukkan bahwa SVM lebih unggul dan stabil dibandingkan Naive Bayes dalam melakukan analisis sentimen komentar Instagram pada kasus El Clasico. Keunggulan SVM diduga berasal dari kemampuannya menangani data berdimensi tinggi hasil pembobotan TF-IDF serta kemampuannya membentuk hyperplane pemisah yang lebih optimal antar kelas sentimen. Dengan demikian, SVM dinilai lebih sesuai digunakan pada penelitian ini dibandingkan Naive Bayes, terutama untuk data teks media sosial yang bersifat tidak terstruktur dan memiliki variasi bahasa yang tinggi.

KESIMPULAN

Penelitian ini berhasil melakukan analisis sentimen terhadap komentar pengguna Instagram terkait laga El Clásico antara Barcelona dan Real Madrid dengan membandingkan algoritma Naive Bayes dan Support Vector Machine (SVM) menggunakan pembagian data latih dan data uji sebesar 80:20. Hasil

pengujian menunjukkan bahwa algoritma SVM memiliki kinerja yang lebih unggul dibandingkan Naive Bayes, dengan capaian akurasi sebesar 62,88% dan *weighted F1-score* sebesar 0,62, sementara Naive Bayes memperoleh akurasi 59,53% dan *weighted F1-score* 0,52. Analisis *confusion matrix* mengindikasikan bahwa Naive Bayes cenderung bias terhadap kelas mayoritas sehingga kurang optimal dalam mengenali kelas minoritas, sedangkan SVM menunjukkan kemampuan klasifikasi yang lebih seimbang meskipun masih menghadapi tantangan akibat kompleksitas bahasa seperti sarkasme dan penggunaan slang pada komentar media sosial.

Dengan demikian, dapat disimpulkan bahwa SVM lebih robust dan efektif dalam menangani data berdimensi tinggi serta distribusi kelas tidak seimbang pada analisis sentimen media sosial dibandingkan pendekatan probabilistik Naive Bayes.

SARAN

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dijadikan acuan untuk penelitian selanjutnya guna menutup keterbatasan yang masih ada. Pertama, penelitian selanjutnya disarankan menggunakan dataset dengan jumlah yang lebih besar dan beragam, baik dari rentang waktu yang lebih panjang maupun dari berbagai akun atau topik serupa, agar model mampu menangkap variasi bahasa dan pola sentimen yang lebih luas.

Kedua, metode pelabelan sentimen dapat dikembangkan dengan pendekatan manual labeling atau semi-supervised labeling untuk meningkatkan kualitas label, khususnya dalam menangani komentar yang bersifat ambigu seperti sarkasme atau ironi yang belum dapat ditangani secara optimal oleh metode keyword-based labeling.

Ketiga, penelitian lanjutan dapat mempertimbangkan penggunaan algoritma klasifikasi lain atau pendekatan berbasis deep learning, seperti Long Short-Term Memory (LSTM) atau transformer-based models, untuk membandingkan performanya dengan Naive Bayes dan Support Vector Machine dalam konteks analisis sentimen media sosial.

Terakhir, proses optimasi model dapat ditingkatkan melalui tuning hyperparameter dan evaluasi dengan skema validasi yang lebih komprehensif, seperti *cross-validation*, guna memperoleh performa model yang lebih stabil dan generalisasi yang lebih baik terhadap data baru.

DAFTAR PUSTAKA

- [1] E. Okky Tegar Adinda and W. Priana Primandhana, "Pemanfaatan Media Digital dalam Meningkatkan Pemasaran dan Pertumbuhan UMKM Desa Karanganyar Kabupaten Jombang," *Jurnal Ilmiah Wahana Pendidikan*, vol. 9, no. 21, pp. 304–313, 2023, doi: 10.5281/zenodo.10076990.
- [2] A. D. Pradiptha, F. S. Al Farisi, M. F. Pratama, D. A. R. Agustini, and M. Munawir, "Analisis Sentimen Suporter terhadap Performa Tim Nasional Sepakbola Indonesia pada Turnamen Sea Games 2023 dengan Metode Naive

**Komparasi Algoritma Naive Bayes dan Support Vector Machine pada Analisis Sentimen
Komentar Instagram Liga El Clásico Barcelona vs Real Madrid
(Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid)**

- Bayes,” *Jurnal Sains dan Informatika*, vol. 11, no. 1, pp. 30–39, Jun. 2025, doi: 10.34128/jsi.v11i1.775.
- [3] K. Anwar, “KLIK: Kajian Ilmiah Informatika dan Komputer Analisa sentimen Pengguna Instagram Di Indonesia Pada Review Smartphone Menggunakan Naive Bayes,” vol. 2, no. 4, pp. 148–155, 2022, [Online]. Available: <https://djournal.com/klik>
- [4] D. Septiani and I. Isabela, “SINTESIA: Jurnal Sistem dan Teknologi Informasi Indonesia Analisis Term Frequency Inverse Document Frequency (TF-IDF) Dalam Temu Kembali Informasi pada Dokumen Teks,” 2023.
- [5] H. Mukhtar, J. Al Amien, and M. A. Rucyat, “Filtering Spam Email menggunakan Algoritma Naive Bayes,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 3, no. 1, pp. 9–19, May 2022, doi: 10.37859/coscitech.v3i1.3652.
- [6] S. D. Wahyuni and R. H. Kusumodestoni, “Optimalisasi Algoritma Support Vector Machine (SVM) Dalam Klasifikasi Kejadian Data Stunting,” *Bulletin of Information Technology (BIT)*, vol. 5, no. 2, pp. 56–64, 2024, doi: 10.47065/bit.v5i2.1247.
- [7] A. Prasetyo, T. Ridwan, and A. Voutama, “Analisis Sentimen Terhadap Aplikasi GBWhatsapp Menggunakan Naive Bayes Classifier dan Random Forest Classifier,” *JSiI (Jurnal Sistem Informasi)*, vol. 11, no. 1, pp. 1–9, Mar. 2024, doi: 10.30656/jsii.v11i1.6936.
- [8] J. Rusman, B. Z. Haryati, and A. Michael, “Optimisasi Hiperparameter Tuning pada Metode Support Vector Machine untuk Klasifikasi Tingkat Kematangan Buah Kopi,” *Jurnal Komputer dan Informatika*, vol. 11, no. 2, pp. 195–202, Oct. 2023, doi: 10.35508/jicon.v11i2.12571.
- [9] A. K. Dewi, Noni Fauzia Rahmadani, R. Syahputri, and Luftia Rahma Nasution, “Hoax News Detection on Platform X Using Text Mining Approach and Machine Learning Algorithm,” *Data Sciences Indonesia (DSI)*, vol. 5, no. 1, pp. 33–46, Jul. 2025, doi: 10.47709/dsi.v5i1.6011.
- [10] T. Gori, A. Sunyoto, and H. Al Fatta, “Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, pp. 215–224, Feb. 2024, doi: 10.25126/jtiik.20241118074.
- [11] D. Rifaldi *et al.*, “Evaluasi Sentimen Pengguna ChatGPT Menggunakan Naive Bayes: Tinjauan dari Confusion Matrix dan Classification Report Evaluation ChatGPT User Sentiment using Naive Bayes: A Review of Confusion Matrix and Classification Report,” *Jurnal Riset Sistem dan Teknologi Informasi (RESTIA)*, vol. 3, no. 2, pp. 81–89, 2025.
- [12] A. Karimah and G. Dwilestari, “Analisis Sentimen Komentar Video Mobil Listrik di Platform Youtube dengan Metode Naive Bayes,” 2024. [Online]. Available: <https://www.kaggle.com/datasets/billycemerson/anali>
- [13] B. Hakim, “Analisa Sentimen Data Text Preprocessing Pada Data Mining Dengan Menggunakan Machine Learning,” *JBASE - Journal of Business and Audit Information Systems*, vol. 4, no. 2, Aug. 2021, doi: 10.30813/jbase.v4i2.3000.
- [14] A. Aljabar, B. M. Karomah, K. Kunci, and : Bert, “Mengungkap Opini Publik: Pendekatan BERT-based-caused untuk Analisis Sentimen pada Komentar Film,” 2024.

- [15] R. E. Pambudi *et al.*, “Analisis Klasifikasi Sentimen Pengguna MyPertamina Menggunakan Metode Evaluasi Precision, Recall, dan F1-Score,” 2025. [Online]. Available: <https://jti.aisyahuniversity.ac.id/index.php/AJIEE>
- [16] J. Elektronika and D. Komputer, “Mengoptimalkan Proses Pembersihan Data dalam Analisis Big Data Menggunakan Pipeline Berbasis AI,” vol. 17, no. 2, 2024, doi: 10.51903/elkom.v17i2.2311.
- [17] D. Farah Zhafira, B. Rahayudi, and P. Korespondensi, “Analisis Sentimen Kebijakan Kampus Merdeka Menggunakan Naïve Bayes dan Pembobotan TF-IDF Berdasarkan Komentar pada Youtube,” 2021.
- [18] W. N. Ibrahim Al-Obaydy, H. A. Hashim, Y. AbdulKhaleq Najm, and A. A. Jalal, “Document classification using term frequency-inverse document frequency and K-means clustering,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 27, no. 3, pp. 1517–1524, Sep. 2022, doi: 10.11591/ijeecs.v27.i3.pp1517-1524.
- [19] S. Jessica Angelina, A. Bijaksana Putra Negara, H. Muhardi, J. H. Nawawi, and K. Barat, “Analisis Pengaruh Penerapan Stopword Removal Pada Performa Klasifikasi Sentimen Tweet Bahasa Indonesia Analyzing The Impact Of Applying Stopword Removal On Indonesian Tweet Sentiment Classification,” vol. 02, no. 1, 2023, doi: 10.26418/juara.v2i1.69680.
- [20] F. Harahap, N. E. Saragih, E. T. Siregar, and H. Sariangsah, “Fitriana Harahap Penerapan Data Mining Dengan Penerapan Data Mining Dengan Algoritma Naive Bayes Classifier Dalam Memprediksi Pembelian Cat KATA KUNCI Data Mining Purchase of paint Naive Bayes. KORESPONDENSI,” 2021.