



Analisis Sentimen Mahasiswa Terhadap Kurikulum Literasi Digital di Universitas Singaperbangsa Karawang Menggunakan Naïve Bayes

Ibtihal Qomariyyah Luthfiyyah^{1*}, Betha Nurina Sari², Taufik Ridwan³

^{1,2}Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang, Jl. HS.Ronggo Waluyo, Puseurjaya, Telukjambe timur, Karawang, Jawa Barat 41361, Indonesia.

³Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang, Jl. HS.Ronggo Waluyo, Puseurjaya, Telukjambe timur, Karawang, Jawa Barat 41361, Indonesia.

*Penulis Korespondensi, Email: 2010631170079@student.unsika.ac.id

Abstrak—Implementasi Kurikulum Literasi Digital di Universitas Singaperbangsa Karawang (Unsika) sebagai langkah konkrit mengingat pentingnya literasi digital. Evaluasi kurikulum merupakan langkah penting dalam memastikan keefektifan pembelajaran. Saat ini belum ada mekanisme dari pihak Unsika untuk mendorong mahasiswa memberikan *feedback* terhadap implementasi kurikulum. Salah satu caranya adalah dengan analisis sentimen, diperlukan analisis sentimen menggunakan algoritma *Naïve Bayes* yang berkontribusi dalam memberikan *feedback* terhadap evaluasi kurikulum. Proses analisis sentimen ini menggunakan metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*). Dalam upaya untuk mendapatkan persepsi mahasiswa dilakukanlah survei menggunakan kuesioner. Jumlah minimal responden ditentukan dengan rumus Slovin sebanyak 388. Pada penelitian ini jumlah data yang digunakan sebanyak 591. Adanya ketidakseimbangan dalam data, untuk mengatasi hal tersebut dapat dilakukan teknik *oversampling* menggunakan ADASYN (*Adaptive Synthetic Sampling Approach*). Data telah dibersihkan sehingga menghasilkan 347 sentimen positif dan 176 sentimen negatif. Hasil penelitian ini menunjukkan model terbaik dan *word frequency* berupa visualisasi kata-kata yang berperan penting pada setiap kategori sentimen untuk digunakan evaluasi kurikulum. Dari delapan skenario model yang diuji, model yang dilatih dengan algoritma *Naïve Bayes* menggunakan pembagian 90% *data training* dan 10% *data testing* dengan penerapan ADASYN menjadi model terbaik dengan *accuracy* 89%, *precision* 100%, *recall* 85%, dan *f1-score* 92%.

Kata Kunci: ADASYN; Analisis Sentimen; Kurikulum Literasi Digital; *Naïve Bayes*; *Oversampling*.

Abstract—Implementation of the Digital Literacy Curriculum at University of Singaperbangsa Karawang (Unsika) as a concrete step considering the importance of digital literacy. Curriculum evaluation is an important step in ensuring the effectiveness of learning. Currently there is no mechanism from Unsika to encourage students to provide feedback on curriculum implementation. One way is by sentiment analysis, which requires sentiment analysis using the *Naïve Bayes* algorithm which contributes to providing feedback on curriculum evaluation. This sentiment analysis process uses the CRISP-DM (*Cross Industry Standard Process for Data Mining*) methodology. In an effort to obtain student perceptions, a survey was conducted using a questionnaire. The minimum number of respondents determined using the Slovin formula is 388. In this study the amount of data used was 591. There is an imbalance in the data, to overcome this an oversampling technique can be used using ADASYN (*Adaptive Synthetic Sampling Approach*). The data has been cleaned to produce 347 positive sentiments and 176 negative sentiments. The results of this research show the best model and word frequency in the form of visualization of words that play an important role in each sentiment category for use in curriculum evaluation. Of the eight model scenarios tested, the model trained with the *Naïve Bayes* algorithm using a division of 90% training data and 10% testing data with the application of ADASYN became the best model with an accuracy of 89%, precision 100%, recall 85%, and f1-score 92%.

Keywords: ADASYN; Sentiment Analysis; Digital Literacy Curriculum; *Naïve Bayes*; *Oversampling*.

1. PENDAHULUAN

Angka literasi digital di Indonesia berada di level rendah. Berdasarkan laporan dari *Institute for Management Development* (IMD) dalam *World Digital Competitiveness Ranking 2022*, ranking Indonesia di urutan 51 dari 63 negara [1]. Hal tersebut menunjukkan bahwa sumber daya manusia terkait literasi digital perlu ditingkatkan.

Literasi digital adalah gaya kecakapan untuk memperoleh, mencerna, dan memanfaatkan informasi digital dari berbagai sumber [2]. Literasi digital itu semestinya tidak hanya kemampuan untuk menggunakan berbagai sumber digital, namun juga gaya berpikir yang berasal dari literasi komputer dan informasi [2]. Pendidikan literasi digital perlu diupayakan oleh seluruh lapisan pemegang kepentingan. Dalam jagat pendidikan, khususnya

pendidikan tinggi, memiliki peran pada desain pembelajaran untuk memasukkan kurikulum literasi digital ke dalam struktur pendidikan.

Salah satu perguruan tinggi yang sudah mengakui pentingnya literasi digital yaitu Universitas Singaperbangsa Karawang (Unsika). Langkah konkrit telah diambil melalui penetapan Mata Kuliah Wajib Kurikulum (MKWK) berfokus pada literasi digital sesuai dengan Keputusan Rektor Unsika Nomor 189/UN64/KPT/2022. MKWK meliputi mata kuliah Pengantar Literasi Digital, *Artificial Intelligence* (A) dan *Data Analytics* (D), *Blockchain* (B) dan *Cloud Computing* (C), serta Final Proyek Literasi Digital. Setiap mata kuliah dalam kurikulum literasi digital memiliki bobot SKS (Standar Kredit Semester) yang berbeda-beda. Mata kuliah Pengantar Literasi Digital (2 SKS), *Artificial Intelligence* dan *Data Analytics* (3 SKS), *Blockchain* dan *Cloud Computing* (3 SKS), dan Final Proyek Literasi Digital (3 SKS). Kurikulum mulai berjalan pada semester gasal Tahun Akademik 2022/2023.

Mata kuliah dalam kurikulum wajib diambil oleh mahasiswa Program Studi Sarjana kecuali mahasiswa Program Studi Sarjana Informatika dan Sarjana Sistem Informasi. Kewajiban ini mencerminkan komitmen Unsika untuk memberikan bekal literasi digital kepada semua mahasiswa, pengecualian untuk prodi Informatika dan Sistem Informasi didasarkan bahwa mahasiswa dari prodi tersebut telah memiliki dasar pengetahuan dalam bidang teknologi.

Kelebihan dan kekurangan yang dimiliki kurikulum tersebut menyebabkan adanya berbagai persepsi mahasiswa dan saat ini belum ada mekanisme atau inisiatif yang dirancang oleh pihak Unsika untuk mendorong mahasiswa memberikan *feedback* terhadap implementasi kurikulum. Evaluasi kurikulum sangat penting untuk pengembangan, implementasi, dan pemeliharaan kurikulum [3]. Oleh karena itu, diperlukan analisis sentimen yang akan berkontribusi dalam memberikan *feedback* terhadap evaluasi kurikulum literasi digital di Unsika dan membuat mahasiswa lebih terbantu apabila kurikulum ini menjadi lebih baik.

Analisis sentimen adalah penelitian komputasional pandangan tentang luapan perasaan yang diekspresikan dalam bentuk teks [4]. Sentimen terhadap kurikulum literasi digital ini penting untuk dilakukan agar mahasiswa yang telah merasakan pembelajaran kurikulum tersebut dapat memberikan komentarnya baik itu positif atau negatif, kelebihan ataupun kekurangan. Analisis sentimen atau penambangan opini adalah gabungan dari *data mining* dan *text mining*, sebuah metode untuk menganalisis persepsi, evaluasi, perasaan, dan emosi seseorang terhadap suatu topik, produk, layanan, organisasi, individu, atau kegiatan tertentu, baik itu dalam percakapan atau tulisan [5].

Text mining adalah metode penambangan data dengan menggunakan data teks. Perbedaan utama antara *data mining* dan pengelolaan menggunakan *text mining* adalah jenis data yang mewakili objek pekerjaannya [6]. Keduanya berbeda, *data mining* berfokus pada data yang terstruktur, sedangkan *text mining* melibatkan fitur-fitur yang khusus dan cenderung tidak terstruktur, yang memerlukan tahapan *preprocessing* pada data teks [7].

Naïve Bayes adalah algoritma yang umum digunakan dalam algoritma klasifikasi *data mining* [8]. Terdapat penelitian sebelumnya terkait analisis sentimen menggunakan *naïve bayes* yang dilakukan oleh beberapa peneliti seperti, “Perbandingan Metode K-NN, *Naïve Bayes*, *Decision Tree* untuk Analisis Sentimen Tweet Twitter Terkait Opini Terhadap PT PAL Indonesia” [9]. Hasil akurasi metode K-NN yaitu 83,38%, metode *Naïve Bayes* yaitu 84,08%, metode *Decision Tree* yaitu 81,90%.

Penelitian lain dengan judul “Analisis Sentimen Terhadap Pembelajaran Dosen Berdasarkan Kritik Mahasiswa Menggunakan Metode *Naïve Bayes*” [10]. Dengan menerapkan metode *Naïve Bayes* pada uji coba dengan pembagian data 60:40, diperoleh tingkat akurasi sebesar 83,92%. Pada pembagian data 70:30, tingkat akurasi mencapai 83,26%, sementara pada pembagian data 80:20, akurasi mencapai 81,96%. Hasil menunjukkan terdapat 2484 sentimen positif, 152 sentimen negatif dan 267 sentimen netral.

Penelitian lain dengan judul “Analisis Sentimen Mahasiswa Terkait Pembelajaran Tatap Muka Menggunakan Metode *Naïve Bayes Classifier*”, yang melakukan analisis sentimen terkait pembelajaran tatap muka dengan menggunakan kuesioner sebagai sumber datanya dan menggunakan algoritma *Naïve Bayes Classifier* untuk klasifikasi data yang berhasil mendapatkan akurasi dengan rata-rata sebesar 84% [11].

Penelitian lain dengan judul “Analisis Sentimen Terhadap Program Kampus Merdeka Menggunakan Algoritma *Naïve Bayes Classifier* di Twitter”. Penelitian ini menggunakan *word cloud* dengan kata terbanyak untuk menunjukkan hasilnya. Berdasarkan hasil penelitian, sistem dapat mengklasifikasikan sentimen positif sebanyak 272 persepsi dan sentimen negatif sebanyak 229 persepsi. *Accuracy* rata-rata adalah 60%, *precision* 64%, *recall* 58%, dan *f1-score* 58% [12].

Penelitian lain dengan judul “Pembobotan TF-IDF Menggunakan *Naïve Bayes* Pada Sentimen Masyarakat Mengenai Isu Kenaikan BIPIH”. Data yang digunakan berasal dari media sosial Twitter. Data dikategorikan menjadi persepsi pro dan kontra, lalu diolah menggunakan *python* dan *jupyter* sebagai teks editor. Algoritma *Multinomial Naïve Bayes* (MNB) digunakan untuk mengklasifikasikan teks dan melakukan pembobotan kata dengan TF-IDF. Hasil pengujian menunjukkan nilai akurasi sebesar 89% dan ROC 91% [13].

Seringkali, data yang tidak seimbang ditemukan dalam *dataset* atau sumber data, pada kasus seperti itu perlu menggunakan opsi *data balancing*. Dengan mengatasi ketidakseimbangan kelas dalam data, *data*

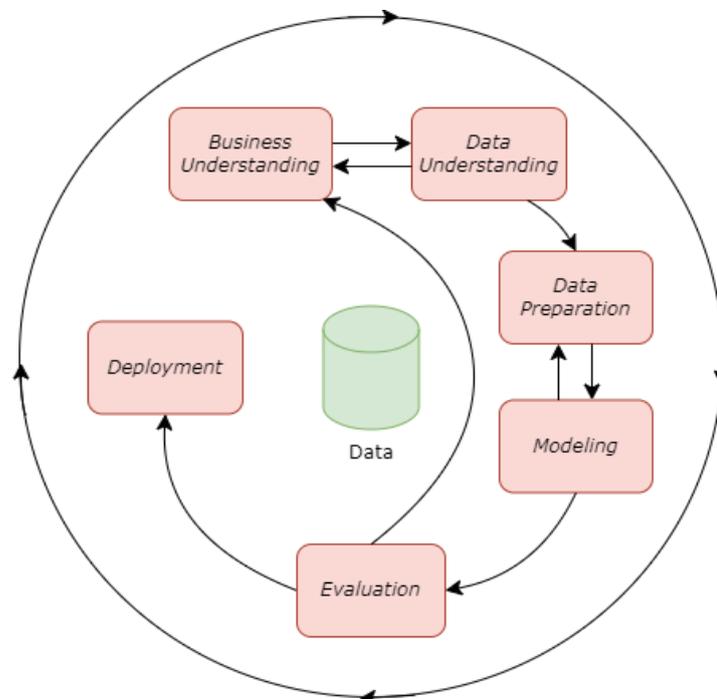
balancing mempunyai dua opsi, *undersampling* dan *oversampling*, terkadang dapat menggunakan kombinasi keduanya [14]. Studi tentang penanganan data tidak seimbang telah dilakukan pada penelitian dengan judul ‘Penanganan *Imbalanced Dataset* untuk Klasifikasi Komentar Program Kampus Merdeka Pada Aplikasi Twitter’. Pada penelitian tersebut, telah menggunakan algoritma klasifikasi SVM (*Support Vector Machine*) dan menggunakan beberapa teknik *data balancing* yaitu *undersampling*, *oversampling*, dan *random combination sampling*. Teknik *oversampling* menggunakan SMOTE (*Synthetic Minority Over-sampling Technique*) dan ADASYN (*Adaptive Synthetic Sampling Approach*). Teknik *data balancing* terbaik ditunjukkan oleh *oversampling* yaitu ADASYN yang berhasil meningkatkan akurasi hingga 0,903 dan *f1-score* 0,9 [15].

Berdasarkan uraian terkait penelitian sejenis yang telah dijelaskan sebelumnya, maka penelitian ini akan fokus pada mengolah persepsi mahasiswa terhadap Kurikulum Literasi Digital di Unsika menggunakan algoritma *Naïve Bayes*. Dalam upaya untuk mendapatkan persepsi para mahasiswa dilakukanlah survei dengan menggunakan kuesioner *google form*. Kategori yang digunakan pada data merupakan kategori positif dan negatif. Salah satu teknik *data balancing* yang akan digunakan adalah *oversampling* dengan menggunakan ADASYN. Terdapat empat skenario pembagian data, yakni 60:40, 70:30, 80:20, dan 90:10. Masing-masing skenario pembagian data akan diterapkan pada model sebelum penerapan ADASYN dan setelah penerapan ADASYN, sehingga ada delapan model yang akan diuji dan diperoleh satu model terbaik. Hasil analisis sentimen akan divisualisasikan dengan *word frequency* yang mewakili frekuensi kemunculan dari setiap kata dalam korpus teks dengan menggunakan pendekatan TF-IDF (*Term Frequency-Inverse Document Frequency*).

Penelitian ini bertujuan untuk menganalisis *feedback* yang diberikan oleh mahasiswa secara lebih sistematis dan mendalam, serta mengetahui performa metode algoritma dari model yang diuji dalam mengklasifikasi komentar mahasiswa yang positif dan negatif, dengan harapan dapat memberikan masukan bagi pengembangan kurikulum yang lebih sesuai dengan kebutuhan dan harapan mahasiswa.

2. METODOLOGI PENELITIAN

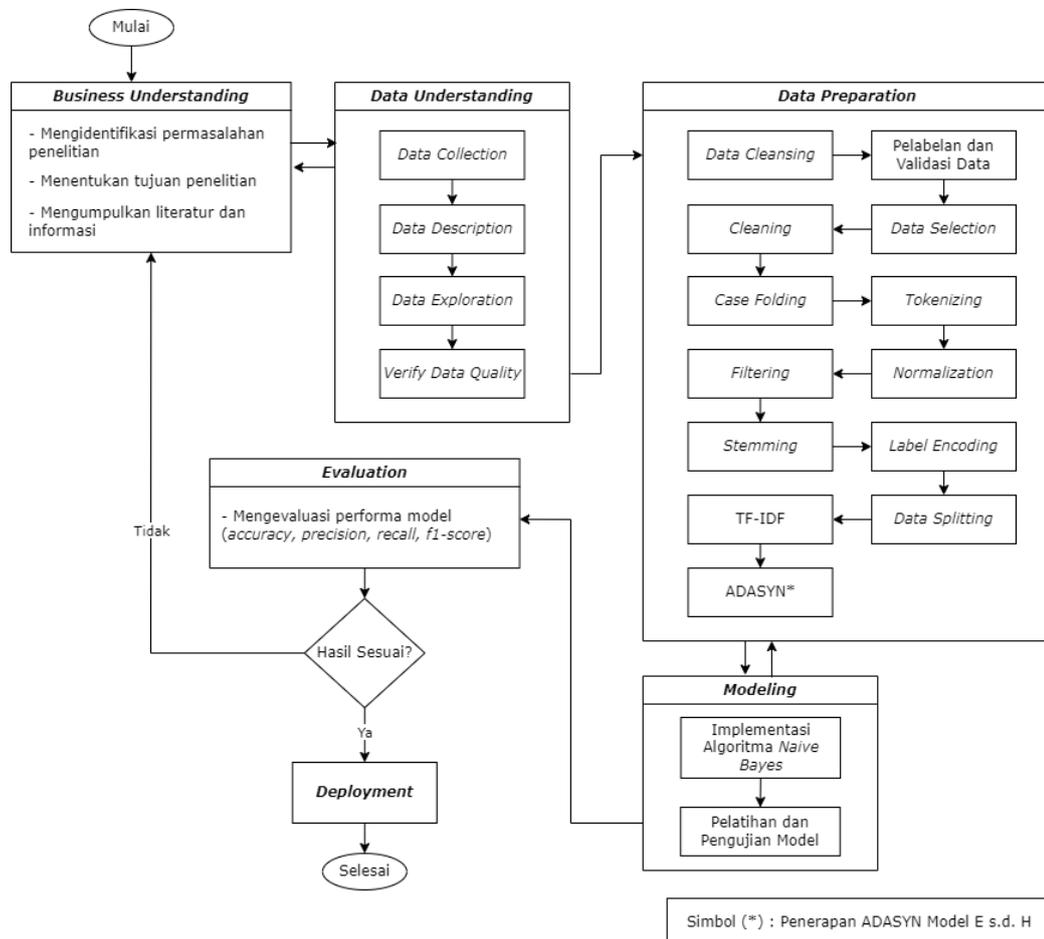
Metodologi penelitian yang akan digunakan pada penelitian ini dapat dilihat pada Gambar 1 dalam CRISP-DM (*Cross Industry Standard Process for Data Mining*). Tahapan yang ditempuh yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*.



Gambar 1. Metodologi Penelitian

2.1 Tahapan Penelitian

Berdasarkan proses CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang telah dipaparkan dalam metodologi penelitian, dapat dibuat tahapan penelitian pada Gambar 2 dengan tahapan yaitu:



Gambar 2. Tahapan Penelitian

2.2 Business Understanding

Dalam tahap ini, fokus utama adalah memahami tujuan penelitian dan kebutuhan informasi yang mendasari analisis sentimen terhadap kurikulum literasi digital di Unsika. Perlu diidentifikasi alasan utama di balik pelaksanaan analisis sentimen. Penting untuk melakukan studi literatur dan pengumpulan informasi terkait guna memperdalam pemahaman terhadap konteks. Pemahaman yang lebih mendalam untuk memastikan bahwa analisis sentimen yang dilakukan relevan dan memberikan kontribusi yang berarti terhadap implementasi kurikulum literasi digital di Unsika.

2.3 Data Understanding

Tahap kedua melibatkan sumber data yang akan digunakan untuk analisis sentimen. Dalam hal ini, data dikumpulkan berasal dari kuesioner yang diberikan kepada mahasiswa Unsika angkatan 2021-2023 program sarjana yang telah mendapatkan pembelajaran kurikulum literasi digital. *Sampling* dapat digunakan sebagai representasi populasi (N) dengan tingkat toleransi (e) tertentu. Untuk menentukan minimal jumlah responden atau sampel (n) menggunakan rumus Slovin.

$$n = \frac{N}{1 + Ne^2}$$

Setelah data terkumpul kemudian data tersebut dipahami setiap atributnya dan dipilih atribut apa saja yang akan digunakan untuk proses klasifikasi. Struktur dan karakteristik data dieksplorasi, termasuk bagian komentar mahasiswa.

2.4 Data Preparation

Langkah berikutnya adalah mempersiapkan data dengan membersihkan data sebelum menggunakan algoritma *Naïve Bayes*. Ini melibatkan penanganan hasil analisis awal data. Pelabelan data secara manual juga dilakukan pada tahap ini. *Text preprocessing* dilakukan setelah pelabelan data selesai. Berikut adalah langkah-langkah dalam proses *text preprocessing* [16]:

a. *Cleaning*

Tahap ini melibatkan penghilangan gangguan atau *noise* dalam teks seperti simbol, tanda baca, tautan, dan lain-lain. Ada contoh beberapa hal yang tidak diperlukan dan harus dibersihkan seperti berikut: @!?, 😊👤, dan hal lain yang bukan kata.

b. *Case Folding*

Case folding berfungsi untuk memastikan bahwa penggunaan huruf kapital digunakan secara sama rata. Misalnya, dapat mengubah data teks tulisan "LiTEraSi DIGital" dengan mengubah semua huruf menjadi huruf kecil (*lowercase*) "literasi digital".

c. *Tokenizing*

Tokenizing memungkinkan untuk membedakan pemisah kata. Misalnya, tulisan "literasi digital" dipisah per kata menjadi "literasi", "digital".

d. *Normalization*

Pada tahap ini menormalkan teks dengan menghilangkan variasi yang tidak diperlukan, seperti pengulangan karakter dan singkatan pada kata. Misalnya, "bgt" seharusnya "banget", "horeee" seharusnya "hore".

e. *Filtering*

Filtering adalah proses setelah *normalization*, yang mengambil kata-kata penting dari token yang dihasilkan. Contoh *stopword* seperti "saya", "yang", "di", "ke", "ini", "itu", dan lainnya kata umum yang sering muncul dan tidak memiliki arti.

f. *Stemming*

Tahap ini mengubah kata dalam teks menjadi bentuk dasarnya sesuai dengan aturan bahasa yang benar. Misalnya, mengubah kata-kata menjadi kata dasar seperti "belajar" menjadi "ajar".

Teknik *percentage split* diterapkan untuk pembagian dataset. Berikut terdapat empat skenario yang digunakan dapat dilihat pada Tabel 1.

Tabel 1. Skenario Pembagian Data

Skenario	Data Latih (%)	Data Uji (%)
60:40	60	40
70:30	70	30
80:20	80	20
90:10	90	10

Implementasi ekstraksi fitur TF-IDF dilakukan setelah pembagian data menjadi set pelatihan dan set pengujian. Data yang sudah melalui ekstraksi fitur, kemudian dilakukan teknik *oversampling* menggunakan ADASYN.

2.5 Modeling

Tahap ini menjelaskan pemilihan dan implementasi model. Dalam konteks penelitian ini, algoritma yang dipilih adalah algoritma *Naïve Bayes* untuk analisis sentimen. *Naïve Bayes* merupakan salah satu algoritma klasifikasi, dimana memerlukan data latih berlabel sentimen positif dan negatif.

2.6 Evaluation

Tahap evaluasi melibatkan penggunaan *confusion matrix* sebagai metrik evaluasi utama. Matriks ini memberikan gambaran lebih detail tentang performa model, termasuk *accuracy*, *precision*, *recall*, dan *f1-score*. Penelitian membandingkan hasil metrik evaluasi dari beberapa skenario model yang sudah ditentukan. Pada tahap ini juga diputuskan apakah hasil *text mining* dapat digunakan untuk mencapai tujuan penelitian.

2.7 Deployment

Pada tahap terakhir, fokus utama diberikan pada penyusunan dokumentasi mengenai langkah-langkah dari proses *text mining*. *Word frequency* berupa visualisasi kata-kata yang berperan penting untuk digunakan evaluasi kurikulum. Pengetahuan berupa sentimen persepsi mahasiswa yang berhasil diketahui dari proses *text mining* sehingga dapat digunakan untuk mengevaluasi Kurikulum Literasi Digital di Unsika.

3. HASIL DAN PEMBAHASAN

Hasil penelitian yang telah dilakukan adalah berupa proses melakukan analisis sentimen dengan mengolah persepsi mahasiswa terhadap Kurikulum Literasi Digital di Unsika menggunakan algoritma *Naïve Bayes* dengan ADASYN. Kategori yang digunakan pada data merupakan kategori positif dan negatif. Data yang digunakan dalam penelitian ini dalam bentuk teks komentar mahasiswa Unsika. Pengumpulan data melalui penyebaran kuesioner dalam rentang waktu November 2023 sampai dengan Januari 2024. Jumlah minimal responden ditentukan melalui rumus Slovin sebesar 388. Pada penelitian ini jumlah data yang digunakan sebesar 591. Hasil analisis sentimen divisualisasikan dengan *word frequency*.

3.1 Business Understanding

Dalam tahap ini telah memahami masalah penelitian yang berdasarkan pada latar belakang dan tujuan penelitian. Adapun permasalahan pada Kurikulum Literasi Digital adalah kelebihan dan kekurangan yang dimiliki kurikulum tersebut yang diimplementasikan di berbagai fakultas Unsika sehingga menyebabkan adanya berbagai persepsi mahasiswa dan kurangnya mekanisme yang melibatkan mahasiswa untuk memberikan *feedback* sebagai bahan evaluasi terhadap implementasi kurikulum.

Evaluasi kurikulum merupakan langkah penting dalam memastikan keefektifan pembelajaran. Akan tetapi, saat ini belum ada mekanisme formal atau inisiatif yang dirancang oleh pihak Unsika untuk mendorong mahasiswa memberikan *feedback* terhadap implementasi kurikulum. Kurangnya evaluasi menyebabkan sulitnya mengetahui sejauh mana kurikulum ini berhasil mencapai tujuan pembelajaran yang ditetapkan dan memenuhi kebutuhan mahasiswa.

Oleh karena itu, melalui pendekatan *data mining*, salah satunya adalah analisis sentimen menggunakan algoritma *Naïve Bayes*, penelitian ini bertujuan untuk menganalisis *feedback* yang diberikan oleh mahasiswa secara lebih sistematis dan mendalam, serta mengetahui performa metode algoritma dari model yang diuji dalam mengklasifikasi komentar mahasiswa yang positif dan negatif, dengan harapan dapat memberikan masukan bagi pengembangan kurikulum yang lebih sesuai dengan kebutuhan dan harapan mahasiswa.

3.2 Data Understanding

Selanjutnya, dalam tahap *data understanding*, peneliti melakukan pemahaman mendalam terhadap data teks komentar mahasiswa. Tahapan *data understanding* ini terdiri dari beberapa langkah, yakni *data collection*, *data description*, *data exploration*, dan *verify data quality*.

3.2.1 Data Collection

Dalam upaya untuk menciptakan mekanisme yang memfasilitasi pengumpulan *feedback* secara terstruktur dari mahasiswa, dapat dilakukan dengan survei menggunakan kuesioner yang dibuat melalui *google form*. Kuesioner disebarkan kepada mahasiswa Unsika angkatan 2021 – 2023 dari berbagai fakultas kecuali Fakultas Ilmu Komputer dan berbagai program studi sarjana yang telah merasakan pembelajaran Kurikulum Literasi Digital. Rentang waktu pengumpulan data dari November 2023 hingga Januari 2024 telah menghasilkan jumlah responden yang melebihi jumlah minimal yang diperlukan menurut rumus Slovin.

$$n = \frac{N}{1 + Ne^2} = \frac{12790}{1 + (12790 \times (0,05^2))} = \frac{12790}{32,975} = 387,86 = 388$$

Dalam penelitian ini, nilai N (jumlah total populasi) mahasiswa Unsika angkatan 2021 – 2023 adalah 12790 dan e (*margin of error*) yang dapat diterima adalah 5% (0,05), maka jumlah minimal sampel n adalah 388. Data yang telah dikumpulkan melebihi jumlah minimal sebanyak 591.

3.2.2 Data Description

Setelah data berhasil terkumpul, langkah selanjutnya adalah memulai *data description*. Langkah ini bertujuan untuk memahami secara mendalam tentang deskripsi 5 (lima) variabel yang terdapat dalam *dataset*. Deskripsi variabel dapat dilihat pada Tabel 2.

Tabel 2. Deskripsi Variabel Data

Variabel	Tipe Data	Deskripsi
Timestamp	Numerik	Representasi waktu di mana tanggapan dari mahasiswa diterima melalui <i>google form</i>
Angkatan	Numerik	Tahun masuknya mahasiswa ke Unsika, tahun 2021, 2022, dan 2023
Fakultas	Kategorik	Nama fakultas di Unsika
Program Studi	Kategorik	Nama program studi sarjana di Unsika
Komentar	Kategorik	Teks yang merupakan tanggapan langsung dari mahasiswa terkait pengalaman belajar dalam Kurikulum Literasi Digital di Unsika

3.2.3 Data Exploration

Dalam konteks analisis sentimen, langkah ini bertujuan untuk memahami karakteristik data teks yang akan dianalisis, serta untuk mengeksplorasi pola-pola atau tren yang ada dalam *dataset*. Jumlah mahasiswa angkatan 2022 memberikan komentar terbanyak sebesar 352. Jumlah mahasiswa Fakultas Teknik memiliki jumlah komentar terbanyak (181). Jumlah mahasiswa S1 Teknik Mesin memiliki jumlah komentar terbanyak (105).

3.2.4 Verify Data Quality

Langkah terakhir dalam tahap *data understanding* sangat penting dalam proses analisis data. Tujuan utamanya adalah untuk memastikan bahwa data yang digunakan dalam penelitian memiliki kualitas yang baik dan dapat diandalkan. Proses ini dimulai dengan identifikasi berbagai masalah yang bisa terjadi dalam *dataset* seperti nilai yang hilang (*missing value*), duplikat, kesalahan entri, atau ketidaksesuaian format data.

Pertama, dilakukan pengecekan terhadap adanya *missing value* menggunakan fungsi *isna().sum()*, hasilnya menunjukkan bahwa tidak ada *missing value* yang terdapat dalam *dataset*.

Kedua, dilakukan pengecekan terhadap keberadaan data duplikat. Dengan menggunakan fungsi *duplicated().sum()*, tidak ditemukan adanya duplikat dalam *dataset*. Hal ini menunjukkan bahwa setiap entri dalam *dataset* unik dan tidak ada data yang sama persis yang muncul lebih dari satu kali.

Ketiga, dilakukan pemeriksaan terhadap *dataset* untuk memastikan keberadaan komentar yang sesuai dengan kriteria. Analisis sentimen memerlukan data komentar dalam bentuk teks kata – kata yang mencerminkan ekspresi perasaan mahasiswa. Oleh karena itu, perlu dicek apakah *dataset* sudah memenuhi *rule* tersebut. Data telah dicek secara manual, pada kolom ‘Komentar’ ada yang hanya berisi emoji (👍), (👎), dan tanda baca titik (.), strip (-), *underscore* (_). Kemudian, dicek menggunakan program *python* untuk menemukan letak indeksinya.

Berdasarkan pengecekan yang menunjukkan letak indeks dengan data yang hanya berisi titik (.) di ‘Komentar’ adalah [38, 114, 218, 589], letak indeks dengan data yang hanya berisi strip (-) adalah [19, 33, 43, 164, 200, 228, 229, 233, 248, 277, 301, 375, 390, 401, 534, 540, 548, 556], letak indeks dengan data yang hanya berisi *underscore* (_) adalah [468], letak indeks dengan data yang hanya berisi emoji (👎) adalah [231], dan letak indeks dengan data yang hanya berisi emoji (👍) adalah [250]. Total *rows* data yang tidak memenuhi *rule* adalah 25 dapat dilihat pada Tabel 3. Data tersebut tidak menunjukkan ekspresi perasaan mahasiswa dalam bentuk teks. Maka dari itu, data yang tidak relevan akan dihapus pada langkah awal *data preparation*.

Tabel 3. Hasil Cek Ketidaksesuaian *Rule Data*

Komentar	Jumlah	Indeks
.	4	[38, 114, 218, 589]
-	18	[19, 33, 43, 164, 200, 228, 229, 233, 248, 277, 301, 375, 390, 401, 534, 540, 548, 556]
_	1	[468]
👎	1	[231]
👍	1	[250]

3.3 Data Preparation

Pada tahap ini, data yang telah dikumpulkan dan dipahami karakteristiknya perlu dipreparasi untuk analisis lebih lanjut. Langkah – langkah dalam persiapan data termasuk *data cleansing*, pelabelan dan validasi data, *data selection*, *text preprocessing* (*cleaning*, *case folding*, *tokenizing*, *normalization*, *filtering*, *stemming*), *label encoding*, *data splitting*, TF-IDF, dan ADASYN.

3.3.1 Data Cleansing

Langkah awal dalam tahap persiapan data yang bertujuan untuk menghapus atau memperbaiki data yang tidak sesuai dengan *rule* yang telah diidentifikasi pada tahap *Data Understanding*. Penanganan data menggunakan fungsi *drop()* yang menghapus 25 data tidak relevan sesuai Tabel 3, sehingga ketika dicek menggunakan fungsi *shape* diketahui bahwa ukuran data (566, 5) artinya jumlah baris data yang awalnya 591 berkurang menjadi 566 dan jumlah kolom data ada 5.

3.3.2 Pelabelan dan Validasi Data

Model yang dibuat untuk memahami komentar mahasiswa memerlukan kategori atau label. Kategori ini membantu model mengenali apakah komentar mahasiswa bersifat positif atau negatif. Perlu adanya penambahan variabel yaitu “Label” sehingga jumlah variabel ada 6. Proses pemberian label dilakukan secara manual dengan mengamati setiap komentar dari hasil tahap sebelumnya. Kemudian, validasi dilakukan oleh seorang ahli Bahasa Indonesia, Bapak Dr. Achmad Suherman, M.Pd., M.Si., yang merupakan dosen mata kuliah Bahasa Indonesia di Unsika. Hasil dari pelabelan dan validasi data komentar dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pelabelan dan Validasi Data

Label	Jumlah Label Menurut Peneliti	Jumlah Label Menurut Validator
Positif	356	365
Negatif	196	177
Netral	14	24

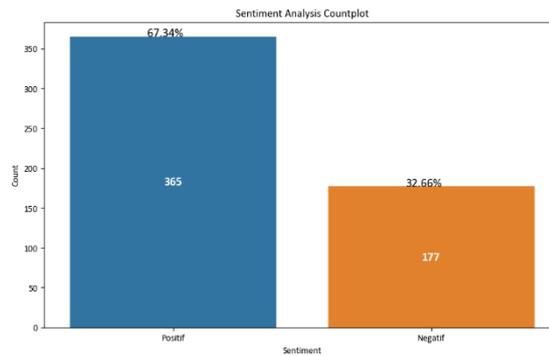
Data yang digunakan untuk proses selanjutnya adalah data hasil pelabelan dari validator yang menghasilkan data komentar yang memiliki label “Positif” sebanyak 365 dan label “Negatif” sebanyak 177. Berikut satu contoh perbedaan pelabelan antara peneliti dengan validator dapat dilihat pada Tabel 5.

Tabel 5. Contoh Perbedaan Pelabelan Antara Peneliti dan Validator

Komentar	Jumlah Label Menurut Peneliti	Jumlah Label Menurut Validator
Secara pembelajaran literasi digital sangat bagus di terapkan di mahasiswa sehubungan dengan perkembangan teknologi namun, perlu di pertimbangkan lagi apakah praktek dan materi nya sudah bagus jika di terapkan di pembelajaran	Positif	Netral

3.3.3 Data Selection

Setelah proses pelabelan dan validasi data, dilakukan *data selection* untuk memilih data yang relevan dalam analisis sentimen. Data dengan label “Netral” dihapus karena pada penelitian ini label sentimen yang digunakan hanya “Positif” dan “Negatif”. Data yang diperoleh dari hasil pelabelan dan validasi data sebanyak 566 baris dan 6 kolom, terdapat 24 data komentar yang memiliki label “Netral”, terdapat 4 variabel yang tidak relevan yaitu “Timestamp”, “Angkatan”, “Fakultas”, dan “Program Studi”. Jadi total data setelah dilakukan proses *data selection* ini sebanyak 542 data yang dapat dilihat pada Gambar 3.



Gambar 3. Proporsi Data Setelah *Data Selection*

Visualisasi yang ditunjukkan pada Gambar 3 di atas menggambarkan proporsi data yang memiliki sentimen positif dan negatif. Dari visualisasi tersebut, terlihat bahwa mayoritas data, yaitu 67,34% memiliki sentimen positif dengan jumlah 365. Hal ini menunjukkan bahwa mayoritas mahasiswa memiliki pandangan yang baik terhadap kurikulum literasi digital. Di sisi lain, terdapat 32,66% data yang memiliki sentimen negatif dengan jumlah 177. Hal ini menunjukkan bahwa terdapat minoritas mahasiswa yang memiliki persepsi yang tidak puas.

3.3.4 Cleaning

Pada tahap ini, karakter yang tidak relevan seperti tanda baca, simbol, dan emoji dihilangkan. Dampak positif dari proses tersebut dapat menghemat waktu dan sumber daya dalam proses analisis sentimen. Hal ini penting untuk menangani volume data yang besar dalam waktu singkat. Program *cleaning* mengimpor modul “re” untuk bekerja dengan ekspresi reguler (*regular expression*) dan fungsi “clean” dari pustaka “cleantext” untuk membersihkan teks. Tabel 6 merupakan hasil penerapan *cleaning*.

Tabel 6. Hasil *Cleaning*

Sebelum <i>Cleaning</i>	Setelah <i>Cleaning</i>
sangat mengesankan hihi di fh bljr ngoding 😄	sangat mengesankan hihi di fh bljr ngoding
Sejauh ini masih baguss 👍	Sejauh ini masih baguss

3.3.5 Case Folding

Proses ini mengubah semua huruf menjadi huruf kecil (*lowercase*). *Case folding* membantu algoritma klasifikasi sentimen untuk lebih mudah membandingkan kata-kata dan meningkatkan konsistensi klasifikasi. *Case folding* menggunakan fungsi “clean” dari pustaka “cleantext”. Tabel 7 merupakan hasil penerapan *case folding*.

Tabel 7. Hasil *Case Folding*

Sebelum <i>Case Folding</i>	Setelah <i>Case Folding</i>
sangat mengesankan hihi di fh bljr ngoding	sangat mengesankan hihi di fh bljr ngoding
Sejauh ini masih baguss	sejauh ini masih baguss

3.3.6 Tokenizing

Teks dipisahkan menjadi kata-kata individual yang membantu algoritma klasifikasi sentimen untuk memahami makna setiap kata dalam teks. Program *tokenizing* mengimpor fungsi “word_tokenize” dari modul “nltk.tokenize”. Adapun hasil penerapan *tokenizing* dapat dilihat di Tabel 8.

Tabel 8. Hasil *Tokenizing*

Sebelum <i>Tokenizing</i>	Setelah <i>Tokenizing</i>
sangat mengesankan hihi di fh bljr ngoding	['sangat', 'mengesankan', 'hihi', 'di', 'fh', 'bljr', 'ngoding']
sejauh ini masih baguss	['sejauh', 'ini', 'masih', 'baguss']

3.3.7 Normalization

Salah satu langkah penting yang bertujuan untuk menormalkan teks dengan mendeteksi dan memperbaiki kesalahan ejaan atau tidak baku dalam teks. Contohnya, ['fh'] menjadi ['fakultas', 'hukum']. Peneliti meninjau data komentar satu per satu apakah ada kata-kata yang memiliki kesalahan eja, kemudian peneliti membuat kamus normalisasi. Adapun hasil penerapan *normalization* dapat dilihat pada Tabel 9.

Tabel 9. Hasil *Normalization*

Sebelum <i>Normalization</i>	Setelah <i>Normalization</i>
['sangat', 'mengesankan', 'hihi', 'di', 'fh', 'bljr', 'ngoding']	['sangat', 'mengesankan', 'hihi', 'di', 'fakultas', 'hukum', 'belajar', 'pengkodean']
['sejauh', 'ini', 'masih', 'baguss']	['sejauh', 'ini', 'masih', 'bagus']

3.3.8 Filtering

Kata-kata yang tidak penting seperti kata ganti dan kata hubung dihilangkan. *Filtering* membantu algoritma klasifikasi sentimen fokus pada kata-kata yang memiliki makna emosional dari mahasiswa. Contohnya, “sangat”, “hihi”, “di”, “sejauh”, “ini”, “masih”. Program *filtering* menggunakan modul “stopwords” dari “nltk.corpus”. Daftar *stopwords* untuk Bahasa Indonesia dari NLTK (*Natural Language Toolkit*). Adapun hasil penerapan *filtering* dapat dilihat di Tabel 10.

Tabel 10. Hasil *Filtering*

Sebelum <i>Filtering</i>	Setelah <i>Filtering</i>
['sangat', 'mengesankan', 'hihi', 'di', 'fakultas', 'hukum', 'belajar', 'pengkodean']	['mengesankan', 'fakultas', 'hukum', 'belajar', 'pengkodean']
['sejauh', 'ini', 'masih', 'bagus']	['bagus']

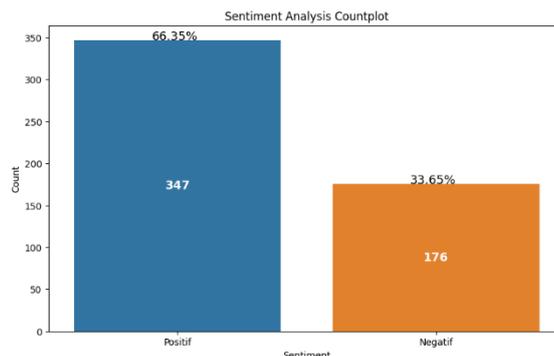
3.3.9 Stemming

Pada tahap terakhir dalam *text preprocessing* ini kata-kata diubah menjadi akar katanya. Contohnya, “mengesankan” menjadi “kesan”, “pengkodean” menjadi “kode”. Program *stemming* menggunakan kelas “StemmerFactory” dari modul “Sastrawi.Stemmer.Factory”. Adapun hasil penerapan *stemming* dapat dilihat di Tabel 11.

Tabel 11. Hasil *Stemming*

Sebelum <i>Stemming</i>	Setelah <i>Stemming</i>
['mengesankan', 'fakultas', 'hukum', 'belajar', 'pengkodean']	['kesan', 'fakultas', 'hukum', 'ajar', 'kode']
['bagus']	['bagus']

Setelah dilakukan *text preprocessing*, ternyata ada data yang isinya hanya [] ruang kosong. Kemudian, dicek menggunakan program *python* untuk menemukan letak indeksinya. Total *rows* data yang kosong hanya berisi [] adalah 19. Data tersebut perlu dihapus karena akan berpengaruh pada performa model. penanganan data yang menghapus 19 data kosong ketika dicek menggunakan fungsi *shape* diketahui bahwa ukuran data (523, 2) artinya jumlah baris data yang awalnya 542 berkurang menjadi 523 yang dapat dilihat pada Gambar 4.



Gambar 4. Proporsi Data Setelah Hapus Data Kosong

Visualisasi yang ditunjukkan pada Gambar 4 di atas menggambarkan proporsi data sentimen positif dan negatif setelah dilakukan penghapusan data kosong menggunakan *python*. Dari visualisasi tersebut, terlihat bahwa mayoritas data 66,35% memiliki sentimen positif dengan jumlah 347. Di sisi lain, terdapat 33,65% data yang memiliki sentimen negatif dengan jumlah 176.

3.3.10 Label Encoding

Langkah lanjutan dalam penelitian ini setelah data melalui proses *text preprocessing* yaitu *label encoding*. Setelah teks dibersihkan dan dinormalkan, *label encoding* berperan untuk mengubah label sentimen (“Positif”, “Negatif”) menjadi representasi numerik. *Label encoding* diimplementasikan dengan mengimpor kelas “LabelEncoder” dari modul “sklearn.preprocessing”. Label sentimen “Positif” menjadi 1, label sentimen “Negatif” menjadi 0.

3.3.11 Data Splitting

Tahap ini merupakan langkah penting dalam *machine learning* untuk membagi data menjadi dua set, *data training* dan *data testing*. *Data training* digunakan untuk melatih model, sedangkan *data testing* digunakan untuk menguji kinerja model pada data yang belum pernah dilihat sebelumnya. *Data splitting* diimplementasikan menggunakan fungsi “train_test_split” dari “sklearn.model_selection”. Tabel 12 merupakan hasil seluruh skenario *data splitting*.

Tabel 12. Hasil Pembagian *Data Training* dan *Data Testing*

Skenario	Data Latih (<i>Data Training</i>)	Data Uji (<i>Data Testing</i>)
60:40	313	210
70:30	366	157
80:20	418	105
90:10	470	53

3.3.12 TF-IDF

Ekstraksi fitur TF-IDF dilakukan setelah data dibagi menjadi *data training* dan *data testing*. Dengan *python*, TF-IDF dapat diimplementasikan menggunakan kode *python* dengan mengimpor kelas “TfidfVectorizer” dari modul “sklearn.feature_extraction.text”. Adapun cuplikan hasil penerapan TF-IDF dapat dilihat pada Gambar 5.

	ada	adaptasi	agama	agroteknologi	ahli	ajar	akademik	akibat	akses	aktif	...	wabil	wadah	wajib	wawas	web	wifi	wordpress	youtube	zamar	
0	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1	0.0	0.0	0.0	0.0	0.0	0.178059	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
5	0.0	0.0	0.0	0.0	0.0	0.170804	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
6	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7	0.0	0.0	0.0	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
8	0.0	0.0	0.0	0.0	0.0	0.462090	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
9	0.0	0.0	0.0	0.0	0.0	0.115377	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

Gambar 5. Hasil TF-IDF

3.3.13 ADASYN

Setelah mengekstraksi fitur menggunakan TF-IDF, langkah selanjutnya adalah mengatasi ketidakseimbangan data yang ada dalam dataset. Salah satu teknik yang efektif untuk menangani ketidakseimbangan data dalam klasifikasi teks adalah *oversampling*. Dalam penelitian ini, telah menggunakan ADASYN untuk *oversampling* data minoritas. ADASYN diimplementasikan menggunakan kode *python* dengan mengimpor kelas “ADASYN” dari modul “imblearn.over_sampling” yang bekerja dengan cara mensintesis data baru yang mirip dengan data minoritas yang sudah ada. Proses ini dilakukan secara adaptif, di mana data yang lebih sulit diklasifikasikan akan diprioritaskan untuk disintesis data baru. Hasil penerapan ADASYN menunjukkan jumlah data kelas minoritas “Negatif” diperbesar mendekati jumlah data kelas mayoritas “Positif” yang dapat dilihat pada Tabel 13.

Tabel 13. Hasil Penerapan ADASYN

Skenario	Data Latih (<i>Data Training</i>)		Data Uji (<i>Data Testing</i>)	
	Positif	Negatif	Positif	Negatif
60:40	208	105	208	203
70:30	244	122	244	233
80:20	279	139	279	261
90:10	307	163	307	298

3.4 Modeling

Pada tahap *modeling*, dilakukan pembangunan model klasifikasi sentimen berdasarkan data yang telah melalui tahap *preprocessing* sebelumnya. Langkah awal yang dilakukan adalah pembuatan skenario model sebelum diimplementasikan algoritma klasifikasi. Penelitian ini menggunakan algoritma klasifikasi *Naïve Bayes*. Selanjutnya dilakukan pelatihan dalam pembangunan model. Terakhir, dilakukan pengujian model untuk menilai performa model yang telah dibangun. Berikut merupakan penjelasan rinci dari tahapan *modeling* yang dilakukan:

3.4.1 Implementasi *Naïve Bayes*

Proses ini dilakukan dengan cara membuat skenario pemodelan yang akan diimplementasikan algoritma *Naïve Bayes*. Pada penelitian ini, implementasi *Naïve Bayes* yang menggunakan salah satu jenis model *Naïve Bayes* yaitu “MultinomialNB”, sesuai untuk data dengan distribusi multinomial seperti yang terjadi pada data teks.

3.4.2 Pelatihan dan Pengujian Model

Model *Naïve Bayes* yang telah dibentuk kemudian dilatih menggunakan data latih. Program pelatihan model *Naïve Bayes* “*mnb*” yang dilatih menggunakan metode “*fit()*”. Setelah proses pelatihan, dilakukan pengujian model dengan menerapkan pada data uji yang telah dipisahkan. Pengujian model dapat diimplementasikan menggunakan kode *python*. Fungsi “*predict()*” dipanggil pada model “*mnb*” yang telah dilatih sebelumnya. Argumen yang diberikan (“*X_test_tfidf*”) adalah matriks fitur yang sudah diproses menggunakan TF-IDF dan merupakan data uji yang belum pernah dilihat sebelumnya. Hasil dari prediksi akan disimpan dalam variabel “*y_pred_class*”. Variabel ini berisi prediksi kelas untuk setiap data uji yang diberikan, sesuai dengan urutan data dalam “*X_test_tfidf*”. Pengujian dilakukan untuk keseluruhan delapan model dengan menggunakan metode *confusion matrix*.

3.5 Evaluation

Pada tahap evaluasi model, dilakukan pengukuran kinerja model *Naïve Bayes* yang telah dibangun pada tahap *modeling* sebelumnya. Evaluasi bertujuan untuk mengetahui seberapa baik model dapat melakukan klasifikasi sentimen pada data uji. Beberapa metrik yang digunakan antara lain *accuracy*, *precision*, *recall*, dan *f1-score*. Hasil evaluasi model secara keseluruhan dapat dilihat pada Tabel 14

Tabel 14. Hasil Evaluasi Model

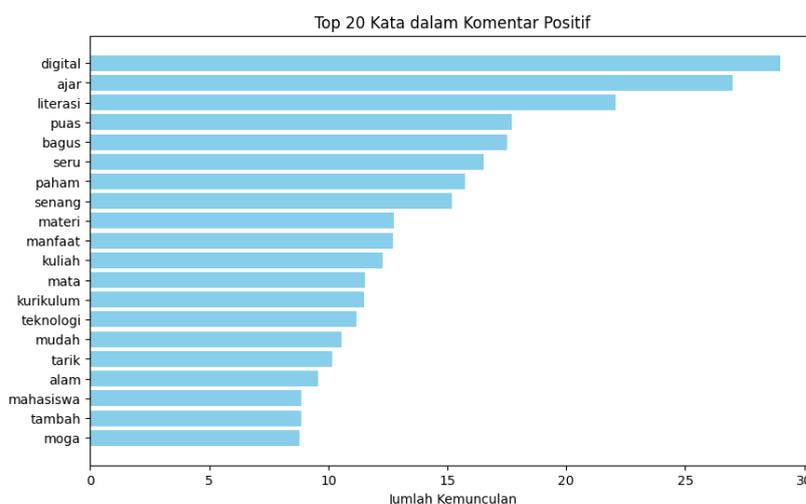
Model	Skenario	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
A	60:40 tanpa ADASYN	0,73	0,73	0,96	0,83
B	70:30 tanpa ADASYN	0,74	0,73	0,95	0,83
C	80:20 tanpa ADASYN	0,76	0,74	0,97	0,84
D	90:10 tanpa ADASYN	0,87	0,87	0,98	0,92
E	60:40 dengan ADASYN	0,79	0,88	0,79	0,83
F	70:30 dengan ADASYN	0,82	0,87	0,84	0,87
G	80:20 dengan ADASYN	0,80	0,86	0,82	0,87
H	90:10 dengan ADASYN	0,89	1	0,85	0,92

Berdasarkan hasil evaluasi di atas, model H (rasio *data splitting* 90:10 setelah penerapan ADASYN) terpilih sebagai model terbaik untuk klasifikasi sentimen. Model H memiliki *accuracy* 89%, *precision* 100%, *recall* 85%, dan *f1-score* 92%. Pemilihan model H didasarkan pada beberapa pertimbangan. Model H yang dilatih dengan teknik *oversampling* ADASYN dan rasio split 90:10 menunjukkan performa terbaik secara keseluruhan. Dengan *accuracy* 89% dan *f1-score* 92%, model H berhasil mengklasifikasikan sentimen secara akurat dengan mempertimbangkan keseimbangan antara *precision* dan *recall* yang sangat baik. *Precision* 100%

pada model H merupakan nilai tertinggi diantara semua model. Hal ini berarti model sangat akurat dalam memprediksi data positif tanpa ada kesalahan prediksi data negatif sebagai positif. Meskipun *recall* sedikit lebih rendah yaitu 85% dibanding model D, namun perbedaannya tidak terlalu signifikan. Keunggulan *precision* yang didukung nilai evaluasi lain yang sangat baik menjadikan model H sebagai pilihan terbaik untuk kasus klasifikasi sentimen ini. Oleh karena itu, hasil evaluasi yang telah diperoleh sesuai dengan tujuan penelitian.

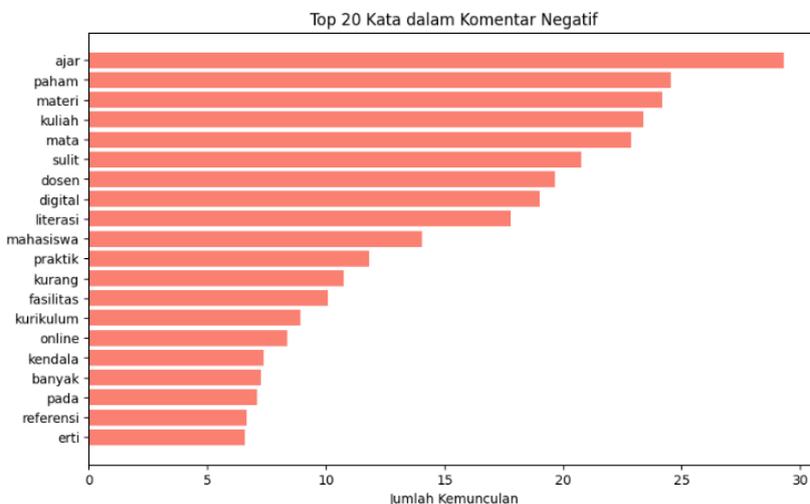
3.6 Deployment

Tahap *deployment* merupakan tahap akhir dalam metodologi CRISP-DM. Pada tahap ini, fokus utama adalah penyusunan dokumentasi proses *text mining* dan penerapan hasil analisis ke dalam visualisasi *word frequency*. Dalam *word frequency*, terdapat jumlah kemunculan yang mewakili frekuensi kemunculan dari setiap kata dalam korpus teks dengan menggunakan pendekatan TF-IDF. *Word frequency* positif dibentuk dari kata-kata yang sering muncul pada data sentimen positif. Demikian pula *word frequency* negatif dibentuk berdasarkan kata-kata yang sering muncul pada data sentimen negatif. Hasil visualisasi *word frequency* dapat dilihat pada Gambar 6 dan Gambar 7.



Gambar 6. Word Frequency Positif

Berdasarkan hasil visualisasi *word frequency* komentar sentimen positif pada Gambar 6, kata-kata seperti “puas”, “bagus”, “seru”, “manfaat”, “mata”, “kuliah”, dan “kurikulum” mencerminkan apresiasi mahasiswa terhadap kurikulum dan materi yang diberikan. Kata “paham” dan “mudah” menunjukkan bahwa sebagian mahasiswa merasa materi mudah dipahami. Kata-kata “digital”, “literasi”, dan “teknologi” mencerminkan mahasiswa memiliki ketertarikan pada topik-topik terkait dunia teknologi dan literasi digital. Kata-kata seperti “senang”, “tarik”, dan “alam” mengindikasikan pengalaman belajar yang menyenangkan dan menarik bagi mahasiswa. Terakhir, kata “tambah”, “moga” mencerminkan harapan mahasiswa agar kurikulum ini dapat terus dikembangkan dan ditingkatkan di masa mendatang.



Gambar 7. Word Frequency Negatif

Di sisi lain, hasil visualisasi *word frequency* komentar sentimen negatif pada Gambar 7, kata-kata seperti “paham”, “materi”, “sulit”, dan “erti” menunjukkan adanya masalah dalam memahami materi yang diberikan. Kata “ajar” dan “dosen” mengindikasikan adanya masalah kualitas pengajaran dan kinerja dosen. Kata-kata “praktik”, “online”, dan “kendala” mencerminkan kendala yang dihadapi mahasiswa dalam melakukan praktik atau mengikuti pembelajaran secara *online*. Kata “fasilitas”, “kurang” menunjukkan kurangnya fasilitas pendukung yang kurang memadai. Kata “referensi” mengindikasikan kekurangan dalam penyediaan sumber belajar atau referensi yang memadai bagi mahasiswa.

4. KESIMPULAN

Hasil analisis sentimen dari mahasiswa terhadap Kurikulum Literasi Digital di Unsika yang menggunakan 591 data komentar, kemudian data tersebut dibersihkan sehingga menghasilkan 523 data komentar dengan masing-masing kategori sentimen yakni 347 komentar positif dan 176 komentar negatif. Hasil visualisasi *word frequency* pada setiap kategori sentimen memberikan gambaran kata-kata kunci yang mencerminkan aspek-aspek yang mendapatkan apresiasi maupun kritik dari mahasiswa. Berdasarkan hasil visualisasi *word frequency* pada komentar positif, menunjukkan bahwa mahasiswa memberikan pandangan yang positif dengan mengapresiasi manfaat, kegunaan, dan pengalaman belajar yang diberikan oleh kurikulum tersebut. Dalam visualisasi *word frequency* pada komentar negatif, menunjukkan bahwa terdapat beberapa masalah atau ketidakpuasan yang diungkapkan mahasiswa. Diperlukan peningkatan dalam beberapa hal, meliputi, kesulitan dalam pemahaman materi, fasilitas yang kurang memadai, ketidakpuasan terhadap konten kurikulum, praktik atau pembelajaran secara *online*, kurangnya dukungan atau bantuan dari dosen, atau ketidaksesuaian gaya pengajaran dengan kebutuhan mahasiswa, sehingga hal ini dapat menjadi masukan bagi pihak Unsika untuk melakukan perbaikan dalam implementasi kurikulum literasi digital.

Dari delapan skenario model yang diuji, model yang dilatih dengan algoritma *Naïve Bayes* menggunakan pembagian *data training* 90% dan *data testing* 10% setelah penerapan ADASYN menjadi model terbaik dengan *accuracy* 89%, *precision* 100%, *recall* 85%, dan *f1-score* 92%. Penerapan ADASYN terbukti mampu memengaruhi performa model. Penggunaan skenario *data splitting* juga memengaruhi hasil performa. Terdapat beberapa faktor lain, seperti tahapan *preprocessing* data teks yang juga memainkan peran penting.

Penelitian ini hanya menggunakan satu algoritma, *Naïve Bayes*, tetapi ada banyak algoritma lain yang mungkin lebih efektif. Selain itu, tidak ada teknik seleksi fitur (*feature selection*) yang digunakan untuk menentukan fitur-fitur yang paling relevan atau informatif dalam analisis sentimen. Penggunaan teknik ini dapat meningkatkan akurasi dan interpretasi hasil analisis sentimen, yang merupakan perbaikan penting untuk penelitian selanjutnya.

UCAPAN TERIMAKASIH

Terima kasih disampaikan kepada pihak-pihak yang telah mendukung terlaksananya penelitian ini.

REFERENCES

- [1] E. F. Santika, “Indonesia Terpentak Jauh dari Singapura soal Daya Saing Digital,” databoks. Diakses: 17 Desember 2023. [Daring]. Tersedia pada: <https://databoks.katadata.co.id/datapublish/2023/06/30/indonesia-terpentak-jauh-dari-singapura-soal-daya-saing-digital>
- [2] H. A. Naufal, “Literasi Digital,” *Perspektif*, vol. 1, no. 2, hlm. 195–202, Okt 2021, doi: 10.53947/perspekt.v1i2.32.
- [3] S. A. Walewangko, H. I. Untu, C. A. P. Koleangan, dan D. A. Katuuk, *Kurikulum Pendidikan Konsep Dasar, Landasan, Komponen, Pengembangan, Implementasi, Evaluasi dan Dinamika Perkembangannya di Indonesia*. Makassar: Nas Media Pustaka, 2022.
- [4] R. Dermawan, M. Izman Herdiansyah, dan M. I. Herdiansyah, “Analisis Sentimen Komentar Kinerja Kegiatan Kepala Daerah Kota Lubuk Linggau,” *Bina Darma Conference on Computer Science*, no. Vol 3 No 5 (2021): Bina Darma Conference on Computer Science (BDCCS), hlm. 1027–1040, 2022, Diakses: 16 Maret 2024. [Daring]. Tersedia pada: <https://conference.binadarma.ac.id/index.php/BDCCS/article/view/2493/1135>
- [5] F. Romadoni, Y. Umidah, dan B. N. Sari, “Text Mining Untuk Analisis Sentimen Pelanggan Terhadap Layanan Uang Elektronik Menggunakan Algoritma Support Vector Machine,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 9, no. 2, hlm. 247–253, Jul 2020, doi: 10.32736/sisfokom.v9i2.903.
- [6] F. A. Nugraha, N. H. Harani, dan R. Habibi, *Analisis Sentimen Terhadap Pembatasan Sosial Menggunakan Deep Learning*. Bandung: Kreatif Industri Nusantara, 2020.
- [7] A. K. Fauziyyah, “Analisis Sentimen Pandemi Covid-19 Pada Streaming Twitter Dengan Text Mining Python,” *Jurnal Ilmiah SINUS*, vol. 18, no. 2, hlm. 31–42, Jul 2020, doi: 10.30646/sinus.v18i2.491.

- [8] F. Marisa, A. L. Maukar, dan T. M. Akhriza, *Data Mining Konsep dan Penerapannya*, 1 ed. Yogyakarta: Deepublish, 2021.
- [9] F. S. Pattiha dan H. Hendry, “Perbandingan Metode K-NN, Naïve Bayes, Decision Tree untuk Analisis Sentimen Tweet Twitter Terkait Opini Terhadap PT PAL Indonesia,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 2, hlm. 506, Apr 2022, doi: 10.30865/jurikom.v9i2.4016.
- [10] N. Ferdiansyah dan A. Solichin, “Analisis Sentimen Terhadap Pembelajaran Dosen Berdasarkan Data Kritik Saran Mahasiswa Menggunakan Metode Naïve Bayes,” *Bit (Fakultas Teknologi Informasi Universitas Budi Luhur)*, vol. 19, no. 2, hlm. 104–111, 2022, Diakses: 12 Agustus 2023. [Daring]. Tersedia pada: <https://journal.budiluhur.ac.id/index.php/bit/article/download/2041/1209>
- [11] H. Santoso, Armansyah, dan D. Desliani, “Analisis Sentimen Mahasiswa Terkait Pembelajaran Tatap Muka Menggunakan Metode Naïve Bayes Classifier,” *Techno.COM*, vol. 21, no. 3, hlm. 644–654, Agu 2022, doi: 10.33633/tc.v21i3.6262.
- [12] E. Febriyani dan H. Februariyanti, “Analisis Sentimen Terhadap Program Kampus Merdeka Menggunakan Algoritma Naive Bayes Classifier Di Twitter,” *Jurnal Tekno Kompak*, vol. 17, no. 1, hlm. 25–38, 2023, doi: 10.33365/jtk.v17i1.2061.
- [13] R. Wati, S. Ernawati, dan H. Rachmi, “Pembobotan TF-IDF Menggunakan Naïve Bayes pada Sentimen Masyarakat Mengenai Isu Kenaikan BIPIH,” *Jurnal Manajemen Informatika (JAMIKA)*, vol. 13, no. 1, hlm. 84–93, Apr 2023, doi: 10.34010/jamika.v13i1.9424.
- [14] M. R. Baig, *Optimizing AI and Machine Learning Solution*. India: BPB Publications, 2024.
- [15] C. Magnolia, A. Nurhopipah, D. Bagus, dan A. Kusuma, “Penanganan Imbalanced Dataset untuk Klasifikasi Komentar Program Kampus Merdeka Pada Aplikasi Twitter,” *Edu Komputika*, vol. 9, no. 2, 2022, [Daring]. Tersedia pada: <http://journal.unnes.ac.id/sju/index.php/edukom>
- [16] M. D. Hendriyanto, A. A. Ridha, dan U. Enri, “Analisis Sentimen Ulasan Aplikasi MOLA Pada Google Play Store Menggunakan Algoritma Support Vector Machine,” *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 5, no. 1, hlm. 1–7, 2022, doi: 10.31539/intecom.v5i1.3708.