

BAB II TINJAUAN PUSTAKA

2.1 Klasifikasi Sentimen

Klasifikasi sentimen merupakan proses mengelompokkan teks berdasarkan opini atau emosi yang terkandung di dalamnya menjadi kategori seperti positif, negatif, atau netral. Tujuannya adalah untuk memahami persepsi pengguna terhadap suatu produk, layanan, atau lembaga melalui ulasan yang mereka tulis (8). Proses ini sangat penting dalam era digital saat ini, di mana ulasan online menjadi sumber data utama untuk evaluasi publik.

Selain itu, klasifikasi sentimen menjadi bagian penting dari analisis teks karena mampu mengubah data ulasan yang tidak terstruktur menjadi informasi yang bermakna, sehingga memudahkan identifikasi pola emosi dalam teks (15). Hal ini membantu organisasi seperti universitas untuk mengukur kepuasan *stakeholder* secara objektif.

Dalam penelitian Analisis Ulasan Pelanggan Menggunakan *Naïve Bayes Classifier* pada Plus Coffee and Space, dijelaskan bahwa klasifikasi sentimen digunakan untuk memahami tingkat kepuasan pelanggan terhadap layanan berdasarkan ulasan yang diunggah di platform digital, yang sering melibatkan analisis frekuensi kata untuk mendeteksi sentimen (12,16). Pendekatan ini dapat diterapkan pada ulasan Google Maps untuk universitas.

Lebih lanjut, klasifikasi sentimen juga mampu memberikan wawasan strategis bagi lembaga atau organisasi, terutama dalam mengevaluasi persepsi publik terhadap aspek seperti kualitas layanan atau produk, yang dapat diukur secara kuantitatif (14). Hasil klasifikasi ini dapat digunakan untuk mendukung pengambilan keputusan manajerial yang lebih tepat dan berbasis data, seperti perbaikan layanan berdasarkan *feedback* negatif (17).

Dengan demikian, dalam konteks penelitian ini, klasifikasi sentimen diterapkan untuk mengelompokkan ulasan pengguna Google Maps terhadap Universitas Muhammadiyah Gresik sehingga dapat diketahui kecenderungan opini masyarakat terhadap universitas tersebut, apakah bernada positif, negatif, atau

netral, yang membantu universitas dalam meningkatkan reputasi dan layanan pendidikan (7).

2.2 Google Maps

Google Maps tidak hanya berfungsi sebagai layanan navigasi, tetapi juga sebagai media bagi pengguna untuk memberikan ulasan atau penilaian terhadap suatu lokasi. Ulasan ini berisi opini subjektif pengguna yang menggambarkan pengalaman mereka, sehingga menjadi sumber data penting untuk analisis sentimen, terutama dalam konteks lokasi seperti universitas yang sering dikunjungi mahasiswa dan masyarakat (18).

Ulasan di Google Maps memiliki karakteristik unik, yaitu berisi teks singkat dengan bahasa yang beragam dan seringkali informal, seperti penggunaan slang atau emoji, yang menambah kompleksitas analisis (11). Hal ini menjadi tantangan dalam proses analisis karena diperlukan tahap pra-pemrosesan teks untuk menghasilkan data yang lebih terstruktur, termasuk normalisasi bahasa agar algoritma dapat bekerja optimal (19).

Ulasan pengguna di Google Maps juga dapat mencerminkan citra dan reputasi sebuah tempat, termasuk lembaga pendidikan seperti universitas, di mana ulasan positif dapat meningkatkan daya tarik bagi calon mahasiswa (20). Oleh karena itu, analisis sentimen terhadap ulasan Google Maps dapat membantu pihak universitas memahami persepsi masyarakat dan meningkatkan kualitas layanan, seperti infrastruktur atau interaksi dengan staf, berdasarkan *feedback* yang dikumpulkan (21).

2.3 Natural Language Processing (NLP)

Natural Language Processing (NLP) merupakan cabang dari kecerdasan buatan yang memungkinkan komputer memahami, menafsirkan, dan menghasilkan bahasa manusia secara alami. NLP memainkan peran penting dalam analisis teks, termasuk dalam klasifikasi sentimen, karena dapat mengekstrak makna dari teks yang kompleks (22).

NLP digunakan untuk memproses teks dari Google Maps menggunakan *Natural Language Toolkit* (NLTK) dan *TextBlob* agar komputer mampu mengenali polaritas dari setiap ulasan, seperti mendeteksi kata-kata positif atau negatif dalam

konteks budaya Indonesia (7). Proses ini mencakup tokenisasi, penghapusan *stopword*, *stemming*, dan pembobotan kata, yang membantu mengurangi *noise* dalam data ulasan untuk akurasi yang lebih baik (11).

Dengan bantuan NLP, teks ulasan yang awalnya tidak terstruktur dapat diolah menjadi representasi numerik yang dapat diproses oleh algoritma seperti *Multinomial Naïve Bayes*, sehingga memungkinkan analisis sentimen otomatis pada skala besar (23).

2.4 Text Mining

Text Mining adalah proses ekstraksi informasi berharga dari kumpulan teks yang besar melalui pendekatan statistik dan komputasional. Proses ini melibatkan beberapa tahap, yaitu *preprocessing*, transformasi teks, analisis pola, dan interpretasi hasil, yang sangat berguna untuk mengelola data ulasan yang volumenya tinggi (4).

Dalam konteks klasifikasi sentimen, *text mining* membantu mempersiapkan data ulasan agar siap untuk diklasifikasikan, dengan fokus pada pengolahan teks informal seperti yang sering ditemukan di Google Maps (12). Tahap-tahap dalam *text mining* mencakup pembersihan data (*cleaning*), tokenisasi, dan pembobotan kata yang nantinya digunakan dalam proses klasifikasi, sehingga data menjadi lebih representatif untuk model *machine learning* (12).

Dengan demikian, *text mining* menjadi tahap awal yang penting dalam menghasilkan data berkualitas untuk analisis sentimen ulasan Google Maps, yang dapat mengungkap tren opini publik terhadap universitas (6).

2.5 Perbedaan Naïve Bayes dan Multinomial Naïve Bayes

Naïve Bayes merupakan algoritma klasifikasi berbasis probabilitas yang bekerja dengan prinsip *Bayes Theorem* dan asumsi independensi antar fitur. Algoritma ini banyak digunakan pada permasalahan *text mining* karena sederhana, cepat, dan mampu bekerja dengan baik pada data berukuran besar (11). Namun, *Naïve Bayes* memiliki beberapa varian yang disesuaikan dengan tipe datanya. Pada kasus analisis teks, model yang paling umum digunakan adalah *Multinomial Naïve Bayes* (MNB) karena mampu memanfaatkan frekuensi kemunculan kata untuk menentukan kelas suatu dokumen (1).

Perbedaan mendasar antara *Naïve Bayes* standar dan *Multinomial Naïve Bayes* terletak pada cara keduanya memodelkan fitur. *Naïve Bayes* biasa (*Gaussian/Bernoulli*) hanya mempertimbangkan keberadaan atau ketidakhadiran fitur dalam dokumen, sedangkan MNB mempertimbangkan jumlah kemunculan setiap kata (*term frequency*) sebagai dasar pembobotan (4). Pendekatan ini membuat MNB lebih akurat ketika digunakan pada dataset teks yang panjang dan memiliki variasi kata yang tinggi, seperti ulasan Google Maps yang sering menggunakan bahasa tidak baku dan kata berulang (5). Penelitian-penelitian sebelumnya juga menunjukkan bahwa MNB unggul dalam performa pada kasus klasifikasi teks dibanding varian *Naïve Bayes* lainnya (7).

Dengan mempertimbangkan karakteristik data ulasan pengguna yang berbasis teks bebas, sangat bervariasi, dan kaya frekuensi kata, penggunaan *Multinomial Naïve Bayes* menjadi pilihan yang paling relevan untuk penelitian ini. Selain terbukti menghasilkan akurasi tinggi pada berbagai studi serupa (12), MNB juga lebih stabil dalam memproses dataset yang besar serta lebih efektif dalam mengidentifikasi pola sentimen berdasarkan distribusi kata dalam setiap ulasan (9). Oleh karena itu, varian ini dipilih sebagai algoritma utama dalam pemodelan sentimen ulasan Google Maps pada penelitian ini.

2.6 Term Frequency-Inverse Document Frequency (TF-IDF)

Term Frequency–Inverse Document Frequency (TF-IDF) adalah metode pembobotan kata yang digunakan untuk menentukan seberapa penting suatu kata dalam dokumen tertentu dibandingkan dengan seluruh kumpulan dokumen. TF-IDF berfungsi untuk memperkuat kata-kata yang memiliki nilai pembeda tinggi antar dokumen dan melemahkan kata yang sering muncul secara umum, seperti kata penghubung yang tidak bermakna (1).

Metode ini sangat efektif dalam analisis sentimen karena membantu mengidentifikasi kata-kata kunci yang membedakan ulasan positif dan negatif, misalnya kata "bagus" versus "buruk" dalam konteks ulasan universitas (10).

Rumus TF-IDF dapat dinyatakan sebagai berikut:

$$TF - IDF(t, d) = TF(t, d) \times \log \left(\frac{N}{DF(t)} \right) \quad (2.1)$$

Dengan :

1. $TF(t, d)$ = frekuensi kemunculan kata t pada dokumen d .
2. $IDF(t) = \log(N/df(t))$, dimana N adalah jumlah dokumen dan $df(t)$ adalah jumlah dokumen yang mengandung kata t .

Metode TF-IDF digunakan untuk mengubah teks ulasan menjadi representasi numerik yang dapat diproses oleh algoritma klasifikasi seperti Naïve Bayes, sehingga meningkatkan akurasi dalam mendeteksi sentimen (3).

2.7 Multinomial Naïve Bayes

Multinomial Naïve Bayes (MNB) merupakan salah satu algoritma klasifikasi yang sering digunakan dalam analisis teks karena kemampuannya mengolah data berbentuk frekuensi kata. MNB bekerja berdasarkan teorema *Bayes* dengan asumsi independensi antar fitur, yang membuatnya efisien untuk dataset teks besar seperti ulasan Google Maps (5).

Algoritma ini sangat cocok untuk klasifikasi sentimen karena dapat menghitung probabilitas kata-kata dalam konteks positif, negatif, atau netral, dengan performa yang baik meskipun data tidak terdistribusi normal (12).

Rumus dasar Naïve Bayes adalah sebagai berikut:

$$P(C|X) = \frac{P(C) \prod_{i=1}^n P(x_i|C)}{P(X)} \quad (2.2)$$

Dimana :

1. $P(C|X)$ adalah probabilitas kelas C diberikan data X ,
2. $P(C)$ adalah probabilitas prior dari kelas C ,
3. $P(x_i|C)$ adalah probabilitas fitur x_i dalam kelas C .

Model MNB terbukti efektif untuk analisis sentimen karena efisien dalam menghitung peluang kata yang muncul berulang kali dalam teks, seperti kata-kata umum dalam ulasan universitas (4). Penelitian lain juga menunjukkan bahwa MNB memberikan akurasi tinggi dalam mengklasifikasikan ulasan pengguna pada

berbagai aplikasi, termasuk yang berkaitan dengan pendidikan dan layanan publik (15).

2.8 Evaluasi Model Klasifikasi

Evaluasi model dilakukan untuk mengukur kinerja model klasifikasi dalam memprediksi kelas dengan benar. Beberapa metrik umum yang digunakan antara lain *accuracy*, *precision*, *recall*, dan *F1-score*, yang biasanya diperoleh dari *confusion matrix* untuk memastikan model tidak bias terhadap kelas tertentu (9).

Metrik ini penting dalam analisis sentimen karena membantu menilai seberapa baik model membedakan ulasan positif dan negatif, terutama pada data ulasan Google Maps yang bervariasi (10).

Rumus dasar untuk evaluasi adalah:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

$$Precision = \frac{TP}{TP + FP} \quad (2.4)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.5)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.6)$$

Nilai akurasi yang tinggi mencerminkan kemampuan model dalam melakukan klasifikasi sentimen dengan baik, sementara *precision* dan *recall* membantu mengidentifikasi kekuatan model dalam menghindari kesalahan klasifikasi (4).

2.9 Penelitian Terdahulu

Tabel 2.1. Penelitian Terdahulu

Peneliti	Judul	Metode	Objek Penelitian	Hasil

Sri Lestanti, Saiful Nur Budiman, Erwan (2024)	Analisis Sentimen Berdasarkan Hasil Review Lokasi Google Map Menggunakan Natural Language Toolkit TextBlob dan Naïve Bayes	Naïve Bayes & TextBlob	Ulasan lokasi di Google Maps	Menghasilkan tingkat akurasi yang cukup baik dengan model Naïve Bayes dibandingkan TextBlob dalam mengklasifikasikan sentimen positif dan negatif.
Dani Adrian Firmansah, Nanang Yudi Setiawan, Dian Eka Ratnawati (2025)	Analisis Ulasan Pelanggan Menggunakan Naïve Bayes Classifier pada Plus Coffee and Space	Naïve Bayes Classifier	Review pelanggan kafe Plus Coffee and Space	Sistem mampu mengklasifikasikan ulasan pelanggan dengan akurasi 87%, memudahkan pengelola mengetahui kepuasan pelanggan.
Muhammad Alfarissi Nurdin, Sena Wijayanto (2025)	Analisis Sentimen Ulasan Pengguna Tentang Pantai Widarapayung Pada Google Maps Menggunakan	Naïve Bayes	Ulasan pengguna di Google Maps	Model mampu mengidentifikasi persepsi pengunjung terhadap objek wisata dengan tingkat akurasi mencapai 90%.

	Algoritma Naïve Bayes			
Pandu Gian Rahardandi, Muhammad Fauzan, Muhammad Putra Wicaksana (2024)	Systematic Literature Review: Analisis Sentimen pada Situs Google dan Penerapannya	Systematic Literature Review	Studi literatur situs Google	Menyimpulkan bahwa metode Naïve Bayes mendominasi efektivitas analisis sentimen di berbagai studi.
Rizqia Lestika Atimi, Enda Esyudha Pratama (2022)	Implementasi Model Klasifikasi Sentimen pada Review Produk Lazada Indonesia	Naïve Bayes	Review produk e- commerce Lazada	Hasil menunjukkan model efektif mendeteksi sentimen positif dan negatif untuk mendukung analisis kepuasan pelanggan.
Mohammad Yoga Pratama, Cahyo Crysdian (2025)	Klasifikasi User Review pada Aplikasi Online Travel Booking Menggunakan <i>Multinomial Naïve Bayes</i>	<i>Multinomial Naïve Bayes</i>	Review pengguna aplikasi travel online	Akurasi model mencapai 91%, efektif dalam mengelompokkan sentimen pengguna.
Laurentina Adinda Puspita Sari, Mustafid, Triastuti	Penerapan Metode <i>Multinomial Naïve Bayes</i> dengan Seleksi	<i>Multinomial Naïve Bayes + Information Gain</i>	Ulasan layanan IndiHome	Seleksi fitur meningkatkan akurasi hingga 92% dengan efisiensi pemrosesan data yang lebih cepat.

Wuryandari (2025)	Fitur Information Gain untuk Analisis Sentimen terhadap Layanan IndiHome			
Isra Elwanda Putra, Asriyanik, Fathia Frazna Azzahra (2025)	Pemanfaatan <i>Multinomial</i> <i>Naïve Bayes</i> untuk Analisis Sentimen Ulasan Aplikasi Mobile JKN	<i>Multinomial</i> <i>Naïve</i> <i>Bayes</i>	Ulasan aplikasi Mobile JKN	Menghasilkan akurasi 89% dan membantu instansi mengetahui persepsi pengguna terhadap aplikasi layanan publik.
Robbi Zulcharnain, Ginanjari Abdurrahman, Daryanto (2025)	Analisis Sentimen Ulasan Duolingo dengan Metode Algoritma <i>Multinomial</i> <i>Naïve Bayes</i>	<i>Multinomial</i> <i>Naïve</i> <i>Bayes</i>	Ulasan aplikasi Duolingo	Model berhasil mengidentifikasi opini pengguna dengan akurasi 90% serta mendukung evaluasi pengembangan aplikasi.
Machrus Izunnahdi, Ginanjari Aburrahman, Ari Eko	Sentimen Analisis pada Data Ulasan Aplikasi KAI Access di	<i>Multinomial</i> <i>Naïve</i> <i>Bayes</i>	Ulasan aplikasi KAI Access	Model memberikan hasil klasifikasi positif dan negatif dengan akurasi 88%, efektif

Wardoyo (2021)	Google PlayStore Menggunakan Metode <i>Multinomial</i> <i>Naïve Bayes</i>			untuk evaluasi aplikasi.
-------------------	--	--	--	-----------------------------

