

## **ANALISIS SENTIMEN PENGGUNA TWITTER TERHADAP KEBIJAKAN ROYALTI RESTORAN DAN KAFE DENGAN MULTINOMIAL NAIVE BAYES**

**Stephanie Gabriella Wijaya<sup>1\*</sup>, Suharyadi<sup>2</sup>**

<sup>1,2</sup>Sistem Informasi, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Indonesia

E-mail: <sup>1\*</sup>stephaniegabriellawijaya@gmail.com, <sup>2</sup>haryadi@uksw.edu

(\*: coresponding author)

**Abstrak-**Kewajiban pembayaran royalti musik pada restoran dan kafe yang diatur dalam Peraturan Pemerintah Nomor 56 Tahun 2021 memunculkan beragam respons di masyarakat. Perbedaan pemahaman terhadap ketentuan royalti, mekanisme pemungutan, serta kekhawatiran pelaku usaha terkait beban biaya operasional mendorong munculnya diskusi publik secara intens di media sosial, khususnya *Twitter*. Media sosial berperan sebagai ruang ekspresi opini yang merefleksikan sikap, persepsi, dan kecenderungan sentimen masyarakat terhadap kebijakan tersebut. Namun, kecenderungan sentimen publik terhadap kebijakan royalti restoran dan kafe masih belum banyak dikaji secara sistematis menggunakan pendekatan analisis sentimen berbasis data dan pembelajaran mesin. Oleh karena itu, penelitian ini bertujuan untuk menganalisis sentimen pengguna *Twitter* terkait kebijakan royalti restoran dan kafe dengan menerapkan metode *Multinomial Naive Bayes*. Sebanyak 1,513 unggahan berbahasa Indonesia dikumpulkan sebagai data penelitian melalui penerapan teknik *web scraping* menggunakan kata kunci yang relevan. Pelabelan sentimen dilakukan dengan pendekatan *lexicon-based* ke dalam tiga kategori, yaitu positif, netral, dan negatif. Tahapan analisis mencakup prapemrosesan teks, ekstraksi fitur menggunakan *Term Frequency–Inverse Document Frequency* (TF-IDF), penanganan ketidakseimbangan data dengan *Synthetic Minority Over-sampling Technique* (SMOTE), serta optimasi parameter model menggunakan *GridSearchCV*. Hasil analisis menunjukkan bahwa sentimen netral mendominasi perbincangan publik sebesar 81.96%, diikuti sentimen negatif sebesar 12.23% dan sentimen positif sebesar 5.82%. Model *Multinomial Naive Bayes* menghasilkan nilai akurasi dan *F1-score* masing-masing sebesar 95%, yang menunjukkan kinerja klasifikasi sentimen yang sangat baik dalam mengidentifikasi kecenderungan opini publik terhadap kebijakan royalti restoran dan kafe.

**Kata Kunci:** Analisis Sentimen, Kebijakan Royalti, Twitter, Multinomial Naive Bayes, SMOTE

**Abstract-***The obligation to pay music royalties in restaurants and cafés, as regulated under Government Regulation Number 56 of 2021, has generated diverse public responses. Differences in understanding of royalty provisions, collection mechanisms, and concerns among business operators regarding operational cost burdens have driven intensive public discussions on social media, particularly Twitter. Social media functions as a space for opinion expression that reflects public attitudes, perceptions, and sentiment tendencies toward the policy. However, public sentiment toward restaurant and café royalty policies has not been widely examined in a systematic manner using data-driven sentiment analysis and machine learning approaches. Accordingly, this study aims to analyze Twitter users' sentiment regarding restaurant and café royalty policies by applying the Multinomial Naive Bayes method. A total of 1,513 Indonesian-language tweets were collected as research data through web scraping using relevant keywords. Sentiment labeling was conducted using a lexicon-based approach into three categories: positive, neutral, and negative. The analytical stages included text preprocessing, feature extraction using Term Frequency–Inverse Document Frequency (TF-IDF), handling class imbalance with the Synthetic Minority Over-sampling Technique (SMOTE), and model parameter optimization using GridSearchCV. The results indicate that neutral sentiment dominates public discourse at 81.96%, followed by negative sentiment at 12.23% and positive sentiment at 5.82%. The Multinomial Naive Bayes model achieved accuracy and F1-score values of 95%, demonstrating strong performance in classifying public sentiment toward restaurant and café royalty policies.*

**Keywords:** Sentiment Analysis, Royalty Policy, Twitter, Multinomial Naive Bayes, SMOTE

### **1. PENDAHULUAN**

Inovasi teknologi digital telah membentuk cara baru bagi masyarakat dalam menyuarakan opini dan mengakses informasi. Media sosial, khususnya *Twitter* yang kini dikenal sebagai *X*, menjadi salah satu platform di Indonesia untuk mengekspresikan pandangan publik terhadap berbagai isu, termasuk kebijakan pemerintah. Kecepatan arus informasi serta luasnya jangkauan pengguna menjadikan *Twitter* sebagai sumber data yang relevan untuk menganalisis respons dan persepsi masyarakat terhadap suatu kebijakan [1]. Situasi ini memunculkan kebutuhan akan pendekatan analitis yang mampu memproses data tekstual dalam jumlah besar secara efektif dan presisi.

Salah satu regulasi yang memicu beragam tanggapan dari masyarakat adalah Peraturan Pemerintah Nomor 56 Tahun 2021 tentang Pengelolaan Royalti Hak Cipta Lagu dan/atau Musik. Regulasi tersebut menetapkan kewajiban bagi penyelenggara layanan publik yang bersifat komersial, termasuk restoran dan kafe, untuk membayarkan royalti atas pemanfaatan lagu dan musik [2]. Tujuan dari kebijakan ini adalah menjamin perlindungan hukum atas hak ekonomi para pencipta karya musik. Pelaku Usaha Mikro, Kecil, dan Menengah (UMKM) menyatakan kekhawatiran terhadap penerapan kebijakan tersebut karena dipandang sebagai beban tambahan pada operasi bisnis mereka. Penelitian terdahulu menunjukkan bahwa kewajiban pembayaran royalti oleh pelaku usaha kafe belum dijalankan

secara optimal, terutama akibat rendahnya tingkat pemahaman dan kesadaran terhadap pentingnya perlindungan hak cipta [3].

Pelaksanaan kebijakan royalti musik di lapangan masih dihadapkan pada sejumlah kendala. Tingkat pemahaman dan kesadaran pelaku usaha terhadap kewajiban pembayaran royalti relatif rendah, meskipun upaya sosialisasi telah dilakukan oleh Lembaga Manajemen Kolektif Nasional (LMKN) [2]. Ketiadaan Sistem Informasi Lagu dan Musik (SILM) juga menyebabkan penerapan kebijakan difokuskan pada pengguna berskala besar dan menengah, sementara pelaku usaha kecil belum dapat dijangkau secara optimal akibat keterbatasan sumber daya operasional [4]. Pelaku usaha kafe juga memiliki pandangan bahwa mereka sudah memiliki hak menggunakan lagu setelah membeli kuota dan aplikasi musik premium, padahal hal tersebut tidak termasuk pembayaran royalti untuk penggunaan komersial [3]. Dinamika pro dan kontra terhadap kebijakan ini tercermin dalam diskusi publik di media sosial yang perlu dianalisis secara sistematis.

Analisis sentimen dilakukan untuk menemukan kecenderungan emosi atau pendapat yang termuat dalam suatu teks, kemudian mengelompokkannya ke dalam kategori sentimen positif, netral, dan negatif. Data teks yang berasal dari media sosial dapat dimanfaatkan untuk membaca kecenderungan opini masyarakat melalui pendekatan analisis sentimen yang merupakan bagian dari bidang *Natural Language Processing* [1]. Penelitian Awali et al. menunjukkan bahwa analisis sentimen terhadap data media sosial *Twitter* mampu memberikan gambaran yang jelas mengenai persepsi dan respons publik terhadap isu nasional strategis, serta menjadi alat yang efektif untuk memetakan dominasi sentimen dalam perbincangan daring [5]. Penelitian pada platform Shopee Mall menghasilkan tingkat akurasi sebesar 81.90% [6]. Sementara itu, penelitian terhadap layanan publik menggunakan data *Twitter* menghasilkan akurasi sebesar 65.39% dengan *F1-score* 39.69% [7]. Kedua penelitian tersebut menunjukkan bahwa performa klasifikasi masih dapat ditingkatkan, terutama dalam menangani distribusi data sentimen yang tidak seimbang serta kompleksitas bahasa informal di media sosial. Selain itu, kajian yang secara spesifik menelaah sentimen publik terhadap kebijakan royalti restoran dan kafe pada media sosial *Twitter* masih terbatas dan belum banyak mengangkat isu kebijakan ekonomi kreatif yang berdampak langsung pada pelaku usaha dan pencipta karya.

Metode *Multinomial Naive Bayes* dalam penelitian ini digunakan sebagai algoritma klasifikasi untuk mengelompokkan opini publik ke dalam kategori sentimen positif, netral, dan negatif. Metode tersebut dipilih karena mampu mengolah data teks berbasis frekuensi kemunculan kata, sehingga sesuai dengan karakteristik unggahan yang bersifat singkat dan memiliki variasi kosakata yang tinggi [8]. Melalui pendekatan tersebut, penelitian ini dilakukan untuk menganalisis sentimen publik terhadap kebijakan royalti musik pada restoran dan kafe melalui percakapan pengguna *Twitter*. Oleh karena itu, penelitian ini berjudul “Analisis Sentimen Pengguna *Twitter* terhadap Kebijakan Royalti Restoran dan Kafe dengan *Multinomial Naive Bayes*.”

## 2. METODE PENELITIAN

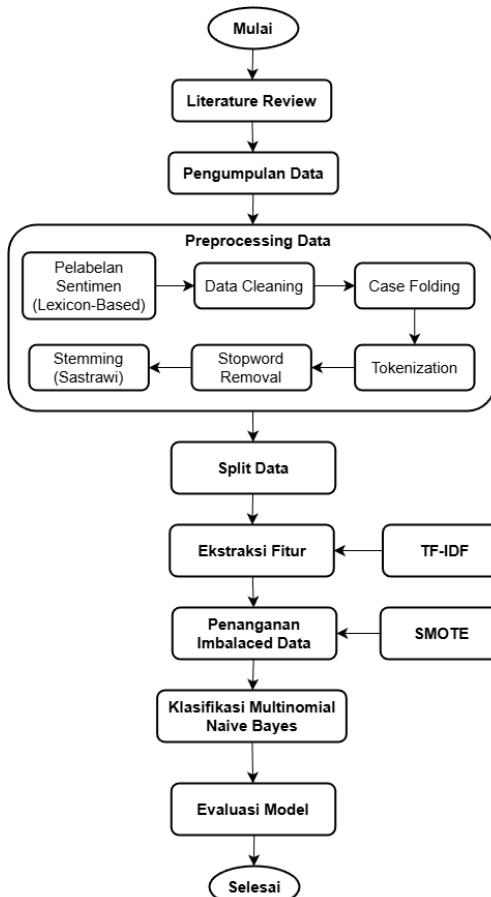
Penelitian ini menggunakan algoritma *Multinomial Naive Bayes* sebagai metode untuk menganalisis sentimen masyarakat terhadap kebijakan royalti di restoran dan kafe yang dibahas pada media sosial *Twitter*. Pendekatan ini dipilih karena *Multinomial Naive Bayes* sesuai untuk klasifikasi data teks berbasis frekuensi kata serta mampu mengelompokkan dokumen ke dalam kategori sentimen secara efisien. Tahapan penelitian meliputi proses kajian literatur, pengumpulan data, pelabelan sentimen, prapemrosesan data teks, pembagian data, ekstraksi fitur, penanganan ketidakseimbangan kelas, proses klasifikasi menggunakan *Multinomial Naive Bayes*, serta evaluasi kinerja model. Rangkaian tahapan penelitian tersebut disajikan secara pada Gambar 1.

Penelitian ini diawali dengan *literature review* dan pengumpulan data unggahan terkait kebijakan royalti restoran dan kafe. Data kemudian diberi label sentimen dan diproses melalui tahap prapemrosesan teks, meliputi pembersihan teks, konversi huruf kecil, tokenisasi, penghapusan *stopword*, serta *stemming* menggunakan pustaka Sastrawi. Data hasil prapemrosesan selanjutnya dibagi menjadi data pelatihan dan pengujian, kemudian direpresentasikan dalam bentuk numerik menggunakan metode TF-IDF. Ketidakseimbangan kelas pada data pelatihan ditangani dengan metode SMOTE sebelum proses klasifikasi menggunakan algoritma *Multinomial Naive Bayes*. Kinerja model selanjutnya dievaluasi menggunakan *confusion matrix* dan *classification report*.

### 2.1 Pengumpulan Data

Sebagai dasar utama dalam analisis sentimen, tahap awal penelitian ini adalah pengumpulan data. Tahap ini menjadi penting karena kualitas data yang digunakan akan menentukan ketepatan hasil analisis [9]. Data diperoleh dari media sosial *Twitter*, yang dipilih karena menyediakan percakapan publik secara terbuka, berlangsung cepat, dan sering digunakan masyarakat untuk menyampaikan pandangan terkait isu kebijakan publik. Pengambilan data dilakukan menggunakan teknik *web scraping* agar unggahan dapat dikumpulkan dalam jumlah besar secara efisien, mengingat keterbatasan akses data historis melalui API *Twitter*. Proses ini dilakukan dengan bantuan *Tweet Harvest* berbasis *Node.js* yang memanfaatkan *Chromium browser* dan *authentication token* [10]. Pencarian data menggunakan 20 variasi kata kunci bahasa Indonesia (*lang:id*) yang berkaitan dengan royalti musik, hak cipta, lisensi, lembaga pengelola royalti, serta konteks restoran dan kafe. Setiap kata kunci dibatasi hingga 200 unggahan dengan pengaturan

jeda waktu tertentu untuk menghindari pembatasan akses. Seluruh unggahan yang berhasil dikumpulkan disimpan dalam format CSV, kemudian digabungkan dan diseleksi ulang melalui proses deduplikasi berdasarkan identitas, tautan, dan isi teks unggahan.



**Gambar 1.** Tahap Penelitian

## 2.2 Pelabelan Data (*Lexicon-Based*)

Data latih dalam proses klasifikasi dibentuk berdasarkan hasil pelabelan sentimen pada setiap data teks. Pendekatan *lexicon-based* digunakan untuk mengelompokkan sentimen berdasarkan makna kata tanpa ketergantungan pada data berlabel manual dalam jumlah besar. Pendekatan ini sesuai untuk analisis kebijakan publik yang memiliki kosakata tematik dan berulang pada percakapan media sosial [11]. Pendekatan *lexicon-based* diterapkan dengan menggunakan kamus kata kunci yang disesuaikan dengan konteks kebijakan royalti musik di Indonesia sebagai dasar pelabelan sentimen. Kata kunci sentimen positif mencakup istilah yang merepresentasikan dukungan terhadap kebijakan, seperti "setuju", "mendukung", "wajar", "adil", "menghargai karya", dan "hak musisi". Kata kunci sentimen negatif mencakup istilah yang menunjukkan kritik atau penolakan, antara lain "ribet", "meresahkan", "pungli", "pemalakan", dan "merugikan". Selain itu, indikator netral digunakan untuk mengidentifikasi unggahan yang bersifat informatif tanpa kecenderungan opini, seperti tautan berita, kata tanya, dan pengumuman. Penentuan label sentimen dilakukan berdasarkan dominasi kemunculan kata kunci dalam setiap unggahan. Uggahan diklasifikasikan sebagai sentimen positif atau negatif apabila skor kata kunci terkait lebih dominan, sedangkan unggahan yang tidak menunjukkan perbedaan skor yang signifikan atau didominasi indikator informatif dikategorikan sebagai sentimen netral.

## 2.3 Preprocessing Data

Agar data teks dapat dianalisis secara optimal pada tahap klasifikasi sentimen, dilakukan proses prapemrosesan untuk menyeragamkan dan menyederhanakan struktur teks. Pada tahap awal prapemrosesan, elemen bukan teks dihapus untuk mengurangi *noise*, sedangkan teks dinormalisasi melalui pengubahan seluruh huruf menjadi huruf kecil. Spasi yang berlebih akibat proses pembersihan juga disesuaikan agar teks lebih terstruktur. Teks yang telah dibersihkan kemudian dipecah menjadi satuan kata melalui proses tokenisasi. Setelah proses tokenisasi, kata-kata yang bersifat umum dan tidak memiliki peran penting dalam pembentukan sentimen dieliminasi. Tahap ini dilakukan

melalui proses *stopword removal* dengan memanfaatkan daftar *stopword* dari pustaka Sastrawi yang dilengkapi dengan kosakata khas percakapan media sosial, seperti "yg", "dan", "gak", "ya", "ke", serta istilah sejenis. Setelah itu, setiap kata dikembalikan ke bentuk dasarnya melalui proses *stemming* menggunakan algoritma Sastrawi, sehingga variasi kata dengan makna sama diperlakukan sebagai satu bentuk, misalnya "pembayaran" menjadi "bayar". Pada tahap akhir, token yang memiliki panjang kurang dari tiga karakter dihapus karena dinilai tidak memiliki makna yang relevan dalam analisis sentimen.

## 2.4 Split Data

Data hasil prapemrosesan dibagi menjadi dua kelompok, yaitu data pelatihan dan data pengujian dengan proporsi masing-masing sebesar 80% dan 20%. Proses pembagian tersebut dilakukan menggunakan metode *stratified split* agar distribusi kelas sentimen tetap terjaga secara seimbang pada kedua kelompok data. Penetapan nilai *random state* sebesar 42 digunakan agar proses pembagian data bersifat konsisten dan dapat direplikasi pada proses pengujian selanjutnya.

## 2.5 Ekstraksi Fitur (TF-IDF)

Sebelum melalui proses klasifikasi, data teks terlebih dahulu diubah ke dalam bentuk numerik melalui proses pembobotan kata. Pendekatan ini menilai setiap kata berdasarkan tingkat kemunculannya dalam dokumen tertentu serta tingkat keumumannya di seluruh korpus data [12]. Kata-kata yang bersifat lebih spesifik dan informatif terhadap suatu konteks akan memperoleh bobot yang lebih tinggi dibandingkan kata-kata yang sering muncul secara umum. Representasi numerik yang dihasilkan melalui TF-IDF selanjutnya digunakan sebagai masukan dalam proses klasifikasi sentimen, dengan perhitungan bobot mengacu pada Persamaan (1) [12].

$$W(i,j) = tf(i,j) \times \log \left( \frac{N}{df(j)} \right) \quad (1)$$

Keterangan:

W(i,j) = Bobot TF-IDF untuk term ke-j pada dokumen ke-i

tf(i,j) = Frekuensi kemunculan term ke-j dalam dokumen ke-i

N = Jumlah total dokumen

df(j) = Jumlah dokumen yang mengandung term ke-j

## 2.6 Penanganan Imbalanced Data

Kinerja model klasifikasi dapat dipengaruhi oleh perbedaan jumlah data pada setiap kelas sentimen, terutama ketika mencari kelas dengan jumlah data yang lebih sedikit. Untuk mengurangi dampak tersebut, penelitian ini menggunakan metode *Synthetic Minority Over-sampling Technique* (SMOTE) pada data pelatihan. Metode SMOTE menghasilkan sampel baru pada kelas minoritas dengan melakukan interpolasi antar data yang memiliki kedekatan karakteristik melalui pendekatan *k-nearest neighbors*. Penerapan teknik ini bertujuan menciptakan distribusi data yang lebih proporsional sehingga proses pembelajaran model tidak didominasi oleh kelas mayoritas. Agar tidak menimbulkan kebocoran data, SMOTE hanya diterapkan pada data pelatihan dan tidak digunakan pada data pengujian [13].

## 2.7 Hyperparameter Tuning

Optimasi *hyperparameter* dilakukan untuk memperoleh konfigurasi parameter terbaik pada model klasifikasi sebelum proses pembelajaran dilakukan. Proses ini bertujuan meningkatkan kinerja model dan mengurangi kesalahan klasifikasi[14]. Optimasi dilakukan menggunakan *GridSearchCV* dengan pendekatan *stratified 5-fold cross validation* untuk menjaga proporsi kelas pada setiap *fold*. Parameter yang diuji pada proses *hyperparameter tuning* mencakup komponen pendukung dan model klasifikasi utama, dengan fokus optimasi diarahkan pada kinerja *Multinomial Naive Bayes*, sebagaimana ditunjukkan pada Tabel 1.

**Tabel 1.** Parameter Hyperparameter Tuning

Komponen	Parameter	Nilai yang Diuji
TF-IDF	ngram_range	(1,2), (1,3)
	max_features	5000, 8000
	min_df	1, 2
	max_df	0.85, 0.90
	sublinear_tf	True
SMOTE	k_neighbors	3, 5, 7
	sampling_strategy	auto, not majority
<i>Multinomial Naive Bayes</i>	alpha	0.01, 0.1, 0.5, 1.0

Dari seluruh kombinasi parameter yang diuji, konfigurasi terbaik ditentukan berdasarkan kinerja *Multinomial Naive Bayes* sebagai model klasifikasi utama, sedangkan parameter TF-IDF dan SMOTE berperan sebagai pendukung dalam pipeline pemodelan.

## 2.8 Klasifikasi Multinomial Naive Bayes

Penentuan kecenderungan sentimen unggahan ke dalam kelas positif, netral, dan negatif dilakukan menggunakan algoritma *Multinomial Naive Bayes* sebagai model klasifikasi. Proses klasifikasi dilakukan dengan menghitung peluang kemunculan suatu kelas sentimen berdasarkan fitur teks yang dimiliki oleh unggahan tersebut. Kelas sentimen dengan nilai peluang terbesar kemudian dipilih sebagai hasil klasifikasi akhir. Perhitungan peluang kelas dilakukan berdasarkan prinsip *Teorema Bayes*, yang memodelkan hubungan antara fitur teks dan kelas sentimen. Hubungan tersebut dinyatakan pada Persamaan (2) [15].

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

Keterangan:

$P(C|X)$  = probabilitas posterior kelas C terhadap fitur X

$P(X|C)$  = probabilitas *likelihood* fitur X pada kelas C

$P(C)$  = probabilitas prior kelas C

$P(X)$  = probabilitas *evidence* fitur X

Untuk mengatasi permasalahan kemunculan nilai probabilitas nol akibat kata tertentu tidak muncul pada data pelatihan, diterapkan teknik *Laplace smoothing* dengan penambahan parameter penghalus.

## 2.9 Evaluasi Model

Proses validasi *5-fold cross* digunakan untuk mengevaluasi kemampuan model untuk membuat generalisasi pada berbagai jenis data [7]. Pada tahap validasi ini, kinerja model dievaluasi menggunakan metrik akurasi. Ini dilakukan untuk memastikan bahwa proporsi dari setiap kelas sentimen tetap seimbang. Selanjutnya, *confusion matrix* digunakan untuk menganalisis kinerja klasifikasi pada data uji. Analisis ini dilengkapi dengan *F1-score*, akurasi, *precision*, dan *recall*, yang merupakan metrik yang umum digunakan dalam analisis sentimen. *Confusion matrix* digunakan untuk menunjukkan perbandingan antara label nyata dan hasil prediksi untuk setiap kelas sentimen. Tabel 2 menunjukkan struktur *confusion matrix* yang digunakan dalam penelitian ini.

**Tabel 2. Struktur Confusion matrix**

Nilai Prediksi	Positif	Netral	Negatif
Aktual Positif	TP	FN <sub>t</sub>	FN
Aktual Netral	FP	TN <sub>t</sub>	FN <sub>t</sub>
Aktual Negatif	FP	FN <sub>t</sub>	TN

Berdasarkan *confusion matrix*, metrik evaluasi yang dihitung meliputi [16]:

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

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

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

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

Selain evaluasi pada data uji, validasi model dilakukan melalui penerapan *5-fold cross validation* guna menilai stabilitas serta kemampuan generalisasi model. Evaluasi pada tahap ini menggunakan metrik akurasi dan *weighted F1-score*.

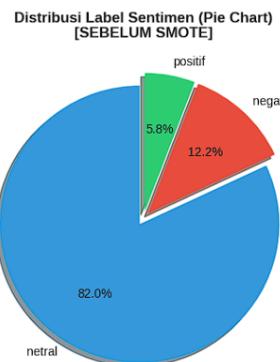
## 3. HASIL DAN PEMBAHASAN

### 3.1 Pengumpulan Data

Unggahan yang membahas tentang kebijakan royalti musik di restoran dan kafe menjadi dasar dalam proses pengumpulan data pada penelitian ini. Pengumpulan data dilakukan dengan teknik *web scraping* menggunakan *Tweet Harvest* versi 2.6.1. Proses *crawling* dilakukan menggunakan 20 variasi *query* pencarian berbahasa Indonesia yang terkait dengan topik royalti musik, hak cipta, lisensi, organisasi royalti (WAMI, KCI, ASIRI), serta istilah terkait restoran dan kafe. Setelah dilakukan proses *crawling* dari platform *Twitter* dengan berbagai *query* pencarian, berhasil dikumpulkan sebanyak 1,513 unggahan unik setelah proses deduplikasi. Data yang diperoleh mencakup teks unggahan (*full\_text*), bahasa, waktu pembuatan, dan metadata lainnya.

### 3.2 Pelabelan Data

Metode *lexicon-based* digunakan dalam penelitian ini untuk menandai setiap unggahan. metode ini menggunakan kamus kata kunci yang dikategorikan ke dalam tiga kategori sentimen yaitu positif, negatif, dan netral. Kata-kata dalam kategori negatif menunjukkan kritik atau penolakan terhadap kebijakan royalti, dan kata-kata dalam kategori netral menunjukkan pernyataan atau konten informatif yang tidak terpengaruh oleh pendapat. Gambar 2 menunjukkan distribusi label sentimen sebelum penanganan ketidakseimbangan data. Hasil pelabelan menunjukkan bahwa sentimen netral mendominasi dengan 1.240 unggahan (81.96%), diikuti oleh sentimen negatif sebanyak 185 unggahan (12.23%) dan sentimen positif sebanyak 88 unggahan (5.82%).



**Gambar 2.** Distribusi Label Sentimen Sebelum SMOTE

Dominasi sentimen netral menunjukkan bahwa sebagian besar percakapan *Twitter* terkait kebijakan royalti restoran dan kafe bersifat informatif tanpa sikap yang tegas. Sentimen negatif merepresentasikan kekhawatiran dan kritik dari pelaku usaha, sedangkan sentimen positif mencerminkan dukungan terhadap perlindungan hak cipta musisi. Ketidakseimbangan distribusi sentimen ini berpotensi memengaruhi proses klasifikasi, khususnya pada kelas minoritas. Contoh unggahan untuk setiap kelas sentimen disajikan pada Tabel 3.

**Tabel 3.** Contoh Uggahan per Kelas Sentimen

Sentimen	Contoh Uggahan
Positif	Maasyallah ada hikmahnya ya dibalik ribut2 bayar royalti. Cafe skrg tentrem bgt cuma stel instrumen musik...
Negatif	Akibat dari persoalan royalti ini masyarakat menjadi takut untuk sekedar menikmati musik terutama pihak resto atau cafe...
Netral	@lastpushh @panditfootball Hmm terakhir yg mirip2 itu pro kontra royalti musik di cafe ya...

### 3.3 Preprocessing Data

Dalam tahap ini, data dipersiapkan melalui beberapa proses prapemrosesan, antara lain pembersihan data, *case folding*, tokenisasi, penghapusan *stopword*, serta *stemming* menggunakan pustaka Sastrawi. Proses-proses ini bertujuan untuk menyempurnakan struktur teks sebelum memasuki tahap klasifikasi. Hasil *preprocessing* dapat dilihat pada Tabel 4.

**Tabel 4.** Hasil Preprocessing Data

Proses	Hasil
Teks Asli	@lastpushh @panditfootball Hmm terakhir yg mirip2 itu pro kontra royalti musik di cafe ya...
Clean Text	mmm akhir mirip pro kontra royalti musik cafe...

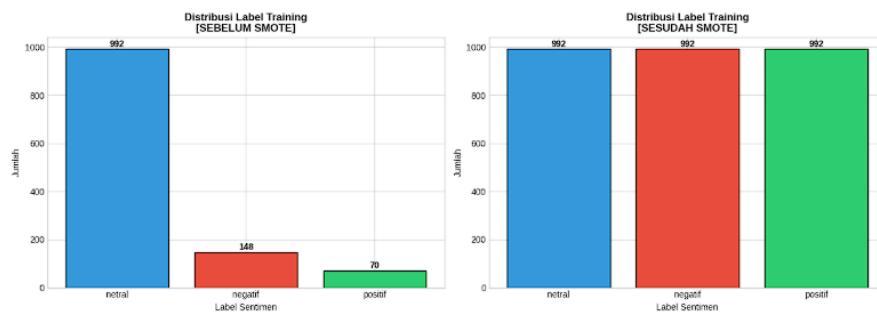
Setelah seluruh tahapan prapemrosesan yang meliputi pembersihan teks, penghapusan *stopword*, dan proses *stemming* diselesaikan, diperoleh sebanyak 1.513 unggahan yang dinyatakan layak untuk dianalisis lebih lanjut.

### 3.4 Ekstraksi Fitur

Melalui teknik *Term Frequency–Inverse Document Frequency* (TF-IDF), setiap kata dalam teks diberikan bobot yang mencerminkan tingkat kepentingannya. Pembobotan tersebut didasarkan pada frekuensi kemunculan kata dalam dokumen tertentu serta tingkat penyebarannya di seluruh kumpulan data. Representasi numerik yang dihasilkan dari proses ini digunakan sebagai masukan dalam tahap klasifikasi sentimen. Hasil optimasi parameter menunjukkan bahwa konfigurasi TF-IDF yang diterapkan mencakup *ngram\_range* (1,2), *max\_features* 8000, *min\_df* 1, *max\_df* 0.85, dan *sublinear\_tf* bernilai benar.

### 3.5 Penanganan *Imbalanced Data*

Ketidakseimbangan jumlah data antar kelas sentimen menjadi salah satu kendala dalam proses klasifikasi pada penelitian ini. Untuk mengatasi permasalahan tersebut, diterapkan metode SMOTE pada data pelatihan. Metode ini bertujuan menyeimbangkan distribusi kelas dengan menambahkan sampel sintetis pada kelas yang jumlahnya lebih sedikit. Perbandingan distribusi data sebelum dan sesudah penerapan SMOTE disajikan pada Gambar 3.



**Gambar 3.** Perbandingan Distribusi Label Sebelum dan Sesudah SMOTE

Sebelum penerapan SMOTE, distribusi data latih terdiri dari 992 unggahan netral, 148 unggahan negatif, dan 70 unggahan positif. Setelah SMOTE diterapkan dengan parameter  $k\_neighbors = 5$  dan  $sampling\_strategy = auto$ , jumlah data pada masing-masing kelas menjadi seimbang, yaitu 992 sampel per kelas. Penerapan SMOTE bertujuan mendukung kinerja *Multinomial Naive Bayes* agar mampu mengenali kelas minoritas secara lebih seimbang, sehingga proses pembelajaran model tidak didominasi oleh kelas mayoritas.

### 3.6 Klasifikasi dengan *Multinomial Naive Bayes*

Penelitian ini menerapkan algoritma *Multinomial Naive Bayes* untuk mengklasifikasikan sentimen unggahan. Data yang telah dipraproses dibagi menjadi data latih dan data uji menggunakan metode *stratified split*. Optimasi parameter dilakukan menggunakan *GridSearchCV* dengan skema *stratified 5-fold cross validation* guna memperoleh konfigurasi model dengan kinerja klasifikasi yang konsisten. Hasil optimasi parameter terbaik disajikan pada Tabel 5.

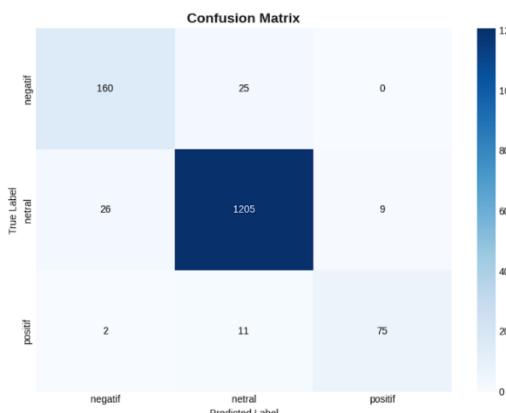
**Tabel 5.** Parameter Terbaik Model *Multinomial Naive Bayes*

Parameter	Nilai
nb_alpha	0.01
Best CV F1-score	0.7703

Berdasarkan hasil optimasi tersebut, *Multinomial Naive Bayes* dengan nilai alpha sebesar 0.01 digunakan sebagai model akhir dalam proses klasifikasi sentimen. Model ini memberikan nilai *F1-score* tertinggi pada proses validasi silang dan menunjukkan performa klasifikasi yang stabil pada data uji.

### 3.7 Evaluasi Model

Model *Multinomial Naive Bayes* dievaluasi untuk mengukur kemampuannya dalam mengklasifikasikan sentimen ke dalam tiga kelas, yaitu negatif, netral, dan positif. Hasil evaluasi berdasarkan *confusion matrix* ditampilkan pada Gambar 4.



**Gambar 4.** Confussion Matrix

Berdasarkan Gambar 4, model mampu mengklasifikasikan sebagian besar data dengan benar pada seluruh kelas sentimen. Pada kelas negatif, sebanyak 160 data diklasifikasikan secara tepat, sementara 25 data masih salah diklasifikasikan sebagai netral. Pada kelas netral, sebanyak 1.205 data berhasil diklasifikasikan dengan benar. Adapun pada kelas positif, model mengklasifikasikan 75 data secara tepat dengan sebagian kecil kesalahan ke kelas netral.

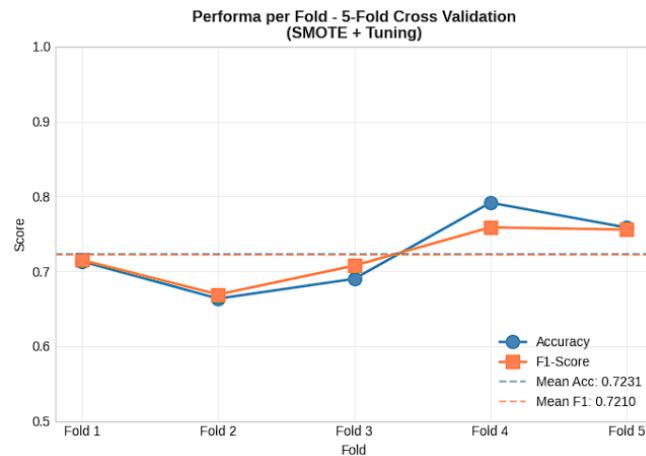
Classification Report :					
	precision	recall	f1-score	support	
negatif	0.85	0.86	0.86	185	
netral	0.97	0.97	0.97	1240	
positif	0.89	0.85	0.87	88	
accuracy			0.95	1513	
macro avg	0.90	0.90	0.90	1513	
weighted avg	0.95	0.95	0.95	1513	

**Gambar 5. Classification Report**

Gambar 5 menampilkan nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas sentimen, serta nilai *macro average* dan *weighted average*. *Macro average* memberikan bobot yang sama pada setiap kelas, sedangkan *weighted average* mempertimbangkan proporsi jumlah data pada tiap kelas [17]. Pada penelitian ini, distribusi data tidak seimbang dengan dominasi kelas netral, sehingga *weighted average* lebih representatif dalam menggambarkan kinerja model, dengan nilai *precision* 95%, *recall* 95%, dan *F1-score* 95% dan akurasi sebesar 95%.

### 3.8 Cross Validation

Untuk menilai kestabilan serta kemampuan generalisasi model, pengujian tambahan dilakukan melalui metode *5-fold cross validation*. Hasil dari proses validasi silang tersebut disajikan pada Gambar 5.



**Gambar 6. Hasil 5-Fold Cross validation**

Hasil *cross validation* menunjukkan rata-rata akurasi sebesar  $72.31\% \pm 4.62\%$  dan rata-rata *F1-score* sebesar  $72.10\% \pm 3.33\%$ . Standar deviasi yang relatif kecil menunjukkan bahwa model memiliki stabilitas yang baik dalam mengklasifikasikan sentimen pada berbagai subset data. Perbedaan antara hasil evaluasi pada keseluruhan data 95% dan *cross validation* 72% menunjukkan adanya sedikit *overfitting*, namun model tetap memiliki kemampuan generalisasi yang cukup baik.

### 3.9 Pembahasan

Berdasarkan hasil analisis sentimen terhadap kebijakan royalti di restoran dan kafe pada media sosial *Twitter*, dapat diidentifikasi beberapa temuan penting. Pertama, sentimen netral mendominasi dengan persentase 81.96% dari total unggahan, yang menunjukkan bahwa sebagian besar diskusi di *Twitter* bersifat informatif tanpa menyertakan opini yang jelas. Hal ini sejalan dengan karakteristik *Twitter* sebagai platform berbagi berita dan informasi. Kedua, sentimen negatif (12.23%) lebih banyak dibandingkan sentimen positif (5.82%), yang mencerminkan adanya kekhawatiran dan kritik dari masyarakat terhadap implementasi kebijakan royalti. Kata yang sering muncul dalam sentimen negatif seperti "bayar", "takut", "masalah", dan "rugi" menunjukkan keresahan pelaku usaha kafe dan restoran terhadap kewajiban pembayaran royalti. Penelitian ini sejalan dengan penelitian Pertiwi et al. yang menemukan rendahnya pemahaman pelaku usaha kafe tentang kewajiban pembayaran royalti [3].

Ketiga, model *Multinomial Naive Bayes* menunjukkan kinerja klasifikasi yang baik dengan akurasi sebesar 95% pada data uji. Hasil ini menunjukkan bahwa *Multinomial Naive Bayes* mampu memodelkan distribusi kata pada masing-masing kelas sentimen secara efektif. Dibandingkan dengan penelitian Hamidah et al. yang mencapai akurasi 82% pada analisis sentimen ulasan kopi menggunakan *Naive Bayes*, penelitian ini menunjukkan performa yang lebih baik pada konteks data kebijakan publik di media sosial [18]. Keempat, penerapan teknik SMOTE terbukti efektif dalam menangani ketidakseimbangan data. Sebelum SMOTE, distribusi data latih sangat tidak seimbang (netral: 992, negatif: 148, positif: 70).

Setelah penerapan SMOTE, distribusi menjadi seimbang dengan masing-masing kelas memiliki 992 sampel. Hal ini berkontribusi pada peningkatan performa model, terutama untuk kelas minoritas (positif dan negatif). Kelima, hasil *cross validation* dengan rata-rata akurasi 72,31% menunjukkan bahwa model mampu melakukan generalisasi yang cukup baik meskipun terdapat perbedaan dengan hasil evaluasi pada keseluruhan data. Perbedaan ini menunjukkan adanya sedikit *overfitting*, yang umum terjadi pada data dengan distribusi tidak seimbang meskipun sudah diterapkan teknik *oversampling*.

## 4. KESIMPULAN

Hasil analisis sentimen terhadap kebijakan royalti musik pada restoran dan kafe berdasarkan data *Twitter* menunjukkan bahwa perbincangan publik didominasi oleh sentimen netral sebesar 81,96%, yang menandakan sebagian besar unggahan bersifat informatif tanpa sikap yang tegas. Sentimen negatif sebesar 12,23% mencerminkan adanya kritik dan kekhawatiran masyarakat, terutama terkait dampak kebijakan terhadap pelaku usaha, sedangkan sentimen positif sebesar 5,82% menunjukkan adanya dukungan terhadap perlindungan hak cipta musisi. Algoritma *Multinomial Naive Bayes* berhasil mengklasifikasikan sentimen dan menghasilkan nilai akurasi dan *F1-score* sebesar 95%. Hasil *cross validation* menunjukkan bahwa algoritma ini memiliki tingkat kestabilan yang cukup baik, meskipun masih ditemukan indikasi *overfitting*. Temuan tersebut menunjukkan bahwa algoritma *Multinomial Naive Bayes* efektif dalam memetakan sentimen publik terhadap kebijakan royalti restoran dan kafe berdasarkan data media sosial *Twitter*. Untuk penelitian selanjutnya, disarankan penggunaan sumber data dari media sosial lain agar gambaran sentimen masyarakat menjadi lebih luas. Selain itu, pengembangan metode pelabelan yang lebih kontekstual perlu dipertimbangkan agar hasil klasifikasi mampu merepresentasikan opini pengguna secara lebih akurat.

## DAFTAR PUSTAKA

- [1] A. Khusna and Y. Yamasari, “Analisis Sentimen Ulasan Google Maps Menggunakan Long Short-Term Memory (LSTM)(Studi Kasus: Kafe di Surabaya),” *J. Informatics Comput. Sci.*, pp. 446–454, 2025.
- [2] A. L. Gunawan, E. Kuspraningrum, and F. N. Hediati, “Implementasi Penarikan Royalti Pengguna Lagu/Musik Pada Usaha Mikro, Kecil, Kafe di Kota Samarinda,” *J. Suara Huk.*, vol. 5, no. 1, pp. 190–206, 2023.
- [3] W. Pertiwi, F. Firdaus, and N. Rasudin, “Tanggung Jawab Pembayaran Royalti Kepada Pemegang Hak Cipta Lagu Dan/Atau Musik Oleh Pelaku Usaha Kafe Di Kecamatan Sail Kota Pekanbaru,” *Innov. J. Soc. Sci. Res.*, vol. 4, no. 4, pp. 8126–8138, 2024.
- [4] L. Rhomaningtias, A. Khairunisa, S. S. M. Wara, and K. M. Hindrayani, “Analisis Sentimen Ulasan Aplikasi Smile Indonesia Menggunakan Metode Naive Bayes Dan Support Vector Machine (Svm): Sentiment Analysis Of Smile Indonesia Application Reviews Using Naive Bayes And Support Vector Machine (Svm) Methods,” *HOAQ (High Educ. Organ. Arch. Qual. J. Teknol. Inf.)*, vol. 16, no. 1, pp. 79–91, 2025.
- [5] M. R. Awali, S. Wahyu, and A. H. Azizah, “Analisis Sentimen Opini Publik Terhadap Kasus Korupsi Bahan Bakar Minyak Oplosan PT Pertamina dengan Hybrid Model Deep Learning,” *SKANIKA Sist. Komput. dan Tek. Inform.*, vol. 8, no. 2, pp. 244–256, 2025.
- [6] M. A. F. Rahman, Z. R. Mair, and D. Sartika, “Klasifikasi Ulasan Pelanggan Shopee Mall Terhadap E-Commerce Penjualan Baju Batik Metode Naïve Bayes,” *IDEALIS Indones. J. Inf. Syst.*, vol. 7, no. 2, pp. 164–177, 2024.
- [7] E. Salim and A. Solichin, “Analisis Sentimen Pada Media Sosial Twitter Terhadap Pelayanan Dinas Kependudukan Dan Pencatatan Sipil Menggunakan Algoritma Naïve Bayes,” *IDEALIS Indones. J. Inf. Syst.*, vol. 5, no. 2, pp. 79–86, 2022.
- [8] F. A. Ramadhan, S. H. Sitorus, and T. Rismawan, “Penerapan Metode Multinomial Naïve Bayes untuk Klasifikasi Judul Berita Clickbait dengan Term Frequency-Inverse Document Frequency,” *J. Sist. dan Teknol. Inf.*, vol. 11, no. 1, p. 70, 2023.
- [9] D. Nurwahidah, G. Dwilestari, N. D. Nuris, and R. Narasati, “Analisis Sentimen Data Ulasan Pengguna Aplikasi Google Kelas Pada Google Play Store Menggunakan Algoritma Naïve Bayes,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 6, pp. 3673–3678, 2023.
- [10] M. H. B. Ibrahim, A. Dzulkarnain, and A. Rausanfita, “Penggunaan Metode Naïve Bayes untuk Klasifikasi Topik Tweet Bidang dan Non-Bidang Rektorat Telkom University pada Akun Telyufess,” *Bull. Comput. Sci. Res.*, vol. 5, no. 5, pp. 876–885, 2025.

- [11] Z. Fatah, "Analisis Sentimen Komentar YouTube terhadap Tragedi Demo 25 Agustus Menggunakan Pendekatan Lexicon-Based," *J. Mhs. Tek. Inform.*, vol. 4, no. 2, pp. 217–224, 2025.
- [12] R. Wati, S. Ernawati, and H. Rachmi, "Pembobotan TF-IDF Menggunakan Naïve Bayes pada Sentimen Masyarakat Mengenai Isu Kenaikan BIPIH," *J. Manaj. Inform.*, vol. 13, no. 1, pp. 84–93, 2023.
- [13] C. Candra, K. W. Chandra, and H. Irsyad, "Efektifitas SMOTE dalam Mengatasi Imbalanced Class Algoritma K-Nearest Neighbors pada Analisis Sentimen terhadap Starlink," *J. Ilmu Komput. dan Inform.*, vol. 4, no. 1, pp. 31–42, 2024.
- [14] S. Y. Nailendra, W. Witanti, and G. Abdillah, "Optimasi Prediksi Penjualan Retail Online Menggunakan LightGBM dan Hyperparameter Tuning," *J. Algoritm.*, vol. 22, no. 2, pp. 1931–1942, 2025.
- [15] F. K. S. Dewi, "Klasifikasi Berita Menggunakan Metode Multinomial Naïve Bayes," *Scan J. Teknol. Inf. dan Komun.*, vol. 16, no. 3, pp. 1–8, 2021.
- [16] T. Hardiani and R. N. Putri, "Implementasi Metode Naïve Bayes Classifier Untuk Klasifikasi Stunting Pada Balita," *Digit. Transform. Technol.*, vol. 4, no. 1, pp. 621–627, 2024, doi: 10.47709/digitech.v4i1.4481.
- [17] D. Siregar, F. Ladaya, N. Z. Albaqi, and B. M. Wardana, "Penerapan Metode Support Vector Machines (SVM) dan Metode Naïve Bayes Classifier (NBC) dalam Analisis Sentimen Publik terhadap Konsep Child-free di Media Sosial Twitter," *J. Stat. dan Apl.*, vol. 7, no. 1, pp. 93–104, 2023.
- [18] D. A. Hamidah, R. Salkiawati, and R. Sari, "Analisis Sentimen Ulasan Customer Kopi TMLST Menggunakan Algoritma Naïve Bayes," *J. Students 'Research Comput. Sci.*, vol. 5, no. 1, pp. 27–40, 2024.