

KOMBINASI LEXICON-BASED DAN MULTINOMIAL NAÏVE BAYES CLASSIFIER DALAM ANALISIS SENTIMEN ARTIS SONG JOONG KI SEBAGAI BRAND AMBASSADOR SCARLETT WHITENING

Suci Kurniawati^{1*}, Suparti², Sugito³, Hasbi Yasin⁴

^{1,2,3} Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

*Email: sucikurniawati16@gmail.com

DOI: 10.14710/j.gauss.15.1.143-153

Article Info:

Received: 2024-08-09

Accepted: 2025-12-30

Available Online: 2025-05-29

Keywords:

K-Drama; Twitter; Sentiment Analysis; Lexicon-Based; SentiWordNet; Multinomial Naïve Bayes Classifier

Abstract: Twitter as a social media platform can be utilized as a means of exchanging information about current events. The topic of K-Drama is often discussed by the public on Twitter and reaches trending topics, especially during the pandemic in Indonesia. The popularity of K-Drama in Indonesia has led to marketing strategies where actors are chosen as brand ambassadors. Song Joong Ki is one of the actors who has been chosen by Scarlett Whitening products to become their brand ambassador. The public expresses their responses on Twitter, and sentiment analysis is necessary to classify these responses as positive, neutral, or negative. The sentiment analysis combines the *Lexicon-Based* method and *Multinomial Naïve Bayes Classifier*. SentiWordNet is used in the *Lexicon-Based* classification method. The data preprocessing stage of this research includes cleansing, case folding, word normalization, tokenizing, filtering, and stemming. The combination of the *Lexicon-Based* method and *Multinomial Naïve Bayes Classifier* yielded an accuracy score of 81.50%. The words “jadi”, “brand”, and “ambassador” dominate the *word cloud*, indicating that the public extensively discusses the appointment of Song Joong Ki as the brand ambassador for Scarlett Whitening.

1. PENDAHULUAN

Internet dan *smartphone* hadir di Indonesia sebagai hasil dari kemajuan digitalisasi dalam era globalisasi. Penggunaan *smartphone* saat ini erat kaitannya dengan media sosial sebagai sarana berinteraksi dan menyebarkan informasi, seperti yang terjadi di platform Twitter. Pengguna Twitter di Indonesia cukup aktif dan telah mencapai angka 14,05 juta pengguna pada Januari 2021 (We Are Social & HootSuite, 2021). Twitter sebagai platform *microblogging* memungkinkan untuk mengirim dan membaca pesan berdasarkan topik yang sedang dibahas. Salah satu topik yang sering dibicarakan di Twitter adalah *K-Drama*, yaitu drama televisi berbahasa Korea berformat miniseri (Prasanti & Dewi, 2020). *K-Drama* juga menjadi sumber hiburan ketika pandemi COVID-19 melanda Indonesia mendorong peningkatan minat terhadap *K-Drama*. Keberhasilan *K-Drama* dalam menarik minat masyarakat Indonesia juga berdampak pada pemasaran produk, dengan penggunaan *brand ambassador* aktor seperti Song Joong Ki untuk promosi produk Scarlett Whitening. Promosi oleh selebriti Korea memiliki potensi meningkatkan kesadaran merek terhadap produk (Indriningtyas, 2022).

Tanggapan-tanggapan publik di Twitter akan dimanfaatkan sebagai penelitian untuk mengidentifikasi sentimen terhadap Scarlett Whitening yang membawa Song Joong Ki menjadi *brand ambassador* produk. Tanggapan diklasifikasi dengan analisis sentimen menjadi positif, netral, dan negatif. Terdapat penelitian sebelumnya yang membahas analisis sentimen menggunakan tanggapan publik di Twitter. Slamet *et al.* (2022) meneliti tanggapan publik di Twitter tentang produk perawatan lokal dengan *brand ambassador* merupakan artis Korea. Penelitian tersebut mengaplikasikan algoritma *Naïve Bayes* dan *Support Vector*

Machine (SVM) untuk analisis sentimen. Hasil penelitian memperoleh model SVM sebagai model terbaik dengan nilai akurasi 83,86%.

Penelitian akan berfokus pada penggunaan metode *Lexicon-Based* dan *Multinomial Naïve Bayes Classifier*. *Lexicon-Based* adalah metode klasifikasi berupa penilaian polaritas untuk setiap kata dan tidak memerlukan data berlabel. Metode *Lexicon-Based* yang akan digunakan yaitu SentiWordNet. *Multinomial Naïve Bayes Classifier* adalah pengembangan dari metode *Naïve Bayes Classifier* dan termasuk *machine learning*. Kombinasi *Lexicon-Based* dan *Multinomial Naïve Bayes Classifier* pernah dilakukan dalam penelitian Anggina *et al.* (2022) untuk ulasan pelanggan terhadap Formaggio Coffee and Resto. Penelitian tersebut menggunakan *InSet* sebagai *Lexicon-Based* yang dikombinasi dengan *Multinomial Naïve Bayes Classifier* dan memperoleh rata-rata akurasi sebesar 0,95.

2. TINJAUAN PUSTAKA

Twitter merupakan platform mikroblog yang penggunaannya dimungkinkan mampu membaca dan mengirim pesan *real-time* atau *tweet*. *Tweet* terbatas oleh 280 karakter dan dapat berisi pemikiran pribadi, pendapat, atau komentar tentang fenomena atau objek tertentu. Twitter juga efektif dalam penyebaran informasi kepada pengguna di seluruh dunia.

Song Joong Ki adalah aktor Korea Selatan yang mulai dikenal publik pada acara *Music Bank* dan *Running Man*. Aktor yang berasal dari agensi HighZium Studio ini pernah mendapatkan “Daesang” atau penghargaan utama dari *KBS Drama Award 2016* setelah menjadi aktor dalam drama *Descendant of The Sun*.

Scarlett Whitening merupakan *brand* lokal asal Indonesia dengan produk yang ditujukan untuk perawatan wajah, rambut, dan tubuh. Produk ini didirikan tahun 2017 dengan pendirinya yaitu Felicya Angelista. Pengelolaan produk Scarlett Whitening dipegang oleh PT. Opto Lumbung Sejahtera.

Brand ambassador menurut Lea-Greenwood (2013) adalah bentuk strategi perusahaan dalam mengomunikasikan dan menjalin hubungan antara produk dengan publik. *Brand ambassador* sering memilih selebriti karena kepribadiannya yang berpengaruh dan mampu menarik minat konsumen agar membeli produk. Pelibatan selebriti juga berfungsi sebagai alat yang mewakili segmen pasar yang menjadi sasaran.

Analisis sentimen adalah sebuah metode untuk mengidentifikasi polaritas teks dari suatu dokumen dan bertujuan untuk menentukan sentimen tersebut bersifat positif, netral, atau negatif. Metode ini merupakan bagian dari *text mining* yang telah diterapkan secara luas untuk berbagai bidang, seperti produk dan pelayanan, bisnis, politik, dan pemerintahan. Analisis sentimen juga dijadikan sebagai referensi penting dalam pengembangan produk dan layanan yang berkualitas dalam dunia bisnis (Liu, 2015).

Proses awal untuk melakukan analisis sentimen adalah *preprocessing* data. Data berupa teks yang tidak terstruktur diolah dalam tahap ini agar didapatkan data yang mampu diproses dengan komputer (Sabrani *et al.*, 2020). Beberapa tahap *preprocessing* data yang dilakukan oleh penelitian ini yaitu:

1. *Cleansing* yaitu proses membersihkan dokumen seperti menghilangkan *white space* dan karakter yang tidak relevan dengan informasi.
2. *Case folding* merupakan tahap mengonversikan huruf dalam kalimat menjadi huruf kecil sehingga tidak ada perbedaan saat pembobotan kata.
3. Normalisasi kata yaitu proses mengembalikan kata ke bentuk yang sesuai dengan ejaan.
4. *Tokenizing* adalah pembagian kalimat menjadi unit-unit kata atau token tanpa memperhatikan peran dan hubungan pada setiap kata yang ada dalam suatu kalimat.
5. *Filtering* yaitu tahap dihapusnya kata-kata yang tidak mengandung makna khusus dengan menggunakan daftar *stopwords*.

6. *Stemming* yaitu proses pengembalian dari sebuah kata ke bentuk dasarnya dengan menghilangkan afiksasi.

Term Frequency-Inverse Document Frequency (TF-IDF) yaitu metode pencarian informasi dengan penggabungan dari perhitungan frekuensi kata dan inversi frekuensi dokumen (Tammina, 2020). TF-IDF terdiri atas perhitungan *Term Frequency* dan *Inverse Document Frequency*. *Term Frequency* (TF) merupakan perhitungan frekuensi kata yang muncul dalam dokumen, sedangkan *Inverse Document Frequency* (IDF) merupakan pengukuran sebaran kata dalam dokumen yang relevan. Nilai dari IDF akan berbanding terbalik dengan nilai TF. Nilai IDF akan lebih besar ketika kemunculan katanya sedikit. Algoritma perhitungan TF-IDF dirumuskan sebagai:

$$w_{dk} = tf_{dk} \times \log\left(\frac{N}{df_k}\right) \quad (1)$$

w_{dk} merupakan bobot kata k di dokumen d , tf_{dk} merupakan jumlah kemunculan kata k pada dokumen d , N merupakan total dokumen keseluruhan, dan df_k merupakan jumlah dokumen yang mengandung kata k .

Lexicon-Based merupakan metode klasifikasi dengan karakteristik berupa penggunaan kamus kata yang disebut *sentiment lexicon* atau *opinion lexicon* (Liu, 2015). *Lexicon-Based* memiliki berbagai model, salah satunya adalah SentiWordNet. SentiWordNet adalah hasil anotasi otomatis dari *synset* WordNet yang mengindikasikan tingkat positif, negatif, dan objektivitas kata-kata dalam setiap *synset* (Baccianella et al., 2010). Tingkat ini ditentukan oleh skor positif, negatif, dan netral yang terkait dengan *synset*. Penggunaan SentiWordNet untuk bahasa Indonesia memerlukan translasi ke dalam bahasa Inggris karena SentiWordNet hanya memiliki *synset* dalam bahasa Inggris.

Tahapan yang dilakukan dalam klasifikasi *Lexicon-Based* terdiri dari perhitungan tingkat kata, tingkat kalimat, dan tingkat dokumen. Tingkat kata menghitung selisih skor positif dan negatif *synset*. Perolehan skor melibatkan perbandingan kata yang muncul dengan kata dalam kamus berdasarkan *Parts-of-Speech Tagging* (POS Tagging). POS Tagging memberikan tanda kelas kata untuk setiap kata dan membantu memahami konteks kata dalam kalimat (Ghabayen & Ahmed, 2020). SentiWordNet mengenali empat jenis POS antara lain “n” yaitu *noun* (kata benda), “v” yaitu *verb* (kata kerja), “r” yaitu *adverb* (kata keterangan), dan “a” yaitu *adjective* (kata sifat).

Tahap selanjutnya setelah melakukan perhitungan tingkat kata adalah tingkat kalimat. Perhitungan tingkat kalimat dihitung rata-ratanya dengan formula:

$$Skor\ kalimat_{Pos} = \frac{1}{nk} \sum_{i=1}^{nk} skor\ kata\ positif_i \quad (2)$$

$$Skor\ kalimat_{Neg} = \frac{1}{nk} \sum_{i=1}^{nk} skor\ kata\ negatif_i \quad (3)$$

$Skor\ kalimat_{Pos}$ merupakan jumlah skor positif kalimat, $Skor\ kalimat_{Neg}$ merupakan jumlah skor negatif kalimat, nk merupakan banyaknya kata dari suatu kalimat, $skor\ kata\ positif_i$ merupakan skor positif kata ke- i , dan $skor\ kata\ negatif_i$ merupakan skor negatif kata ke- i .

Tingkat dokumen melakukan perhitungan rata-rata skor dari tingkat kalimat dengan persamaan:

$$Skor\ dokumen_{Pos} = \frac{1}{ns} \sum_{i=1}^{ns} skor\ kalimat\ positif_i \quad (4)$$

$$Skor\ dokumen_{Neg} = \frac{1}{ns} \sum_{i=1}^{ns} skor\ kalimat\ negatif_i \quad (5)$$

$Skor\ dokumen_{Pos}$ adalah jumlah skor positif dalam dokumen, $Skor\ dokumen_{Neg}$ adalah jumlah skor negatif dalam dokumen, ns adalah banyaknya kalimat dalam dokumen, $skor\ kalimat\ positif_i$ adalah skor positif kalimat ke- i , dan $skor\ kalimat\ negatif_i$ adalah skor negatif kalimat ke- i .

Hasil perhitungan tingkat dokumen dilanjutkan dengan penentuan sentimen berupa membandingkan jumlah skor positif dan negatif. Sebuah *tweet* termasuk ke dalam kelas positif bila skor positif lebih besar daripada skor negatif. *Tweet* memiliki skor positif yang lebih kecil dari skor negatif diklasifikasikan ke dalam kelas negatif. Bila skor positif dan skor negatif memiliki nilai yang sama besar maka dikelompokkan pada kelas netral. Penentuan kelas ini dapat ditulis sebagai:

$$dok_{sentimen} = \begin{cases} positif, & \text{jika } skor\ dokumen_{Pos} > skor\ dokumen_{Neg} \\ netral, & \text{jika } skor\ dokumen_{Pos} = skor\ dokumen_{Neg} \\ negatif, & \text{jika } skor\ dokumen_{Pos} < skor\ dokumen_{Neg} \end{cases} \quad (6)$$

Naïve Bayes Classifier adalah sebuah klasifikasi yang didasarkan oleh Teorema Bayes untuk mengestimasi probabilitas posterior sebagai pengukuran ketidakpastian prediksi (Tan *et al.*, 2019). Salah satu algoritma *Naïve Bayes Classifier* yang cukup umum digunakan yaitu *Multinomial Naïve Bayes Classifier*. Metode ini termasuk *supervised learning* yang dikenal sederhana dan mampu memodelkan probabilitas dari kumpulan kata (Sabrani *et al.*, 2020). Persamaan probabilitas dokumen dalam suatu kelas dituliskan dalam rumus:

$$P(c|d) \propto P(c) \prod_{1 \leq k \leq n_d} P(t_k|c) \quad (7)$$

$P(c|d)$ adalah probabilitas suatu dokumen d pada kelas c , $P(c)$ adalah probabilitas prior dokumen yang berada di kelas c , $P(t_k|c)$ adalah probabilitas bersyarat kata t_k untuk dokumen di kelas c , dan t_1, t_2, \dots, t_{n_d} adalah kata-kata pada dokumen dengan n_d merupakan jumlah kata dalam dokumen tersebut.

Tujuan dari klasifikasi yaitu mencari kelas terbaik dari suatu dokumen dan dapat ditentukan menggunakan *Maximum a Posteriori* dari kelas c atau C_{MAP} . C_{MAP} dicari dengan persamaan:

$$C_{MAP} = \arg \max_{c \in C} \hat{P}(c) \prod_{1 \leq k \leq n_d} \hat{P}(t_k|c) \quad (8)$$

$\hat{P}(c)$ dan $\hat{P}(t|c)$ dapat dihitung melalui persamaan:

$$\hat{P}(c) = \frac{N_c}{N} \quad (9)$$

$$\hat{P}(t|c) = \frac{w_{ct} + 1}{(\sum_{w' \in V} w_{ct'}) + B'} \quad (10)$$

N_c merupakan jumlah dari kelas c untuk keseluruhan dokumen, N merupakan total keseluruhan dokumen, w_{ct} merupakan nilai pembobotan TF-IDF dari kata t pada kelas c , $\sum_{w' \in V} w_{ct'}$ merupakan jumlah pembobotan dari seluruh kata yang berada di kelas c , B' merupakan banyak kata unik dalam seluruh dokumen.

Pengukuran kinerja sistem klasifikasi menjadi aspek penting saat mengevaluasi kemampuan sistem dalam mengklasifikasi data. *Confusion matrix* menjadi sebuah alat yang berguna untuk menganalisis sejauh mana klasifikasi mampu mengenali dokumen dalam berbagai kelas (Han *et al.*, 2012). *Confusion matrix* umumnya digunakan pada perhitungan *Precision*, *Recall*, *F1-Score*, dan *Accuracy*.

Precision mengevaluasi kemampuan *classifier* dalam memprediksi kelas secara benar. *Recall* mengukur kemampuan sistem menemukan kelas yang benar dari seluruh kelas aktual. *F1-score* atau *F-measure* yaitu nilai gabungan dari *Precision* dan *Recall*, sedangkan *Accuracy* adalah nilai pengukuran dari data yang terprediksi benar terhadap keseluruhan data. *Confusion matrix* diperlihatkan dalam Gambar 1.

		Kelas Aktual		
		Negatif	Netral	Positif
Kelas Prediksi	Negatif	TN	NetN	FN
	Netral	NNet	TNet	PNet
	Positif	FP	NetP	TP

Gambar 1. *Confusion Matrix* 3 Kelas

Keterangan:

TP : Data kelas positif terprediksi benar positif oleh *classifier*

NetP : Data kelas netral yang diprediksi menjadi kelas positif

FP : Data kelas negatif yang salah terprediksi menjadi negatif

PNet : Data kelas positif yang terprediksi menjadi kelas netral

TNet : Data kelas netral terprediksi benar netral oleh *classifier*

NNet : Data kelas negatif yang salah terprediksi menjadi kelas netral

FN : Data kelas negatif yang salah terprediksi menjadi positif

NetN : Data kelas netral yang diprediksi menjadi negatif

TN : Data kelas negatif terprediksi benar negatif oleh *classifier*

Klasifikasi *multi class* yang memuat 3 kelas seperti pada Gambar 1 akan didapatkan *Precision*, *Recall*, *F1-Score*, dan *Accuracy*. *Accuracy* yaitu membandingkan kelas yang benar terklasifikasi terhadap data keseluruhan dan *confusion matrix* ukuran 3×3 dicari melalui persamaan:

$$Acc = \frac{TP + TN + TNet}{Total} \quad (11)$$

TP merupakan jumlah data terprediksi benar pada kelas positif, TN merupakan data yang terprediksi benar negatif, $TNet$ merupakan data yang diklasifikasi benar untuk kelas netral, dan $Total$ merupakan jumlah seluruh data yang diujikan.

Precision yaitu pengujian besarnya kelas yang mampu diprediksi secara benar oleh *classifier*. *Recall* yaitu tingkat kemampuan dari *classifier* dalam menemukan kelas yang

benar terklasifikasi dari seluruh kelas aktual. *F1-score* yaitu perbandingan rata dari *Precision* dan *Recall*. Perhitungan *Precision*, *Recall*, dan *F1-Score* menggunakan rata-rata *Weighted Average* melalui persamaan:

$$WAP = \frac{\sum_{c=1}^C p_c n_c}{\sum_{c=1}^C n_c} \quad (12)$$

$$WAR = \frac{\sum_{c=1}^C r_c n_c}{\sum_{c=1}^C n_c} \quad (13)$$

$$WAF = \frac{\sum_{c=1}^C f_c n_c}{\sum_{c=1}^C n_c} \quad (14)$$

WAP adalah *Weighted Average Precision* atau nilai rata-rata akhir *Precision* berdasarkan banyak data masing-masing kelas, *WAR* adalah nilai *Weighted Average Recall* atau nilai rata-rata akhir *Recall* berdasarkan banyak data masing-masing kelas, *WAF* adalah *Weighted Average F1-score* atau nilai rata-rata akhir *F1-score* berdasarkan banyak data masing-masing kelas, p_c adalah *Precision* dari kelas ke- c , r_c adalah *Recall* dari kelas ke- c , f_c adalah *F1-score* dari kelas ke- c , C adalah banyak kelas klasifikasi, dan n_c adalah banyaknya data aktual kelas ke- c .

Nilai p_c , r_c , dan f_c diambil dari nilai *Precision*, *Recall*, dan *F1-score* setiap kelas yang ada. Nilai tersebut diperoleh menggunakan prinsip *confusion matrix* 2×2 yang diilustrasikan dalam Gambar 2.

		Kelas Aktual				
		Negatif	Netral	Positif		
Kelas Prediksi	Negatif	TN	NetN	FN	→ TP	→ FN
	Netral	NNet	TNet	PNet	→ TN	
	Positif	FP	NetP	TP	→ FP	

Gambar 2. Ilustrasi Perhitungan *Confusion Matrix* 3×3

Gambar 2 menampilkan contoh perhitungan pada kelas negatif. Nilai TN pada *confusion matrix* 3×3 menjadi TP. FP diisi oleh jumlah nilai NNet dan FP sedangkan FN menjumlahkan nilai NetN dan FN. FP berisi jumlah dari nilai TNet, PNet, NetP, dan TP. Perhitungan yang dilakukan pada setiap kelas ini menggunakan formula:

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$Recall = \frac{TP}{TP + FN} \quad (16)$$

$$F1\ score = \frac{2(Recall \times Precision)}{Recall + Precision} \quad (17)$$

Word cloud adalah gambaran visual berbentuk grafis dua dimensi yang menampilkan kata-kata dari dokumen. *Word cloud* mudah dipahami oleh pengguna awam yang mampu menciptakan tampilan menarik dan memikat secara estetika (Castellà & Sutton, 2014). Ukuran huruf mengindikasikan frekuensi kemunculan kata tersebut.

3. METODE PENELITIAN

Penelitian ini memanfaatkan *tweet* dalam bahasa Indonesia yang diperoleh melalui *scraping* dengan *Tweepy* dan *Scweet*. Data primer ini tersaring sebanyak 1.000 *tweet* yang mencakup periode waktu dari 30 Agustus 2021 hingga 7 Oktober 2021. *Scraping* hanya mengambil *tweet* yang menyebutkan “Song Joong Ki” dan “Scarlett Whitening” yang merupakan kata kunci dari pencarian *tweet*. Variabel dalam penelitian terdiri atas waktu penulisan *tweet*, isi *tweet*, dan nama akun (*username*). Microsoft Excel 2013 dan Python 3.9 adalah *software* yang dipakai untuk penelitian ini. Berikut tahapan analisis yang dilakukan.

1. Mengambil data dengan *scraping* menggunakan *library Tweepy* dan *Scweet* dari Python.
2. Melakukan *preprocessing tweet* yang meliputi *cleansing*, *case folding*, normalisasi teks, *tokenizing*, *filtering*, dan *stemming*.
3. Memberikan label pada setiap *tweet* dengan salah satu metode *Lexicon-Based* yaitu SentiWordNet.
4. Membobotkan setiap kata dengan TF-IDF.
5. Membuat model klasifikasi dengan perbandingan 80%:20% menggunakan *Multinomial Naïve Bayes Classifier*.
6. Mengevaluasi hasil klasifikasi dengan *confusion matrix* seperti *Precision*, *Recall*, *F1-score*, dan *Accuracy*.
7. Membuat interpretasi visual dengan *word cloud*.

4. HASIL DAN PEMBAHASAN

Pengambilan data dengan *scraping* dilakukan pada Python melalui *library Tweepy* dan *Scweet*. Penggunaan kedua *library* mampu menarik data tanpa adanya duplikasi *tweet* atau *retweet*. Hasil pencarian mendapat 1.377 *tweet* dan berhasil disaring sebanyak 1.000 *tweet* dalam Microsoft Excel karena adanya *tweet-tweet* yang tidak relevan. Data yang diperoleh berupa waktu *tweet* ditulis, isi *tweet*, dan *username* atau nama akun dari penulis *tweet*.

Data sebanyak 1.000 *tweet* tersebut diproses dalam tahap *preprocessing* data. Seluruh teks dalam *tweet* diolah hingga menjadi data yang siap digunakan untuk proses selanjutnya. *Preprocessing* data menerapkan tahapan-tahapan yaitu:

1. *Cleansing* bermanfaat untuk membersihkan dokumen dari karakter dan *white space* yang tidak berhubungan dengan informasi. Karakter ini meliputi tanda baca dan angka.
2. *Case Folding* berguna untuk mengganti seluruh huruf pada *tweet* menjadi huruf kecil agar tidak diartikan berbeda saat pemberian bobot kata.
3. Normalisasi kata berfungsi dalam mengubah kata ke bentuk yang sesuai dengan ejaan. Normalisasi memakai kamus yang berisi kata-kata tidak sesuai ejaan dan perbaikan kata. Kamus kata normalisasi menggunakan hasil penelitian Salsabila *et al.* (2018) dan beberapa tambahan kata baru secara manual yang belum ada dalam penelitian tersebut.
4. *Tokenizing* melakukan pemisahan pada setiap kata dalam *tweet*. Kata yang dipisah tidak mempertimbangkan hubungan dari masing-masing kata.
5. *Filtering* berfungsi sebagai proses dihilangkannya kata yang kemunculannya sering pada *tweet* namun tidak terdapat makna tertentu. Proses tersebut memanfaatkan daftar *stopwords* yang diperoleh dari Sastrawi, yaitu *library* yang dikhususkan penggunaannya untuk pengolahan teks dalam bahasa Indonesia.
6. *Stemming* berfungsi untuk pengembalian kata menjadi bentuk kata dasarnya. Imbuhan atau afiksasi yang terdapat dalam suatu kata dihilangkan dalam tahap ini. *Stemming* memanfaatkan *library* Sastrawi untuk diolah pada Python.

Pengolahan data *tweet* selanjutnya yaitu mengimplementasikan metode *Lexicon-Based* yaitu pemberian label oleh SentiWordNet. Pelabelan menghitung rata-rata skor *synset* yang

didapat secara otomatis berdasarkan POS *Tagging* dari setiap kata dalam *tweet*. Perhitungan tersebut menghasilkan skor positif dan skor negatif yang dibandingkan sebagai penentu label kelas sentimen. Perhitungan label data dengan SentiWordNet diilustrasikan dalam Tabel 2.

Tabel 1. Ilustrasi Pelabelan dengan SentiWordNet

<i>Tweet</i> Hasil		serius, scarlett, kolaborasi, song, joongki, asli, keren, banget				
<i>Preprocessing</i> Data:		Rerata Skor Positif	Rerata Skor Negatif	Rerata Kalimat Positif	Rerata Kalimat Negatif	Label Sentimen
Kalimat 1	serius (-0,0833), scarlett (0), kolaborasi (0), song (0), joongki (0)	0	-0,0167	0,0452	-0,0292	Positif
Kalimat 2	asli (-0,125), keren (0,1458), banget (0,125)	0,0903	-0,0417			

Skor kata didapat dengan menghitung rata-rata nilai *synset* dari suatu kata berdasarkan *tagger*. Contohnya seperti kata “keren” memiliki skor 0,1458 dari kamus SentiWordNet dan POS *Tagging* memberikan *tagger* “a”. Kata “keren” dengan terjemahan yaitu “cool” ini memiliki 6 *synset* yang ditampilkan oleh Tabel 3, sehingga rata-ratanya yaitu:

$$skor = \frac{((0,25-0,125)+(0,5-0)+(0-0)+(0,5-0,5)+(0,125-0,25)+(0,375-0))}{6} = \frac{0,875}{6} = 0,1458$$

Tabel 2. Daftar *Synset* Kata "cool" SentiWordNet

<i>Synset Term</i>	POS	<i>Pos Score</i>	<i>Neg Score</i>
<i>cool#1</i>	a	0,25	0,125
<i>cool#2</i>	a	0,5	0,0
<i>cool#3</i>	a	0,0	0,0
<i>cool#4</i>	a	0,5	0,5
<i>cool#5</i>	a	0,125	0,25
<i>cool#6</i>	a	0,375	0,0

Pelabelan dengan SentiWordNet didapatkan *tweet* yang termasuk ke dalam positif berjumlah 763 *tweet*, kelas negatif 219 *tweet*, dan kelas netral 18 *tweet*. *Tweet* hasil pelabelan dibagi ke dalam data *training* dan data *testing*. Perbandingan untuk data *training* dan data *testing* adalah 80%:20% yang berarti 1.000 *tweet* dipergunakan sebanyak 800 *tweet* untuk data *training* dan 200 *tweet* lainnya adalah data *testing*.

Data yang telah dibagi untuk masing-masing data *training* dan data *testing* diberikan bobot menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF). *Term Frequency* yang telah diperoleh untuk setiap kata pada seluruh *tweet* dikalikan dengan nilai IDF berdasarkan pada Persamaan 1. TF-IDF memberikan bobot untuk setiap kata seperti yang dicontohkan dalam Tabel 4.

Tabel 3. Pembobotan TF-IDF Dokumen

<i>Tweet</i>	ambassador	banget	brand	jadi	joongki	keren
Tweet 1	0	0	0	0,2857	0,0009	0
Tweet 2	0	0	0	0	0,0009	0
Tweet 3	0,1884	0	0,2154	0	0,0009	0

Tweet 4	0,1884	0	0,2154	0,5713	0,0009	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Tweet 1000	0,1884	0	0,2154	0,2857	0,0009	0

Proses pengujian dengan *Multinomial Naïve Bayes Classifier* memprediksi kelas dari data *testing*. Kinerja dari klasifikasi akan mengevaluasi 200 data *testing* menjadi tiga kelas yaitu positif, netral, dan negatif. *Confusion matrix* dimanfaatkan untuk mengevaluasi hasil prediksi seperti yang terlihat oleh Tabel 5.

Tabel 4. *Confusion Matrix* Hasil Pengujian

Kelas Prediksi	Kelas Aktual		
	Positif	Netral	Negatif
Positif	139	0	14
Netral	2	2	0
Negatif	21	0	22

Tabel 5 menampilkan hasil pengujian dan dapat diketahui bahwa data yang benar terprediksi sebesar 139 *tweet* untuk kelas positif, 22 *tweet* pada kelas negatif, dan 2 *tweet* dari kelas netral. *Confusion matrix* juga menghasilkan beberapa nilai seperti *Precision*, *Recall*, *F1-score*, dan *Accuracy*. Perhitungan untuk *Precision*, *Recall*, dan *F1-score* didapat oleh setiap kelas sentimen sedangkan *Accuracy* diperoleh berdasarkan data yang mampu terprediksi benar oleh *classifier* dan hasilnya ditunjukkan oleh Tabel 6.

Tabel 5. Hasil *Precision*, *Recall*, dan *F1-score* untuk Setiap Kelas

Kelas	Positif	Netral	Negatif
<i>Precision</i>	0,9085	0,500	0,5116
<i>Recall</i>	0,8580	1,000	0,6111
<i>F1-score</i>	0,8825	0,6667	0,5570
<i>Accuracy</i>	0,8150		

Nilai *Precision*, *Recall*, dan *F1-score* yang terdapat dalam Tabel 6 kemudian dikalkulasikan hingga mendapat nilai akhir dari *Precision*, *Recall*, dan *F1-score*. Nilai tersebut didapatkan dengan menghitung hasil *Precision*, *Recall*, dan *F1-score* yang memanfaatkan Persamaan 12, 13, dan 14.

$$\begin{aligned}
 WAP &= \frac{\sum_{c=1}^C p_c n_c}{\sum_{c=1}^C n_c} \\
 &= \frac{(0,9085 \times 162) + (0,5116 \times 36) + (0,5 \times 2)}{162 + 36 + 2} = \frac{166,5946}{200} \\
 &= 0,8330 = 83,30\%
 \end{aligned}$$

$$\begin{aligned}
 WAR &= \frac{\sum_{c=1}^C r_c n_c}{\sum_{c=1}^C n_c} \\
 &= \frac{(0,8580 \times 162) + (0,6111 \times 36) + (1 \times 2)}{162 + 36 + 2} = \frac{162,9956}{200}
 \end{aligned}$$

DAFTAR PUSTAKA

- Anggina, S., Setiawan, N. Y., & Bachtiar, F. A. 2022. Analisis Ulasan Pelanggan Menggunakan Multinomial Naïve Bayes Classifier dengan Lexicon-Based dan TF-IDF Pada Formaggio Coffee and Resto. *@is The Best : Accounting Information Systems and Information Technology Business Enterprise*, Vol. 7, No. 1, pp. 76–90. DOI: 10.34010/AISTHEBEST.V7I1.7072.
- Baccianella, S., Esuli, A., & Sebastiani, F. 2010. SentiWordNet 3.0: An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining. *Proceedings of the 7th International Conference on Language Resources and Evaluation, LREC 2010*, pp. 2200–2204. http://www.lrec-conf.org/proceedings/lrec2010/pdf/769_Paper.pdf.
- Castellà, Q., & Sutton, C. 2014. Word Storms: Multiples of Word Clouds for Visual Comparison of Documents. *WWW 2014 - Proceedings of the 23rd International Conference on World Wide Web*, pp. 665–675. DOI: 10.1145/2566486.2567977.
- Ghabayen, A. S., & Ahmed, B. H. 2020. Polarity Analysis of Customer Reviews Based on Part-of-Speech Subcategory. *Journal of Intelligent Systems*, Vol. 29, No. 1, pp. 1535–1544. DOI: 10.1515/jisys-2018-0356.
- Han, J., Kamber, M., & Pei, J. 2012. *Data Mining: Concepts and Techniques 3rd Edition*. California. Morgan Kaufmann.
- Indriningtyas, D. 2022. Brand Ambassador Artis Korea pada E-Commerce di Indonesia. *Perspektif Komunikasi: Jurnal Ilmu Komunikasi Politik Dan Komunikasi Bisnis*, Vol. 6, No. 2, pp. 219–230. DOI: 10.24853/pk.6.2.219-230.
- Lea-Greenwood, G. 2013. *Fashion Marketing Communications*. New Jersey. John Wiley & Sons.
- Liu, B. 2015. *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. Cambridge. Cambridge University Press.
- Prasanti, R. P., & Dewi, A. I. N. 2020. Dampak Drama Korea (Korean Wave) Terhadap Pendidikan Remaja. *Lectura: Jurnal Pendidikan*, Vol. 11, No. 2, pp. 256–269. DOI: 10.31849/lectura.v11i2.4752.
- Sabrani, A., et al. 2020. Metode Multinomial Naïve Bayes untuk Klasifikasi Artikel Online Tentang Gempa di Indonesia. *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya*, Vol. 2, No. 1, pp. 89–100. DOI: 10.29303/jtika.v2i1.87.
- Salsabila, N. A., et al. 2018. Colloquial Indonesian Lexicon. *Proceedings of the 2018 International Conference on Asian Language Processing, IALP 2018*, pp. 226–229. DOI: 10.1109/IALP.2018.8629151.
- Slamet, R., et al. 2022. Twitter Sentiment Analysis of South Korea Artists as Brand Ambassadors of Local Beauty Products. *Journal of Information Technology and Computer Science (INTECOMS)*, Vol. 5, No. 1, pp. 145–153. DOI: 10.31539/intecom.v5i1.3933.
- Tamina, S. 2020. A Hybrid Learning Approach for Sentiment Classification in Telugu Language. *2020 International Conference on Artificial Intelligence and Signal Processing (AISP)*, pp. 1–6. DOI: 10.1109/AISP48273.2020.9073109.
- Tan, P.-N., et al. 2019. *Introduction to Data Mining: Global Edition 2nd Edition*. New York. Pearson Education.
- We Are Social dan HootSuite. 2021. *Indonesian Digital Report 2021*. <https://datareportal.com/reports/digital-2021-indonesia>. (Diakses: 15 September 2021).