

ANALISIS SENTIMEN ULASAN KEDAI KOPI MENGGUNAKAN METODE *NAÏVE BAYES* DENGAN SELEKSI FITUR ALGORITME GENETIKA

Naziha Azhar^{*1}, Putra Pandu Adikara², Sigit Adinugroho³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹nazihazhr16@gmail.com, ²adikara.putra@ub.ac.id, ³sigit.adinu@ub.ac.id

*Penulis Korespondensi

(Naskah masuk: 01 Desember 2020, diterima untuk diterbitkan: 10 Juni 2021)

Abstrak

Di era sekarang, kedai kopi tak hanya dikenal sebagai tempat berkumpul dan menyeruput kopi saja, tetapi kedai kopi telah menjadi tempat yang nyaman untuk belajar dan bekerja. Namun, tidak semua kedai kopi memiliki kualitas yang baik sesuai dengan apa yang diharapkan pelanggan. Ulasan tentang kedai kopi dapat membantu pemilik kedai kopi untuk mengetahui bagaimana respons mengenai produk dan pelayanannya. Ulasan tersebut perlu diklasifikasikan menjadi ulasan positif atau negatif sehingga membutuhkan analisis sentimen. Terdapat beberapa tahap pada penelitian ini yaitu *pre-processing* untuk pemrosesan ulasan, ekstraksi fitur menggunakan *Bag of Words* dan *Lexicon Based Features*, serta mengklasifikasikan ulasan menggunakan metode *Naïve Bayes* dengan Algoritme Genetika sebagai seleksi fitur. Data yang digunakan pada penelitian ini sebanyak 300 data dengan 210 data sebagai data latih dan 90 data sebagai data uji. Hasil evaluasi yang didapatkan dari klasifikasi *Naïve Bayes* dan seleksi fitur Algoritme Genetika yaitu *accuracy* sebesar 0,944, *precision* sebesar 0,945, *recall* sebesar 0,944, dan *f-measure* sebesar 0,945 dengan menggunakan parameter Algoritme Genetika terbaik yaitu banyak generasi = 50, banyak populasi = 18, *crossover rate* = 1, dan *mutation rate* = 0.

Kata kunci: analisis sentimen, kedai kopi, *naïve bayes*, seleksi fitur, algoritme genetika

SENTIMENT ANALYSIS FOR COFFEE SHOP REVIEWS USING *NAÏVE BAYES* METHOD WITH GENETIC ALGORITHM FEATURE SELECTION

Abstract

In this era, coffee shops are not only known as a place to gather and drink coffee, but also have become a comfortable place to study and work. However, not all coffee shops are in good quality according to what customers expect. Coffee shop reviews can help coffee shop owners to find out the response to their products and services. These reviews need to be classified as positive or negative reviews so that sentiment analysis is needed. There are several steps in this study, which are *pre-processing* to process reviews, feature extraction using *Bag of Words* and *Lexicon Based Features*, also classifying reviews using the *Naïve Bayes* method with Genetic Algorithm as a feature selection. The data used in this study were 300 data with 210 data as training data and 90 data as test data. Evaluation results obtained from the *Naïve Bayes* classification and Genetic Algorithm feature selection are 0.944 for accuracy, 0.945 for precision, 0.944 for recall, and 0.945 for *f-measure* using the best Genetic Algorithm parameters which are many generations = 50, many populations = 18, *crossover rate* = 1, and *mutation rate* = 0.

Keywords: sentiment analysis, coffee shop, *naïve bayes*, feature selection, genetic algorithm

1. PENDAHULUAN

Kedai kopi ialah sebagai tempat menyediakan minuman olahan dari biji kopi dan berbagai jenis minuman lainnya, serta menyediakan makanan ringan sebagai kudapan pendamping minum kopi untuk dikonsumsi oleh masyarakat. Di era sekarang, kedai kopi tak hanya dikenal sebagai tempat berkumpul dan menyeruput kopi saja, tetapi kedai kopi telah menjadi tempat yang nyaman untuk

belajar dan bekerja. Bahkan saat ini kedai kopi memberikan fasilitas-fasilitas yang menarik agar pelanggan tertarik untuk datang ke kedai kopi tersebut. Namun, tidak semua kedai kopi yang diinginkan pelanggan memiliki kualitas yang baik. Pelanggan juga terkadang ingin lebih dahulu mengetahui kualitas dari kedai kopi tersebut, baik dari segi hidangan maupun fasilitas yang ada sebelum mengunjungi kedai kopi tersebut.

Perkembangan teknologi informasi saat ini sangat mendukung keberadaan perkembangan bisnis makanan dan minuman. Banyak aplikasi yang mendukung perkembangan bisnis makanan dan minuman, salah satunya yaitu aplikasi Zomato. Zomato merupakan suatu aplikasi yang memiliki fitur pencarian restoran atau *café* dan memberikan keterangan lengkap yang dibutuhkan oleh pelanggan. Zomato menyediakan informasi antara lain nama tempat, alamat, kontak, menu, foto dan ulasan. Para pengguna Zomato yang telah terdaftar dapat memberikan ulasan dan menilai restoran atau *café* yang telah mereka kunjungi. Ulasan ini dapat digunakan dengan baik untuk pemasaran pada pelaku bisnis tersebut.

Ulasan tentang kedai kopi dapat membantu pelanggan untuk mengetahui kualitas dari kedai kopi, baik menu atau pun pelayanannya, layak atau tidak untuk dipilih. Ulasan tentang kedai kopi ini juga dapat membantu pemilik kedai kopi untuk mengetahui bagaimana respons mengenai produk dan pelayanannya. Dengan respons baik, tentunya dapat meningkatkan keuntungan perusahaan dan juga membuka peluang untuk memproduksi lebih banyak. Begitu pun sebaliknya, dengan respons negatif, pemilik kedai kopi dapat melakukan perbaikan. Namun, terkadang pemilik kedai kopi tidak memiliki banyak waktu untuk menganalisis ulasan atau komentar yang jumlahnya tidak sedikit dan menyebabkan rumitnya membedakan ulasan tersebut positif atau negatif. Maka dibutuhkan sistem yang mampu memproses ulasan dengan penerapan analisis sentimen. Analisis sentimen ialah penggunaan *text mining* untuk memahami sentimen sosial yang ada pada merek, produk, atau pun layanan dengan mengidentifikasi dan mengekstraksi suatu informasi yang didapatkan. Analisis sentimen memiliki tugas dasar mengelompokkan teks berdasarkan pola di suatu dokumen. Dokumen tersebut dapat membentuk pola sentimen yang bersifat positif maupun negatif (Liu, 2012).

Metode *Naïve Bayes* ialah salah satu metode yang kerap dipakai dan berguna untuk melakukan analisis sentimen. Metode ini telah digunakan dalam penelitian analisis sentimen *review* produk menggunakan algoritme *Naïve Bayes* pada studi kasus *endorsement* terhadap produk “KFC Salted Egg”. Penelitian ini mendapatkan hasil akurasi senilai lebih dari 84% (Ramdhani, Andreswari dan Hasibuan, 2018).

Namun, klasifikasi teks memiliki permasalahan utama yakni dimensi tinggi dari *feature space*, yang mana seringkali teks memiliki beberapa ribu fitur. Fitur tersebut beberapa diantaranya tidak relevan dan tidak berguna untuk klasifikasi yang berakibat nilai akurasi berkurang dan dapat memperlambat proses klasifikasi atau membuat pengklasifikasian tidak dapat diterapkan (Chen et al., 2009). Penggunaan seleksi fitur telah dilakukan pada penelitian yang membahas tentang implementasi

dari algoritme *Naïve Bayes* dengan Algoritme Genetika sebagai seleksi fitur untuk analisis sentimen pada ulasan perusahaan *fashion online*. Hasil dari penelitian ini mendapatkan nilai akurasi dari metode *Naïve Bayes* sebelum menggunakan seleksi fitur sebesar 68,50%, sedangkan nilai akurasi setelah menggunakan Algoritme Genetika sebagai seleksi fitur sebesar 87,50%. Hal ini menunjukkan bahwa terdapat peningkatan nilai akurasi sebesar 19% (Ernawati et al., 2019).

Penelitian ini diharapkan mampu melakukan analisis sentimen pada studi kasus ulasan kedai kopi sehingga mendapatkan nilai akurasi dalam penggunaan metode *Naïve Bayes* dan dapat mengetahui pengaruh Algoritme Genetika sebagai seleksi fitur, serta mengetahui berapa perbandingan waktu komputasi yang diperlukan pada analisis sentimen ini.

2. METODE PENELITIAN

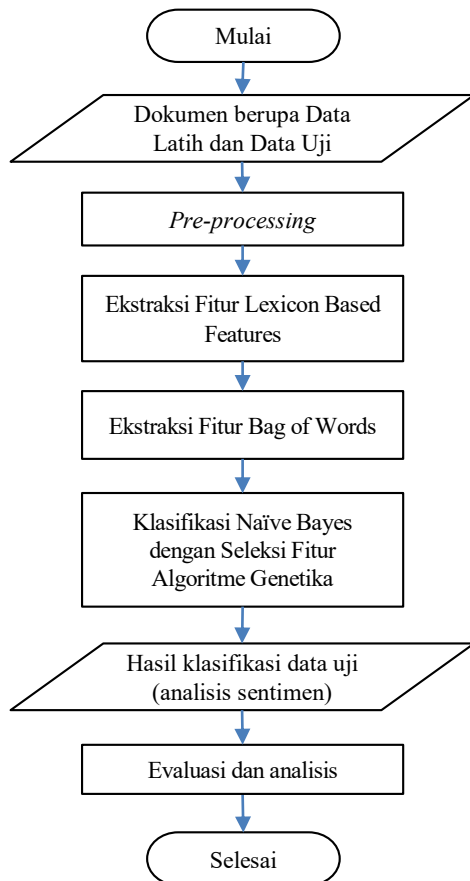
Beberapa tahap yang dilakukan pada penelitian yaitu dimulai dengan mengumpulkan data sebanyak 300 ulasan. Data yang sudah dikumpulkan akan dilakukan beberapa proses yaitu *pre-processing* teks, ekstraksi fitur *Bag of Words* dan *Lexicon Based Features*, serta melakukan pembobotan kata. Kemudian proses perhitungan seleksi fitur menggunakan Algoritme Genetika dan klasifikasi menggunakan metode *Naïve Bayes* untuk mendapatkan hasil klasifikasi yakni antara positif atau negatif. Gambaran umum metodologi penelitian yang dilakukan dapat dilihat pada Gambar 1.

2.1. Pengumpulan Data

Data yang digunakan untuk penelitian ini dikumpulkan secara manual dan dipilih secara acak dari situs *zomato.com*. Penggunaan data pada penelitian ini yakni ulasan kedai kopi yang berlokasi di Jakarta dan Serpong Utara. Data yang dikumpulkan berupa ulasan dari pelanggan terkait pelayanan dan pengalaman saat mengunjungi salah satu kedai kopi pada web tersebut. Penelitian ini menggunakan data sebanyak 300 dokumen yang mana dokumen tersebut terdiri dari 150 ulasan positif dan 150 ulasan negatif dan akan digunakan sebagai data uji dan data latih.

2.2. Text Pre-processing

Text pre-processing ialah salah satu langkah dalam memproses teks menjadi lebih terstruktur. Untuk mempersiapkan data mentah agar dapat dilakukannya analisis maka diperlukannya langkah *text pre-processing* (Hadna, Santosa dan Winarno, 2016). *Case folding*, *cleaning*, dan *tokenizing* termasuk pada langkah *pre-processing* teks.



Gambar 1 Gambaran umum sistem

2.2.1. Case Folding

Suatu tahap yang mengonversi semua karakter pada dokumen menjadi *case* yang sama disebut *case folding*. Penggunaan huruf kapital dilakukan pada semua dokumen secara tidak konsisten sehingga proses ini diperlukan (Witten, Moffat dan Bell, 1999). Contoh proses *case folding* yaitu kata “Kedai” yang dilakukan pengubahan menjadi kata “kedai”.

2.2.2. Cleaning

Proses selanjutnya yaitu proses *cleaning*. Proses ini dilakukan dengan menghapus karakter-karakter selain huruf untuk menghilangkan *delimiter*. Karakter angka, tanda baca, atau karakter lain selain huruf termasuk dari karakter yang dihilangkan pada proses *cleaning* (Hemalatha, Varma dan Govardhan, 2012).

2.2.3. Tokenizing

Tokenizing ialah suatu proses pengambilan kata yang merupakan penyusun suatu dokumen (Webster dan Kit, 1992). Proses ini dilakukan dengan memisah kalimat berdasarkan karakter pemisah kata yang tidak berpengaruh pada pemrosesan teks. Spasi atau pun tanda baca ialah bagian dari karakter-karakter pemisah kata tersebut.

2.3. Raw Term Frequency

Raw Term Frequency ialah jumlah munculnya suatu kata pada dokumen (Raschka, 2014). *Raw Term Frequency* ini memperhatikan frekuensi kemunculan term yang mana suatu *term* yang muncul sebanyak 10 kali pada dokumen akan memiliki bobot lebih tinggi dari *term* yang hanya muncul sebanyak 1 kali. Persamaan (1) merupakan persamaan untuk menghitung *Raw Term Frequency*.

$$w_{t,d} = tf_{t,d} \quad (1)$$

Keterangan:

$tf_{t,d}$: banyaknya *term* t yang muncul (frekuensi) dalam dokumen d

2.4. Lexicon Based Features

Lexicon Based Features yakni pembobotan yang diberikan kepada fitur dengan bantuan *lexicon* yang terjadi pada tiap kata. Seluruh kata yang berupa sentimen positif atau sentimen negatif melakukan proses pembobotan ini. Tujuan dari *Lexicon Based Features* yakni sebagai penentuan orientasi pada sentimen kata (Siddiqua, Ahsan dan Chy, 2017). Tabel 1 menunjukkan fitur-fitur yang terdapat pada *Lexicon Based Features* (Siddiqua, Ahsan dan Chy, 2017).

2.5. Algoritme Genetika

Agar mampu mengatasi masalah *machine learning*, Algoritme Genetika ialah suatu algoritme optimasi yang bisa digunakan dengan prinsip-prinsip seleksi alam dan genetika alami (Wati, 2016). Dalam menyelesaikan permasalahan, algoritme genetika memiliki beberapa fase yakni inisialisasi populasi, reproduksi, evaluasi, dan seleksi (Darma, Perdana dan Indriati, 2018).

Tabel 1. Fitur-fitur dalam *Lexicon Based Features*

Kode Fitur	Deskripsi Fitur
F1	Banyaknya kata pada dokumen yang bersentimen positif.
F2	Banyaknya kata pada dokumen yang bersentimen negatif.
F3	Banyaknya kata positif yang merupakan kata sifat (<i>adjective</i>).
F4	Banyaknya kata negatif yang merupakan kata sifat (<i>adjective</i>).
F5	Banyaknya kata positif yang merupakan kata kerja (<i>verb</i>).
F6	Banyaknya kata negatif yang merupakan kata kerja (<i>verb</i>).
F7	Banyaknya kata positif yang merupakan kata keterangan (<i>adverb</i>).
F8	Banyaknya kata negatif yang merupakan kata keterangan (<i>adverb</i>).
F9	Persentase kata positif yang merupakan kata sifat (<i>adjective</i>).
F10	Persentase kata negatif yang merupakan kata sifat (<i>adjective</i>).
F11	Persentase kata positif yang merupakan kata kerja (<i>verb</i>).
F12	Persentase kata negatif yang merupakan kata

Kode Fitur	Deskripsi Fitur
	kerja (<i>verb</i>).
F13	Persentase kata positif yang merupakan kata keterangan (<i>adverb</i>).
F14	Persentase kata negatif yang merupakan kata keterangan (<i>adverb</i>).
F15	Banyaknya kata pada dokumen yang berupa kata penegasan.

2.5.1. Inisialisasi Populasi

Inisialisasi populasi ialah tahap pertama dari proses Algoritme Genetika. Proses ini dilakukan untuk menciptakan individu-individu (kromosom) awal secara acak yang nantinya dijadikan solusi untuk permasalahan. Nilai pada tiap individu tersebut bernilai 0 atau 1.

2.5.2. Reproduksi Crossover

Crossover ialah suatu cara reproduksi yang melakukan pemilihan induk (*parent*) sebanyak dua individu dari populasi secara acak. Agar dapat mengetahui jumlah keturunan yang didapatkan, dibutuhkan inisialisasi parameter *crossover rate* pada proses reproduksi *crossover* (Mahmudy, 2015). Persamaan (2) memiliki tujuan agar dapat mengetahui jumlah keturunan yang dihasilkan.

$$jmlOffspring = cr \times popSize \quad (2)$$

Keterangan:

cr : parameter *crossover rate*

popSize : banyak populasi

jmlOffspring : banyak keturunan yang didapatkan reproduksi *crossover*

Metode *one-cut-point* ialah metode *crossover* yang dipakai pada penelitian ini. Metode ini dilakukan dengan menentukan satu titik potong dengan acak dan mengubah bagian kanan setiap induknya dengan cara ditukar sehingga dihasilkannya keturunan.

2.5.3. Reproduksi Mutation

Mutation merupakan suatu cara reproduksi yang menentukan satu individu dari populasi secara *random*. Proses reproduksi *mutation* ini dilakukan dengan mengubah satu nilai gen di titik potong yang sudah ditetapkan secara acak. Agar banyaknya keturunan yang dihasilkan dapat diketahui, dibutuhkan inisialisasi parameter *mutation rate* pada proses mutasi (Mahmudy, 2015). Persamaan (3) ialah persamaan untuk menghitung jumlah keturunan yang didapatkan dari proses mutasi.

$$jmlOffspring = mr \times popSize \quad (3)$$

Keterangan:

mr : parameter *mutation rate*

popSize : banyak populasi

jmlOffspring : jumlah *offspring* yang dihasilkan dari reproduksi mutasi

2.5.4. Evaluasi

Evaluasi dilakukan dengan perhitungan nilai *fitness* dalam setiap kromosom. Untuk menetapkan tingkat kriteria yang akan diraih, individu tersebut masing-masing mempunyai fungsi yang disebut fungsi *fitness* (Saputri, Mahmudy dan Ratnawati, 2015). Apabila nilai *fitness* yang didapatkan semakin besar, kromosom tersebut dapat memiliki peluang yang besar untuk dijadikan solusi. Menghitung nilai akurasi merupakan suatu cara untuk melakukan proses evaluasi. Persamaan (4) merupakan *fitness function* untuk proses evaluasi.

$$Fitness = \frac{jumlah\ hasil\ prediksi\ benar}{jumlah\ total\ prediksi} \quad (4)$$

2.5.5. Seleksi

Tahapan ini merupakan seleksi terhadap individu berdasarkan nilai *fitness*-nya. Kromosom tersebut diseleksi dan dijadikan induk untuk melakukan reproduksi *crossover* dan *mutation*. Metode *elitism* ialah salah satu metode yang bisa dipakai untuk proses seleksi. Untuk dapat masuk dan diproses di generasi berikutnya, individu yang mempunyai nilai *fitness* paling tinggi akan dipilih dengan memakai metode *elitism* ini. Proses *elitism* dilakukan sebagai pencegahan hilangnya kromosom-kromosom terbaik dikarenakan reproduksi sebelumnya. (Febriyana dan Mahmudy, 2016).

2.6. Klasifikasi Naïve Bayes

Metode pengklasifikasian yang paling umum digunakan, tetapi mempunyai akurasi yang tinggi yaitu Klasifikasi *Naïve Bayes*. *Naïve Bayes* merupakan pengetahuan sebelumnya yang digabungkan dengan pengetahuan baru yang mengarah pada teorema Bayes. Konsep dasarnya yaitu dengan menggabungkan probabilitas kata dan kategori untuk memperkirakan probabilitas kategori dokumen (Ernawati et al., 2019). Persamaan (5) merupakan teorema Bayes untuk menghitung probabilitas posterior (Han, Kamber dan Pei, 2012).

$$P(c_j|w_i) = \frac{P(c_j) \times P(w_i|c_j)}{P(w_i)} \quad (5)$$

Keterangan:

$P(c_j|w_i)$: posterior atau peluang kategori *j* saat munculnya kata *i*

$P(w_i|c_j)$: *likelihood* atau peluang kata *i* yang masuk ke kategori *j*

$P(c_j)$: prior atau peluang munculnya kategori *j*

$P(w_i)$: peluang munculnya suatu kata

i : indeks kata dari kata pertama sampai kata ke-*k*

j : indeks kategori dari kategori pertama sampai kategori ke-*n*

Dikarenakan peluang munculnya kata tidak berpengaruh pada perbandingan hasil klasifikasi

seluruh kategori, maka peluang tersebut bisa dihapus pada saat pengklasifikasian. Persamaan (6) merupakan proses pada klasifikasi yang disederhanakan.

$$P(c_j|w_i) = P(c_j) \times P(w_i|c_j) \quad (6)$$

Persamaan (7) ialah persamaan dari peluang munculnya suatu kategori di seluruh dokumen (Manning, Raghavan dan Schütze, 2009).

$$P(c_j) = \frac{N_{c_j}}{N} \quad (7)$$

Keterangan:

N_{c_j} : banyak dokumen yang merupakan kategori c_j
 N : jumlah semua dokumen latih yang digunakan

Persamaan (8) ialah perhitungan nilai posterior jika *likelihood* kata w_i dalam kategori c_j dilakukan perkalian dimulai dari $i = 1$ hingga $i = k$.

$$P(c_j|w_i) = P(c_j) \times P(w_1|c_j) \times \dots \times P(w_k|c_j) \quad (8)$$

Selanjutnya ialah proses penentuan kelas yang ditentukan melalui nilai peluang yang paling besar dari setiap kemungkinan kelas. Persamaan (9) merupakan rumus untuk memilih nilai terbesar (Manning, Raghavan dan Schütze, 2009).

$$c_{MAP} = \arg \max_{c \in C} P(c) \prod_{i=1}^n P(w_i|c) \quad (9)$$

2.6.1. Multinomial Naïve Bayes

Multinomial Naïve Bayes menggunakan persamaan *likelihood* dalam menghitung peluang suatu kata yang masuk ke suatu kelas. Penggunaan *Laplace smoothing* dilakukan agar terhindar dari angka nol pada persamaan *likelihood* (Manning, Raghavan dan Schütze, 2009). Persamaan (10) merupakan persamaan *likelihood*.

$$P(w_i|c_j) = \frac{\text{count}(w_i.c) + 1}{(\sum_{w \in V} \text{count}(w_i.c)) + |V|} \quad (10)$$

Keterangan:

$P(w_i|c_j)$: *likelihood* atau peluang kata i masuk ke kategori j
 $\text{count}(w_i.c)$: jumlah suatu kata yang ada pada suatu kelas
 $\sum_{w \in V} \text{count}(w_i.c)$: jumlah semua kata yang ada di dalam suatu kelas
 $|V|$: jumlah semua kata unik yang terdapat di seluruh kelas

2.6.2. Gaussian Naïve Bayes

Gaussian Naïve Bayes ialah algoritme pengklasifikasian pada nilai yang menggunakan data kontinu untuk menghitung probabilitas fitur

termasuk dalam suatu kategori. Persamaan (11) merupakan persamaan untuk menghitung nilai peluang *Gaussian Naïve Bayes* (John dan Langley, 1995).

$$P(x|c_k) = \frac{1}{\sqrt{2\pi\sigma_k^2}} e^{-\frac{(v-\mu_k)^2}{2\sigma_k^2}} \quad (11)$$

Keterangan:

x : atribut kontinu
 v : nilai
 c_k : kelas
 μ_k : rata-rata nilai dalam atribut kontinu
 σ_k^2 : ragam nilai dalam atribut kontinu

2.7. Confusion Matrix

Confusion matrix adalah pilihan yang baik untuk melaporkan hasil dari masalah klasifikasi karena dapat dilakukannya pengamatan pada hubungan antara *output* dari klasifikasi dan kelas aktualnya. *Confusion matrix* berguna untuk mengetahui performa dari *classifier* yang digunakan, apakah dapat mengidentifikasi dokumen dengan baik dari tiap kelas. Tabel 2 menunjukkan empat kemungkinan yang terjadi pada *confusion matrix* (Han, Kamber dan Pei, 2012).

Tabel 2. *Confusion Matrix*

Klasifikasi	Kelas Hasil Prediksi Positif	Kelas Hasil Prediksi Negatif
Kelas Aktual Positif	True Positives (TP)	False Negatives (FN)
Kelas Aktual Negatif	False Positives (FP)	True Negatives (TN)

Keterangan:

- *True Positives* (TP) adalah jumlah hasil prediksi positif yang benar ketika diklasifikasikan.
- *False Negatives* (FN) adalah jumlah hasil prediksi negatif yang salah ketika diklasifikasikan.
- *False Positives* (FP) adalah jumlah hasil prediksi positif yang salah ketika diklasifikasikan.
- *True Negatives* (TN) adalah jumlah hasil prediksi negatif yang benar ketika diklasifikasikan.

Persamaan (12), Persamaan (13), Persamaan (14), dan Persamaan (15) ialah persamaan untuk menghitung *Accuracy*, *Precision*, *Recall*, dan *F-Measure* berdasarkan hasil dari Tabel 2 (Han, Kamber dan Pei, 2012).

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (12)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (13)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (14)$$

$$F - Measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (15)$$

3. HASIL DAN PEMBAHASAN

3.1. Pengujian Banyak Generasi

Skenario untuk menguji banyak generasi ini dilakukan dengan memakai banyak populasi = 10, *crossover rate* = 0,5, dan *mutation rate* = 0,5. Sebagai catatan, karena Algoritme Genetika bersifat stokastik, maka hasil yang diperoleh setiap percobaan dapat berbeda karena adanya pemilihan acak saat proses di dalamnya seperti *crossover* dan *mutation*. Oleh karena itu dalam pengujian dilakukan 5 kali percobaan dan dari 5 percobaan tersebut kemudian dihitung rata-rata pada tiap generasi. Grafik hasil pengujian ditunjukkan pada Gambar 2.

Pada Gambar 2 yaitu hasil uji untuk banyak generasi yang memperoleh hasil terbaik yaitu pada banyak generasi = 50. Banyak generasi tersebut memperoleh hasil rata-rata *accuracy* sama dengan 0,933, rata-rata *precision* sama dengan 0,934, rata-rata *recall* sama dengan 0,933, dan rata-rata *f-measure* sama dengan 0,934.


Banyak generasi memiliki pengaruh pada jumlah iterasi yang dilakukan pada proses seleksi fitur. Semakin sedikit generasi maka semakin kecil kemungkinan fitur terbaik diseleksi untuk proses regenerasi, begitu pun sebaliknya. Apabila generasi semakin banyak maka semakin kecil kemungkinan fitur terbaik diseleksi untuk proses regenerasi. Pada pengujian ini secara umum terjadi peningkatan akurasi. Jumlah generasi yang digunakan memengaruhi peningkatan yang terjadi. Namun, terjadi juga penurunan pada uji coba setelah generasi = 50 dikarenakan semakin banyaknya generasi yang digunakan belum tentu dapat memproses secara optimal dan mendapatkan hasil yang optimal.

3.2. Pengujian Banyak Populasi


Pada skenario pengujian banyak populasi ini dilakukan dengan memakai banyak generasi = 50, *crossover rate* = 0,5, dan *mutation rate* = 0,5. Pengujian ini melakukan 5 percobaan dan dari 5 percobaan tersebut kemudian dihitung rata-rata pada tiap populasi. Grafik hasil pengujian ditunjukkan pada Gambar 3.

Dari Gambar 3, hasil dari pengujian yang menghitung banyaknya populasi yang memperoleh hasil terbaik yaitu pada banyak populasi = 18. Banyak populasi tersebut memperoleh hasil *average accuracy* sama dengan 0,938, *average precision* sama dengan 0,939, *average recall* sama dengan 0,938, dan *average f-measure* sama dengan 0,938. Pada pengujian ini secara umum terjadi peningkatan akurasi. Peningkatan ini terjadi dikarenakan pengaruh banyaknya populasi yang dipakai. Penggunaan populasi yang banyak dapat


menghasilkan kombinasi *term* yang banyak pula untuk bisa dipilih sehingga hal ini terjadi. Namun, terjadi juga penurunan pada uji coba saat banyak populasi sebesar 6 dan 20 dikarenakan tidak munculnya suatu *term* pada individu dapat berpengaruh pada hasil evaluasi.



Gambar 2. Grafik Hasil Pengujian Banyak Generasi



Gambar 3. Grafik Hasil Pengujian Banyak Populasi



Gambar 4. Grafik Hasil Pengujian Kombinasi *cr* dan *mr*

Tabel 3. Perbandingan hasil analisis sentimen beserta waktu komputasinya

Metode	Evaluasi				Waktu Komputasi (detik)
	Accuracy	Precision	Recall	F-Measure	
<i>Naïve Bayes</i>	0,9	0,9002	0,9	0,9001	12
<i>Naïve Bayes</i> + Algoritme Genetika	0,944	0,945	0,944	0,945	183


3.3. Pengujian Kombinasi *Crossover Rate* (*cr*) dan *Mutation Rate* (*mr*)

Pada skenario untuk menguji penggunaan *cr* beserta *mr* ini memakai banyak populasi = 18, dan banyak generasi = 50. Pengujian ini menerapkan 5 kali percobaan dan dihitungnya rata-rata pada tiap kombinasi *cr* dan *mr* dari 5 percobaan tersebut. Gambar 4 menunjukkan grafik hasil pengujian.

Dari Gambar 4 yaitu hasil pengujian pada kombinasi *crossover rate* (*cr*) dan *mutation rate* (*mr*) yang memperoleh hasil paling baik yaitu saat nilai *cr* = 1 dan nilai *mr* = 0. Kombinasi *cr* dan *mr* tersebut memperoleh hasil *average accuracy* sama dengan 0,944, *average precision* sama dengan 0,945, *average recall* sama dengan 0,944, dan *average f-measure* sama dengan 0,945. Secara umum, nilai akurasi pada pengujian ini meningkat walaupun hasilnya tidak stabil. Nilai akurasi juga menurun pada saat *cr* = 0,4 dan *mr* = 0,6 dan juga saat *cr* = 0,8 dan *mr* = 0,2. Namun, terjadi juga peningkatan pada saat *cr* = 0,7 dan *mr* = 0,3 dan juga saat *cr* = 1 dan *mr* = 0.

3.4. Pengujian Pengaruh Seleksi Fitur Algoritme Genetika

Pengujian ini dilakukan dengan membandingkan hasil klasifikasi *Naïve Bayes* dengan menggunakan seleksi fitur Algoritme Genetika dan hasil klasifikasi *Naïve Bayes* tanpa seleksi fitur. Pengujian ini menggunakan banyak populasi = 18, banyak generasi = 50, *crossover rate* (*cr*) = 1, dan *mutation rate* (*mr*) = 0 pada seleksi fitur Algoritme Genetika. Pengujian ini mengalami lima kali percobaan dan dari 5 percobaan tersebut kemudian dihitung rata-rata hasil evaluasinya. Pengujian menghasilkan grafik yang ditunjukkan Gambar 5 dengan membandingkan hasil *accuracy*, *precision*, *recall*, dan *f-measure* sesuai hasil pada Tabel 3.



Gambar 5. Grafik Hasil Pengujian Pengaruh Seleksi Fitur Algoritme Genetika

Pada sistem yang hanya menggunakan klasifikasi *Naïve Bayes*, sistem menggunakan *Lexicon Based Features* yaitu seluruh kata dalam kamus dan *Bag of Words* yang berupa kata-kata tunggal yang antar katanya saling tidak berhubungan. Tabel 3 menunjukkan perbandingan hasil dari sistem. Sistem ini melakukan proses komputasi dengan waktu 12 detik. Kata-kata yang digunakan untuk proses klasifikasi berjumlah 1753 kata. Sistem mendapatkan banyak kata yang hampir sama antara dua kelas sehingga hanya sedikit perbedaan penggunaan kata antar dua kelas. Hal ini terjadi pada data uji yang hasil klasifikasinya salah yaitu "*Kopinya enak sih, tp suasana ga enak bgt. It's ok kalo tempatnya kecil, tp setidaknya bisa harus lebih tegas dalam urusan smoking or non smoking area, masa ada yg ngerokok padahal duduk di bawah AC yang berhembus*". Pada data uji tersebut terdapat kata-kata positif seperti kata "*enak*" dan "*ok*", padahal data uji tersebut merupakan kelas negatif. Pada data uji tersebut juga memiliki banyak kata yang sulit dibedakan antara dua kelas sehingga hasil klasifikasinya salah. Evaluasi yang dihasilkan pada klasifikasi *Naïve Bayes* ialah 0,9 untuk nilai akurasi, 0,9002 untuk nilai *precision*, 0,9 untuk nilai *recall*, dan 0,9001 untuk nilai *f-measure*.

Pada sistem yang menggunakan seleksi fitur Algoritme Genetika pada klasifikasi *Naïve Bayes* bisa mengenal sentimen pada data uji dengan lebih baik. Sistem ini melakukan proses komputasi dengan waktu 3 menit 3 detik, sehingga kenaikan akurasi sebesar 4,4% memerlukan waktu 15,25 kali lipat jika menggunakan seleksi fitur Algoritme Genetika. Algoritme Genetika juga telah menyeleksi fitur kata-kata yang digunakan untuk proses klasifikasi menjadi sebanyak 899 kata. Sistem ini dapat mengenal sentimen pada data uji dengan lebih baik yang mana hal ini terjadi pada data uji yang ditentukan kelasnya dengan benar oleh sistem yakni "*Untuk makanannya sendiri saya pesan tuna pesto yang katanya menu rekomendasi di cafe ini. Benar saja setelah saya cicipi ternyata memang enak, campuran pesto yang tidak berlebihan di nasi membuat kita tidak "enek" saat memakannya, ditambah dengan potongan telur rebus yang membuat menu makan siang saya menjadi terasa lebih sempurna*". Pada pengujian data uji tersebut diklasifikasikan salah jika menggunakan klasifikasi *Naïve Bayes* tanpa seleksi fitur. Namun, jika menggunakan seleksi fitur Algoritme Genetika dapat diklasifikasikan dengan benar. Hal ini dikarenakan pada data tersebut mengandung lebih banyak kata tunggal yang terdapat pada kedua kelas

dibandingkan kata tunggal yang berbeda dari kedua kelas. Pada penggunaan seleksi fitur, beberapa dari kata yang tidak memiliki sentimen seperti kata “untuk”, “sendiri”, “saya”, “pesan”, “tuna”, “pesto”, “cafe”, “saja”, “campuran”, “telur”, “rebus”, dan “membuat” tidak digunakan untuk perhitungan klasifikasi sehingga hasil klasifikasi benar yaitu termasuk kelas positif. Evaluasi yang dihasilkan dengan digunakannya seleksi fitur Algoritme Genetika pada klasifikasi *Naïve Bayes* ialah *accuracy* yaitu 0,944, *precision* yaitu 0,945, *recall* yaitu 0,944, serta *f-measure* yaitu 0,945.

4. KESIMPULAN

Kesimpulan yang dapat diambil yaitu penggunaan metode *Naïve Bayes* dan seleksi fitur Algoritme Genetika pada analisis sentimen ulasan kedai kopi menghasilkan rata-rata *accuracy* tertinggi yaitu sebesar 0,944 dalam lima kali percobaan dengan nilai parameter terbaik yaitu banyak populasi = 18, banyak generasi = 50, *crossover rate* = 1, serta *mutation rate* = 0. Hasil tersebut menggunakan data yakni 300 dokumen dengan rasio 70:30 dalam pembagian data latih dan uji yang mana 210 data berupa data latih serta 90 data berupa data uji.

Penggunaan Algoritme Genetika sebagai seleksi fitur berpengaruh dalam analisis sentimen ulasan kedai kopi menggunakan metode *Naïve Bayes* yaitu dapat meningkatkan nilai akurasi senilai 4,4% atau 0,044. Hal ini dikarenakan beberapa kata tidak bersentimen dihilangkan dan tidak melakukan perhitungan klasifikasi.

Ada perbedaan akurasi namun waktu yang diperlukan juga signifikan. Waktu yang diperlukan metode *Naïve Bayes* dan seleksi fitur Algoritme Genetika untuk melakukan analisis sentimen ulasan kedai kopi yaitu 3 menit 3 detik, sedangkan tanpa menggunakan seleksi fitur Algoritme Genetika yaitu 12 detik. Hal ini menunjukkan kenaikan akurasi sebesar 4,4% perlu waktu 15,25 kali lipat jika menggunakan seleksi fitur Algoritme Genetika.

DAFTAR PUSTAKA

- CHEN, J., HUANG, H., TIAN, S. & QU, Y., 2009. Feature Selection for Text Classification with *Naïve Bayes*. *Expert Systems with Applications*, [daring] 36(3), hal.5432–5435. Tersedia pada: <<http://dx.doi.org/10.1016/j.eswa.2008.06.054>>.
- DARMA, I.M.B.S., PERDANA, R.S. & INDRIATI, 2018. Penerapan Sentimen Analisis Acara Televisi Pada Twitter Menggunakan Support Vector Machine dan Algoritma Genetika sebagai Metode Seleksi Fitur. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, [daring] 2(3), hal.998–1007. Tersedia pada: <<http://j-ptiik.ub.ac.id>>.
- ERNAWATI, S., YULIA, E.R., FRIEYADIE & SAMUDI, 2019. Implementation of the *Naïve Bayes* Algorithm with Feature Selection using Genetic Algorithm for Sentiment Review Analysis of Fashion Online Companies. *2018 6th International Conference on Cyber and IT Service Management, CITSM 2018*, hal.1–5.
- FEBRIYANA, R. & MAHMUDY, W.F., 2016. Penjadwalan Kapal Penyeberangan Menggunakan Algoritma Genetika. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 3(1), hal.43.
- HADNA, N.M.S., SANTOSA, P.I. & WINARNO, W.W., 2016. Studi Literatur Tentang Perbandingan Metode Untuk Proses Analisis Sentimen Di Twitter. *Seminar Nasional Teknologi Informasi dan Komunikasi (SENTIKA)*. [daring] Tersedia pada: <<https://fti.uajy.ac.id/sentika/publikasi/makalah/2016/95.pdf>>.
- HAN, J., KAMBER, M. & PEI, J., 2012. *Data Mining: Concepts and Techniques*. 3rd ed. Waltham: Morgan Kaufmann Publishers.
- HEMALATHA, I., VARMA, G.P.S. & GOVARDHAN, A., 2012. Preprocessing the Informal Text for efficient Sentiment Analysis. *International Journal of Emerging Trends & Technology in Computer Science*, 1(2), hal.58–61.
- JOHN, G.H. & LANGLEY, P., 1995. Estimating Continuous Distributions in Bayesian Classifiers George. *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*.
- LIU, B., 2012. *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers.
- MAHMUDY, W.F., 2015. Dasar-Dasar Algoritma Evolusi. *Universitas Brawijaya*.
- MANNING, C.D., RAGHAVAN, P. & SCHÜTZE, H., 2009. *An Introduction to Information Retrieval*. Cambridge: Cambridge University Press.
- RAMDHANI, S.L., ANDRESWARI, R. & HASIBUAN, M.A., 2018. Sentiment Analysis of Product Reviews using *Naïve Bayes* Algorithm: A Case Study. *The 2nd East Indonesia Conference on Computer and Information Technology: Internet of Things for Industry, EIconCIT 2018*, hal.123–127.
- RASCHKA, S., 2014. *Naive Bayes and Text Classification I - Introduction and Theory*. *CoRR*, [daring] abs/1410.5. Tersedia pada: <<http://arxiv.org/abs/1410.5329>>.
- SAPUTRI, M.W., MAHMUDY, W.F. & RATNAWATI, D.E., 2015. Optimasi Vehicle Routing Problem With Time Window (VRPTW) Menggunakan Algoritma Genetika Pada Distribusi Barang. *Repository Jurnal*

- Mahasiswa PTIIK Universitas Brawijaya*, 5(12), hal.1–10.
- SIDDIQUA, U.A., AHSAN, T. & CHY, A.N., 2017. Combining a rule-based classifier with ensemble of feature sets and machine learning techniques for sentiment analysis on microblog. *19th International Conference on Computer and Information Technology, ICCIT 2016*, hal.304–309.
- WATI, R., 2016. Penerapan Algoritma Genetika Untuk Seleksi Fitur Pada Analisis Sentimen Review Jasa Maskapai Penerbangan. *Jurnal Evolusi*, 4(1), hal.25–31.
- WEBSTER, J.J. & KIT, C., 1992. Tokenization As The Initial Phase in NLP. *Proceedings of the 14th International Conference on Computational Linguistics*.
- WITTEN, I.H., MOFFAT, A. & BELL, T.C., 1999. *Managing Gigabytes: Compressing and Indexing Documents and Images*. 2nd ed. San Francisco: Morgan Kaufmann Publishers.

Halaman ini sengaja dikosongkan