

Analisis Sentimen Konsumen terhadap *Food, Services, and Value* di Restoran dan Rumah Makan Populer Kota Makassar Berdasarkan Rekomendasi Tripadvisor Menggunakan Metode CRISP-DM dan SERVQUAL

Yerik Afrianto Singgalen*

Faculty of Business Administration and Communication, Tourism Department, Atma Jaya Catholic University of Indonesia, Jakarta, Indonesia

Email: yerik.afrianto@atmajaya.ac.id

Email Penulis Korespondensi: yerik.afrianto@atmajaya.ac.id

Submitted: 13/03/2023; Accepted: 27/03/2023; Published: 31/03/2023

Abstrak—Kuliner merupakan salah satu aktivitas ekonomi yang mendukung pertumbuhan ekonomi nasional serta merepresentasikan gastronomi nusantara. Aktivitas wisata kuliner menjadi populer bagi wisatawan nusantara dan mancanegara untuk merasakan cita rasa makanan berdasarkan kebudayaan masing-masing daerah. Makassar menjadi salah satu wilayah yang memiliki keanekaragaman jenis makanan dan minuman, serta memiliki hubungan dengan nilai-nilai sosial-budaya lokal. Mempertimbangkan hal tersebut maka penelitian ini bertujuan menganalisis sentimen konsumen terhadap makanan dan layanan di sepuluh restaurant wilayah makassar berdasarkan rekomendasi website Tripadvisor menggunakan metode Cross-Industry Standard Process for Data Mining (CRISPD-DM) serta Service Quality (SERVQUAL). Tahapan CRISP-DM ialah sebagai berikut : tahap memahami proses bisnis (business understanding); tahap memahami data (data understanding); tahap menyiapkan data (data preparation); tahap pemodelan (modeling); tahap evaluasi (evaluation); dan tahap implementasi (deployment). Algoritma yang digunakan sebagai model ialah k-Nearest Neighbor (kNN), Naïve Bayes Classifier (NBC), Decision Tree (DT) dan Support Vector Machine (SVM). Hasil penelitian ini menunjukkan bahwa algoritma DT ketika menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 93.25%, presisi sebesar 88.74%, recall sebesar 99.10%, dan f-measure sebesar 93.62%. Selanjutnya, algoritma k-NN tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 98.72%, presisi sebesar 98.72%, recall sebesar 100 % dan f-measure sebesar 99.36%. Meskipun demikian, nilai AUC yang dihasilkan ialah 0.905 (90.5%). Adapun, algoritma SVM ketika menggunakan operator SMOTE menghasilkan nilai akurasi sebesar 99.42%, presisi sebesar 100%, recall sebesar 98.84%, dan f-measure sebesar 99.42%. Adapun, nilai AUC yang dihasilkan ialah 1.000 (100%). Berdasarkan nilai ROC, terdapat tiga algoritma yang dapat digunakan sebagai model dalam kerangka kerja CRISPP-DM dan SERVQUAL yaitu algoritma k-NN tanpa SMOTE serta algoritma DT dan SVM menggunakan operator SMOTE.

Kata Kunci: SERVQUAL; CRISP-DM; DT; k-NN; NBC; SVM

Abstract—Culinary is one of the economic activities that support national economic growth and represents the gastronomy of the archipelago in Indonesia. Culinary tourism activities have become famous for domestic and foreign tourists to experience the taste of a food based on the culture of each region. Makassar is one of the regions with diverse types of food and beverages and has a relationship with local socio-cultural values. Considering this, this study aims to analyze consumer sentiment toward food and services in ten restaurants in Makassar based on the recommendations of the Tripadvisor website using the Cross-Industry Standard Process for Data Mining (CRISPD-DM) and Service Quality (SERVQUAL) methods. The stages of CRISP-DM are as follows: the stage of understanding business processes; the stage of understanding data; the stage of preparing data; the modeling stage; the evaluation stage; and the deployment stage. The algorithms used as models are k-Nearest Neighbor (kNN), Naïve Bayes Classifier (NBC), Decision Tree (DT), and Support Vector Machine (SVM). The results of this study show that the DT algorithm when using the SMOTE operator where the resulting accuracy value is 93.25%, precision is 88.74%, recall is 99.10%, and f-measure is 93.62%. In addition, the k-NN algorithm without using the SMOTE operator showed an accuracy value of 98.72%, a precision of 98.72%, a recall of 100%, and an f-measure of 99.36%. However, the resulting AUC value is 0.905 (90.5%). Meanwhile, when using the SMOTE operator, the SVM algorithm produces an accuracy value of 99.42%, a precision of 100%, a recall of 98.84%, and an f-measure of 99.42%. Meanwhile, the resulting AUC value is 1,000 (100%). Based on the ROC value, three algorithms can be used as models in the CRISPP-DM and SERVQUAL frameworks: the k-NN algorithm without SMOTE and the DT and SVM algorithms using the SMOTE operator.

Keywords: SERVQUAL; CRISP-DM; DT; k-NN; NBC; SVM

1. PENDAHULUAN

Indonesia terkenal dengan kekayaan kuliner yang beragam dan unik. Aidah berpendapat bahwa salah satu kuliner yang terkenal, unik dan populer di Indonesia ialah Nasi Goreng [1]. Lebih jauh, Aidah menjelaskan bahwa hidangan Nasi Goreng terdiri dari campuran bahan nasi dengan rempah-rempah khas Indonesia yang diberi topping telur, daging, atau makanan laut. Meskipun demikian, Aidah menekankan kasus yang lebih spesifik yakni kualitas produk dan layanan serta keputusan pembelian produk kuliner Nasi Goreng BBM Pak Gatot di Padang, Indonesia. Selain Nasi Goreng, hidangan makanan Sate juga sangat terkenal di Indonesia, dengan ciri khas daging yang dipanggang dengan kecap kemudian disajikan dengan bumbu kacang dan lontong [2]. Lebih lanjut, Sani et al. berpendapat bahwa kuliner Sate Padang merupakan gastronomi unggulan Indonesia yang menarik wisatawan. Selanjutnya, Raharjo et al. berpendapat bahwa Gado-gado juga merupakan makanan khas Indonesia yang disukai banyak orang [3]. Karakteristik masakan Gado-gado terdiri dari sayuran yang dicampur bumbu kacang dan kerupuk sebagai pengganti nasi. Hal ini menunjukkan bahwa kuliner khas Indonesia memiliki keistimewaan pada bumbu yang khas serta penggunaan bahan-

bahan yang segar. Meskipun demikian, perkembangan dan keberlanjutan wisata kuliner di Indonesia perlu dioptimalkan melalui manajemen pelayanan terhadap wisatawan secara optimal.

Kuliner Indonesia tidak terbatas pada karakteristik hidangan berupa makanan dan minuman sebagai produk unggulan, melainkan juga pelayanan yang diberikan kepada pelanggan. Mastan dan Toni menegaskan bahwa produk dan layanan wisata kuliner berperan penting dalam meningkatkan kepuasan (*satisfaction*) dan kesetiaan (*loyalty*) pelanggan [4]. Selain itu, Azzahra dan Wibowo menunjukkan bahwa kepuasan pelanggan terhadap produk dan layanan wisata kuliner dapat diidentifikasi dan dianalisis berdasarkan data teks yang tertera di sejumlah platform digital seperti *Tripadvisor* menggunakan teknik *data mining* maupun *text processing* [5]. Selanjutnya, Fauzi et al. menunjukkan bahwa era *Big Data* memungkinkan pengembang bisnis untuk memanfaatkan data digital sebagai aset dalam mengidentifikasi dan menganalisis preferensi pelanggan terkait dengan produk dan layanan wisata kuliner [6]. Adapun, Sari menunjukkan bahwa algoritma yang digunakan dalam proses analisis sentimen akan menentukan nilai akurasi, presisi dan sensitivitas sebagai rujukan performa dari algoritma yang digunakan [7]. Hal ini menunjukkan bahwa analisis sentimen konsumen terhadap produk dan layanan wisata kuliner dapat dilakukan menggunakan metode *text processing* atau *data mining*. Dengan demikian, penelitian ini menggunakan metode *Cross-Industry Standard Process for Data Mining* (CRISP-DM) dalam proses analisis sentimen.

Dalam konteks Indonesia, kajian tentang wisata kuliner bersifat kontekstual sesuai produk unggulan masing-masing daerah. Mempertimbangkan hal tersebut maka penelitian ini bertujuan mengkaji kualitas produk dan layanan wisata kuliner di Kota Makassar berdasarkan perspektif pelanggan terhadap aspek produk (makanan dan minuman), layanan (penyajian), dan nilai (harga yang layak). Adapun, metode *Cross-Industry Standard Process for Data Mining* (CRISP-DM) digunakan untuk memahami proses bisnis wisata kuliner (*business understanding*), memahami data yang akan diproses (*data understanding*), menyiapkan data (*data preparation*), membuat pemodelan (*modeling*), mengevaluasi hasil pemodelan (*evaluation*), dan menerapkan hasil pemodelan (*deployment*). Singgalen, menunjukkan bahwa analisis sentimen wisatawan terhadap produk dan layanan di destinasi, hotel, maupun *restaurant* sangat penting dilakukan untuk menghasilkan sejumlah rekomendasi bagi pihak pengelola agar dapat meningkatkan kualitas produk dan layanan sehingga mampu memenuhi ekspektasi wisatawan [8]–[12]. Dalam konteks wisata kuliner di Makassar, pendekatan CRISP-DM dapat dielaborasi dengan metode SERVQUAL di tahap evaluasi untuk meninjau persepsi konsumen terhadap kinerja penyedia jasa makanan dan minuman. Dengan demikian, dapat direkomendasikan strategi peningkatan manajemen pelayanan *restaurant* secara komprehensif dan kontekstual.

Metode SERVQUAL dapat digunakan untuk menganalisis kualitas layanan di berbagai perusahaan maupun organisasi melalui kajian yang spesifik pada dimensi bukti fisik (*tangible*), dimensi kehandalan (*reliability*), daya tanggap (*responsiveness*), jaminan (*assurance*), dan empati (*empathy*). Conde et al. menjelaskan bahwa metode SERVQUAL dapat disesuaikan dengan konteks badan usaha untuk mengevaluasi kualitas layanan berdasarkan masing-masing dimensi yang berhubungan dengan ekspektasi maupun pengalaman pelanggan ketika mengonsumsi produk dan layanan [13]. Selain itu, Juliana et al. menekankan bahwa setiap komponen dalam dimensi SERVQUAL memiliki pengaruh terhadap loyalitas konsumen, sebagaimana konteks industri *restaurant* di Indonesia. Hal ini menunjukkan bahwa metode SERVQUAL perlu dielaborasi dengan metode CRISP-DM untuk mempertajam analisis terkait dengan kepuasan wisatawan terhadap *food*, *service*, dan *value* yang diperoleh dari penyedia produk dan layanan kuliner di Kota Makassar, Indonesia. Dengan demikian, kajian ini memiliki peluang untuk berkontribusi melalui gagasan konstruktif untuk mengoptimalkan manajemen pelayanan di industri *restaurant* yang mendukung keberlanjutan wisata kuliner melalui partisipasi aktif masyarakat lokal di sektor pariwisata.

Partisipasi masyarakat lokal dalam aktivitas wisata kuliner dapat meningkatkan pendapatan per-kapita, mendorong pertumbuhan ekonomi keluarga, meningkatkan kesejahteraan sosial, serta memudahkan akses terhadap berbagai sumberdaya hingga kepentingan yang berhubungan dengan keberlanjutan penghidupan. Putra et al. menjelaskan bahwa bentuk partisipasi masyarakat lokal dalam pengembangan wisata kuliner dapat diidentifikasi dari berbagai kegiatan, mulai dari proses pengumpulan bahan baku, proses pengolahan bahan baku, alat-alat yang digunakan dalam proses pengolahan, proses ketika produk telah matang dan siap dikonsumsi [14]. Samtono et al. menekankan bahwa keterlibatan masyarakat lokal sebagai pelaku usaha menunjukkan adanya inisiatif untuk mengembangkan ekonomi kreatif melalui pengolahan produk pangan menjadi daya tarik wisata [15]. Hal ini menunjukkan bahwa wisata kuliner dapat dilihat dari perspektif penyedia produk dan layanan, serta perspektif wisatawan sebagai konsumen. Dalam konteks penelitian ini, penyedia produk dan layanan untuk kuliner di Kota Makassar fokus pada rumah makan atau *restaurant* yang direkomendasikan website *Tripadvisor* sebagai 10 rumah makan atau *restaurant* terbaik di Makassar sebagai berikut : *The Eatery Restaurant*, *Golden Asian*, *Gravity Sky Lounge*, *Pallu Basa Serigala*, *La Piccola Italy*, *Rumah Makan Nelayan*, *Coto Nusantara*, *Rumah Makan Seafood Apong*, *Sop Konro Karebossi* dan *Lae Lae*. Dengan demikian, batasan sekaligus fokus utama dalam penelitian ini ialah data teks dalam bentuk ulasan terhadap makanan (*food*), layanan (*services*), dan nilai (*value*).

Perkembangan wisata kuliner juga berhubungan dengan identitas kebudayaan masyarakat di suatu daerah yang berhubungan dengan gastronomi, dimana warisan budaya dalam bentuk bahan baku makanan serta rempah-rempah yang dapat dikonsumsi oleh khalayak. Utami menegaskan bahwa kuliner merupakan identitas budaya, oleh sebab itu kuliner melambangkan identitas sosial masyarakat sekaligus sebagai bentuk komunikasi yang efektif dari budaya yang khas dengan karakter nasional yang kuat serta fitur yang beragam [16]. Disisi lain, Rusmaniah et al. berpendapat bahwa seiring dengan perkembangan zaman, keberadaan kuliner lokal di Indonesia mulai kurang dikenali oleh generasi sekarang seiring dengan masuknya berbagai produk makanan import [17]. Berdasarkan studi kasus pada

penyedia produk dan jasa kuliner di Makassar sesuai rekomendasi website *Tripadvisor*, dapat diketahui adanya bauran antara penyedia produk dan jasa kuliner khas lokal dengan produk dan jasa kuliner dari daerah bahkan negara lain. Hal ini menunjukkan bahwa analisis sentimen wisatawan terhadap kualitas produk dan jasa kuliner terhadap produk makanan dan minuman lokal maupun dari negara lain dapat dianalisis dan dilakukan perbandingan, untuk memberikan rekomendasi yang relevan. Dengan demikian luaran penelitian ini dapat berkontribusi secara konseptual terhadap perkembangan wisata kuliner di Makassar, Indonesia.

Penelitian ini mengadopsi algoritma *k-Nearest Neighbor* (k-NN), *Decision Tree* (DT), *Naïve Bayes Classifier* (NBC), dan *Support Vector Machine* (SVM) untuk menguji performa serta menganalisis relevansi penggunaan model sesuai konteks dan data teks. Anissa menunjukkan bahwa masing-masing algoritma yang digunakan perlu dievaluasi untuk mengidentifikasi akurasi, *recall*, dan *presisi* sehingga dapat diperoleh informasi tentang algoritma dengan performa terbaik [18]. Adapun, Dewi juga menunjukkan bahwa masing-masing perusahaan maupun organisasi memiliki kompleksitas data yang perlu dikelola menggunakan metode klasifikasi melalui berbagai algoritma untuk pengambilan keputusan yang menentukan keberlangsungan operasional bisnis, manajemen layanan, sistem produksi dan distribusi, maupun berbagai kepentingan lainnya [19]. Selain itu, Barro et al. menekankan bahwa data yang dikelola memiliki tipe, label, atribut dan kuantitas yang berbeda-beda, sehingga diperlukan operator *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyeimbangkan data sebelum diuji menggunakan algoritma [20]. Selanjutnya, Haranto dan Sari menegaskan bahwa nilai *confusion matrix* akan menunjukkan performa algoritma terbaik yang relevan dengan konteks dan data set [21]. Hal ini menunjukkan bahwa kerangka kerja CRISP-DM pada tahap pemodelan perlu mempertimbangkan konteks analisis data dan dataset yang dikelola, selanjutnya dapat dievaluasi berdasarkan metode SERVQUAL untuk memberikan rekomendasi yang sesuai. Adapun, konteks pembahasan penelitian ini terkait dengan wisata kuliner di kota Makassar, Indonesia.

Analisis sentimen konsumen terhadap makanan, layanan, dan nilai yang diberikan di restoran dan rumah makan sangat penting untuk meningkatkan pengalaman pelanggan dan kepuasan mereka. Melalui analisis sentimen, pemilik bisnis dapat memahami apa yang diinginkan pelanggan, apa yang mereka sukai, dan apa yang perlu diperbaiki. Analisis sentimen juga dapat membantu meningkatkan kualitas produk dan layanan yang ditawarkan, serta meningkatkan reputasi bisnis. Selain itu, analisis sentimen juga berkontribusi pada penelitian tentang analisis sentimen secara keseluruhan, dengan memberikan contoh kasus nyata yang dapat digunakan sebagai bahan penelitian lebih lanjut. Dengan demikian, analisis sentimen konsumen di restoran dan rumah makan bukan hanya penting bagi bisnis itu sendiri, tetapi juga memiliki nilai penting dalam pengembangan penelitian tentang analisis sentimen. Penelitian ini lebih fokus pada aspek emosional dan pengalaman pelanggan dalam mengonsumsi makanan dan layanan di tempat makan. Selain itu, penelitian ini juga mencakup analisis terhadap nilai yang diberikan oleh bisnis dalam hal harga dan kualitas produk yang ditawarkan. Selain itu, faktor lingkungan juga menjadi salah satu faktor penting yang memengaruhi sentimen pelanggan dalam konteks penelitian ini. Oleh karena itu, penelitian analisis sentimen konsumen terhadap makanan, layanan, dan nilai di restoran dan rumah makan memiliki fokus dan pendekatan yang unik dibandingkan dengan penelitian analisis sentimen lainnya.

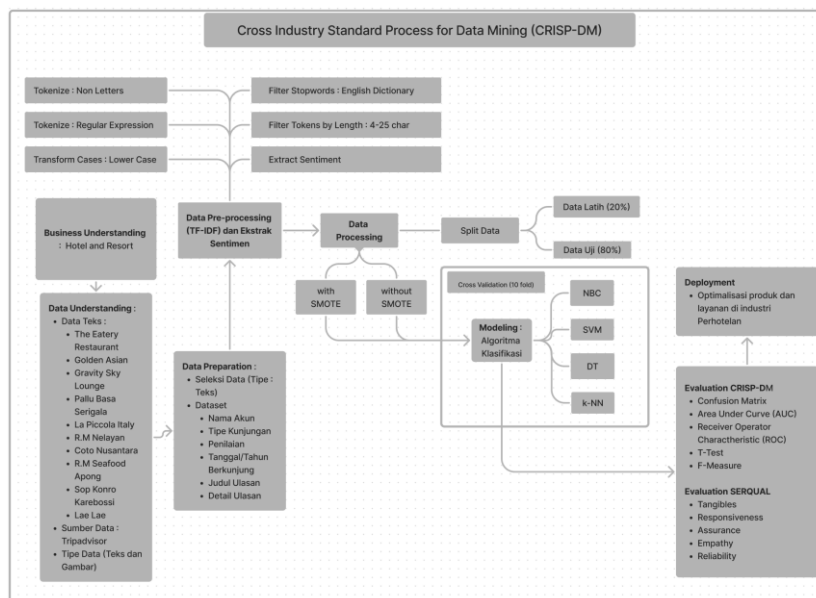
2. METODOLOGI PENELITIAN

2.1 Cross-Industry Standard Process for Data Mining (CRISP-DM) and Service Quality (SERVQUAL)

Metode yang digunakan dalam analisis sentimen wisatawan terhadap kualitas layanan hotel dan resort di Lombok ialah *Cross Industry Standard Process for Data Mining* (CRISP-DM) yang dihubungkan dengan metode *Service Quality* (SERVQUAL). Metode CRISP-DM meliputi beberapa tahapan sebagai berikut : tahap memahami proses bisnis (*business understanding*), tahap memahami data (*data understanding*), tahap menyiapkan data (*data preparation*), tahap pemodelan (*modeling*), tahap evaluasi (*evaluation*) dan tahap implementasi (*deployment*). Sementara itu, metode SERVQUAL menekankan pada dimensi bukti fisik (*tangible*), dimensi daya tanggap (*responsiveness*), dimensi kehandalan (*reliability*), dimensi jaminan (*assurance*), dimensi empati (*empathy*). Latarbelakang penggunaan metode CRISP-DM ialah untuk mengidentifikasi sentimen, mengklasifikasi data sentimen, dan menganalisis data sentimen wisatawan terhadap kualitas produk dan layanan di hotel. Sementara itu, metode SERVQUAL digunakan untuk mengklasifikasi data sentimen serta menganalisis kepuasan pelanggan.

Gambaran tentang implementasi metode CRISP-DM dan SERVQUAL ialah sebagai berikut : tahap *business understanding*, dilakukan studi literatur tentang manajemen pelayanan *restaurant*, psikologi pelayanan, perilaku wisatawan, dan analisis sentimen tamu *restaurant* untuk memahami preferensi pasar wisata kuliner berdasarkan konteks wilayah Makassar, Indonesia; tahap *data understanding*, dilakukan seleksi dan validasi data teks dalam bentuk ulasan member website *Tripadvisor* berdasarkan kategori nama akun, penilaian, judul, ulasan, tipe kunjungan (*solo, couple, with friends, with family*), serta tanggal berkunjung ke *restaurant* tersebut; tahap *data preparation*, dilakukan proses seleksi data yang akan dibersihkan (*tokenize, transform cases, filter stopwords, filter tokens by length*); tahap *data processing*, dilakukan pembagian data latih (20%) dan data uji (80%), kemudian dilakukan pengujian algoritma menggunakan operator SMOTE Upsampling serta dilakukan perbandingan dengan hasil pengujian algoritma tanpa menggunakan SMOTE Upsampling untuk menganalisis nilai *Area Under Curve* (AUC); tahap *modeling*, dilakukan klasifikasi dataset menggunakan operator *cross validation* pada algoritma algoritma *k-Nearest Neighbor* (k-NN), *Decision Tree* (DT), *Naïve Bayes Classifier* (NBC), dan *Support Vector Machine* (SVM) untuk mengetahui algoritma

dengan performa terbaik; tahap *evaluation*, dilakukan analisis nilai *confusion matrix*, *Area Under Curve* (AUC), dan *Receiver Operating Characteristic* (ROC), f-measures, and T-Test. Adapun, hasil klasifikasi data berdasarkan ekstrak sentimen yang divisualisasi menggunakan wordcloud/bar-column akan dihubungkan dengan setiap dimensi dalam metode SERVQUAL yakni dimensi bukti fisik (*tangible*), dimensi daya tanggap (*responsiveness*), dimensi kehandalan (*reliability*), dimensi jaminan (*assurance*), dimensi empati (*empathy*); tahap deployment, diberikan rekomendasi model dan luaran hasil analisis sentimen berdasarkan CRISP-DM dan SERVQUAL untuk mengoptimalkan produk dan layanan *restaurant* maupun rumah makan. Adapun, alur dari keseluruhan tahapan dapat dilihat pada gambar 1 berikut ini.



Bagan 1. Tahapan Penelitian sesuai CRISP-DM dan SERVQUAL

Bagan 1 merupakan perpaduan antara metode CRISP-DM dan metode SERVQUAL dalam menganalisis analisis sentimen konsumen terhadap *food*, *service*, and *value* di sepuluh restaurant atau rumah makan populer versi Tripadvisor, menggunakan algoritma k-NN, NBC, DT, dan SVM. Berdasarkan hasil pengumpulan data, terdapat sepuluh *restaurant* serta rumah makan di Kota Makassar versi Tripadvisor, sebagai berikut : *The Eatery Restaurant*; *Golden Asian*; *Gravity Sky Lounge*; *Pallu Basa Serigala*; *La Piccola Italy*; *Rumah Makan Nelayan*; *Coto Nusantara*; *Rumah Makan Seafood Apong*; *Sop Konro Karebossi*; dan *Lae Lae*. Adapun, informasi terkait sumber dan jumlah data sebelum maupun setelah dilakukan penyaringan, dapat dilihat pada tabel berikut.

Tabel 1. Data Restaurant serta Rumah Makan Populer Versi Tripadvisor

Dataset	Jumlah Data (Sebelum Filter)	Jumlah Data (Setelah Filter)	Link Tripadvisor
The Eatery Restaurant	294	284	https://www.tripadvisor.com/Restaurant_Review-g297720-d12362862-Reviews-The_Eatery_Restaurant-Makassar_South_Sulawesi_Sulawesi.html
Golden Asian	161	155	https://www.tripadvisor.com/Restaurant_Review-g297720-d12362889-Reviews-Golden_Asian-Makassar_South_Sulawesi_Sulawesi.html
Gravity Sky Lounge	172	169	https://www.tripadvisor.com/Restaurant_Review-g297720-d13396542-Reviews-Gravity_Sky_Lounge-Makassar_South_Sulawesi_Sulawesi.html
Pallu Basa Serigala	473	430	https://www.tripadvisor.com/Restaurant_Review-g297720-d7347714-Reviews-Pallu_Basa_Serigala-Makassar_South_Sulawesi_Sulawesi.html
La Piccola Italy	163	149	https://www.tripadvisor.com/Restaurant_Review-g297720-d12948284-Reviews-La_Piccola_Italy-Makassar_South_Sulawesi_Sulawesi.html
R.M. Nelayan	265	238	https://www.tripadvisor.com/Restaurant_Review-g297720-d3512865-Reviews-R_M_Nelayan-Makassar_South_Sulawesi_Sulawesi.html
Coto Nusantara	421	389	https://www.tripadvisor.com/Restaurant_Review-g297720-d6415175-Reviews-Coto_Nusantara-Makassar_South_Sulawesi_Sulawesi.html
R.M. Seafood Apong	308	285	https://www.tripadvisor.com/Restaurant_Review-g297720-d6598861-Reviews-Rumah_Makan_Seafood_Apong-Makassar_South_Sulawesi_Sulawesi.html
Sop Konro Karebossi	483	437	https://www.tripadvisor.com/Restaurant_Review-g297720-d6168215-Reviews-Sop_Konro_Karebossi-Makassar_South_Sulawesi_Sulawesi.html
Lae Lae	310	215	https://www.tripadvisor.com/Restaurant_Review-g297720-d1190015-Reviews-Lae_Lae-Makassar_South_Sulawesi_Sulawesi.html

Tabel 1 merupakan dataset yang digunakan dalam proses klasifikasi untuk analisis sentimen konsumen terhadap *food*, *service*, dan *value* dari masing-masing restaurant atau rumah makan di Kota Makassar, berdasarkan versi website Tripadvisor. Terdapat sepuluh data dari masing-masing restaurant atau rumah makan yang dikumpulkan dan disaring dari website Tripadvisor sebagai berikut : *The Eatery Restaurant*, jumlah data setelah difilter ialah 284

dari 294; *Golden Asian*, jumlah data setelah difilter ialah 155 dari 161; *Gravity Sky Lounge*, jumlah data setelah difilter ialah 169 dari 172; *Pallu Basa Serigala*, jumlah data setelah difilter ialah 430 dari 473; *La Piccola Italy*, jumlah data setelah difilter ialah 149 dari 163; *Rumah Makan Nelayan*, jumlah data setelah difilter ialah 238 dari 265; *Coto Nusantara*, jumlah data setelah difilter ialah 389 dari 421; *Rumah Makan Seafood Apung*, jumlah data setelah difilter ialah 285 dari 308; *Sop Konro Karebossi*, jumlah data setelah difilter ialah 437 dari 489; *Lae Lae*, jumlah data setelah difilter ialah 215 dari 310. Dalam konteks analisis sentimen konsumen terhadap *food*, *service*, dan *value*, seluruh data dijumlahkan untuk diproses sesuai dengan kerangka kerja CRISP-DM dan SERVQUAL.

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

Term Frequency-Inverse Document Frequency (TF-IDF) adalah salah satu teknik pemrosesan bahasa alami yang umum digunakan dalam analisis teks, termasuk analisis sentimen. Lebih jauh, Vitandi et al. menjelaskan bahwa TF-IDF digunakan untuk mengukur seberapa penting suatu kata dalam dokumen atau korpus melalui tahapan dalam proses sebagai berikut : tokenisasi; pre-processing; menghitung Term Frequency (TF); menghitung Inverse Document Frequency (IDF); mengalikan TF dan IDF. Pada tahap tokenisasi, dokumen atau teks yang akan dianalisis dibagi menjadi token, yakni unit terkecil yang bisa diolah oleh program. Pada tahap ini, tanda baca, angka, dan kata penghubung biasanya dihilangkan. Selanjutnya, pada tahap preprocessing, token-token yang telah dihasilkan pada tahap sebelumnya diproses lebih lanjut, seperti menghilangkan kata-kata yang tidak penting (stop words), mengubah kata menjadi bentuk dasar (stemming), dan melakukan normalisasi seperti mengubah kata yang ditulis dengan huruf besar menjadi huruf kecil. Selanjutnya, pada tahap menghitung term frequency (TF), frekuensi kemunculan setiap token dalam dokumen dihitung. Hal ini dilakukan untuk mengetahui seberapa sering sebuah kata muncul dalam dokumen. Kemudian pada tahap menghitung inverse document frequency (IDF), bobot diberikan pada setiap kata berdasarkan seberapa umum kata tersebut dalam korpus teks. Kata-kata yang jarang muncul pada korpus akan memiliki bobot yang lebih tinggi daripada kata-kata yang sering muncul. Adapun, tahap akhirnya ialah mengalikan TF dengan IDF, nilai TF dan IDF dikalikan untuk menghasilkan skor TF-IDF yang akan digunakan sebagai dasar untuk menganalisis sentimen [22].

Pada kerangka kerja CRISP-DM proses TF-IDF dilakukan untuk memahami data dan menyipakan data (tahap *data understanding* dan *data preparation*), proses seleksi diperlukan untuk membersihkan dan merapikan data ulasan yang telah dikumpulkan. Selanjutnya, pembobotan kata diperlukan untuk memperoleh informasi tentang jumlah kata yang paling sering muncul dalam data ulasan. Pembobotan kata merupakan proses pemberian nilai pada setiap kata yang telah melewati tahap *Pre-Processing*. Penelitian ini menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) dengan persamaan (1) dan (2) berikut :

$$IDF(w) = \log\left(\frac{N}{DF(w)}\right) \quad (1)$$

$$W_{ij} = TF_{ij} \times \log\left(\frac{D}{DF_j}\right) \quad (2)$$

Kosasih dan Alberto menunjukkan bahwa proses pembobotan kata dapat dilakukan dengan beberapa tahapan sebagai berikut : pertama, menghitung jumlah Term Frequency (TF) tiap kata, dimana kalimat yang telah dipisah menjadi kata akan diberi nilai dan setiap kata yang muncul akan diberi nilai 1; kedua, menghitung jumlah *Document Frequency* (DF) tiap kata dengan cara menjumlahkan nilai TF pada tiap kata; ketiga, menghitung jumlah *Inverse Document Frequency* (IDF) yang ditunjukkan pada persamaan (1); keempat, menghitung bobot (*Weight*) pada tiap kata yang diperoleh dari hasil perkalian nilai TF dengan IDF sebagaimana persamaan (2) [23]. Ardiansyah et al. menjelaskan bahwa TF-IDF merupakan metode yang berguna untuk mengekstrak fitur-fitur penting dari teks dalam analisis sentimen [24]. Dalam analisis sentimen, TF-IDF dapat membantu mengidentifikasi kata-kata atau frasa-frasa yang paling sering muncul pada teks dengan sentimen positif atau negatif, dan dapat digunakan sebagai fitur pada model klasifikasi [25]. Dengan menggunakan metode ini, kita dapat memperoleh informasi yang lebih relevan dan bermanfaat dari data teks, sehingga dapat meningkatkan kinerja model klasifikasi dalam memprediksi sentimen dari teks baru.

2.3 Synthetic Minority Oversampling Technique (SMOTE)

Synthetic Minority Oversampling Technique (SMOTE) adalah teknik resampling data yang umum digunakan dalam machine learning, khususnya untuk menangani masalah ketidakseimbangan kelas [26]. SMOTE menghasilkan sampel baru yang mirip dengan data minoritas dengan cara membuat sampel sintesis baru dari data yang sudah ada. Lebih jauh, Sofyan dan Prasetya menjelaskan beberapa tahapan dalam implementasi SMOTE sebagai berikut : menentukan kelas minoritas; memilih sampel minoritas; menghitung jarak antara sampel; memilih tetangga-tetangga terdekat; membuat sampel sintesis baru; menguji performa model. Secara spesifik, pada tahap menentukan kelas minoritas, kelas minoritas dalam kasus analisis sentimen adalah kelas sentimen negatif. Selanjutnya, pada tahap memilih sampel minoritas, sampel-sampel yang termasuk dalam kelas minoritas dipilih untuk melakukan proses oversampling. Pada tahap menghitung jarak antara sampel, jarak antara setiap sampel dalam kelas minoritas dihitung untuk menentukan sampel-sampel mana yang akan digunakan untuk membuat sampel sintesis baru. Pada tahap memilih tetangga-tetangga terdekat, setelah jarak antara setiap sampel dihitung, tetangga-tetangga terdekat dipilih untuk digunakan dalam proses pembuatan sampel sintesis. Kemudian, pada tahap membuat sintesis baru, setelah tetangga-tetangga

terdekat dipilih, sampel sintetis baru dibuat dengan cara mengambil perbedaan antara sampel minoritas dan tetangga-tetangganya, dan mengalikan dengan bilangan acak antara 0 dan 1. Sampel sintetis baru ini kemudian ditambahkan ke data latih sebagai data baru. Adapun, pada tahap menguji performa model, setelah proses oversampling selesai dilakukan, model yang telah dilatih menggunakan data baru tersebut dievaluasi untuk melihat apakah performanya meningkat [27].

Penelitian ini menggunakan operator SMOTE Upsampling di aplikasi Rapidminer untuk mengatasi masalah ketidakseimbangan data, terutama pada dataset Gunung Rinjani. Barro et al. berpendapat bahwa ketidakseimbangan data akan terjadi apabila jumlah objek di suatu kelas data memiliki kuantitas yang lebih tinggi dibandingkan dengan kelas lain, dimana kelas data yang objeknya lebih banyak disebut kelas mayor sedangkan yang lain disebut minor [28]. Disisi lain, Kurniawati menekankan bahwa pengolahan algoritma yang tidak mempertimbangkan ketidakseimbangan data cenderung menitikberatkan kelas mayor dan bukan kelas minor, oleh sebab itu diperlukan teknik SMOTE yang menggunakan metode oversampling untuk memperbanyak pengamatan secara acak dengan menambah jumlah data kelas minor (data buatan) agar setara dengan kelas mayor [29]. Adapun, data buatan atau sintesis tersebut dibuat berdasarkan *k*-tetangga terdekat (*k-Nearest Neighbor*). Pembangkit data buatan yang berskala numerik diukur jarak kedekatannya dengan jarak euclidean sedangkan data kategorik berdasarkan kelas minor yang berubahnya berskala kategorik, dilakukan dengan rumus *Value Difference Metric* (VDM) yaitu :

$$\Delta(x, y) = w_x w_y \sum_{i=1}^N \delta(x_i y_i)^r \tag{3}$$

Persamaan (3) merupakan proses untuk membangkitkan data numerik. Dimana $\Delta(x, y)$ adalah jarak antara amatan x dengan y , sementara $w_x w_y$ merupakan bobot amatan (dapat diabaikan), N merupakan banyaknya pebuah penjelas, r bernilai 1 (jarak manhattan) atau 2 (jarak euclidean), serta $\delta(x_i y_i)^r$ jarak antar kategori. Adapun, proses pembangkit data buatan (sintesis) untuk data numerik dilakukan dengan menghitung perbedaan antar vektor utama dengan *k*-tetangga terdekatnya, kalikan perbedaan dengan angka yang diacak diantara 0 dan 1, kemudian tambahkan perbedaan tersebut ke dalam nilai utama pada vektor utama asal sehingga diperoleh vektor utama yang baru. Selanjutnya, pembangkit data kategorik dapat dilakukan melalui persamaan (4) sebagai berikut.

$$\delta(V_1 V_2) = \sum_{i=1}^n \left| \frac{C_{1i}}{c_1} - \frac{C_{2i}}{c_2} \right|^k \tag{4}$$

Dimana, $\delta(V_1 V_2)$ merupakan jarak antara nilai V_1 dan V_2 sedangkan C_{1i} merupakan banyaknya V_1 yang termasuk kelas I, dan C_{2i} merupakan banyaknya V_2 yang termasuk kelas I. Sementara itu, i merupakan banyaknya kelas, C_1 banyaknya nilai 1 terjadi, C_2 banyaknya nilai 2 terjadi, n merupakan banyaknya kategori, dan k merupakan konstansa. Proses pembangkitan data buatan (sintesis) untuk data kategori dilakukan dengan memilih mayoritas antara vektor utama yang dipertimbangkan dengan *k*-tetangga terdekatnya untuk nilai nominal, jika nilai sama maka akan dipilih secara acak. Selanjutnya, nilai tersebut dijadikan data contoh kelas buatan yang baru. Disisi lain, Heranova menjelaskan bahwa SMOTE merupakan teknik oversampling yang berguna dalam mengatasi masalah ketidakseimbangan kelas pada data teks dalam analisis sentimen [30]. Dalam analisis sentimen, kelas minoritas seperti sentimen negatif sering kali memiliki jumlah sampel yang lebih sedikit dibandingkan kelas mayoritas seperti sentimen positif. Dengan menggunakan SMOTE, kita dapat menghasilkan sampel sintetis baru yang mirip dengan data minoritas, sehingga dapat meningkatkan kualitas dan akurasi model klasifikasi [31]. Dengan demikian, SMOTE dapat membantu meningkatkan kinerja model klasifikasi dalam memprediksi sentimen dari teks baru dengan kelas minoritas yang lebih seimbang.

2.4 Algoritma Naïve Bayes Classifier

Naive Bayes Classifier (NBC) memiliki keunggulan tersendiri dalam mengklasifikasikan data dengan probabilitas sederhana melalui teorema Bayes dengan asumsi independensi yang tinggi [32]. Studi ini didasarkan pada jumlah dataset yang digunakan dalam metode dengan kemampuan klasifikasi yang cepat dan akurat. Pengklasifikasi Naive Bayesian hanya membutuhkan data pelatihan dalam jumlah yang relatif kecil untuk menentukan estimasi parameter yang diperlukan untuk proses klasifikasi. Pada tahap klasifikasi, nilai kelas ditentukan dari data yang didasarkan pada suku yang terjadi, dengan menggunakan persamaan berikut.

$$P(X_k|Y) = \frac{P(Y|X_k)}{\sum_i P(Y|X_i)} \tag{5}$$

Dimana, keadaan posterior (Probabilitas X_k di dalam Y) dapat dihitung dari keadaan prior (Probabilitas Y di dalam X_k) dibagi dengan jumlah dari semua probabilitas Y di dalam semua X_i . Dalam konteks penelitian ini, data teks yang diperoleh dari website Tripadvisor diklasifikasi menggunakan persamaan berikut

$$P(v1|C=c) = \frac{CountTerms(v1, docsv(c))}{AllTerms(docs(c))} \tag{6}$$

Dimana $v1$ merupakan salah satu suku kata yang muncul dalam ulasan pengguna website Tripadvisor terhadap kualitas produk dan layanan di Destinasi Wisata Candi Borobudur. Sedangkan, $CountTerms(v1, docsv(c))$ merujuk pada jumlah kemunculan suatu kata berlabel c (“positif” atau “negatif”). Adapun, $AllTerms(docs(c))$ merujuk pada jumlah semua kata berlabel c yang ada pada dataset. Untuk menghindari adanya nilai nol pada probabilitas maka

diimplementasikan laplace smoothing, untuk mengurangi probabilitas dari hasil yang terobservasi, dan jua meningkatkan probabilitas hasil yang belum terobservasi. Dengan demikian, persamaan yang digunakan ialah sebagai berikut :

$$P(v_1|C=c) = \frac{\text{CountTerms}(v_1, \text{docsv}(c))+1}{\text{AllTerms}(\text{docs}(c))+|V|} \tag{7}$$

Dimana $|V|$ merujuk pada jumlah semua kata dalam data ulasan yang ada di dataset. Dengan demikian, proses klasifikasi data ulasan akan menunjukkan kata dengan nilai tertinggi sebagai representasi perhatian pengulas terhadap produk dan jasa layanan yang diterima.

2.5 Algoritma Support Vector Machine

Support Vector Machine (SVM) merupakan salah satu algoritma yang dapat digunakan untuk klasifikasi data menggunakan hyperplane [33]. Karim menjelaskan bahwa konsep SVM menitikberatkan pada *risk minimization*, yaitu estimasi fungsi dengan cara meminimalisir batas dari *generalization error*, sehingga SVM mampu mengatasi *overfitting* [34]. Adapun, fungsi regresi dari metode SVM adalah sebagai berikut.

$$f(x) = w^T \varphi(x) + b \tag{8}$$

Dimana w merupakan vector pembobot, $\varphi(x)$ merupakan sebuah fungsi yang memetakan x ke dalam suatu dimensi, dan b merupakan faktor bias. Selanjutnya, Nida et al., menunjukkan bahwa SVM memiliki kelebihan dalam generalisasi data yang tinggi serta mampu menghasilkan model klasifikasi yang baik meskipun dilatih dengan data yang relatif sedikit. Meskipun demikian, sangat sulit diaplikasikan untuk himpunan data dengan sampel dan dimensi yang besar [35].

2.6 Evaluasi Klasifikasi (Confusion Matrix)

Pada tahap evaluasi, setiap algoritma akan dievaluasi berdasarkan nilai akurasi, presisi, *recall*, dan nilai *f-measure*. Evaluasi klasifikasi didasarkan pada pengujian pada objek yang benar dan objek yang salah. Validasi digunakan untuk menentukan jenis model yang terbaik melalui *confusion matrix* sebagai informasi mengenai hasil klasifikasi actual yang dapat diprediksi oleh suatu sistem melalui nilai akurasi, presisi, dan *recall*, melalui persamaan berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+FN} \tag{9}$$

$$\text{Presisi/Specificity} = \frac{TP}{TP+FP} \tag{10}$$

$$\text{Recall/Sensitivity} = \frac{TP}{TP+FN} \tag{11}$$

$$f - \text{measure} = \frac{2x(\text{Presisi} \times \text{recall})}{\text{presisi} + \text{recall}} \tag{12}$$

Ginantra et al., berpendapat bahwa *confusion matrix* merupakan gambaran akan akurasi, presisi, *recall* dari proses klasifikasi data. Akurasi adalah ketepatan sistem dalam melakukan proses klasifikasi dengan benar; presisi atau *sensitivity* adalah rasio jumlah dokumen yang relevan dengan total jumlah dokumen yang ditemukan pada sistem klasifikasi; *recall* atau *specificity* adalah rasio jumlah dokumen yang ditemukan kembali oleh sistem klasifikasi dengan total jumlah dokumen yang relevan; *f-measure* adalah metrik evaluasi yang populer untuk menangani masalah *imbalance class* dengan mengombinasikan *recall*/sensivitas dan presisi sehingga menghasilkan metrik yang efektif untuk mencari kembali informasi dalam himpunan yang tidak seimbang [36]. Dengan demikian, evaluasi performa algoritma terbaik dapat direkomendasikan sebagai model yang relevan dengan dataset untuk memperoleh luaran analisis sentimen yang tergolong *fit* atau sesuai.

3. HASIL DAN PEMBAHASAN

Kuliner Indonesia mengalami perkembangan seiring dengan meningkatnya aktivitas wisata di berbagai daerah. Suteja dan Wahyuningsih menegaskan bahwa invensi budaya kuliner di Indonesia melalui komodifikasi kegiatan penunjang pariwisata sangat efektif dalam mendukung pertumbuhan pariwisata daerah hingga nasional [37]. Hal ini menunjukkan bahwa aktivitas perjalanan wisata secara tidak langsung mendorong pertumbuhan kuliner Indonesia. Sinaga et al. menegaskan bahwa ketahanan aktivitas wisata kuliner juga didukung oleh pemasaran wisata kuliner menggunakan teknologi informasi [38]. Khair et al. menegaskan bahwa pelatihan penggunaan teknologi terhadap pelaku bisnis kuliner menjadi salah satu faktor pendukung optimalisasi teknologi informasi dalam pemasaran usaha kuliner [39]. Hal ini menunjukkan bahwa teknologi menjadi media komunikasi yang efektif digunakan oleh konsumen bisnis kuliner untuk mengatur perjalanan wisata kuliner di suatu daerah, hingga keputusan untuk membeli produk makanan dan minuman di suatu unit usaha atau bisnis kuliner sesuai preferensi terhadap makanan (*food*), pelayanan (*service*), dan nilai (*value*). Dengan demikian, penelitian ini akan membahas hasil analisis sentimen konsumen terhadap makanan (*food*), pelayanan (*service*), dan nilai (*value*) berdasarkan konteks wisata kuliner di Kota Makassar, Indonesia.



Sentimen konsumen terhadap produk dan layanan di rumah makan maupun restaurant dipengaruhi oleh berbagai faktor seperti makanan (*food*), layanan (*service*), dan nilai (*value*). Mastan dan Toni menunjukkan bahwa persepsi konsumen terhadap produk dan makanan di rumah makan maupun *restaurant* perlu dianalisis secara komprehensif agar dapat memberikan rekomendasi yang tepat dan relevan bagi para pengusaha bisnis kuliner di Indonesia [40]. Disisi lain, Asmara et al. menegaskan bahwa opini konsumen yang dipublikasikan melalui berbagai media terkait produk dan layanan di rumah makan maupun *restaurant* mencerminkan citra wisata kuliner Indonesia [41]. Adapun, Fauzi et al. menekankan bahwa pendekatan *big data* melalui kajian analisis sentimen konsumen produk dan layanan Usaha Mikro Kecil dan Menengah (UMKM) diperlukan untuk mengidentifikasi faktor-faktor yang menghambat perkembangan UMKM khususnya di sektor bisnis kuliner [42]. Hal ini menunjukkan bahwa analisis sentimen di bidang pariwisata perlu dikaji secara komprehensif berdasarkan konteks baik destinasi, hotel, rumah makan maupun *restaurant*, sehingga dapat diketahui persepsi konsumen terhadap kualitas produk dan layanan [8], [9], faktor-faktor yang memengaruhi kepuasan wisatawan [10], [43], serta faktor-faktor yang menghambat pertumbuhan bisnis di bidang pariwisata [11], [12] sehingga dapat diberikan rekomendasi yang sesuai.

Penilaian konsumen terhadap makanan (*food*), pelayanan (*service*), dan nilai (*value*) dapat dikaji dari perspektif SERVQUAL. Sari dan Siregar menunjukkan bahwa SERVQUAL terdiri dari beberapa dimensi, sebagai berikut : dimensi bukti fisik (*tangibles*); dimensi daya tanggap (*responsiveness*); dimensi kehandalan (*reliability*); dimensi jaminan (*assurance*); dimensi empati (*empathy*) [44]. Lebih jauh, Trianata menunjukkan bahwa tantangan dalam pengembangan bisnis kuliner ialah kualitas pelayanan terhadap konsumen, dimana kendala yang sering dihadapi pelaku bisnis kuliner terkait kualitas layanan pramusaji ialah rendahnya disiplin dalam mengikuti pelatihan *Standard Operational Procedure* (SOP), waktu penyajian makanan yang lamban, tidak berpenampilan rapi dan memperhatikan SOP tentang kebersihan (*hygiene*) dan sanitasi, minim pengetahuan tentang menu serta tidak fasih dalam menjelaskan menu secara detail menggunakan bahasa asing, tidak tanggap terhadap permintaan dan keluhan konsumen [45]. Hal ini menunjukkan bahwa SERVQUAL dapat digunakan dalam mengklasifikasi sentimen negatif dan positif konsumen dalam data ulasan (data teks) yang diproses melalui kerangka kerja CRISP-DM. Adapun, hasil klasifikasi data teks berdasarkan alat ukur SERVQUAL dapat dilihat pada table 2 berikut.

Tabel 2. Klasifikasi Data Teks Berdasarkan SERVQUAL

SERVQUAL	Kata	Jumlah Kata dalam Klasifikasi Negatif	Jumlah Kata dalam Klasifikasi Positif
Tangible	Food	0	1298
	Tempat	26	1262
	Nyaman	6	386
	Restaurant	12	758
	Ruangan	2	86
Responsiveness	Pelayanan	6	384
	Cepat	2	256
	Menyajikan	0	70
	Disediakan	4	52
Reliability	Dilayani	0	60
	Memuaskan	0	290
	Friendly	0	144
	Membantu	0	116
Assurance	Menyenangkan	0	68
	Senang	0	58
	Dijamin	0	44
	Authentic	2	62
	Reasonable	0	52
Empathy	Istimewa	6	42
	Kenyang	0	46
	Ramah	10	596
	Sopan	0	40
	Disambut	0	36
	Baik	4	606
	Terbaik	2	198

Tabel 2 merupakan tahapan dalam proses TF-IDF di aplikasi Rapidminer dapat dijelaskan sebagai berikut : memilih dokumen yang ingin diolah; menyiapkan dan membersihkan data, dokumen diproses dengan menghilangkan karakter-karakter tidak penting seperti tanda baca, angka, dan stopword (kata-kata yang tidak memiliki arti) kemudian diubah ke dalam bentuk lowercase; tahap tokenisasi, dimana kalimat dibagi menjadi token atau kata-kata terpisah; menghitung frekuensi masing-masing kata; kemudian menghitung seberapa umum kata tersebut dalam semua



dokumen. Setelah menghitung frekuensi kata dan inversi dokumen, bobot TF-IDF untuk setiap kata dihitung dengan mengalikan frekuensi kata dengan inversi dokumen. Selanjutnya, hasil TF-IDF dilanjutkan ke tahap klasifikasi sesuai metode SERVQUAL berdasarkan masing-masing dimensi didominasi oleh sentimen positif. Dimensi bukti fisik (*tangible*) menunjukkan beberapa kata yang merupakan representasi atas ekspektasi dan pengalaman konsumen seperti food, tempat, nyaman, restaurant, ruangan. Hal ini berarti bahwa konsumen merasa senang dengan tempat atau ruangan yang digunakan untuk makan dan minum di restoran tersebut. Sementara itu, dimensi daya tanggap (*responsiveness*) menunjukkan persepsi konsumen terkait dengan sikap tanggap karyawan yang diekspresikan melalui beberapa kata seperti cepat, menyajikan, disediakan, dilayani, memuaskan. Hal ini berarti bahwa konsumen merasa puas dengan kecepatan penyajian serta pelayanan di restoran. Disisi lain, dimensi keandalan (*reliability*) menunjukkan pandangan konsumen terkait dengan konsistensi, ketepatan waktu yang ditunjukkan melalui beberapa kata seperti membantu, menyenangkan, senang, dijamin, authentic. hal ini menunjukkan bahwa konsumen merasa senang dengan pelayanan sesuai yang dijanjikan. Adapun, dimensi jaminan (*assurance*) merupakan jaminan kepuasan, kenyamanan dan keamanan konsumen yang terejawantahkan dalam beberapa kata seperti *reasonable*, istimewa, kenyang, ramah, dan sopan. Hal ini menunjukkan bahwa konsumen merasakan pelayanan yang ramah dan sopan serta memperoleh makanan atau minuman yang istimewa, memuaskan, serta harga yang sesuai atau masuk akal. Sedangkan, dimensi empati (*empathy*) menunjukkan bahwa konsumen merasa disambut dengan baik, sebagaimana penilaian konsumen dalam kata disambut, baik, dan terbaik. Hal ini menunjukkan bahwa pelayanan menggunakan empati dapat mengekspresikan sikap kesungguhan atau tulus dalam memberikan pelayanan. Dengan demikian, dapat diketahui bahwa ekspektasi konsumen terhadap makanan (*food*), pelayanan (*service*), dan nilai (*value*) tergolong positif. Selanjutnya, data ulasan konsumen diekstrak untuk mengidentifikasi klasifikasi kelas negatif dan positif sebagaimana table 3 berikut.

Tabel 3. Proses Ekstrak Sentimen dari Ulasan Wisatawan

Review					
The taste is so good (the soup), but the meat are so chewy not tender which is sad compare to the taste of the soup.. Place is so crowded (never ending customers) and so hot, i'm sweating all the time..lol. I also hate their floor, so dirty, liquid everywhere (spilled tea, water, etc) it's kinda dangerous tho					
String Scoring					
good (0.49) sad (-0.54) lol (0.46) hate (-0.69) dirty (-0.49) dangerous (-0.54)					
Sentiment	Score	Negativity	Positivity	Uncovered Tokens	Tokens
Negatif	-1,3	2,3	0,9	67	73
Review					
I was in Makassar last week and our joint venture partner took us to Apong. Makassar is well known for its fresh seafood but the choice in Apong was really something else. There were seven of us and we feasted on crabs, prawns and different types of fish. It was either steamed, fried or grilled... and absolutely wonderful. If you get to Makassar, make the effort to go and dine at Apong's. You will not regret the choice. Happy eating....					
String Scoring					
well (0.28) fresh (0.33) wonderful (0.69) regret (-0.46) happy (0.69)					
Sentiment	Score	Negativity	Positivity	Uncovered Tokens	Tokens
Positif	1,5	0,5	2	88	93

Tabel 3 merupakan proses ekstrak sentimen dari data ulasan setelah diklasifikasikan masing-masing dimensi dalam kerangka kerja SERVQUAL. Proses ekstrak sentimen dilakukan menggunakan aplikasi Rapidminer setelah proses TF-IDF. Operator *Extract sentiment* di RapidMiner mengidentifikasi sentimen atau perasaan dari teks, apakah itu positif maupun negatif dengan mencocokkan setiap kata dengan kamus sentimen untuk menentukan apakah kata tersebut memiliki sentimen positif atau negatif. Jumlah kata positif dan negatif dihitung dan dijadikan acuan untuk menentukan sentimen keseluruhan dokumen. Hal tersebut dapat dilihat dari *score*, *string score*, *uncovered tokens*, dan *tokens*. Selanjutnya, pada tahap pemodelan dilakukan evaluasi berdasarkan kinerja algoritma Decision Tree sebagaimana tabel 4 berikut

Tabel 4. Performance Vector of DT Algorithm (with and Without SMOTE)

DT Tanpa SMOTE			DT dengan SMOTE		
PerformanceVector:			PerformanceVector:		
accuracy: 98.58% +/- 0.37% (micro average: 98.58%)			accuracy: 93.25% +/- 0.95% (micro average: 93.25%)		
ConfusionMatrix:			ConfusionMatrix:		
True:	Negatif	Positif	True:	Negatif	Positif
Negatif:	0	6	Negatif:	3774	39
Positif:	56	4312	Positif:	544	4279
AUC (optimistic): 0.999 +/- 0.003 (micro average: 0.999) (positive class: Positif)			AUC (optimistic): 0.998 +/- 0.001 (micro average: 0.998) (positive class: Positif)		



<p>AUC: 0.499 +/- 0.002 (micro average: 0.499) (positive class: Positif)</p> <p>AUC (pessimistic): 0.000 +/- 0.000 (micro average: 0.000) (positive class: Positif)</p> <p>precision: 98.72% +/- 0.12% (micro average: 98.72%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 0 6</p> <p>Positif: 56 4312</p> <p>recall: 99.86% +/- 0.31% (micro average: 99.86%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 0 6</p> <p>Positif: 56 4312</p> <p>f_measure: 99.29% +/- 0.19% (micro average: 99.29%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 0 6</p> <p>Positif: 56 4312</p>	<p>AUC: 0.935 +/- 0.009 (micro average: 0.935) (positive class: Positif)</p> <p>AUC (pessimistic): 0.873 +/- 0.019 (micro average: 0.873) (positive class: Positif)</p> <p>precision: 88.74% +/- 1.45% (micro average: 88.72%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 3774 39</p> <p>Positif: 544 4279</p> <p>recall: 99.10% +/- 0.49% (micro average: 99.10%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 3774 39</p> <p>Positif: 544 4279</p> <p>f_measure: 93.63% +/- 0.85% (micro average: 93.62%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 3774 39</p> <p>Positif: 544 4279</p>
---	--

Tabel 3 menunjukkan bahwa performa algoritma DT tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 98.58%, presisi sebesar 98.72%, recall sebesar 99.86% dan f-measure sebesar 99.29%. Meskipun demikian, nilai AUC yang dihasilkan ialah 0.499 (49.9%). Berbeda halnya dengan performa algoritma DT ketika menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 93.25%, presisi sebesar 88.74%, recall sebesar 99.10%, dan f-measure sebesar 93.62%. Adapun, nilai AUC yang dihasilkan ialah 0.873 (87.3%). Hal ini berarti algoritma DT menggunakan SMOTE menunjukkan performa yang lebih baik dibandingkan dengan tanpa menggunakan SMOTE. Salah satu kelemahan algoritma DT dalam analisis sentimen adalah kecenderungan untuk overfitting pada data training yang digunakan. Hal ini terjadi ketika algoritma membuat struktur pohon yang sangat kompleks untuk memaksimalkan akurasi pada data training, namun hasilnya tidak dapat diterapkan pada data yang belum pernah dilihat sebelumnya. Selain itu, kelemahan lainnya adalah sensitifitas terhadap perubahan pada data training, dimana penambahan atau penghapusan data training dapat mengubah struktur pohon dan hasil akhir dari analisis sentimen yang dilakukan. Selain itu, salah satu kelebihan algoritma DT yang menggunakan SMOTE (Synthetic Minority Over-sampling Technique) ialah meningkatkan akurasi pada klasifikasi data yang tidak seimbang atau tidak proporsional. Dengan menggunakan SMOTE, algoritma dapat menghasilkan sampel sintesis yang mewakili kelas minoritas dalam jumlah yang sama dengan kelas mayoritas, sehingga meningkatkan akurasi dan mengurangi bias pada hasil analisis sentimen. Selain itu, penggunaan SMOTE juga dapat mengurangi overfitting pada data training dan meningkatkan kemampuan generalisasi pada data yang belum pernah dilihat sebelumnya. Berikut ini adalah performa algoritma k-NN dapat dilihat pada tabel 5 berikut.

Tabel 5. Performance Vector of k-NN Algorithm (with and Without SMOTE)

k-NN Tanpa SMOTE	k-NN dengan SMOTE
<p>PerformanceVector:</p> <p>accuracy: 98.72% +/- 0.12% (micro average: 98.72%)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 0 0</p> <p>Positif: 56 4318</p> <p>AUC (optimistic): 0.959 +/- 0.059 (micro average: 0.959) (positive class: Positif)</p> <p>AUC: 0.905 +/- 0.097 (micro average: 0.905) (positive class: Positif)</p> <p>AUC (pessimistic): 0.851 +/- 0.148 (micro average: 0.851) (positive class: Positif)</p> <p>precision: 98.72% +/- 0.12% (micro average: 98.72%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 0 0</p> <p>Positif: 56 4318</p>	<p>PerformanceVector:</p> <p>accuracy: 51.57% +/- 0.25% (micro average: 51.57%)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 4318 4182</p> <p>Positif: 0 136</p> <p>AUC (optimistic): 1.000 +/- 0.000 (micro average: 1.000) (positive class: Positif)</p> <p>AUC: 0.870 +/- 0.011 (micro average: 0.870) (positive class: Positif)</p> <p>AUC (pessimistic): 0.740 +/- 0.022 (micro average: 0.740) (positive class: Positif)</p> <p>precision: 100.00% +/- 0.00% (micro average: 100.00%) (positive class: Positif)</p> <p>ConfusionMatrix:</p> <p>True: Negatif Positif</p> <p>Negatif: 4318 4182</p> <p>Positif: 0 136</p>



recall: 100.00% +/- 0.00% (micro average: 100.00%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 0 0 Positif: 56 4318 f_measure: 99.36% +/- 0.06% (micro average: 99.36%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 0 0 Positif: 56 4318	recall: 3.15% +/- 0.49% (micro average: 3.15%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 4318 4182 Positif: 0 136 f_measure: 6.10% +/- 0.92% (micro average: 6.11%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 4318 4182 Positif: 0 136
---	---

Tabel 5 menunjukkan bahwa performa algoritma k-NN tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 98.72%, presisi sebesar 98.72%, recall sebesar 100 % dan f-measure sebesar 99.36%. Meskipun demikian, nilai AUC yang dihasilkan ialah 0.905 (90.5%). Berbeda halnya dengan performa algoritma k-NN ketika menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 51.57%, presisi sebesar 100%, recall sebesar 3.15%, dan f-measure sebesar 6.10%. Adapun, nilai AUC yang dihasilkan ialah 1.00 (100%). Hal ini berarti algoritma k-NN tanpa SMOTE menunjukkan performa yang lebih baik dibandingkan menggunakan SMOTE. Algoritma k-NN dapat digunakan tanpa memerlukan banyak pemrosesan data awal dan tanpa perlu mengubah atau menambahkan sampel sintetis pada data training. Selain itu, algoritma k-NN juga dapat mengatasi masalah noise atau pencilan pada data, karena tidak dipengaruhi oleh distribusi data dan hanya menghitung jarak antara sampel-sampel data. Meskipun tidak menggunakan teknik SMOTE, algoritma k-NN dapat menghasilkan hasil analisis sentimen yang cukup akurat pada data yang seimbang. Berikutnya ialah performa algoritma NBC yang dapat dilihat pada tabel 5 berikut.

Tabel 6. Performance Vector of NBC Algorithm (with and Without SMOTE)

NBC Tanpa SMOTE	NBC dengan SMOTE
PerformanceVector: accuracy: 99.31% +/- 0.44% (micro average: 99.31%) ConfusionMatrix: True: Negatif Positif Negatif: 32 6 Positif: 24 4312 AUC (optimistic): 0.999 +/- 0.001 (micro average: 0.999) (positive class: Positif) AUC: 0.500 +/- 0.000 (micro average: 0.500) (positive class: Positif) AUC (pessimistic): 0.573 +/- 0.281 (micro average: 0.573) (positive class: Positif) precision: 99.45% +/- 0.35% (micro average: 99.45%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 32 6 Positif: 24 4312 recall: 99.86% +/- 0.16% (micro average: 99.86%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 32 6 Positif: 24 4312 f_measure: 99.65% +/- 0.22% (micro average: 99.65%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 32 6 Positif: 24 4312	PerformanceVector: accuracy: 99.93% +/- 0.08% (micro average: 99.93%) ConfusionMatrix: True: Negatif Positif Negatif: 4318 6 Positif: 0 4312 AUC (optimistic): 1.000 +/- 0.000 (micro average: 1.000) (positive class: Positif) AUC: 0.500 +/- 0.000 (micro average: 0.500) (positive class: Positif) AUC (pessimistic): 0.999 +/- 0.002 (micro average: 0.999) (positive class: Positif) precision: 100.00% +/- 0.00% (micro average: 100.00%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 4318 6 Positif: 0 4312 recall: 99.86% +/- 0.16% (micro average: 99.86%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 4318 6 Positif: 0 4312 f_measure: 99.93% +/- 0.08% (micro average: 99.93%) (positive class: Positif) ConfusionMatrix: True: Negatif Positif Negatif: 4318 6 Positif: 0 4312

Tabel 6 menunjukkan bahwa performa algoritma NBC tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 99.31%, presisi sebesar 99.45%, recall sebesar 99.86% dan f-measure sebesar 99.65%. Meskipun demikian, nilai AUC yang dihasilkan ialah 0.500 (50%). Berbeda halnya dengan performa algoritma NBC ketika



menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 99.93%, presisi sebesar 100%, recall sebesar 99.86%, dan f-measure sebesar 99.93%. Adapun, nilai AUC yang dihasilkan ialah 0.500 (50%). Penyebab rendahnya nilai AUC algoritma NBC setelah menggunakan SMOTE dalam analisis sentimen adalah karena adanya penambahan sampel sintesis yang mungkin tidak mewakili keadaan sebenarnya. Hal ini dapat menyebabkan overfitting pada data training dan menghasilkan model yang kurang generalisasi pada data yang belum pernah dilihat sebelumnya. Sementara itu, penyebab rendahnya nilai AUC algoritma NBC tanpa menggunakan SMOTE adalah karena ketidakseimbangan atau tidak proporsionalnya data training yang dapat menyebabkan kurangnya data pada kelas minoritas. Hal ini menyebabkan algoritma NBC sulit untuk mengklasifikasikan data pada kelas minoritas dengan akurat dan menghasilkan nilai AUC yang rendah. Hal ini berarti algoritma NBC tidak direkomendasikan untuk digunakan sebagai model karena memiliki nilai AUC yang rendah, tanpa menggunakan SMOTE maupun setelah menggunakan SMOTE. Selanjutnya, performa algoritma SVM dapat dilihat pada tabel 7 berikut

Tabel 7. Performance Vector of SVM Algorithm (with and Without SMOTE)

SVM Tanpa SMOTE	SVM dengan SMOTE
PerformanceVector: accuracy: 99.18% +/- 0.39% (micro average: 99.18%)	PerformanceVector: accuracy: 99.42% +/- 0.38% (micro average: 99.42%)
ConfusionMatrix: True: Negatif Positif Negatif: 21 1 Positif: 35 4317	ConfusionMatrix: True: Negatif Positif Negatif: 4318 50 Positif: 0 4268
AUC (optimistic): 0.951 +/- 0.039 (micro average: 0.951) (positive class: Positif)	AUC (optimistic): 1.000 +/- 0.000 (micro average: 1.000) (positive class: Positif)
AUC: 0.951 +/- 0.039 (micro average: 0.951) (positive class: Positif)	AUC: 1.000 +/- 0.000 (micro average: 1.000) (positive class: Positif)
AUC (pessimistic): 0.951 +/- 0.039 (micro average: 0.951) (positive class: Positif)	AUC (pessimistic): 1.000 +/- 0.000 (micro average: 1.000) (positive class: Positif)
precision: 99.20% +/- 0.38% (micro average: 99.20%) (positive class: Positif)	precision: 100.00% +/- 0.00% (micro average: 100.00%) (positive class: Positif)
ConfusionMatrix: True: Negatif Positif Negatif: 21 1 Positif: 35 4317	ConfusionMatrix: True: Negatif Positif Negatif: 4318 50 Positif: 0 4268
recall: 99.98% +/- 0.07% (micro average: 99.98%) (positive class: Positif)	recall: 98.84% +/- 0.76% (micro average: 98.84%) (positive class: Positif)
ConfusionMatrix: True: Negatif Positif Negatif: 21 1 Positif: 35 4317	ConfusionMatrix: True: Negatif Positif Negatif: 4318 50 Positif: 0 4268
f_measure: 99.58% +/- 0.20% (micro average: 99.58%) (positive class: Positif)	f_measure: 99.42% +/- 0.38% (micro average: 99.42%) (positive class: Positif)
ConfusionMatrix: True: Negatif Positif Negatif: 21 1 Positif: 35 4317	ConfusionMatrix: True: Negatif Positif Negatif: 4318 50 Positif: 0 4268

Tabel 6 menunjukkan bahwa performa algoritma SVM tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 99.18%, presisi sebesar 99.20%, recall sebesar 99.98% dan f-measure sebesar 99.58%. Adapun, nilai AUC bernilai 0.951 (95,1%). Berbeda halnya dengan performa algoritma SVM ketika menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 99.42%, presisi sebesar 100%, recall sebesar 98.84%, dan f-measure sebesar 99.42%. Adapun, nilai AUC yang dihasilkan ialah 1.000 (100%). Penyebab nilai AUC algoritma SVM mencapai 100% setelah menggunakan SMOTE dalam analisis sentimen adalah karena adanya penambahan sampel sintesis yang memperluas ruang fitur pada data training. Hal ini memungkinkan algoritma SVM untuk menemukan hiperplane yang optimal dan memaksimalkan margin antara kelas-kelas data, sehingga meningkatkan akurasi klasifikasi dan menghasilkan nilai AUC yang tinggi. Selain itu, teknik SMOTE juga dapat mengatasi masalah ketidakseimbangan pada data training dan memungkinkan algoritma SVM untuk mempelajari kelas minoritas dengan lebih baik. Namun, perlu diingat bahwa nilai AUC yang mencapai 100% tidak selalu menjamin keakuratan dan kehandalan dari model, karena dapat terjadi overfitting pada data training dan model tidak dapat digeneralisasikan dengan baik pada data yang belum pernah dilihat sebelumnya.


Salah satu teknik yang dapat digunakan untuk membantu membandingkan nilai rata-rata antara dua atau lebih kelompok data yang berbeda ialah t-test. T-test dapat membantu dalam membandingkan nilai rata-rata antara dua kelompok data yang berbeda dan menentukan apakah perbedaan antara kedua kelompok tersebut signifikan secara statistik. Dalam analisis sentimen, t-test dapat digunakan untuk membandingkan nilai sentimen antara dua kelompok

data. Hasil dari t-test ini dapat memberikan informasi yang berharga untuk menentukan model yang lebih baik sebagaimana hasil t-test algoritma k-NN, NBC, DT, dan SVM pada tabel 7 berikut.

Tabel 7. Pairwise t-Test (with and Without SMOTE)

Pairwise t-Test Tanpa SMOTE				Pairwise t-Test Menggunakan SMOTE			
Probabilities for random values with the same result:				Probabilities for random values with the same result:			
----	0.492	0.040	0.000	----	0.000	0.000	0.000
----	----	0.588	0.017	----	----	0.000	0.539
----	----	----	0.008	----	----	----	0.000
----	----	----	----	----	----	----	----
Values smaller than alpha=0.050 indicate a probably significant difference between the mean values!				Values smaller than alpha=0.050 indicate a probably significant difference between the mean values!			
List of performance values:				List of performance values:			
0: 0.990 +/- 0.002				0: 0.498 +/- 0.002			
1: 0.991 +/- 0.004				1: 0.998 +/- 0.002			
2: 0.991 +/- 0.002				2: 0.970 +/- 0.004			
3: 0.995 +/- 0.003				3: 0.998 +/- 0.001			

Tabel 7 merupakan hasil t-test pada algoritma tanpa menggunakan SMOTE dan setelah menggunakan SMOTE. Hasil perbandingan algoritma tanpa menggunakan SMOTE menunjukkan bahwa algoritma SVM lebih dominan dibandingkan dengan algoritma k-NN, NBC, DT. Sama halnya dengan hasil t-test pada algoritma yang menggunakan SMOTE, dimana algoritma SVM lebih dominan dibandingkan dengan algoritma k-NN, NBC, DT. Hasil uji t yang menunjukkan bahwa algoritma SVM lebih dominan dibandingkan algoritma k-NN, NBC, dan DT setelah menggunakan SMOTE dapat disebabkan oleh beberapa faktor. Pertama, teknik SMOTE dapat meningkatkan kinerja algoritma dengan mengatasi masalah ketidakseimbangan pada data training dan meningkatkan kemampuan generalisasi pada data yang belum pernah dilihat sebelumnya. Kedua, SVM memiliki kemampuan untuk menemukan hiperplane yang optimal dan memaksimalkan margin antara kelas-kelas data, sehingga meningkatkan akurasi klasifikasi pada data yang kompleks. Ketiga, SVM juga memiliki kemampuan untuk mengatasi masalah overfitting pada data training dan dapat mempelajari hubungan nonlinear antara variabel input dan output. Sedangkan k-NN, NBC dan DT cenderung memiliki kelemahan dalam mengatasi masalah ketidakseimbangan dan overfitting pada data training serta cenderung kurang optimal pada data yang kompleks. Oleh karena itu, hasil uji t tersebut menunjukkan bahwa SVM lebih dominan dibandingkan k-NN, NBC dan DT setelah menggunakan SMOTE pada analisis sentimen. Selain itu, nilai ROC bisa dilihat pada gambar 5 berikut.



Gambar 1. Nilai ROC algoritma DT, k-NN, NBC, dan SVM

Gambar 1 merupakan nilai ROC (*Receiver Operating Characteristic*) yang diproses menggunakan aplikasi RapidMiner untuk mengevaluasi performa dari algoritma DT, k-NN, NBC, dan SVM. Fungsi utama nilai ROC adalah untuk menunjukkan seberapa baik model mampu membedakan antara sentimen positif dan negatif dari data yang telah diberikan. Nilai ROC diperoleh dengan memplotting sensitivity (*True Positive Rate*) pada sumbu y dan 1-Specificity (*False Positive Rate*) pada sumbu x. Semakin besar nilai ROC, semakin baik kinerja model dalam membedakan sentimen positif dan negatif dari data yang ada. Nilai ROC yang sempurna adalah 1, sedangkan nilai ROC 0.5

menunjukkan bahwa model tidak memiliki kemampuan untuk membedakan antara sentimen positif dan negatif. Dalam analisis sentimen, ROC dapat membantu memperbaiki model dan meningkatkan akurasi serta efisiensi dari model tersebut. Nilai ROC yang tinggi menandakan model memiliki sensitivitas yang baik dan mampu membedakan sentimen positif dan negatif secara akurat, sehingga dapat membantu pengambilan keputusan yang lebih baik berdasarkan data sentimen yang dianalisis. Dengan demikian dapat diketahui bahwa algoritma DT, k-NN dan SVM dapat digunakan sebagai model dalam analisis sentimen konsumen terhadap *food, services, and value* pada bisnis kuliner di Kota Makassar sebagaimana rekomendasi website Tripadvisor.

Berdasarkan hasil analisis sentimen konsumen terkait dengan *food, services, and value* dalam konteks wisata kuliner di kota Makassar, terdapat beberapa rekomendasi untuk meningkatkan kualitas layanan dan pengalaman pengunjung. Pertama, perlu meningkatkan variasi menu yang ditawarkan dengan mempertimbangkan preferensi lokal dan budaya, serta perlu dipertimbangkan harga yang bersaing dan memberikan nilai yang sepadan dengan kualitas makanan dan layanan yang diberikan. Hal ini merujuk pada hasil TF-IDF berdasarkan klasifikasi dimensi *tangible*. Kedua, peningkatan kualitas pelayanan dapat dilakukan dengan memperhatikan keramahan, kecepatan pelayanan, dan kebersihan tempat makan. Hal ini merujuk pada hasil TF-IDF berdasarkan klasifikasi dimensi *responsiveness, reliability, assurance, and empathy*. Dengan implementasi rekomendasi ini, diharapkan dapat meningkatkan pengalaman wisata kuliner di kota Makassar dan meningkatkan daya tarik wisata kuliner di kota tersebut.

4. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa rekomendasi untuk meningkatkan kualitas layanan dan pengalaman pengunjung. Pertama, perlu meningkatkan variasi menu yang ditawarkan dengan mempertimbangkan preferensi lokal dan budaya, serta perlu dipertimbangkan harga yang bersaing dan memberikan nilai yang sepadan dengan kualitas makanan dan layanan yang diberikan. Rekomendasi tersebut merujuk pada hasil TF-IDF berdasarkan klasifikasi dimensi *tangible*, seperti food, tempat, nyaman, restaurant, ruangan. Kedua, peningkatan kualitas pelayanan dapat dilakukan dengan memperhatikan keramahan, kecepatan pelayanan, dan kebersihan tempat makan. Rekomendasi tersebut merujuk pada hasil TF-IDF berdasarkan klasifikasi dimensi *responsiveness, reliability, assurance, and empathy*, sebagai berikut : cepat, menyajikan, disediakan, dilayani, memuaskan, membantu, menyenangkan, senang, dijamin, authentic, *reasonable*, istimewa, kenyang, ramah, dan sopan, istimewa, memuaskan, serta harga yang sesuai atau masuk akal, disambut, baik, dan terbaik. Sementara itu, hasil evaluasi performa algoritma menunjukkan bahwa algoritma DT, k-NN dan SVM dapat digunakan sebagai model dalam kerangka kerja CRISP-DM. Algoritma DT ketika menggunakan operator SMOTE dimana nilai akurasi yang dihasilkan sebesar 93.25%, presisi sebesar 88.74%, recall sebesar 99.10%, dan f-measure sebesar 93.62%. Selanjutnya, algoritma k-NN tanpa menggunakan operator SMOTE menunjukkan nilai akurasi sebesar 98.72%, presisi sebesar 98.72%, recall sebesar 100 % dan f-measure sebesar 99.36%. Meskipun demikian, nilai AUC yang dihasilkan ialah 0.905 (90.5%). Adapun, algoritma SVM ketika menggunakan operator SMOTE menghasilkan nilai akurasi sebesar 99.42%, presisi sebesar 100%, recall sebesar 98.84%, dan f-measure sebesar 99.42%. Adapun, nilai AUC yang dihasilkan ialah 1.000 (100%).

REFERENCES

- [1] A. N. S. Aidah, "Pengaruh Persepsi Harga dan Kualitas Produk Terhadap Keputusan Pembelian Konsumen," *PERFORMA J. Manaj. dan Start-Up Bisnis*, vol. 5, no. 1, pp. 35–43, 2020, doi: 10.35134/ekobistek.v10i2.114.
- [2] M. R. Sani, M. N. Alia, and D. Riyadi, "Sate Padang Sumatera Barat Sebagai Gastronomi Unggulan di Indonesia," *J. Gastron. Tour.*, vol. 3, no. 2, pp. 103–111, 2016, [Online]. Available: <http://journal.um-surabaya.ac.id/index.php/JKM/article/view/2203>
- [3] A. M. Raharjo, C. Djoko, and E. Melini, "Identifikasi Permasalahan Desain Identitas Visual Restoran Gado-Gado Boplo," in *Koma DKV 2021, 2022*, vol. 2, no. 2021, pp. 37–44.
- [4] I. A. Mastan and Y. Toni, "Analisis Sentimen terhadap Tempat Kuliner Ayam Gedebuk dari Komentar Pengunjung dengan Menggunakan Naive Bayes Classifier," *J. Bus. Audit Inf. Syst.*, vol. 3, no. 1, pp. 42–50, 2020.
- [5] S. A. Azzahra and A. Wibowo, "Analisis Sentimen Multi-Aspek Berbasis Konversi Ikon Emosi dengan Algoritme Naive Bayes untuk Ulasan Wisata Kuliner Pada Web Tripadvisor," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, pp. 737–743, 2020, doi: 10.25126/jtiik.2020731907.
- [6] M. R. Fauzi, R. A. Pratama, P. Laksono, and P. Eosina, "Analisis Big Data Sentimen Konsumen UMKM Sektor Kuliner Menggunakan Multi-Label k-Nearest Neighbor," *Krea-TIF J. Tek. Inform.*, vol. 9, no. 1, pp. 9–20, 2021, doi: 10.32832/kreatif.v9i1.3587.
- [7] R. Sari, "Analisis Sentimen Review Restoran menggunakan Algoritma Naive Bayes berbasis Particle Swarm Optimization," *J. Inform.*, vol. 6, no. 1, pp. 23–28, 2019, doi: 10.31311/ji.v6i1.4695.
- [8] Y. A. Singgalen, "Analisis Sentimen Wisatawan terhadap Taman Nasional Bunaken dan Top 10 Hotel Rekomendasi Tripadvisor Menggunakan Algoritma SVM dan DT berbasis CRISP-DM," *J. Comput. Syst. Informatics*, vol. 4, no. 2, pp. 367–379, 2023, doi: 10.47065/josyc.v4i2.3092.
- [9] Y. A. Singgalen, "Analisis Perilaku Wisatawan Berdasarkan Data Ulasan di Website Tripadvisor Menggunakan CRISP-DM : Wisata Minat Khusus Pendakian Gunung Rinjani dan Gunung Bromo," *J. Comput. Syst. Informatics*, vol. 4, no. 2, pp. 326–338, 2023, doi: 10.47065/josyc.v4i2.3042.
- [10] Y. A. Singgalen, "Analisis Sentimen Pengunjung Pulau Komodo dan Pulau Rinca di Website Tripadvisor Berbasis CRISP-DM," *J. Inf. Syst. Res.*, vol. 4, no. 2, pp. 614–625, 2023, doi: 10.47065/josh.v4i2.2999.



- [11] Y. A. Singgalen, “Analisis Sentimen Wisatawan Melalui Data Ulasan Candi Borobudur di Tripadvisor Menggunakan Algoritma Naïve Bayes Classifier,” *Buuld. Informatics, Technol. Sci.*, vol. 4, no. 3, p. 1343–1352, 2022, doi: 10.47065/bits.v4i3.2486.
- [12] Y. A. Singgalen, “Analisis Performa Algoritma NBC , DT , SVM dalam Klasifikasi Data Ulasan Pengunjung Candi Borobudur Berbasis CRISP-DM,” *Buuld. Informatics, Technol. Sci.*, vol. 4, no. 3, pp. 1634–1646, 2022, doi: 10.47065/bits.v4i3.2766.
- [13] S. K. S. Conde, C. T. Hernandez, E. M. Huerta, G. I. Tellez, and A. T. Lopez, “Analysis of Service Quality in the Restaurant Sector in the State of Tlaxcala Using The Servqual Model,” *J. Econ. Financ. Manag. Stud.*, vol. 5, no. 3, pp. 871–880, 2022, doi: 10.47191/jefms/v5-i3-37.
- [14] A. M. Putra, I. N. J. Ariana, A. S. Sulistyawati, I. N. T. Sutaguna, and N. Narottama, “Pengolahan dan Pengemasan Kuliner Lokal di Desa Wisata Tista Kecamatan Kerambitan Kabupaten Tabanan,” *Bul. Udayana Mengabd.*, vol. 21, no. 4, pp. 326–331, 2022.
- [15] Samtono, E. Rahayu, and Y. D. Risyanti, “Upaya Pengembangan Ekonomi Kreatif Sektor Wisata Kuliner Kampung Singkong,” *Reson. J. Ilm. Pengabd. Masy.*, vol. 6, no. 2, pp. 153–161, 2022.
- [16] S. Utami, “Kuliner Sebagai Identitas Budaya: Perspektif Komunikasi Lintas Budaya,” *Cover. J. Strateg. Commun.*, vol. 8, no. 2, pp. 36–44, 2018, doi: 10.35814/coverage.v8i2.588.
- [17] Rusmaniah, Herman, P. D. Indriyani, R. M. Sari, and D. A. Nugroho, “Pelestarian Kuliner Lokal Jengkol Tahilala Sebagai Warisan Dan Perwujudan Nilai Budaya Banjar Di Desa Pingaran,” *Anterior J.*, vol. 21, no. 3, pp. 57–61, 2022, doi: 10.33084/anterior.v21i3.3502.
- [18] R. Annisa, “Analisis Komparasi Algoritma Klasifikasi Data Mining Untuk Prediksi Penderita Penyakit Jantung,” *J. Tek. Inform. Kaputama*, vol. 3, no. 1, pp. 22–28, 2019, [Online]. Available: <https://jurnal.kaputama.ac.id/index.php/JTIK/article/view/141/156>
- [19] S. Dewi, “Komparasi Metode Algoritma Data Mining pada Prediksi Uji Kelayakan Credit Approval pada Calon Nasabah Kredit Perbankan,” *J. Khatulistiwa Inform.*, vol. 7, no. 1, pp. 59–65, 2019, doi: 10.31294/jki.v7i1.5744.
- [20] R. Azmatul Barro, I. D. Sulvianti, and M. Afendi, “Penerapan Synthetic Minority Oversampling Technique (Smote) Terhadap Data Tidak Seimbang Pada Pembuatan Model Komposisi Jamu,” *Xplore J. Stat.*, vol. 1, no. 1, pp. 1–6, 2013.
- [21] F. F. Haranto and B. W. Sari, “Implementasi Support Vector Machine Untuk Analisis Sentimen Pengguna Twitter Terhadap Pelayanan Telkom Dan Biznet,” *J. Pilar Nusa Mandiri*, vol. 15, no. 2, pp. 171–176, 2019, doi: 10.33480/pilar.v15i2.699.
- [22] S. W. U. Vitandy, A. A. Supianto, and F. A. Bachtar, “Analisis Sentimen Evaluasi Kinerja Dosen menggunakan Term Frequency- Inverse Document Frequency dan Naïve Bayes Classifier,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 6, pp. 6080–6088, 2019, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5645>
- [23] R. Kosasih and A. Alberto, “Analisis Sentimen Produk Permainan Menggunakan Metode TF-IDF Dan Algoritma K-Nearest Neighbor,” *InfoTekJar J. Nas. Inform. dan Teknol. Jar.*, vol. 6, no. 1, pp. 134–139, 2021.
- [24] M. Y. Ardiansyah, M. A. Fauzi, and S. Adinugroho, “Penerapan Term Frequency-Modified Inverse Document Frequency pada Analisis Sentimen Ulasan Barang menggunakan Metode Learning Vector Quantization,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 6, pp. 5592–5598, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [25] M. I. Alfarizi, L. Syafaah, and M. Lestandy, “Emotional Text Classification Using TF-IDF (Term Frequency-Inverse Document Frequency) And LSTM (Long Short-Term Memory),” *JUITA J. Inform.*, vol. 10, no. 2, p. 225, 2022, doi: 10.30595/juita.v10i2.13262.
- [26] E. B. S. Rayhan Rahmanda, “JURNAL RESTI Word2Vec on Sentiment Analysis with Synthetic Minority Oversampling,” *J. RESTI*, vol. 5, no. 2, pp. 599–605, 2022.
- [27] S. Sofyan and A. Prasetyo, “Penerapan Synthetic Minority Oversampling Technique (SMOTE) Terhadap Data Tidak Seimbang Pada Tingkat Pendapatan Pekerja Informal Di Provinsi D.I. Yogyakarta Tahun 2019,” in *Seminar Nasional Official Statistics*, 2021, pp. 868–877. doi: 10.34123/semnasoffstat.v2021i1.1081.
- [28] R. A. Barro, I. D. Sulvianti, and M. Afendi, “Penerapan Synthetic Minority Oversampling Technique (Smote) Terhadap Data Tidak Seimbang Pada Pembuatan Model Komposisi Jamu,” *Xplore J. Stat.*, vol. 1, no. 1, pp. 1–6, 2013.
- [29] Y. E. Kurniawati, “Class Imbalanced Learning Menggunakan Algoritma Synthetic Minority Over-sampling Technique – Nominal (SMOTE-N) pada Dataset Tuberculosis Anak,” *J. Buana Inform.*, vol. 10, no. 2, pp. 134–143, 2019, doi: 10.24002/jbi.v10i2.2441.
- [30] O. Heranova, “Synthetic Minority Oversampling Technique pada Averaged One Dependence Estimators untuk Klasifikasi Credit Scoring,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 3, pp. 443–450, 2019, doi: 10.29207/resti.v3i3.1275.
- [31] K. U. Syaliman, “Enhance the Accuracy of K-Nearest Neighbor (K-Nn) for Unbalanced Class Data Using Synthetic Minority Oversampling Technique (Smote) and Gain Ratio (Gr),” *J. Infokum*, vol. 10, no. 1, pp. 188–195, 2021.
- [32] M. W. Pertiwi, M. F. Adiwisatra, and D. Supriadi, “Analisa Komparasi Menggunakan 5 Metode Data Mining dalam Klasifikasi Persentase Wanita Sudah menikah di Usia 15-49 yang Memakai Alat KB (Keluarga Berencana),” *J. Khatulistiwa Inform.*, vol. 7, no. 1, pp. 37–42, 2019, doi: 10.31294/jki.v7i1.5741.
- [33] D. N. Fitriana and Y. Sibaroni, “Sentiment Analysis on KAI Twitter Post Using Multiclass Support Vector Machine (SVM),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 5, pp. 846–853, 2020, doi: 10.29207/resti.v4i5.2231.
- [34] A. Karim, “Perbandingan Prediksi Kemiskinan di Indonesia Menggunakan Support Vector Machine (SVM) dengan Regresi Linear,” *J. Sains Mat. dan Stat.*, vol. 6, no. 1, pp. 107–112, 2020, doi: 10.24014/jsms.v6i1.9259.
- [35] E. A. Nida, “Analisis Kinerja Algoritma Support Vector Machine (SVM) Guna Pengambilan Keputusan Beli/Jual Pada Saham PT Elnusa Tbk. (ELSA),” *J. Transform.*, vol. 17, no. 2, pp. 160–170, 2020, doi: 10.26623/transformatika.v17i2.1649.
- [36] N. L. W. S. R. Ginantra, C. P. Yanti, G. D. Prasetya, I. B. G. Sarasvandana, and I. K. A. G. Wiguna, “Analisis Sentimen Ulasan Villa di Ubud Menggunakan Metode Naive Bayes, Decision Tree, dan k-NN,” *Janapati*, vol. 11, no. 3, pp. 205–216, 2022.
- [37] W. Suteja and S. Wahyuningsih, “Invensi Budaya Kuliner Melalui Komodifikasi Sebagai Penunjang Kegiatan Pariwisata Di Kawasan Wisata Mataram,” *Media Bina Ilm.*, vol. 13, no. 7, pp. 1397–1404, 2018, [Online]. Available: <http://ejournal.binawakya.or.id/index.php/>



- [38] K. Sinaga, M. A. Nasiution, A. Yasir, and A. Hasoloan, “Pemanfaatan Teknologi Informasi untuk Meningkatkan Pemasaran Wisata Kuliner Halal pada Era New Normal,” *Reswara J. Pengabd. Kpd. Masy.*, vol. 2, no. 2, pp. 205–211, 2021.
- [39] U. Khair, Suriati, and Dharmawati, “Pengenalan Teknologi Internet Berbasis Smartphone Untuk Wisata Kuliner Khas Melayu Bagi Ibu-Ibu Pengusaha Makanan Di Kecamatan Medan Labuhan,” *J. Tunas*, vol. 1, no. 1, pp. 45–49, 2019, doi: 10.30645/jtunas.v1i1.12.
- [40] I. A. Mastan and Y. Toni, “Menggunakan Metode Naive Bayes Classifier Sentiment Analysis Of Chicken Culinary Place From Visitor Comments Uing Naive Bayes Classifier Method,” *J. Bus. Audit Inf. Syst.*, vol. 3, no. 1, pp. 42–50, 2020.
- [41] R. Asmara, A. Basuki, and M. U. H. Al Rasyid, “Analisis Sentimen Temporal Tentang Kuliner Di Kota Surabaya Berbasis Gender Menggunakan Bahasa Indonesia,” *Technomedia J.*, vol. 5, no. 1, pp. 67–81, 2020, doi: 10.33050/tmj.v5i1.1260.
- [42] M. R. Fauzi, R. A. Pratama, P. Laksono, and P. Eosina, “Penerapan Big Data Menggunakan Algoritma Multi-Label K-Nearest Neighbor dalam Analisis Sentimen Konsumen UMKM Sektor Kuliner,” *Krea-TIF J. Tek. Inform.*, vol. 9, no. 1, pp. 9–20, 2021, doi: 10.32832/kreatif.v9i1.3587.
- [43] H. J. Christanto and Y. A. Singgalen, “Sentiment Analysis on Customer Perception towards Products and Services of Restaurant in Labuan Bajo,” *J. Inf. Syst. Informatics*, vol. 4, no. 3, pp. 511–523, 2022, doi: 10.51519/journalisi.v4i3.276.
- [44] N. Sari and A. P. Siregar, “Pengaruh Food Quality, Price, Service Quality dan Perceived Value terhadap Customer Loyalty pada Restoran Aneka Rasa Jambi dengan Customer Satisfaction sebagai Variabel Intervening,” *J-MAS J. Manaj. dan Sains*, vol. 4, no. 2, pp. 368–374, 2019, doi: 10.33087/jmas.v4i2.121.
- [45] I. P. Trianata, “Upaya Supervisor dalam Meningkatkan Kualitas Pelayanan Pramusaji di Husk Restoran The Royal Beach Seminyak Bali,” *J. Mhs. Pariwisata dan Bisnis*, vol. 1, no. 8, pp. 2011–2033, 2022.