

Implementasi *Machine Learning* dengan Metode *Text Mining* dan Algoritma Naïve Bayes untuk Klasifikasi Keluhan Pelanggan pada Twitter Operator Telkomsel

Dedi Dwi Saputra ^{1*}, Riza Fahlapi ², Antonius Yadi Kuntoro ³, Taufik Asra ⁴, Hermanto ⁵

^{1*} Program Studi Teknologi Informasi, Universitas Siber Indonesia, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta, Indonesia.

^{2,3,4} Program Studi Teknologi Informasi, Universitas Bina Sarana Informatika, Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta, Indonesia.

⁵ Program Studi Teknologi Informasi, Politeknik 'Aisyiyah Pontianak, Kota Pontianak, Provinsi Kalimantan Barat, Indonesia.

ABSTRACT

Twitter is one of the most widely used social media platforms in Indonesia, and telecommunication companies such as PT Telekomunikasi Seluler (Telkomsel) utilize their official account, @Telkomsel, as a primary channel for customer interaction and complaint handling. Currently, incoming complaint tweets are still classified manually by the customer service division, a procedure that is time-consuming and prone to human inconsistency. This study implements a text mining approach integrating the Naïve Bayes algorithm, Adaptive Boosting (AdaBoost), and the Synthetic Minority Over-Sampling Technique (SMOTE) to automatically classify Indonesian-language tweets mentioning @Telkomsel into two classes: "Complaint" and "Non-Complaint." A dataset of 2,000 tweets was collected through crawling in RapidMiner, followed by a two-stage text preprocessing workflow utilizing Gataframework and RapidMiner. The classification model was validated using 10-fold cross-validation. The experimental results demonstrate that the combination of Naïve Bayes, AdaBoost, and SMOTE achieves an accuracy of 78.84%, precision of 79.90%, recall of 80.51%, and an AUC of 0.809. These findings confirm that the proposed framework is capable of effectively automating complaint detection to support more responsive customer service operations.

ABSTRAK

Twitter merupakan salah satu platform media sosial yang paling banyak digunakan di Indonesia, dan perusahaan telekomunikasi seperti PT Telekomunikasi Seluler (Telkomsel) memanfaatkan akun resminya, @Telkomsel, sebagai kanal utama interaksi serta penanganan keluhan pelanggan. Selama ini, tweet keluhan yang masuk masih diklasifikasikan secara manual oleh divisi layanan pelanggan (*customer service*), sehingga proses penanganannya membutuhkan waktu lama dan rentan terhadap inkonsistensi manusia. Penelitian ini menerapkan pendekatan *text mining* yang mengintegrasikan algoritma Naïve Bayes, Adaptive Boosting (AdaBoost), dan Synthetic Minority Over-Sampling Technique (SMOTE) untuk mengklasifikasikan tweet berbahasa Indonesia yang menyebut @Telkomsel secara otomatis ke dalam dua kelas, yaitu "Keluhan" dan "Bukan Keluhan". Sebanyak 2.000 tweet dihimpun melalui teknik perayapan (*crawling*) menggunakan RapidMiner, kemudian diproses melalui pra-pemrosesan teks dua tahap menggunakan Gataframework dan RapidMiner. Model klasifikasi dievaluasi menggunakan *10-fold cross-validation*. Hasil pengujian membuktikan bahwa integrasi Naïve Bayes, AdaBoost, dan SMOTE menghasilkan tingkat akurasi (*accuracy*) sebesar 78,84%, presisi (*precision*) 79,90%, *recall* 80,51%, dan nilai AUC sebesar 0,809. Temuan ini menunjukkan bahwa pendekatan yang dikembangkan mampu mengotomatisasi klasifikasi keluhan secara efektif guna mendukung penanganan keluhan pelanggan yang lebih responsif dan terukur.

ARTICLE HISTORY

Received: 1 September 2026.

Revised: 2 September 2026.

Accepted: 26 February 2026.

Available Online: 10 October 2026.

Published: 1 December 2026.

KEYWORDS

Text Mining; Naïve Bayes;
SMOTE; Adaboost; Sentiment
Analysis; Twitter.

KATA KUNCI

Text Mining; Naïve Bayes;
SMOTE; Adaboost; Analisis
Sentimen; Twitter.

1. Pendahuluan

Twitter merupakan salah satu platform media sosial yang paling populer di Indonesia dan banyak dimanfaatkan oleh korporasi modern sebagai sarana promosi interaktif sekaligus kanal pendekatan langsung kepada pelanggan. PT Telekomunikasi Seluler (Telkomsel), sebagai salah satu penyedia layanan telekomunikasi seluler terbesar yang berorientasi pada kepuasan pengguna, mengoperasikan akun resmi @Telkomsel di Twitter sebagai media utama untuk menjangkau opini, pertanyaan, maupun keluhan pelanggan, mengingat karakteristik platform Twitter memungkinkan interaksi asinkron secara seketika (*real-time*) (Antinasari *et al.*, 2017). Dalam operasionalnya sehari-hari, setiap tweet yang masuk saat ini masih dipilah dan diklasifikasikan secara manual oleh tim layanan pelanggan (*customer service*) ke dalam dua kategori biner, yaitu "Keluhan" dan "Bukan Keluhan", sebelum diteruskan ke unit teknis terkait sesuai dengan esensi aduan yang disampaikan.

Keluhan secara umum didefinisikan sebagai pernyataan atau ekspresi ketidakpuasan konsumen terhadap performa produk atau layanan, baik yang disampaikan secara lisan maupun tertulis (Saputra *et al.*, 2018). Kegagalan pemenuhan standar layanan yang tidak segera direspons dan ditangani berpotensi memicu timbulnya persepsi negatif yang menyebar luas (*negative word of mouth*), yang dampaknya terhadap penurunan reputasi merek dan kepercayaan publik terbukti jauh lebih destruktif dibandingkan pengaruh dari promosi positif (*positive word of mouth*) (Saputra *et al.*, 2018). Oleh sebab itu, akselerasi kecepatan tanggap (*response time*) dan konsistensi objektivitas dalam proses penyortiran keluhan menjadi faktor yang sangat krusial bagi penyedia jasa telekomunikasi berskala besar.

Pendekatan penambangan teks (*text mining*) menawarkan instrumen strategis untuk mengotomatisasi pemilahan pesan tersebut secara cerdas. *Text mining* merupakan perluasan dari teknik penggalian data (*data mining*) yang dikhususkan untuk mengekstraksi struktur pengetahuan dari kumpulan data tekstual tak terstruktur (Dirgantara & Suryadarma, 2014), mencakup seluruh prosedur komputasi dalam menemukan pola dan informasi berharga dari korpus dokumen (Hashimi *et al.*, 2015). Meskipun demikian, eksplorasi empiris yang mengkaji efektivitas algoritma pembelajaran mesin untuk klasifikasi sentimen keluhan berbahasa Indonesia informal pada media sosial masih relatif terbatas. Celah riset (*research gap*) inilah yang melandasi urgensi penelitian ini.


Tantangan metodologis mendasar dalam klasifikasi teks aduan media sosial terletak pada fenomena ketidakseimbangan proporsi kelas (*class imbalance*), di mana volume tweet yang murni memuat keluhan teknis cenderung berjumlah minoritas dibandingkan tweet non-keluhan (seperti sapaan, interaksi kasual, atau pertanyaan umum). Kondisi ketimpangan distribusi ini berisiko menyebabkan model klasifikasi standar bias terhadap kelas mayoritas. Guna mengatasi hambatan tersebut, penelitian ini mengintegrasikan algoritma Naïve Bayes dengan teknik peningkatan performa adaptif *Adaptive Boosting* (AdaBoost) dan teknik penyeimbangan data sintetis *Synthetic Minority Over-Sampling Technique* (SMOTE). Kombinasi ini telah terbukti efektif dalam menyintesis sampel buatan pada kelas minoritas tanpa menimbulkan hilangnya representasi data esensial akibat pemangkasan sampel (*undersampling*) maupun jebakan lewat-suai (*overfitting*) akibat duplikasi acak (*random oversampling*) (Anandarajan *et al.*, 2019; Chawla *et al.*, 2002; Zhang *et al.*, 2022).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi kinerja klasifikasi model integratif Naïve Bayes, AdaBoost, dan SMOTE dalam memilah narasi tweet pelanggan @Telkomsel ke dalam kelas "Keluhan" dan "Bukan Keluhan". Data teks dikumpulkan melalui teknik perayapan (*crawling*) menggunakan RapidMiner, kemudian dipersiapkan melalui mekanisme pra-pemrosesan teks dua tahap (*two-stage preprocessing*) memanfaatkan Gataframework dan RapidMiner, sebelum akhirnya dimodelkan dan divalidasi kinerjanya menggunakan skema 10-fold *cross-validation*. Sistematika penulisan artikel ini selanjutnya menguraikan metodologi penelitian yang diterapkan, menyajikan analisis hasil eksperimen dan pembahasannya, serta merangkum kesimpulan dan rekomendasi riset lanjutan.

2. Metodologi

Objek penelitian ini adalah kumpulan pesan tweet berbahasa Indonesia yang menyebut (*mention*) akun resmi @Telkomsel di platform Twitter. Kerangka alur kerja penelitian secara menyeluruh disajikan pada

Gambar 1, yang mencakup tahapan pengumpulan data korpus, pembersihan dan pra-pemrosesan teks dua tahap, penyeimbangan proporsi kelas menggunakan SMOTE, pemodelan dan pengujian klasifikasi menggunakan integrasi Naïve Bayes dan AdaBoost, hingga evaluasi kinerja model berbasis matriks konfusi (*confusion matrix*).




Gambar 1. Kerangka Alur Kerja Penelitian Klasifikasi Tweet Keluhan

Sumber: Diadaptasi dari desain alur proses penelitian (2026).

2.1 Pengumpulan Data

Data dihimpun melalui metode perayapan (*crawling*) menggunakan perangkat lunak RapidMiner dengan kata kunci kueri penelusuran "@Telkomsel". Proses perayapan menghasilkan 2.000 tweet berbahasa Indonesia yang diambil secara acak dari pengguna akun publik. Sebagaimana diilustrasikan pada Gambar 2, alur proses perayapan data terdiri atas operator *Search Twitter* untuk mengekstraksi data mentah dari antarmuka pemrograman aplikasi (API) Twitter, *Select Attributes* untuk menyaring atribut teks relevan dan mengeliminasi metadata yang tidak digunakan, *Remove Duplicates* guna menyaring tweet duplikat agar diperoleh korpus teks yang unik, serta *Write CSV* untuk mengeksport korpus bersih ke dalam format data terstruktur.



Gambar 2. Alur Proses Perayapan Data dari Twitter Menggunakan RapidMiner

Sumber: Desain alur proses pada RapidMiner Studio.

Setelah korpus data unik tersusun, tahap berikutnya adalah pelabelan manual (*ground-truth labeling*) ke dalam dua kelas target, yaitu "Keluhan" dan "Bukan Keluhan". Pelabelan ini membagi data menjadi pasangan data latih (*training set*) untuk proses pembelajaran pola algoritma dan data uji (*testing set*) untuk mengevaluasi kemampuan generalisasi model.

2.2 Pra-pemrosesan Data (*Text Preprocessing*)

Pra-pemrosesan teks dilakukan melalui mekanisme dua tahap (*two-stage preprocessing*) guna memaksimalkan kebersihan fitur tekstual dari bahasa percakapan informal media sosial. Tahap pertama dijalankan menggunakan modul web Gataframework dengan urutan operasi: *Annotation Removal*,

Transformation Remove URL, Tokenize RegExp, Indonesian Stemming, dan Indonesian Stopword Removal. Tahap kedua dilanjutkan menggunakan RapidMiner dengan urutan operasi: *Transform Cases, Tokenization, Filter Tokens by Length, dan N-Gram Generation* (skema *bi-gram*). Contoh transformasi data pada setiap tahapan pra-pemrosesan dirangkum pada Tabel 1 sampai Tabel 6.

Tabel 1. Contoh Hasil Tahapan Annotation Removal

Before	After
"@Telkomsel Halo telkomsel saya mau bertanya... reward sebelumnya blm ilang itu knp ya"	"halo telkomsel saya mau bertanya... reward sebelumnya blm ilang itu knp ya" (huruf kapital diubah menjadi huruf kecil, anotasi dihapus)

Tabel 2. Contoh Hasil Tahapan Transformation Remove URL

Before	After
"Min, kenapa pulsa saya tiba 0 ya? ..." (mengandung tautan URL)	"min, kenapa pulsa saya tiba 0 ya? ..." (tautan/URL telah dihilangkan)

Tabel 3. Contoh Hasil Tahapan Tokenize RegExp

Before	After
Kalimat tweet hasil remove URL, masih mengandung tanda baca	Kalimat tweet terpisah menjadi token-token berdasarkan pola regular expression

Tabel 4. Contoh Hasil Tahapan Indonesian Stemming

Before	After
"...saya mau bertanya... klaim reward selanjutnya... reward sebelumnya..."	"...saya mau tanya... klaim reward lanjut... reward belum..." (kata berimbuhan diubah ke kata dasar)

Tabel 5. Contoh Hasil Tahapan Indonesian Stopword Removal

Before	After
"halo telkomsel saya mau tanya saya kan sering daily check in di aplikasi..."	"halo telkomsel daily check in aplikasi my telkomsel sdh claim rewardnya eror klaim reward reward ilang knp" (kata tidak relevan dihapus)

Tabel 6. Contoh Hasil Tahapan Transform Cases dan Tokenization (Tahap Kedua)

Before	After
"Min Kenapa ya Paket fup aku di kartu satunya gak Berfungsi? Sayang banget udah paketan."	"min kenapa ya paket fup aku di kartu satunya gak berfungsi sayang banget udah paketan" (huruf kecil, tanpa tanda baca, terpisah per kata)

Tahap akhir *preprocessing* adalah *N-Gram Generation* menggunakan skema *bi-gram*, yaitu menggabungkan kata-kata yang berurutan dalam satu kalimat menjadi pasangan kata (contoh: "min" dan "kenapa" digabung menjadi "min_kenapa"). Fitur hasil *n-gram* tersebut kemudian diberi bobot menggunakan TF-IDF sesuai Persamaan (1), di mana nilai bobot suatu *term* merupakan hasil perkalian antara frekuensi kemunculan *term* (TF) dan invers frekuensi dokumen (IDF).

$$TF-IDF = TF \times IDF \quad (1)$$

2.3. Penyeimbangan Data Menggunakan SMOTE

Synthetic Minority Over-Sampling Technique (SMOTE) merupakan algoritma *benchmark* untuk mengatasi permasalahan *class imbalance learning* (Chawla et al., 2002). SMOTE bekerja dengan mensintesis data pada kelas minoritas di ruang input berdasarkan informasi lingkungan (*nearest neighbor*) tanpa hanya menduplikasi data yang sudah ada, sehingga secara efektif mengurangi risiko *overfitting* akibat *oversampling* acak sekaligus mencegah hilangnya informasi akibat *undersampling* acak (Anandarajan et al., 2019; Zhang et al., 2022). Untuk setiap titik data pada kelas minoritas, SMOTE membangkitkan data sintesis

baru di sepanjang garis yang menghubungkan titik tersebut dengan salah satu tetangga terdekatnya yang dipilih secara acak.

2.4. Algoritma Naïve Bayes dan AdaBoost


Naïve Bayes Classifier (NBC) adalah algoritma klasifikasi berbasis Teorema Bayes dengan asumsi independensi antar-fitur (naïve). Inti dari algoritma ini adalah menentukan kelas dengan probabilitas posterior tertinggi berdasarkan fitur-fitur yang diamati (Saputra *et al.*, 2020). Formula dasar Naïve Bayes dinyatakan pada Persamaan (2):

$$P(c|d) = [P(c) \times P(d|c)] / P(d) \quad (2)$$

Dengan $P(c|d)$ adalah peluang dokumen d masuk ke kelas c , $P(c)$ adalah probabilitas prior kelas c , $P(d|c)$ adalah peluang munculnya fitur d pada kelas c , dan $P(d)$ adalah probabilitas fitur d secara keseluruhan. Untuk meningkatkan kinerja klasifikasi dasar Naïve Bayes, penelitian ini menambahkan algoritma Adaptive Boosting (AdaBoost), yaitu metode ensemble yang membangun beberapa model classifier lemah (weak learner) secara berurutan, di mana setiap model berikutnya memberi bobot lebih besar pada data yang sebelumnya salah diklasifikasikan. Kombinasi Naïve Bayes dan AdaBoost pada dataset yang telah diseimbangkan dengan SMOTE diharapkan dapat memperbaiki kinerja klasifikasi, khususnya pada kelas minoritas "Keluhan".

2.5. Desain Eksperimen dan Evaluasi Kinerja

Desain model eksperimen ditunjukkan pada Gambar 3. Proses diawali dengan operator *Read Excel* untuk membaca *dataset*, *Select Attribute* untuk memilih atribut yang digunakan, *Set Role* untuk menentukan peran atribut (*label* dan teks), *Process Documents* untuk memproses teks melalui filter *Transform Cases*, *Tokenize*, *Filter Tokens by Length*, *Stemming*, dan *Stopwords*, kemudian dilanjutkan dengan *SMOTE Upsampling* untuk menyeimbangkan kelas, dan diakhiri dengan operator *Cross Validation* menggunakan algoritma Naïve Bayes dan AdaBoost.



Gambar 3. Desain Model Pengujian Menggunakan Algoritma Naïve Bayes, AdaBoost, dan SMOTE

Sumber: Tangkapan layar desain proses pada aplikasi RapidMiner yang digunakan dalam penelitian ini.

Bagian dalam *Cross Validation*, sebagaimana ditunjukkan pada Gambar 4, terdiri atas proses *training* menggunakan operator *AdaBoost* dan proses *testing* menggunakan *Apply Model* serta *Performance* untuk menghitung metrik evaluasi. Validasi dilakukan dengan skema *10-fold cross-validation*, yaitu *dataset* dibagi menjadi 10 bagian, di mana pada setiap iterasi sembilan bagian digunakan sebagai data latih dan satu bagian sisanya digunakan sebagai data uji, sehingga seluruh data pernah menjadi data uji secara bergiliran.



Gambar 4. Proses Training dan Testing pada Cross Validation (AdaBoost + Naïve Bayes)

Sumber: Tangkapan layar desain proses pada aplikasi RapidMiner yang digunakan dalam penelitian ini.

Kinerja model dievaluasi menggunakan *confusion matrix* untuk memperoleh nilai *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN), yang selanjutnya digunakan untuk menghitung *accuracy*, *precision*, *recall*, dan *Area Under Curve* (AUC).

3. Hasil

Bagian ini menyajikan luaran empiris klasifikasi tweet keluhan pelanggan @Telkomsel menggunakan integrasi algoritma Naïve Bayes, AdaBoost, dan teknik penyeimbangan SMOTE, yang meliputi hasil pengumpulan korpus data, tahapan pra-pemrosesan teks, serta evaluasi performa model klasifikasi.

3.1 Hasil Pengumpulan dan Pelabelan Data

Proses perayapan (*crawling*) menggunakan RapidMiner dengan kueri "@Telkomsel" berhasil mengumpulkan 2.000 tweet berbahasa Indonesia. Setelah melalui tahap penyaringan tweet duplikat (*Remove Duplicates*), diperoleh kumpulan tweet unik yang disimpan dalam format berkas CSV. Seluruh data tersebut kemudian diberi label secara manual ke dalam dua kelas biner, yaitu "Keluhan" dan "Bukan Keluhan". Hasil pelabelan memperlihatkan ketimpangan distribusi kelas (*class imbalance*), di mana volume tweet pada kelas "Bukan Keluhan" mendominasi secara signifikan dibandingkan kelas "Keluhan". Ketimpangan rasio ini menjadi landasan diterapkannya teknik SMOTE pada tahap pemodelan guna mencegah bias algoritma terhadap kelas mayoritas.

3.2 Hasil Pra-pemrosesan Data (*Text Preprocessing*)

Tahapan pra-pemrosesan dua tahap berhasil mentransformasi teks percakapan informal media sosial menjadi representasi fitur numerik yang siap diproses:

- 1) Pra-pemrosesan Tahap Pertama (Gataframework): Menghasilkan korpus tweet yang bersih dari elemen non-tekstual, meliputi penghapusan anotasi akun (@) dan simbol, eliminasi tautan web (*hyperlink/URL*), pemisahan kata berbasis ekspresi reguler (*Tokenize RegExp*), konversi kata berimbuhan ke bentuk dasar (*Indonesian Stemming*), serta pembuangan kata tugas (*Indonesian Stopword Removal*), sebagaimana diilustrasikan pada Tabel 1 sampai Tabel 5 di bagian Metodologi.
- 2) Pra-pemrosesan Tahap Kedua (RapidMiner): Melakukan standarisasi huruf kecil (*Transform Cases*), pemecahan token kata bersih tanpa tanda baca (Tabel 6), pembentukan fitur urutan kata kontekstual (*bi-gram generation*), serta pembobotan nilai term menggunakan TF-IDF sebagai masukan matriks fitur numerik bagi algoritma klasifikasi.

3.3. Hasil Evaluasi Kinerja Model

Evaluasi performa klasifikasi diuji menggunakan skema *10-fold cross-validation* untuk menjamin objektivitas hasil pengujian. Matriks konfusi (*confusion matrix*) dari model Naïve Bayes yang diperkuat dengan AdaBoost dan penyeimbangan SMOTE disajikan pada Tabel 7.

Tabel 7. Confusion Matrix Model Naïve Bayes + AdaBoost + SMOTE

Model	True Positive (TP)	False Positive (FP)	True Negative (TN)	False Negative (FN)
Naïve Bayes + AdaBoost + SMOTE	913	259	221	875


Catatan: Nilai pada matriks merepresentasikan akumulasi prediksi seluruh iterasi validasi silang pada RapidMiner.

Berdasarkan pengujian klasifikasi biner pada RapidMiner, ringkasan capaian metrik performa model yang mencakup *accuracy*, *precision*, dan *recall* disajikan pada Tabel 8.

Tabel 8. Rekapitulasi Kinerja Model Naïve Bayes + AdaBoost + SMOTE

Algoritma / Metode	Akurasi (<i>Accuracy</i>)	Presisi (<i>Precision</i>)	Perolehan (<i>Recall</i>)
Naïve Bayes + AdaBoost + SMOTE	78,84%	79,90%	80,51%

Sebagaimana tertera pada Tabel 8, pengujian validasi silang menghasilkan rata-rata tingkat akurasi sebesar 78,84%, presisi 79,90%, dan *recall* mencapai 80,51%. Tingginya nilai *recall* mengindikasikan bahwa model memiliki sensitivitas yang baik dalam menjangkau tweet yang benar-benar memuat keluhan pelanggan, sehingga meminimalkan tweet aduan yang terlewatkan (*false negative*). Kemampuan diskriminasi model diuji lebih lanjut menggunakan analisis kurva karakteristik operasi penerima (*Receiver Operating Characteristic / ROC*). Kurva ROC dan nilai *Area Under Curve* (AUC) model ditunjukkan pada Gambar 5.



Gambar 5. Kurva ROC dan Nilai AUC Model Naïve Bayes + AdaBoost + SMOTE

Sumber: Luaran evaluasi kinerja RapidMiner Studio.

Model menghasilkan nilai AUC sebesar 0,809 dengan simpangan baku $\pm 0,030$ untuk kelas positif "Keluhan". Mengacu pada kriteria klasifikasi standar, perolehan nilai AUC yang berada pada interval 0,80–0,90 mengonfirmasi bahwa model Naïve Bayes yang dikombinasikan dengan AdaBoost dan SMOTE memiliki tingkat daya pisah (*diagnostic accuracy*) yang masuk dalam kategori klasifikasi yang baik (*good classification*).

4. Pembahasan

Hasil pengujian membuktikan bahwa integrasi algoritma Naïve Bayes, AdaBoost, dan teknik penyeimbangan SMOTE berhasil membangun model klasifikasi keluhan pelanggan dengan performa yang andal, ditunjukkan oleh capaian akurasi sebesar 78,84%, presisi 79,90%, *recall* 80,51%, dan nilai AUC mencapai 0,809. Nilai AUC yang melampaui ambang batas 0,80 mengindikasikan bahwa model memiliki daya pisah (*discriminative power*) yang baik dalam membedakan tweet "Keluhan" dan "Bukan Keluhan", sehingga layak diandalkan untuk keperluan pemilahan teks otomatis pada skala operasional. Meskipun demikian, evaluasi mendalam terhadap matriks konfusi pada Tabel 7 memperlihatkan bahwa frekuensi *False Negative* (FN = 875) masih relatif tinggi jika dibandingkan dengan luaran *True Positive* (TP = 913). Angka ini menunjukkan bahwa model masih rentan melakukan kesalahan tipe II, yaitu mengabaikan sebagian tweet keluhan aktual dan mengklasifikasikannya ke dalam kelompok bukan keluhan. Dinamika ini sangat erat kaitannya dengan karakteristik khas percakapan warganet pada media sosial berbahasa Indonesia, seperti tingginya penggunaan ragam bahasa informal, singkatan yang sangat bervariasi (misalnya: "gak", "blm", "knp", "lemot"), salah ketik (*typo*), hingga ekspresi ketidakpuasan bernada sarkasme atau sindiran halus. Mengingat Naïve Bayes beroperasi atas dasar asumsi independensi fitur (*conditional independence*) dan pencocokan probabilitas kata dasar melalui pembobotan TF-IDF, ketergantungan urutan makna kontekstual yang rumit sering kali gagal diekstraksi secara utuh, sehingga memicu timbulnya derau (*noise*) leksikal yang mengaburkan prediksi probabilitas.

Jika dikomparasikan dengan literatur terdahulu, temuan penelitian ini sejalan dengan studi Saputra *et al.* (2020) yang memadukan Naïve Bayes dan SMOTE untuk analisis sentimen akun layanan pelanggan operator seluler lain (@myXLCare). Penelitian tersebut membuktikan bahwa intervensi SMOTE mampu mengoreksi ketimpangan distribusi kelas secara efektif, sehingga performa klasifikasi pada kelas minoritas dapat ditingkatkan secara konsisten. Temuan empiris ini sekaligus memperkuat argumen Chawla *et al.* (2002) dan Zhang *et al.* (2022) bahwa pembentukan sampel sintesis di ruang fitur terbukti lebih superior dalam mencegah kehilangan informasi struktural teks dibandingkan prosedur pemangkas acak (*random*

undersampling). Penerapan AdaBoost pada penelitian ini memberikan kontribusi dalam memperkuat pembelajar dasar Naïve Bayes melalui mekanisme pembobotan ulang adaptif pada data yang mengalami salah klasifikasi pada iterasi sebelumnya. Kendati demikian, margin peningkatan kinerja yang dihasilkan tergolong moderat. Hal ini mengindikasikan adanya batas performa maksimum (*ceiling effect*) ketika algoritma penguat *ensemble* dipadukan dengan pengklasifikasi probabilitas sederhana (*linear probabilistic classifier*). Apabila matriks fitur representasi (dalam hal ini TF-IDF dan *bi-gram*) belum sanggup merepresentasikan hubungan semantik antarkalimat secara mendalam, maka proses iterasi *boosting* memiliki kapasitas yang terbatas dalam memisahkan batas keputusan antar-kelas secara non-linear.

Dari perspektif manajerial dan implikasi praktis, capaian akurasi (78,84%) dan *recall* (80,51%) yang seimbang menunjukkan bahwa kerangka model ini memiliki potensi aplikatif yang kuat sebagai sistem pendukung keputusan (*assistive tool*) bagi divisi layanan pelanggan PT Telekomunikasi Seluler. Model ini dapat diintegrasikan sebagai instrumen triase otomatis (*automated triage system*) untuk memfilter aliran tweet masuk secara *near real-time*, memisahkan pesan non-kritis, dan memprioritaskan eskalasi tweet keluhan ke meja operasional agen secara lebih responsif. Meskipun demikian, keberadaan tingkat *False Negative* yang masih ada menegaskan bahwa sistem otomasi ini sebaiknya diposisikan sebagai penyaring lapis pertama (*first-line screening*) yang tetap didampingi prosedur verifikasi berkala oleh petugas layanan pelanggan guna meminimalkan aduan konsumen yang luput dari penanganan. Penelitian ini memiliki sejumlah keterbatasan yang patut dipertimbangkan pada kajian mendatang. Pertama, skala korpus yang diuji (2.000 tweet) masih tergolong terbatas untuk dapat merangkum seluruh spektrum variasi dialek, singkatan populer baru, dan idiom percakapan warganet Indonesia. Kedua, formulasi klasifikasi masih terbatas pada skema biner ("Keluhan" vs. "Bukan Keluhan"), sehingga model belum mampu mengidentifikasi subtopik keluhan yang lebih spesifik (seperti gangguan jaringan sinyal, kendala tagihan/pulsa, masalah kuota data, atau malafungsi aplikasi MyTelkomsel). Ketiga, representasi fitur masih mengandalkan rekayasa statistik sederhana (TF-IDF *n-gram*), yang belum memanfaatkan representasi vektor semantik modern seperti penanaman kata (*word embedding*) atau arsitektur pembelajaran mendalam berbasis perhatian konteks (*transformer/deep learning*) yang memiliki ketahanan lebih baik terhadap variasi morfologis bahasa media sosial.

5. Kesimpulan

Penelitian ini berhasil membuktikan bahwa integrasi pendekatan penambangan teks (*text mining*) dengan algoritma Naïve Bayes, metode penguat *Adaptive Boosting* (AdaBoost), dan teknik penyeimbangan data *Synthetic Minority Over-Sampling Technique* (SMOTE) efektif diterapkan untuk mengotomatisasi klasifikasi tweet percakapan pelanggan akun resmi @Telkomsel ke dalam kategori biner "Keluhan" dan "Bukan Keluhan". Model akhir yang divalidasi melalui skema *10-fold cross-validation* menunjukkan kinerja klasifikasi yang andal dan seimbang, dengan capaian tingkat akurasi (*accuracy*) sebesar 78,84%, presisi (*precision*) 79,90%, *recall* 80,51%, serta nilai AUC mencapai 0,809 yang tergolong dalam kategori diskriminasi yang baik (*good classification*). Dari sisi penerapan praktis, kerangka pemodelan ini terbukti layak diimplementasikan sebagai sistem penapisan awal (*first-line screening*) dan alat bantu triase otomatis bagi divisi layanan pelanggan (*customer service*) PT Telekomunikasi Seluler guna memangkas durasi klasifikasi manual serta mempercepat respons penanganan aduan konsumen. Kendati demikian, tingginya angka *False Negative* menunjukkan bahwa sistem otomasi ini tetap memerlukan mekanisme supervisi dan verifikasi manusia (*human-in-the-loop*) pada implementasi operasionalnya. Untuk menyempurnakan performa model pada masa mendatang, penelitian lanjutan direkomendasikan untuk: 1) memperbesar volume dan rentang variasi korpus data percakapan media sosial; 2) mengembangkan skema klasifikasi ke tingkat multi-kelas (*multi-class classification*) guna mengidentifikasi subkategori keluhan teknis secara lebih spesifik (misalnya jaringan, pulsa/kuota, dan aplikasi); serta 3) menerapkan teknik representasi semantik lanjutan berbasis *word embedding* atau model arsitektur teranyar berbasis pembelajaran mendalam (*deep learning/transformer*) guna menangkap konteks kalimat informal secara lebih utuh.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Program Studi Teknologi Informasi, Fakultas Teknologi Informasi, Universitas Siber Indonesia atas dukungan yang diberikan selama proses penelitian dan penulisan artikel ini.

Referensi

- Anandarajan, M., Hill, C., & Nolan, T. (2019). Text preprocessing. In M. Anandarajan, C. Hill, & T. Nolan (Eds.), *Practical text analytics: Maximizing the value of text data* (pp. 45–59). Springer International Publishing. https://doi.org/10.1007/978-3-319-95663-3_4
- Antinasari, P., Perdana, R. S., & Fauzi, M. A. (2017). Analisis sentimen tentang opini film pada dokumen Twitter berbahasa Indonesia menggunakan Naive Bayes dengan perbaikan kata tidak baku. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 1(12), 1718–1724. <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/631>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Dirgantara, U., & Suryadarma, M. (2014). Perhitungan analisis sentimen berbasis komparasi algoritma Naive Bayes dan K-Nearest Neighbour berbasis Particle Swarm Optimization pada komentar insiden pembalap MotoGP 2015. *Jurnal Sistem Informasi Universitas Suryadarma*, 6(2), 1–11. <https://doi.org/10.35968/jsi.v6i2.317>
- Hashimi, H., Hafez, A., & Mathkour, H. (2015). Selection criteria for text mining approaches. *Computers in Human Behavior*, 51, 729–733. <https://doi.org/10.1016/j.chb.2014.10.062>
- Liu, B. (2012). Sentiment analysis and opinion mining. *Synthesis Lectures on Human Language Technologies*, 5(1), 1–167. <https://doi.org/10.2200/S00416ED1V01Y201204HLT016>
- Menurut Para Ahli. (2019). *Pengertian keluhan pelanggan menurut para ahli*. <https://menurutparaahli.com>
- Saputra, D. D., Gata, W., Wardhani, N. K., Parthama, K. S., Setiawan, H., Budilaksono, S., Yogatama, D., Hadiyatna, A., Purnamasari, E. P., Pratama, B., & Novianti, D. (2020). Optimization sentiments of analysis from tweets in myXLCare using Naive Bayes algorithm and Synthetic Minority Over-Sampling Technique method. *Journal of Physics: Conference Series*, 1471(1), Article 012014. <https://doi.org/10.1088/1742-6596/1471/1/012014>
- Saputra, D. D., Pratama, B., Akbar, Y., & Gata, W. (2018). Penerapan text mining untuk assignment complaint handling customer terhadap divisi terkait menggunakan metode decision tree algoritma C4.5 (Studi kasus: PT XL Axiata, Tbk). *CKI On SPOT*, 11(2), 89–96.
- Vu, D.-H. (2022). Privacy-preserving Naive Bayes classification in semi-fully distributed data model. *Computers & Security*, 115, Article 102630. <https://doi.org/10.1016/j.cose.2022.102630>
- Zhang, A., Yu, H., Zhou, S., Huan, Z., & Yang, X. (2022). Instance weighted SMOTE by indirectly exploring the data distribution. *Knowledge-Based Systems*, 249, Article 108919. <https://doi.org/10.1016/j.knosys.2022.108919>