



Klasifikasi Kategori Aduan Masyarakat pada Aplikasi LapoR Gubernur Menggunakan TF-IDF dan *Decision Tree*

Sandi Pradananto^{1*}, Muksan Junaidi²

¹⁻²Program Studi S1 Informatika, Sekolah Tinggi Teknologi Ronggolawe, Cepu, Indonesia

*Penulis Korespondensi: sandipradana3@gmail.com

Abstract. *The digitalization of public complaint services through the LapoR Gub platform in Jawa Tengah has made it easier for citizens to submit aspirations and complaints to local governments. However, the complaint classification process still faces challenges because reports are written in diverse and unstructured free-text formats. This study implements the Decision Tree algorithm to automatically classify public complaint categories in Kabupaten Blora. The dataset consists of 244 complaint records processed using the Term Frequency-Inverse Document Frequency weighting method. To reduce data distribution imbalance, several minority categories were merged, resulting in eight main classes. Model evaluation was conducted using a stratified hold-out method with an 80:20 ratio and 5-fold cross-validation. The testing results achieved an accuracy of 59.18% with a weighted F1-score of 59.79%, while cross-validation produced an average accuracy of 57.35%. In addition, feature importance analysis revealed that words such as “school,” “oil,” “fertilizer,” “agriculture,” and “road” were the dominant factors influencing the classification decisions. Based on these findings, Decision Tree demonstrates good interpretability to support the initial recommendation process for complaint categorization, although its performance is still affected by limited data size and imbalanced class distribution.*

Keywords: *Decision Tree; LapoR Gub; Public Complaints; Text Classification; TF-IDF.*

Abstrak. Digitalisasi layanan pengaduan publik melalui platform LapoR Gub di Jawa Tengah memberikan kemudahan bagi masyarakat dalam menyampaikan aspirasi dan keluhan kepada pemerintah daerah. Akan tetapi, proses pengelompokan aduan masih menghadapi kendala karena laporan ditulis dalam bentuk teks bebas yang beragam dan tidak terstruktur. Penelitian ini mengimplementasikan algoritma *Decision Tree* untuk melakukan klasifikasi otomatis terhadap kategori aduan masyarakat di Kabupaten Blora. Dataset penelitian terdiri dari 244 data aduan yang diproses menggunakan metode pembobotan *Term Frequency-Inverse Document Frequency (TF-IDF)*. Untuk mengurangi ketimpangan distribusi data, beberapa kategori dengan jumlah data terbatas digabungkan sehingga terbentuk delapan kelas utama. Evaluasi model dilakukan menggunakan metode *hold-out stratified* dengan rasio 80:20 serta *5-fold cross-validation*. Hasil pengujian menunjukkan akurasi sebesar 59,18% dengan *weighted F1-score* 59,79%, sedangkan validasi silang menghasilkan rata-rata akurasi sebesar 57,35%. Selain itu, analisis *feature importance* memperlihatkan bahwa kata seperti “sekolah”, “minyak”, “pupuk”, “pertanian”, dan “jalan” menjadi faktor dominan dalam pembentukan keputusan klasifikasi. Berdasarkan hasil tersebut, *Decision Tree* memiliki kemampuan interpretasi yang baik untuk mendukung proses rekomendasi awal kategorisasi aduan, meskipun performanya masih dipengaruhi oleh keterbatasan jumlah data dan distribusi kelas yang tidak seimbang.

Kata Kunci: *Decision Tree; Klasifikasi Teks; LapoR Gub; Pengaduan Masyarakat; TF-IDF.*

1. LATAR BELAKANG

Transformasi digital di sektor pemerintahan telah mengubah mekanisme pelayanan publik menjadi lebih terbuka, cepat, dan terintegrasi. Menurut Indrajit, R. E., et al. (2005), buku *E-Government* dijelaskan bahwa digitalisasi layanan pemerintah berperan penting dalam meningkatkan efisiensi serta transparansi pelayanan masyarakat. Sejalan dengan Peraturan Presiden Nomor 76 Tahun 2013, pemerintah menghadirkan sistem SP4N-LAPOR yang menerapkan konsep *no wrong door policy*, sehingga setiap aduan masyarakat dapat diteruskan secara tepat kepada instansi terkait. Penelitian Ningsih, A. (2023), menyebutkan bahwa sistem pengaduan digital mampu meningkatkan partisipasi publik dan efektivitas penanganan laporan.

Salah satu implementasinya adalah portal LapoGub milik Pemerintah Provinsi Jawa Tengah yang menyediakan layanan aduan melalui web, aplikasi mobile, media sosial, dan telepon terpadu. Kehadiran platform ini mempermudah masyarakat menyampaikan keluhan sekaligus membantu pemerintah dalam memantau dan mengevaluasi kualitas pelayanan publik secara berbasis data.

Meskipun sistem pengaduan digital mampu meningkatkan efektivitas pelayanan publik, proses pengelolaan laporan masih menghadapi kendala teknis, khususnya pada tahap klasifikasi aduan. Laporan masyarakat umumnya ditulis berbentuk teks bebas yang tidak terstruktur, sehingga sering mengandung singkatan, bahasa informal, bahasa daerah, serta penulisan lokasi atau instansi yang tidak konsisten. Kondisi tersebut menyebabkan proses identifikasi kategori aduan menjadi lebih kompleks dan rentan terhadap kesalahan. Jika pengelompokan laporan masih dilakukan secara manual oleh operator, maka proses penanganan akan membutuhkan waktu dan tenaga yang besar, terlebih ketika jumlah aduan meningkat dalam periode tertentu. Menurut Srivastava, A.N., & Sahami, M. (2009), karakteristik data teks yang tidak terstruktur menjadi tantangan utama pada proses pengolahan dan pengelompokan informasi secara otomatis.

Sebagai upaya mengatasi permasalahan tersebut, penerapan machine learning dapat dimanfaatkan untuk melakukan klasifikasi aduan secara otomatis berdasarkan isi teks laporan. Salah satu algoritma klasifikasi yang banyak digunakan adalah *Decision Tree* karena mampu membentuk pola keputusan melalui struktur pohon berdasarkan atribut tertentu. Dalam Han, J., et al. (2012), dijelaskan bahwa *Decision Tree* memiliki kelebihan pada tingkat interpretasi model yang tinggi sehingga proses pengambilan keputusan dapat dipahami melalui aturan berbentuk if-then. Penelitian Implementasi *Decision Tree* untuk Klasifikasi Teks menunjukkan bahwa algoritma ini cukup efektif digunakan dalam proses klasifikasi data teks karena mampu memberikan hasil prediksi yang cepat dan mudah dianalisis. Oleh karena itu, metode *Decision Tree* dinilai relevan untuk membantu proses pengelompokan kategori aduan masyarakat secara lebih cepat, konsisten, dan efisien.

Penelitian mengenai klasifikasi teks pengaduan masyarakat telah banyak dilakukan dengan berbagai pendekatan text mining dan machine learning. Penelitian Purba, M. et al. (2024), menggunakan algoritma *Logistic Regression* dengan ekstraksi fitur TF-IDF dan memperoleh akurasi sebesar 92%. Penelitian oleh Anugrah, R. R. (2023), berhasil mengelompokkan dokumen pengaduan masyarakat dengan akurasi mencapai 84% menggunakan metode *Cosine Similarity* dan *TF-IDF*. Selanjutnya, penelitian Ciang, D. (2023), menunjukkan bahwa algoritma *Decision Tree* mampu digunakan secara efektif pada klasifikasi

data teks berbasis *TF-IDF* memiliki proses pengambilan keputusan yang mudah dipahami. Penelitian Garda, K.A., et al.,(2026), memanfaatkan pendekatan deep learning untuk mengatasi tingginya variasi kategori aduan masyarakat. Selain itu, penelitian Kusuma,I.G.N.A., et al.(2023), menyoroti bahwa ketidakseimbangan data masih menjadi tantangan utama dalam klasifikasi pengaduan masyarakat. Mayoritas penelitian terdahulu fokus pada penggunaan algoritma seperti *Logistic Regression*, *Naïve Bayes*, *Cosine Similarity*, maupun *deep learning*. Sementara itu, implementasi kombinasi pembobotan *TF-IDF* dan *Decision Tree* pada data aduan masyarakat di platform Laport Gubernur Kabupaten Blora masih relatif jarang diteliti.

Berdasarkan permasalahan itu, penelitian ini dilakukan untuk mengembangkan model klasifikasi aduan masyarakat pada platform Laport Gubernur di Kabupaten Blora dengan memanfaatkan pembobotan *TF-IDF* dan algoritma *Decision Tree*. Penelitian ini difokuskan pada proses identifikasi kategori laporan secara otomatis guna membantu pemetaan pola dan distribusi aduan masyarakat. Selain itu, penelitian juga bertujuan untuk mengevaluasi tingkat akurasi model klasifikasi yang dibangun serta menganalisis kata-kata dominan yang berpengaruh dalam pembentukan struktur keputusan pada model *Decision Tree*.

2. KAJIAN TEORITIS

Pengaduan Masyarakat Digital

Pengaduan masyarakat digital merupakan bentuk partisipasi publik dalam mengawasi dan mengevaluasi kualitas pelayanan pemerintah melalui media berbasis teknologi informasi. Menurut Indrajit, R. E., et al. (2005) di buku *E-Government*, digitalisasi layanan publik mampu meningkatkan transparansi, efisiensi, dan keterlibatan masyarakat dalam proses pemerintahan. Melalui platform berbasis web, aplikasi mobile, dan media sosial, laporan masyarakat dapat terdokumentasi secara terintegrasi sehingga mempermudah proses pelacakan, tindak lanjut, dan evaluasi layanan publik. Penelitian Wibowo, P., et al. (2025), menjelaskan bahwa penerapan sistem pengaduan digital berbasis mobile mampu meningkatkan efektivitas pelayanan publik, terutama dalam mempercepat proses penyampaian dan penanganan laporan masyarakat. Di Provinsi Jawa Tengah, platform LaportGub menjadi media resmi bagi masyarakat untuk menyampaikan aspirasi dan keluhan secara terintegrasi. Data pengaduan yang terkumpul tidak hanya berfungsi sebagai dokumentasi pelayanan publik, tetapi juga dapat dimanfaatkan sebagai sumber informasi strategis untuk mendukung evaluasi layanan dan pengambilan keputusan berbasis data.

Klasifikasi Teks

Klasifikasi teks merupakan proses pengelompokan dokumen ke dalam kategori tertentu secara otomatis menggunakan pendekatan machine learning. Dalam penelitian ini, "dokumen" merujuk pada rentetan kalimat aduan warga, sementara "label" merupakan sektor birokrasi yang dituju, serta teks aduan masyarakat diklasifikasikan berdasarkan kategori layanan atau instansi terkait. Menurut Jurafsky, D., & Martin, J. H. (2013), klasifikasi teks berperan penting dalam pengolahan data tidak terstruktur karena mampu membantu identifikasi informasi secara cepat dan efisien. Penelitian Purba, M., et al. (2024), menunjukkan bahwa metode klasifikasi teks mampu memberikan performa yang baik pada data pengaduan masyarakat berbasis digital.

Karakteristik teks pengaduan umumnya tidak baku, mengandung singkatan, bahasa informal, dan istilah lokal sehingga memerlukan tahapan preprocessing sebelum dilakukan proses klasifikasi. Tahapan tersebut meliputi case folding, tokenisasi, penghapusan stopword, serta pembentukan unigram dan bigram untuk mengurangi *noise* pada data teks. Penelitian Anugrah, R. R. (2023) menjelaskan bahwa kombinasi *preprocessing* dan pembobotan *TF-IDF* mampu meningkatkan kualitas representasi fitur dalam proses klasifikasi dokumen pengaduan masyarakat.

TF-IDF

Term Frequency-Inverse Document Frequency (TF-IDF) merupakan metode pembobotan kata yang digunakan untuk mengukur tingkat kepentingan suatu istilah dalam dokumen terhadap keseluruhan kumpulan teks. Kata yang sering muncul pada satu dokumen tetapi jarang ditemukan pada dokumen lain akan memiliki bobot lebih tinggi sehingga dianggap lebih representatif. Menurut Manning, C.D. (2008), *TF-IDF* banyak digunakan dalam text mining karena mampu mengubah data teks tidak terstruktur menjadi representasi numerik yang dapat diproses algoritma *machine learning*.

Pada penelitian klasifikasi pengaduan masyarakat, *TF-IDF* digunakan untuk mengekstraksi fitur penting dari teks aduan sebelum proses klasifikasi dilakukan. Penelitian Purba, M., et al. (2024), menunjukkan bahwa pembobotan *TF-IDF* mampu meningkatkan kualitas representasi fitur dan membantu model dalam mengenali pola kata yang dominan pada laporan masyarakat. Dalam penambangan teks formulasi ini mampu mentransformasikan untaian kalimat menjadi matriks angka yang dapat dicerna oleh algoritma prediksi (Sari & Hidayat, 2022). Implementasi *TF-IDF* pada *library scikit-learn* melalui modul *TfidfVectorizer* juga mempermudah proses ekstraksi fitur secara efisien, terutama data aduan yang umum berbentuk kalimat pendek dan tidak terstruktur.

Algoritma Decision Tree

Decision Tree merupakan algoritma supervised learning yang digunakan untuk proses klasifikasi maupun prediksi melalui struktur berbentuk pohon keputusan. Model ini bekerja dengan membagi data ke beberapa cabang berdasarkan atribut yang memiliki pengaruh paling besar terhadap hasil klasifikasi. Menurut Han, J., et al. (2012), *Decision Tree* memiliki keunggulan pada tingkat interpretasi model yang tinggi karena aturan keputusan dapat dibaca dalam bentuk *if-then*.

Dalam proses pembentukan pohon keputusan, algoritma *Decision Tree* memilih atribut terbaik menggunakan ukuran seperti *Gini impurity* untuk menentukan tingkat kemurnian data pada setiap *node*. Semakin kecil nilai Gini, maka distribusi kelas pada *node* tersebut semakin homogen. Penelitian Oktavianto, H., et al. (2024), menunjukkan bahwa *Decision Tree* memiliki kemampuan klasifikasi yang baik pada data teks karena proses prediksinya *cepat* serta mudah dipahami melalui struktur pohon keputusan. Pada penelitian ini, implementasi *Decision Tree* dilakukan menggunakan library scikit-learn dengan parameter Gini index sebagai dasar utama dalam pembentukan model klasifikasi. Proses pemilihan atribut pada *Decision Tree* dilakukan menggunakan pengukuran impuritas seperti *Information Gain* dan *Gini Index* guna memperoleh pemisahan data yang optimal dalam proses klasifikasi (Charbuty & Abdulazeez, 2021; Gunawan et al., 2021). Nilai *Gini Index* dapat dihitung menggunakan persamaan berikut:

$$\text{Gini}(t) = 1 - \sum [p(j|t)]^2 \dots \dots \dots (i)$$

Di mana $p(j|t)$ merupakan proporsi kelas ke- j pada *node* t . Semakin kecil nilai *Gini Index*, maka semakin baik kualitas pemisahan data yang dihasilkan.

Evaluasi Model Klasifikasi

Evaluasi model klasifikasi dilakukan untuk mengukur kemampuan model dalam memprediksi data baru secara akurat. Menurut Bishop, C.M. & Nasrabadi, N.M.(2006), performa model klasifikasi umumnya diukur menggunakan *metrik accuracy, precision, recall*, dan *F1-score*. *Accuracy* digunakan untuk melihat tingkat ketepatan prediksi secara keseluruhan, sedangkan *precision* dan *recall* digunakan untuk menilai kualitas prediksi pada masing-masing kategori. *F1-score* berfungsi sebagai nilai keseimbangan antara *precision* dan *recall* sehingga sering digunakan pada data yang tidak seimbang. Penelitian Oktavianto, H., et al. (2024), menjelaskan bahwa penggunaan *weighted average* dan *macro average* penting untuk mengevaluasi performa model pada distribusi kelas yang tidak merata. Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan prediksi antar kategori sehingga kelemahan model dapat diidentifikasi dengan lebih jelas.

3. METODE PENELITIAN

Data dan Populasi

Dataset penelitian diekstraksi dari rekapitulasi aplikasi LapoGub khusus untuk yurisdiksi Kabupaten Blora. Setelah proses *cleaning* awal, diperoleh 244 entri aduan yang siap dikomputasi. Atribut yang menempel pada data ini cukup komprehensif, mulai dari nomor tiket, teks narasi, platform pengirim, detail domisili, stempel waktu, label target awal, hingga jejak digital penyelesaian. Karena cakupan datanya yang tidak terlampau masif, seluruh populasi aduan ini ditarik sebagai sampel utuh. Konfigurasi machine learning dirancang dengan menjadikan teks ADUAN sebagai matriks prediktor (fitur) dan KATEGORI sebagai variabel respons (target). Fitur pelengkap seperti jenis kanal atau status sengaja diabaikan agar pohon keputusan yang terbentuk murni merepresentasikan kecerdasan linguistik diuraikan pada Tabel I: Variabel Penelitian sebagai berikut:

Tabel 1. Variabel Penelitian.


Variabel	Tipe	Keterangan	Peran
Aduan	Teks	Isi laporan masyarakat dalam bentuk kalimat atau paragraf bebas	Fitur utama
Kanal	Kategorikal	Sumber laporan seperti <i>Mobile, Website, Whatsapp, Instagram, Call Center, dan Facebook</i>	Deskriptif
Kategori	Kategorikal	Label administratif aduan sebelum penggabungan kategori minor	Target awal
Target	Kategorikal	Label target setelah kategori dengan data kecil digabungkan	Target model
Status	Kategorikal	Status penanganan aduan, misalnya <i>Selesai</i> atau <i>Progress</i>	Deskriptif
Public/Private	Kategorikal	Penanda visibilitas laporan pada sistem	Deskriptif

Preprocessing Data

Standardisasi teks adalah prasyarat mutlak untuk menekan noise dalam klasifikasi klasifikasi teks NLP. Syukurnya, tidak didapati anomali nilai kosong pada atribut aduan. Rentetan kata kemudian diseragamkan menjadi huruf kecil (*case folding*), dipecah menjadi unit token, lalu disaring menggunakan daftar stopword esensial. Menariknya, sistem juga diprogram untuk mengeliminasi kata-kata yang bersifat *overfitting* administratif seperti "gubernur", "blora", dan "kecamatan", guna memastikan mesin hanya memusatkan atensi pada esensi keluhan.

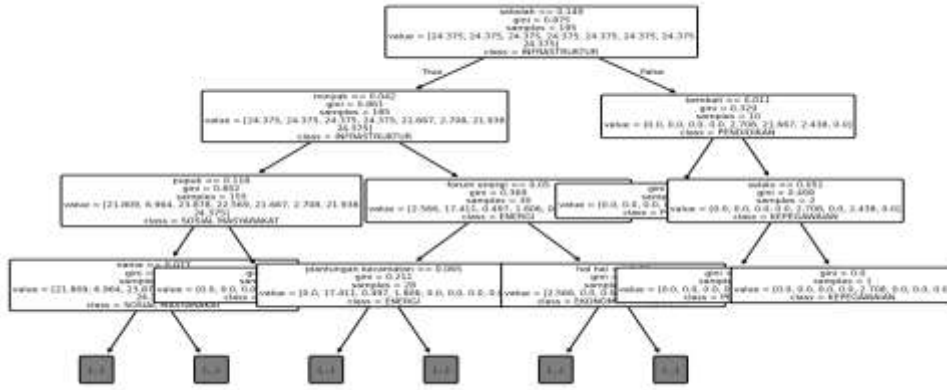
Pada sisi variabel target, dataset mentah menampakkan ketimpangan parah di mana banyak label yang populasinya sangat menyusut. Menghadapi ini, seluruh kategori dengan sampel di bawah angka delapan dilebur menjadi satu identitas baru berlabel "KATEGORI LAINNYA". Agregasi ini krusial untuk mengamankan proses stratified sampling saat partisi data dan menghindari kerancuan heuristik pada pohon akibat kelas ganjil. Berkat perampingan ini, variasi target mengerucut menjadi delapan kelas solid

Pembentukan Model Decision Tree



Gambar 1. Diagram Alir Pembentukan Model.

Pada Gambar I diatas mencerminkan Setup ekstraksi teks dikalibrasi menggunakan rentang n-gram tunggal hingga ganda (1,2), batas *document frequency* minimum di angka 2, maksimal menampung 4000 kosakata, dan menyaring token berkarakter minimal dua huruf. Taktik bigram ini secara khusus diplot untuk menjaring makna dari frasa berdampingan seperti "jalan rusak" atau "pupuk langka". Untuk otak prediksinya, *Decision Tree* dikunci pada kriteria indeks Gini dengan pembatasan penetrasi cabang maksimal 15 level (*max_depth=15*) demi mencegah model menghafal data (*overfitting*). Selain itu, parameter *class_weight='balanced'* diaktifkan sebagai kompensasi atas disparitas jumlah aduan antarkelas, memaksa model untuk lebih menghargai kelas minoritas. Gambar visualisasi model dirakit melalui mekanisme *pipeline* yang mengawinkan *TfidfVectorizer* dengan algoritma *DecisionTreeClassifier* membentuk struktur model seperti pada Gambar 2. dibawah ini:



Gambar 2. Visualisasi Empat Level Awal *Decision Tree* pada Fitur *TF-IDF*.

Evaluasi Model

Uji ketangguhan model dijalankan melalui dua skenario terpisah. Skenario pertama menerapkan pendekatan hold-out stratified dengan rasio konservatif 80:20 (195 data pelatihan berbanding 49 data pengujian). Teknik stratifikasi ini menjamin bahwa anatomi setiap kelas di data training terepresentasikan secara proporsional di data testing. Skenario lanjutan membongkar model lewat *5-fold cross validation* untuk menginspeksi ketahanan arsitektur terhadap pergeseran acak subset data. Laporan evaluasi akhir membedah performa matriks secara komprehensif, ditunjang oleh ekstraksi feature importance guna membuktikan secara logis kata apa saja yang membidani terbentuknya *ranting hierarkis* dapat diuraikan pada Tabel 2 sebagai berikut:

Tabel 2. Parameter Model dan Evaluasi Model.

Komponen	Nilai / Pengaturan
Representasi fitur	<i>TF-IDF unigram dan bigram</i>
Jumlah maksimum fitur	4000 <i>fitur</i>
Kriteria Decision Tree	<i>Gini impurity</i>
Kedalaman maksimum	15 <i>level</i>
Bobot kelas	<i>balanced</i>
Data latih : data uji	80% : 20% atau 195 : 49 data
Validasi silang	<i>5-fold StratifiedKFold</i>
Random state	42

4. HASIL DAN PEMBAHASAN

Analisis Deskriptif Dataset

Analisis awal terhadap karakteristik 244 baris dataset menyingkap tren perilaku partisipasi digital masyarakat Kabupaten Blora. Tingkat adopsi teknologi tampak sangat condong ke penggunaan *smartphone*, di mana dominasi kanal aplikasi (*Mobile*) menyerap 173 laporan (70,90%). Akses melalui peramban Web menyusul di angka 15,57%, disusul oleh platform perpesanan *WhatsApp* sebesar 7,79%, sementara kanal konvensional seperti telepon sentral nyaris tidak diminati (0,82%). Dari kacamata birokrasi, sistem ini terbukti efektif dengan rasio penyelesaian status aduan ("Selesai") mencapai 99,18%. Hal ini mengindikasikan bahwa data linguistik yang diteliti merepresentasikan keluhan yang telah dikurasi dan ditindaklanjuti secara riil dapat diuraikan pada Tabel 3 berikut ini:

Tabel 3. Karakteristik Dataset Aduan.

Aspek	Kelompok	Jumlah	Persentase (%)
Kanal	<i>Mobile</i>	173	70.90
Kanal	<i>Website</i>	38	15.57
Kanal	<i>Whatsapp</i>	19	7.79
Kanal	<i>Instagram</i>	11	4.51
Kanal	<i>Call Center</i>	2	0.82
Kanal	<i>Facebook</i>	1	0.41
Status	Selesai	242	99.18
Status	<i>Progress</i>	2	0.82
Visibilitas	<i>Public</i>	157	64.34
Visibilitas	<i>Private</i>	87	35.66

Pemadatan Kategori Laporan

Sebelum modifikasi, instansi membagi laporan dalam 15 kelompok kerja. Keluhan warga terlihat terkonsentrasi pada permasalahan fasilitas fisik dengan kategori Infrastruktur memimpin jauh (25,00%), dibuntuti isu Sosial Masyarakat (18,85%) dan problem terkait Energi (18,03%). Sayangnya, banyak kategori marjinal seperti Pariwisata dan Mitigasi Bencana sangat miskin sampel. Langkah penggabungan kelas terbukti menyelamatkan data dari risiko kegagalan prediksi algoritmik. Kategori minor berhasil diringkas ke dalam "KATEGORI LAINNYA", membentuk distribusi 8 kelas final yang cukup logis untuk memfasilitasi pembagian rasio *train-test split* yang seimbang diuraikan pada Tabel 4 dan Gambar 2 berikut dibawah ini:

Tabel 4. Distribusi Kelas Target Setelah Penggabungan Kategori Minor.

Kategori Target	Jumlah Aduan	Persentase (%)
Infrastruktur	61	25.00
Sosial Masyarakat	46	18.85
Energi	44	18.03
Kategori Lainnya	34	13.93
Ekonomi Dan Industri	24	9.84
Pertanian	13	5.33
Pendidikan	11	4.51
Kepegawaian	11	4.51

**Gambar 3.** Distribusi Kelas Target Aduan Masyarakat Kabupaten Blora.

Pembagian Data Latih dan Data Uji

Lewat pendekatan stratified, korpus data terbelah menjadi 195 sampel historis untuk melatih bobot node dan 49 sampel unseen untuk menguji ketajamannya. Penjagaan proporsi silang ini memaksa algoritma untuk tetap belajar dari kategori minor. Walau begitu, patut dicatat bahwa penyusutan data uji pada sektor Pendidikan dan Kepegawaian menyisakan masing-masing 2 sampel belaka, yang menuntut interpretasi evaluasi yang hati-hati pada kelas tersebut diuraikan pada Tabel V sebagai berikut:

Tabel 5. Distribusi Data Latih dan Data Uji per Kelas.

Kategori Target	Total	Data Latih	Data Uji
Infrastruktur	61	49	12
Sosial Masyarakat	46	37	9
Energi	44	35	9
Kategori Lainnya	34	27	7

Kategori Target	Total	Data Latih	Data Uji
Ekonomi Dan Industri	24	19	5
Pertanian	13	10	3
Pendidikan	11	9	2
Kepegawaian	11	9	2

Hasil Analisis Model Decision Tree

Sesi pemodelan membuahkan arsitektur *Decision Tree* yang berhasil membentang hingga batas kedalaman 15 tingkat, merajut 40 daun akhir (*leaf nodes*). Struktur hierarkis yang lumayan rapat ini merepresentasikan upaya intens model dalam mengais pola pemisah pada ruang dimensi teks yang sangat variatif. Melirik sisi akurasi global, engine ini mampu mendeteksi 59,18% kategori secara akurat dari 49 data uji. Kalkulasi *F1-Score weighted* menyentuh 59,79%, namun saat dievaluasi menggunakan kaca mata makro, angkanya merangkak ke 62,55%. Fenomena ini menyiratkan bahwa pengaktifan fitur penyeimbang kelas (*class_weight*) bekerja dengan baik dalam mengangkat performa deteksi pada kategori kelas minoritas dapat diuraikan pada Tabel VI dan Tabel VII sebagai berikut:

Tabel 6. Evaluasi *Hold-Out Model Decision Tree* (Data Uji n=49).

Model	Accuracy (%)	Precision Weighted (%)	Recall Weighted (%)	F1 Weighted (%)	F1 Macro (%)
<i>Decision Tree</i>	59.18	62.27	59.18	59.79	62.55

Tabel 7. Laporan Klasifikasi *Decision Tree* per Kelas pada Data Uji.

Kelas	Presisi (%)	Recall (%)	F1-Score (%)	Support
Infrastruktur	72.73	66.67	69.57	12
Sosial Masyarakat	42.86	66.67	52.17	9
Energi	71.43	55.56	62.50	9
Kategori Lainnya	50.00	42.86	46.15	7
Ekonomi Dan Industri	40.00	40.00	40.00	5
Pertanian	100.00	66.67	80.00	3
Pendidikan	100.00	100.00	100.00	2
Kepegawaian	50.00	50.00	50.00	2

Menilik laporan klasifikasi spesifik pada Tabel VII diatas, kelas Infrastruktur dan Energi berhasil menorehkan *F1-score* moderat di kisaran 62-69%, sementara isu Pertanian melonjak hingga 80%. Sebaliknya, performa di sektor Ekonomi dan ranah Sosial tampak stagnan (berkisar 40-52%), sebuah indikasi kuat bahwa kosakata keluhan warga seputar kemiskinan dan kebutuhan pokok saling bertabrakan dan mengecoh model.

*Confusion Matrix***Tabel 8.** *Confusion Matrix Model Decision Tree.*

Aktual \ Prediksi	Infrastruktur	Sosial Masyarakat	Energi	Kategori Lainnya	Ekonomi & Industri	Pertanian	Pendidikan	Kepegawaian
Infrastruktur	8	2	1	1	0	0	0	0
Sosial Masyarakat	2	6	0	0	1	0	0	0
Energi	0	0	5	2	1	0	0	1
Kategori Lainnya	0	4	0	3	0	0	0	0
Ekonomi & Industri	1	1	1	0	2	0	0	0
Pertanian	0	1	0	0	0	2	0	0
Pendidikan	0	0	0	0	0	0	2	0
Kepegawaian	0	0	0	0	1	0	0	1

Berdasarkan Pembedahan *Confusion Matrix* pada Tabel VIII diatas memperjelas titik buta dari algoritma Decision Tree ini. Kategori Infrastruktur yang berkinerja apik sukses mencatatkan 8 tebakan sempurna, meski beberapa laporannya justru tersesat masuk ke ranah Sosial dan Energi. Kelas Energi pun tidak luput dari kesalahan fatal karena beberapa laporan gas elpiji sering tercampur frasa "kelangkaan dan ekonomi" sehingga masuk ke radar kelas Ekonomi dan Industri. Tantangan terbesar mutlak bersarang di kelompok "KATEGORI LAINNYA". Sebagai imbas dari penyatuan berbagai instansi minor, klaster ini mengalami krisis identitas linguistik. Lebih dari separuh tebakannya dibelokkan sistem menuju kelas Sosial Masyarakat.

Konsistensi lewat *Cross-Validation***Tabel 9.** Hasil 5-Fold *Cross Validation Decision Tree.*

Fold ke-	Akurasi (%)	Weighted F1-Score (%)
1	53.06	53.87
2	63.27	64.49
3	61.22	61.09
4	59.18	59.74
5	50.00	48.66
Rata-rata	57.35	57.57
Simpangan Baku	5.02	5.62

Berdasarkan pada Tabel IX diatas, model diacak kembali dalam simulasi silang 5 putaran. Hasilnya memperlihatkan rerata akurasi 57,35% yang selaras dengan performa *weighted F1-Score* di level 57,57%. Rentang deviasi simpangan baku di angka 5,62% menyodorkan fakta realis: pohon keputusan rentan terdistorsi (*unstable*) apabila fondasi sampel pelatihannya berukuran mini dan diubah susunannya. Atas dasar ini, luaran penelitian ini sangat ideal diposisikan sebagai mesin baseline interpretatif, bukan sistem automasi tanpa awak.

Bobot Pengaruh Fitur TF-IDF

Tabel 10. Fitur TF-IDF dengan Kepentingan Tertinggi pada *Decision Tree*.

Fitur/Kata	Feature Importance	Persentase (%)
sekolah	0.1143	11.43
minyak	0.0830	8.30
pupuk	0.0759	7.59
nama	0.0621	6.21
pertanian	0.0592	5.92
jalan	0.0553	5.53
layak	0.0493	4.93
hal	0.0422	4.22
kembali	0.0420	4.20
2025	0.0413	4.13
undang undang	0.0359	3.59
forum energi	0.0273	2.73

Berdasarkan Fitur TF-IDF pada Tabel X diatas, Nilai jual utama *Decision Tree* tersaji secara gemilang lewat ekstraksi kepentingan fitur. Algoritma menetapkan kata "sekolah" (11,43%) sebagai fondasi utama di akar pohon, ditemani token strategis semisal "minyak", "pupuk", dan "jalan". Kemunculan istilah ini sama sekali tidak mengherankan dan berkorelasi langsung dengan urat nadi laporan yang masuk ke Pemprov Jawa Tengah. Kendati demikian, perlu diwaspadai bahwa nilai ini sebatas refleksi reduksi kemurnian node, bukan korelasi kausal murni, sehingga campur tangan verifikator manusia tetap tak ternilai harganya.

5. KESIMPULAN DAN SARAN

Inisiatif pengembangan model *Decision Tree* bersenjatakan *TF-IDF* untuk meringankan beban sortiran aplikasi Lapor Gubernur terbukti potensial secara interpretatif. Dengan memanen 244 korpus teks keluhan warga Kabupaten Blora, algoritma sukses menjangkau isu utama (Infrastruktur, Sosial, dan Energi) dan menembus akurasi rata-rata 57-59% baik dalam pengujian statis maupun silang (*cross-validation*). Walaupun model prediktif ini masih terjangkau sensitivitas akibat minimnya populasi data dan peliknya struktur kalimat informal, kejernihan fitur dominan seperti kemunculan kata kunci "sekolah" dan "jalan rusak" yang dipelajari mesin memvalidasi kepintaran sistem dalam menangkap intisari pengaduan.

Ke depan, sangat direkomendasikan untuk tidak hanya mengakumulasi himpunan teks yang jauh lebih masif, namun juga mengekskansi arsitektur ini ke arah algoritma pembelajar ansambel (*Random Forest* atau *Gradient Boosting*) hingga pengayaan prapemrosesan memanfaatkan model bahasa transformer murni yang dilatih dengan teks Nusantara.

DAFTAR REFERENSI

- Anugrah, R. R. (2023). Penerapan cosine similarity dan pembobotan TF-IDF untuk klasifikasi pengaduan masyarakat berbasis web (Studi kasus: BAGWASSIDIK Ditreskrim Polda Kalbar). *Coding: Jurnal Komputer dan Aplikasi*, 11(1), 100–109. <https://doi.org/10.26418/coding.v11i1.55598>
- Bahreini, M., & Apandi, S. (2025). Perbandingan kinerja Naive Bayes, Support Vector Machine, regresi logistik, dan decision tree untuk klasifikasi sentimen ulasan produk berbasis TF-IDF. *Techno. com*, 24(4). <https://doi.org/10.62411/tc.v24i4.13968>
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). Springer.
- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28. <https://doi.org/10.38094/jastt20165>
- Christianto, Y. (2025). Klasifikasi tingkat literasi digital menggunakan model SVM dan LSTM dengan ekstraksi fitur TF-IDF dan BERT embedding (Doctoral dissertation, Universitas Islam Negeri Maulana Malik Ibrahim).
- Ciang, D. (2023). Klasifikasi toksisitas komentar dengan algoritma Naive Bayes dan decision tree. *Jurnal Komputer dan Informatika*, 18(1), 31–37.
- Garda, K. A., Saraswati, G. W., & Lutfina, E. (2026). Penerapan model deep learning BiLSTM untuk klasifikasi multi-kelas pada data aduan masyarakat. *Jurnal INSTEK (Informatika Sains dan Teknologi*, 11(1), 52–68.
- Gunawan, G., Rahmawati, A., Suhada, S., Hidayatulloh, T., & Wintana, D. (2021). Optimasi linear sampling dan information gain pada algoritma decision tree untuk diagnosis penyakit diabetes. *MULTINETICS*, 7(2), 124–131. <https://doi.org/10.32722/multinetics.v7i2.3796>

- Han, J., Kamber, M., & Pei, J. (2012). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- Indrajit, R. E., Zainudin, A., & Rudianto, D. (2005). *Electronic government in action*. Andi Yogyakarta.
- Jurafsky, D., & Martin, J. H. (2013). *Speech and language processing*. Pearson.
- Kowsari, K., Meimandi, K. J., Heidarysafa, M., Mendu, S., Barnes, L., & Brown, D. (2019). Text classification algorithms: A survey. *Information*, 10(4), 150. <https://doi.org/10.3390/info10040150>
- Kusuma, I. G. N. A., Pradipta, I. M., Santosa, I. M. A., & Dharmendra, I. K. (2023). Penanganan ketidakseimbangan data pada klasifikasi pengaduan masyarakat. *Jurnal Teknologi Informasi dan Komputer*, 9(5). <https://doi.org/10.36002/jutik.v9i5.2643>
- Manning, C. D. (2008). *Introduction to information retrieval*. Syngress. <https://doi.org/10.1017/CBO9780511809071>
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2021). Deep learning-based text classification: A comprehensive review. *ACM Computing Surveys*, 54(3), 1–40. <https://doi.org/10.1145/3439726>
- Ningsih, A. (2023). Implementasi SP4N-LAPOR dalam pelayanan pengaduan masyarakat di Kabupaten Luwu Utara Provinsi Sulawesi Selatan (Doctoral dissertation, IPDN). <https://doi.org/10.33701/jtkp.v4i2.2877>
- Oktavianto, H., Sulistyono, H. W., Wijaya, G., Irawan, D., & Abdurrahman, G. (2024). Analisis perbandingan decision tree dan random forest pada klasifikasi teks data kesehatan. *Bina Insani ICT Journal*, 11(1), 56–65. <https://doi.org/10.51211/biict.v11i1.2928>
- Purba, M., Asri, S. D., Ayumi, V., Salamah, U., & Iryani, L. (2024). Klasifikasi dataset teks pengaduan masyarakat terhadap pemerintah di sosial media menggunakan logistic regression. *JSAI (Journal Scientific and Applied Informatics)*, 7(1), 78–83. <https://doi.org/10.36085/jsai.v7i1.6447>
- Sari, A. N., & Hidayat, R. (2022). Optimasi pembobotan kata TF-IDF untuk klasifikasi keluhan pelanggan menggunakan machine learning. *Jurnal Sistem Informasi*, 11(2), 45–52.
- Srivastava, A. N., & Sahami, M. (Eds.). (2009). *Text mining: Classification, clustering, and applications*. CRC Press. <https://doi.org/10.1201/9781420059458>
- Wibowo, P., Tarigan, M. F. A., & Siregar, H. F. (2025). Implementasi teknologi mobile e-digital dalam meningkatkan efisiensi pengaduan masyarakat. *Jurnal Garuda Pengabdian Kepada Masyarakat*, 3(1), 1–10. <https://doi.org/10.55537/gabdimas.v3i1.934>
- Yuliana, R., & Hakim, A. (2026). Machine learning untuk reformasi birokrasi: Studi kasus LaporanGub di Jawa Tengah. *Jurnal Tata Kelola Digital Nusantara*, 3(1), 10–18.