

MODEL KLASIFIKASI *TWEET* TERKAIT ISU #INDONESIAHELAP MENGGUNAKAN SUPPORT VECTOR MACHINE BERBASIS DISTRIBUSI TOPIK LDA

Fransesko Indrajid^{1*}, I Nyoman Saputra Wahyu Wijaya²

^{1,2} Jurusan Teknik Informatika, Universitas Pendidikan Ganesha; Jl Udayana No. 11, Singaraja, Kec. Buleleng, Kab. Buleleng, Bali, 81116, Indonesia;

Keywords:

Sentiment Analysis;
Support Vector Machine;
Topic Modeling;
Latent Dirichlet Allocation;
#IndonesiaGelap

Correspondent Email:

fransesko@undiksha.ac.id

Abstrak. Tagar #IndonesiaGelap di platform X mencerminkan keresahan masyarakat terhadap dinamika sosial-politik Indonesia. Tingginya volume data tweet terkait tagar ini menghadirkan tantangan praktis dalam pengembangan model klasifikasi teks. Kendala utama terletak pada proses pelabelan data untuk supervised learning, di mana pelabelan manual pada dataset berskala besar menjadi tidak efisien dan memakan waktu lama. Penelitian ini bertujuan untuk mengembangkan model klasifikasi teks sekaligus menyelesaikan permasalahan efisiensi pelabelan tersebut melalui pendekatan otomatis. Metode yang diusulkan mengintegrasikan Latent Dirichlet Allocation (LDA) sebagai generator label otomatis (automated labeling) dan Support Vector Machine (SVM) sebagai pengklasifikasi. LDA digunakan untuk mengekstraksi struktur topik tersembunyi yang kemudian dikonversi menjadi label kategori untuk data latih. Hasil eksperimen menunjukkan bahwa LDA berhasil membentuk 6 label topik yang koheren. Model SVM yang dilatih menggunakan data berlabel otomatis ini, melalui optimasi hyperparameter Kernel RBF, mampu mencapai akurasi sebesar 88,05%. Penelitian ini membuktikan bahwa integrasi LDA dan SVM merupakan solusi strategis untuk mengatasi hambatan pelabelan data, memungkinkan pembangunan model klasifikasi yang akurat pada data media sosial berskala besar tanpa memerlukan intervensi manual.



Copyright © [JITET](http://jitet.undiksha.ac.id) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. The #IndonesiaGelap hashtag on the X platform reflects public unrest regarding Indonesia's socio-political dynamics. The high volume of tweets regarding this hashtag presents practical challenges in developing text classification models. The primary obstacle lies in the data labeling process for supervised learning, where manual labeling on large-scale datasets is inefficient and time-consuming. This study aims to develop a text classification model while solving the labeling efficiency problem through an automated approach. The proposed method integrates Latent Dirichlet Allocation (LDA) as an automated label generator and Support Vector Machine (SVM) as a classifier. LDA is utilized to extract hidden topic structures, which are then converted into category labels for training data. Experimental results show that LDA successfully formed 6 coherent topic labels. The SVM model trained using this automatically labeled data, through RBF Kernel hyperparameter optimization, achieved an accuracy of 88.05%. This study demonstrates that the integration of LDA and SVM is a strategic solution to overcome data labeling bottlenecks, enabling the construction of accurate classification models on massive social media data without the need for manual intervention.

1. PENDAHULUAN

Pada awal tahun 2025, “IndonesiaGelap” mencuat sebagai isu yang ramai diperbincangkan di platform X [1]. Ramai dibicarakan dalam kurun waktu hampir enam bulan, “#IndonesiaGelap” tidak hanya menjadi *trending*, tetapi juga berubah menjadi simbol dari keresahan kolektif masyarakat terhadap kondisi sosial-politik nasional, mencakup kritik terhadap militerisasi sipil, ketimpangan ekonomi, kemunduran demokrasi, serta ketidakpuasan terhadap kinerja pemerintahan yang baru menjabat [2]. Mengingat sifatnya yang telah menjadi wadah kritik yang persisten, besar kemungkinan isu ini akan terus diperbincangkan seiring dengan dinamika pemerintahan kedepannya. Oleh karena itu, terdapat urgensi untuk memahami struktur isu ini secara mendalam melalui pengelompokan atau klasifikasi *tweet* agar pergeseran fokus kritik publik dapat dipantau secara cepat dan akurat.

Keberhasilan klasifikasi *tweet* pada platform X (sebelumnya Twitter) telah teruji dari berbagai eksperimen dengan tujuan penelitian yang beragam, mulai dari ranah hukum hingga analisis sosial. Metode klasifikasi teks terbukti mampu mengidentifikasi konten sensitif seperti dugaan pencemaran nama baik, yang krusial dalam pemantauan pelanggaran hukum di media sosial [3]. Selain itu, pendekatan ini juga efektif dalam memetakan percakapan publik dengan cara mengelompokkan *tweet* ke dalam berbagai kategori topik sosial [4]. Lebih jauh, klasifikasi teks juga diterapkan untuk mendeteksi penyebaran berita bohong atau *hoax* [5], dan menganalisis sentimen masyarakat terhadap suatu isu, sehingga hasilnya dapat dimanfaatkan sebagai bahan pertimbangan dalam perumusan kebijakan yang lebih tepat sasaran [6]. Studi komparasi terhadap berbagai algoritma juga menegaskan bahwa dengan penanganan yang tepat, data *tweet* yang tidak terstruktur dapat diolah menjadi informasi yang akurat dan terorganisir [7].

Namun, penerapan metode klasifikasi pada data dari media sosial seperti isu #IndonesiaGelap menghadapi kendala praktis. Dalam pengembangan model klasifikasi teks, data yang akan digunakan tentunya harus dilabelkan terlebih dahulu karena klasifikasi teks bersifat *supervised learning* [8]. Namun,

volume *tweet* yang sangat besar membuat pelabelan data yang biasanya dilakukan secara manual menjadi mustahil untuk dilakukan secara efisien, karena menganotasi puluhan ribu *tweet* satu per satu akan memakan waktu yang sangat lama. Permasalahan inilah yang menghambat pada saat pengembangan model klasifikasi, sehingga diperlukan sebuah pendekatan otomatis untuk melabeli data tersebut.

Sebagai solusi atas hambatan efisiensi tersebut, pendekatan *unsupervised learning* melalui pemodelan topik (*topic modeling*) menjadi alternatif yang strategis. Secara khusus, metode *Latent Dirichlet Allocation* (LDA) dapat dimanfaatkan untuk mengekstraksi struktur topik tersembunyi dari ribuan *tweet* secara otomatis tanpa memerlukan intervensi manual [9]. Distribusi topik yang dihasilkan oleh LDA kemudian dapat dikonversi menjadi label kategori (*automated labeling*), yang berfungsi sebagai data latih yang siap pakai. Penelitian sebelumnya menunjukkan bahwa dengan pendekatan yang tepat, LDA mampu menghasilkan topik-topik yang koheren dan mudah diinterpretasikan, bahkan pada data media sosial yang penuh variasi [10].

Dengan tersedianya data yang telah terlabeli melalui proses pemodelan topik ini, pengembangan model klasifikasi dapat dilanjutkan ke tahap pembangunan sistem prediksi otomatis (*text classification*). Dalam konteks pengolahan data teks yang kompleks, klasifikasi berfungsi untuk memetakan dokumen input ke dalam kategori kelas yang spesifik berdasarkan pola fitur yang dimilikinya [11]. Dengan karakteristik dataset yang berdimensi tinggi (*high-dimensional space*), maka akan digunakan *Support Vector Machine* (SVM) sebagai algoritma metode utama dalam penelitian ini. Hal ini didasarkan pada prinsip kerja SVM yang berfokus pada penemuan *hyperplane* pemisah optimal (*optimal separating hyperplane*) untuk memaksimalkan margin antar kelas [12]. Oleh karena itu SVM sering digunakan pada penelitian yang menggunakan data platform X (Twitter) dalam berbagai studi empiris dengan fokus permasalahan yang beragam, misalnya pada analisis sentimen terhadap isu politik dan tokoh publik, di mana SVM terbukti mampu memetakan opini masyarakat terkait isu

pemecatan pejabat negara dengan akurasi mencapai 95,13% [13]. Fleksibilitas algoritma ini semakin terlihat dalam kemampuannya menangani masalah sosial, seperti deteksi kalimat perundungan (*cyberbullying*) [14], hingga analisis psikologis yang lebih kompleks melalui klasifikasi delapan jenis emosi pengguna yang dikombinasikan dengan fitur *FastText* [15].

Seiring dengan meningkatnya kebutuhan akan efisiensi dalam analisis data, penelitian ini bertujuan untuk mengkaji kinerja klasifikasi menggunakan Support Vector Machine (SVM) pada dataset #IndonesiaGelap yang dilabeli secara otomatis berdasarkan hasil pemodelan topik LDA. Penelitian ini berfokus pada eksplorasi potensi integrasi antara pelabelan otomatis dan algoritma klasifikasi dalam membangun model analisis. Melalui pendekatan ini, penelitian diharapkan dapat memberikan gambaran mengenai alternatif yang lebih praktis dalam memantau dinamika isu publik secara cepat, tanpa sepenuhnya bergantung pada proses pelabelan manual yang kompleks dan memerlukan waktu yang besar.

2. TINJAUAN PUSTAKA

2.1 Text Classification

Klasifikasi teks (*text classification*) merupakan salah satu tugas fundamental dalam disiplin ilmu *Natural Language Processing* (NLP) dan *Data Mining* yang bertujuan untuk menetapkan kategori atau label kelas yang telah ditentukan sebelumnya (*predefined classes*) ke dalam suatu dokumen teks secara otomatis. Sebagai bagian dari pendekatan *supervised learning*, proses klasifikasi mensyaratkan adanya data latih (*training data*) yang telah memiliki label, di mana algoritma akan mempelajari pola hubungan antara fitur dalam teks dengan kategori targetnya untuk kemudian digunakan dalam memprediksi kelas pada data baru yang belum dikenal [4].

Secara teknis, proses klasifikasi teks tidak dapat dilakukan langsung pada data mentah (*raw data*). Tahapan ini umumnya diawali dengan pra-pemrosesan data (*preprocessing*) untuk membersihkan gangguan atau *noise* seperti tanda baca, angka, dan kata-kata yang tidak bermakna (*stopwords*), serta normalisasi kata. Setelah data bersih, dilakukan tahap ekstraksi fitur (*feature extraction*) untuk mengubah representasi teks menjadi format

numerik atau vektor yang dapat diproses oleh mesin, misalnya menggunakan metode TF-IDF atau *Bag-of-Words* [16]. Kualitas dari pra-pemrosesan dan ekstraksi fitur ini sangat menentukan akurasi akhir dari model klasifikasi yang dibangun [17].

2.2 Support Vector Machine

Support Vector Machine (SVM) adalah algoritma *supervised learning* yang bekerja dengan mencari *hyperplane* atau garis batas terbaik untuk memisahkan data ke dalam kelas-kelas yang berbeda. Prinsip utama algoritma ini adalah memaksimalkan *margin*, yaitu jarak terlebar antara garis batas dengan data terluar dari masing-masing kelas (*support vectors*), untuk menghasilkan keputusan yang paling akurat [4]. Mekanisme ini menjadikan SVM sangat tangguh dalam menangani data teks berdimensi tinggi seperti *tweet*, karena mampu menghasilkan prediksi yang stabil dan meminimalkan risiko kesalahan (*overfitting*) meskipun dihadapkan pada ribuan fitur kata yang kompleks [3], [16].

Untuk menangani data teks media sosial yang sering kali tidak memiliki pola linear yang sederhana, SVM menerapkan teknik *kernel trick*, seperti *Radial Basis Function* (RBF), yang memetakan data ke dimensi lebih tinggi agar lebih mudah dipisahkan [15], [17]. Selain itu, karena penelitian ini melibatkan beberapa label (multi-kelas), SVM menerapkan strategi *One-vs-Rest*. Strategi ini memecah masalah klasifikasi menjadi beberapa bagian sederhana (satu topik lawan sisanya) untuk memastikan setiap kategori isu #IndonesiaGelap dapat dikenali dengan presisi tinggi, sebagaimana telah terbukti efektif dalam berbagai studi pengelompokan topik sosial sebelumnya [4], [13].

2.3 Topic Modeling

Pemodelan topik atau *Topic Modeling* adalah teknik dalam *Natural Language Processing* (NLP) yang digunakan untuk menemukan struktur tematik tersembunyi (*latent structure*) di dalam sekumpulan besar dokumen teks [18]. Sebagai metode *unsupervised learning*, pemodelan topik bekerja dengan menganalisis pola kemunculan kata-kata yang sering muncul bersamaan (*co-occurrence*) untuk mengelompokkan dokumen ke dalam kluster-kluster topik yang berbeda [19].

Dalam penelitian ini, *topic modeling* digunakan sebagai cara untuk memberi label data secara otomatis. Karena *tweet* dengan tagar #IndonesiaGelap tidak memiliki kategori bawaan, *topic modeling* dimanfaatkan untuk mengelompokkan *tweet* ke dalam beberapa isu utama. Hasil pengelompokan tersebut kemudian digunakan sebagai label kelas untuk melatih model klasifikasi SVM. Dengan pendekatan ini, *tweet* yang awalnya tidak terstruktur dapat dimanfaatkan dalam proses klasifikasi tanpa melalui pelabelan manual [4].

2.4 Latent Dirichlet Allocation

Latent Dirichlet Allocation (LDA) adalah sebuah model probabilitas generatif yang populer digunakan untuk pemodelan topik yang diperkenalkan oleh Blei et al., konsep dasar LDA mengasumsikan bahwa setiap dokumen merupakan campuran dari beberapa topik, dan setiap topik merupakan campuran dari sekumpulan kata-kata [20]. Dengan kata lain, LDA bekerja dengan mencari tahu kelompok kata yang sering muncul bersamaan dalam satu konteks dan mengelompokkannya ke dalam topik-topik yang berbeda [21]. Untuk mengukur kualitas topik yang dihasilkan, metrik evaluasi seperti *Topic Coherence* sering digunakan. *Coherence score* yang tinggi mengindikasikan bahwa kata-kata dalam satu topik memiliki keterkaitan semantik yang kuat dan mudah diinterpretasikan oleh manusia [18].

Hasil dari model LDA adalah sekumpulan distribusi kata yang bersifat matematis. Untuk membuatnya dapat dipahami, diperlukan langkah lanjutan yaitu interpretasi hasil. Interpretasi hasil adalah proses subjektif di mana manusia (seorang ahli di bidang terkait, atau domain expert, yang dalam penelitian ini adalah seorang wartawan/jurnalis) menelaah daftar kata kunci teratas dari sebuah topik untuk memberikan label tematik yang bermakna [22]. Langkah ini penting untuk menerjemahkan hasil statistik menjadi label kelas klasifikasi yang dapat dipahami [23].

2.5 Data Preprocessing

Proses *data preprocessing* merupakan sekumpulan teknik yang digunakan untuk membersihkan dan mengubah data teks mentah menjadi format yang terstruktur dan siap untuk diolah ke tahap selanjutnya [24]. Tahapan pra-pemrosesan data dalam penelitian ini meliputi langkah-langkah berikut:

1. Pembersihan Data

Proses ini bertujuan menghilangkan elemen-elemen yang tidak memberikan informasi semantik yang relevan bagi model. Hal ini mencakup penghapusan URL (tautan), *username* (misalnya @pengguna), simbol *hashtag* (#), angka, tanda baca, emoji, serta karakter non-ASCII lainnya. Tujuan utamanya adalah menyisakan teks murni yang siap dianalisis

2. Case Folding

Tahap ini menyeragamkan seluruh karakter huruf menjadi huruf kecil (*lowercase*). Langkah ini penting untuk menghindari duplikasi fitur akibat perbedaan kapitalisasi.

3. Tokenisasi

Tahap akhir dari pra-pemrosesan adalah pemecahan kalimat menjadi potongan-potongan kata tunggal atau *token*.

4. Normalisasi

Langkah untuk mengubah kata-kata tidak baku, *slang*, atau salah ketik menjadi bentuk bakunya. Tahap ini sangat krusial saat menganalisis teks informal dari media sosial. Proses ini biasanya memerlukan kamus atau leksikon kata slang.

5. Stopword Removal

Untuk meningkatkan akurasi hasil, dilakukan proses *stopword removal*. Tahap ini mengeliminasi kata-kata fungsional yang tidak memiliki makna substansial, contohnya kata sambung dan kata ganti, hal ini dilakukan agar model dapat fokus pada kata-kata yang lebih informatif

6. Stemming

Stemming adalah proses reduksi sebuah kata menjadi bentuk dasarnya (*root word*) dengan cara menghilangkan seluruh imbuhan, baik awalan (prefiks) maupun akhiran (sufiks). Tujuan utama dari proses ini adalah untuk menyeragamkan berbagai variasi kata yang memiliki akar yang sama, sehingga dapat mengurangi kompleksitas kosakata dalam teks dan meningkatkan efisiensi analisis.

2.6 TF-IDF Feature Extraction

Setelah tahap pembersihan data, teks *tweet* perlu diubah menjadi format angka agar dapat diproses oleh algoritma komputer. Metode yang digunakan dalam penelitian ini adalah *Term Frequency-Inverse Document Frequency* (TF-

IDF). Metode ini berfungsi untuk memberikan "bobot" atau nilai pada setiap kata berdasarkan seberapa penting kata tersebut dalam membedakan satu *tweet* dengan *tweet* lainnya [4].

Secara sederhana prinsip kerja TF-IDF yaitu TF (*Term Frequency*) menghitung seberapa sering sebuah kata muncul dalam satu *tweet* (semakin sering muncul, nilainya semakin tinggi), sedangkan IDF (*Inverse Document Frequency*) berfungsi mengurangi nilai kata yang terlalu umum dan muncul di banyak *tweet*. Dengan cara ini, kata-kata kunci yang spesifik dan menjadi ciri khas suatu topik (misalnya "konstitusi" atau "bansos") akan mendapatkan bobot tinggi, sementara kata umum yang tidak memiliki makna topik akan diredam. Hasil akhirnya adalah sekumpulan data numerik (vektor) yang siap digunakan oleh SVM untuk mengklasifikasikan topik secara akurat [16], [25].

2.7 Evaluation

Evaluasi model merupakan tahapan fundamental untuk mengukur kinerja algoritma klasifikasi dalam memprediksi data baru yang belum pernah dipelajari sebelumnya. Tujuannya adalah untuk memastikan bahwa model yang dibangun memiliki kemampuan generalisasi yang baik dan tidak hanya menghafal data latih (*overfitting*). Dalam penelitian klasifikasi teks, alat ukur utama yang digunakan adalah *Confusion Matrix* [4].

Dalam penelitian klasifikasi *multi-class* (banyak kelas), alat ukur utama yang digunakan adalah *Confusion Matrix*. Berbeda dengan klasifikasi biner, *confusion matrix* pada klasifikasi multi-kelas dengan N kategori akan membentuk tabel berukuran $N \times N$ [4]. Meskipun tabel matriks bersifat multi-dimensi, perhitungan metrik evaluasi (Presisi, Recall, dan F1-Score) dilakukan dengan memecah masalah multi-kelas menjadi klasifikasi biner menggunakan pendekatan *One-vs-Rest*. Untuk setiap kelas topik, didefinisikan empat parameter dasar:

- True Positive (TP), Jumlah data dari kelas n yang diprediksi dengan benar sebagai kelas n .
- False Positive (FP): Jumlah data dari kelas lain yang salah diprediksi masuk ke kelas n .
- False Negative (FN): Jumlah data dari kelas n yang salah diprediksi masuk ke kelas lain.

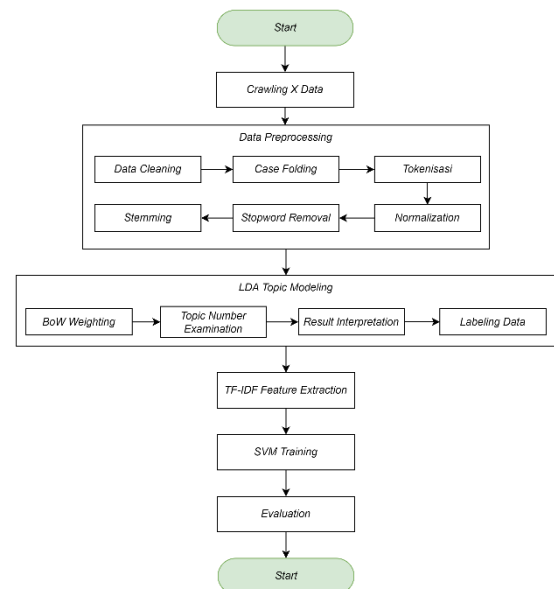
- True Negative (TN): Jumlah data dari kelas lain yang benar diprediksi sebagai bukan kelas n .

Berdasarkan parameter tersebut, kinerja model diukur menggunakan rata-rata (*average*) dari metrik berikut:

1. **Akurasi (*Accuracy*)**: Rasio total prediksi yang benar (diagonal matriks) terhadap keseluruhan jumlah data.
2. **Presisi (*Precision*)**: Tingkat ketepatan prediksi positif untuk setiap kelas. Metrik ini penting untuk melihat seberapa akurat model saat menyatakan sebuah *tweet* termasuk dalam topik tertentu.
3. **Recall**: Kemampuan model dalam menemukan kembali seluruh data yang sebenarnya milik kelas tertentu.
4. **F1-Score**: Rata-rata harmonis antara Presisi dan Recall. Metrik ini menjadi acuan utama dalam penelitian ini karena memberikan penilaian yang objektif terhadap keseimbangan performa model di setiap topik isu #IndonesiaGelap [4], [13].

3. METODE PENELITIAN

Adapun alur penelitian yang disusun pada penelitian ini digambarkan pada Gambar 3. 1 berikut.



Gambar 3. 1
Alur Penelitian

Beberapa tahapan yang ditunjukkan pada Gambar 3. 1 telah dijelaskan secara rinci pada bab sebelumnya. Oleh karena itu, bagian ini

difokuskan pada penjelasan tahapan lain yang belum dibahas.

3.1. LDA Topic Modeling

3.1.1. BoW Weighting

Teks yang telah dibersihkan dan dinormalisasi kemudian diubah ke dalam bentuk representasi numerik menggunakan pendekatan Bag of Words (BoW). Dalam representasi ini, setiap dokumen diwakili oleh frekuensi kemunculan kata-kata yang relevan. Hasil dari tahap ini akan menjadi input utama untuk proses pemodelan topik LDA.

3.1.2. Topic Number Examination

Penentuan jumlah topik (K) terbaik dilakukan melalui Topic Number Examination dengan melatih model LDA pada beberapa nilai K menggunakan parameter yang sama. Setiap model kemudian dievaluasi berdasarkan nilai topic coherence. Model dengan nilai coherence tertinggi dipilih sebagai model terbaik untuk tahap selanjutnya.

3.1.3. Result Interpretation

Tahap interpretasi bertujuan untuk memberikan label tematik yang akurat pada setiap topik yang dihasilkan oleh model LDA. Proses ini melibatkan partisipasi ahli (*domain expert*) dengan latar belakang jurnalisme dan praktisi komunikasi yang memiliki kompetensi linguistik serta pemahaman mendalam mengenai konteks sosial-politik isu #IndonesiaGelap.

4. HASIL DAN PEMBAHASAN

4.1. Crawling Dan Preprocessing Data

Pengumpulan data dilakukan pada periode Februari hingga Agustus 2025 menggunakan library Python *tweet-harvester*. Dari proses ini, berhasil dihimpun sebanyak 57.533 *tweet* mentah terkait isu “#IndonesiaGelap”. Data tersebut kemudian melalui tahapan *preprocessing* untuk membersihkan elemen non-teks, menormalisasi bahasa, dan menghapus duplikasi. Hasilnya, tersisa 48.735 *tweet* bersih yang siap dianalisis. Penurunan volume ini memastikan hanya data berkualitas yang digunakan dalam pemodelan. Contoh hasil transformasi data dapat dilihat pada Tabel 4. 1.

Tabel 4. 1
Sampel Hasil Pra-pemrosesan Data


Data Mentah	Data Bersih
Buat tmn2 yg trun ke jln semangat dan y kita gk tw kpn suara kita bakal dnger sm Pmerintah jgn prnh lelah mbela hak2 kita sehat2 smua yg brjuang untuk indo lbh baik	["buat", "teman-teman", "turun", "jalan", "semangat", "tahu", "kapan", "suara", "bakal", "dengar", "pemerintah", "jangan", "pernah", "lelah", "bela", "hak-hak", "sehat-sehat", "juang", "indonesia", "baik"]

Hasil data bersih ini kemudian digunakan sebagai basis untuk pemodelan topik pada tahap selanjutnya.

4.2. LDA Topic Modeling

4.2.1. Topic Number Examination

Sebelum melakukan ekstraksi topik secara mendalam, langkah krusial yang dilakukan adalah menentukan jumlah topik (K) paling optimal agar hasil pembagian isu menjadi bermakna dan tidak tumpang tindih. Berdasarkan pengujian menggunakan metrik *Coherence score* (C_v) pada rentang topik yang berbeda, model menunjukkan performa terbaik pada jumlah topik $K=6$, seperti yang ditunjukkan pada Gambar 4. 1 berikut.



Gambar 4. 1
Topic Number Examination

Sebagaimana terlihat pada Gambar 4. 1, konfigurasi 6 topik menghasilkan nilai koherensi tertinggi sebesar 0.4770. Nilai ini mengindikasikan bahwa pada titik tersebut, kata-kata dalam setiap topik memiliki keterkaitan semantik yang paling kuat dan mudah diinterpretasikan oleh manusia. Oleh karena itu, analisis selanjutnya didasarkan pada pembagian dataset ke dalam enam kluster topik utama. Nilai yang didapatkan ini sudah lebih

tinggi dari penelitian-penelitian terdahulu yang melakukan *topic modeling* pada data X atau *twitter* yaitu 0.3310 [23], dan 0.3497 [19].

4.2.2. Result Interpretation

Setelah model LDA dijalankan dengan $K=6$, terbentuk enam kelompok diskusi yang merepresentasikan dimensi permasalahan dalam isu #IndonesiaGelap. Interpretasi label topik dilakukan dengan menganalisis kata-kata kunci (top words) yang memiliki probabilitas kemunculan tertinggi di setiap kluster oleh ahli yang memiliki pemahaman terhadap konteks isu yaitu jurnalis/wartawan. Ringkasan topik beserta kata kuncinya disajikan dalam Tabel 4.2.

Tabel 4. 2
Hasil Interpretasi Topik dan Kata Kunci

Topik	Label Topik	Kata Kunci Dominan
1	Kebijakan, Program, dan Revisi UU	undang, tni, makan, tolak, rancang, anak, menteri, danantara, gizi, polri, gratis, jaksa, sipil, dpr, revisi
2	Sumber Daya, Korupsi, dan Pajak	rakyat, indonesia, hidup, pemerintah, jabat, rezim, korupsi, kuasa, koruptor, mati, pimpin, hancur, pajak, percaya, adil
3	Pemilu, Pemimpin, dan Demokrasi	presiden, suara, jokowi, prabowo, pilih, rakyat, dengar, negara, bungkam, demo, wakil, anak, hasil, hidup, diam
4	Aksi Mahasiswa #Indonesia Gelap	mahasiswa, aksi, demo, politik, baca, isu, indonesia, gerak, dukung, artikel, lengkap, fokus, sejarah, indonesiagelap, masyarakat
5	Dukungan Moral dan Semangat	hati, turun, semangat, jalan, tagar, teman, perjuangan, menang, takut, bantu, lupa,

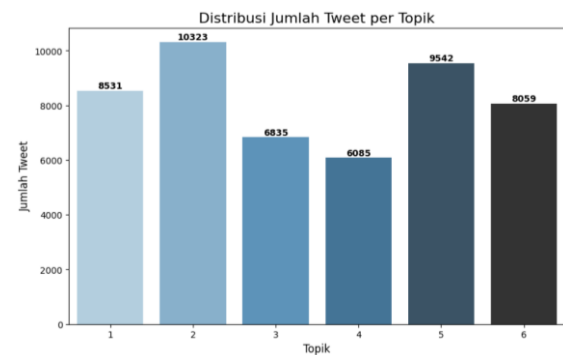
Topik	Label Topik	Kata Kunci Dominan
		umur, sehat, suara, berjuang, aksi, sakit, medis
6	Kecaman Moral Aparat & Pemerintah	allah, gelap, polisi, indonesia, pemerintah, izin, kawal, malu, bayar, tolol, jahat, lucu, otak, zionis, terang

Data Tabel 4. 2 menunjukkan bahwa wacana #IndonesiaGelap memiliki struktur yang kompleks. Isu tidak hanya berisi keluhan umum, tetapi terbagi spesifik menjadi: kritik struktural/legal (Topik 1 & 3), kritik ekonomi/korupsi (Topik 2), gerakan fisik/aksi (Topik 4), solidaritas emosional (Topik 5), hingga ekspresi kemarahan/moral (Topik 6).

4.2.3. Labeling Data

Salah satu tantangan utama dalam analisis data media sosial adalah ketiadaan label kategori (*ground truth*) pada data mentah. Untuk mengatasi hal tersebut, penelitian ini memanfaatkan hasil pemodelan LDA sebagai metode pelabelan otomatis. Setiap dokumen (*tweet*) dalam dataset dianalisis distribusi probabilitasnya terhadap keenam topik yang telah terbentuk. Label topik diberikan berdasarkan nilai probabilitas tertinggi (*dominant topic*) yang dimiliki oleh *tweet* tersebut.

Hasil pelabelan otomatis terhadap 48.735 data *tweet* bersih menghasilkan distribusi kelas sebagai berikut, yang juga divisualisasikan pada



Gambar 4. 2
Distribusi Data Hasil Pelabelan Otomatis

Berdasarkan data tersebut, Topik 2 menjadi kelas yang paling mendominasi. Dataset yang telah terlabeli ini selanjutnya digunakan sebagai

input utama untuk melatih model klasifikasi SVM pada tahap berikutnya.

4.3. SVM Model Building

Pembangunan model klasifikasi diawali dengan membagi dataset menjadi dua bagian menggunakan rasio 80:20. Sebanyak 37.904 *tweet* digunakan sebagai data latih (*training*) untuk mengajarkan model mengenali pola topik, sedangkan 9.476 *tweet* disisihkan sebagai data uji (*testing*) untuk evaluasi objektif. Sebelum masuk ke algoritma SVM, data teks dikonversi menjadi representasi numerik menggunakan metode TF-IDF. Hal ini menghasilkan matriks fitur untuk data latih dengan dimensi (37.904, 5.327), yang berarti model mempelajari pola dari 37 ribu lebih dokumen berdasarkan distribusi 5.327 kata kunci unik.

Selanjutnya, untuk mendapatkan performa klasifikasi yang optimal, dilakukan proses pencarian parameter terbaik (*Hyperparameter Tuning*) menggunakan teknik *Grid Search Cross-Validation*. Eksperimen ini menguji berbagai kombinasi parameter pada algoritma SVM dengan Kernel RBF (*Radial Basis Function*), yang dipilih karena kemampuannya menangani data teks berdimensi tinggi yang tidak terpisah secara linear [17]. Hasil eksperimen menunjukkan bahwa kombinasi parameter terbaik adalah $C = 10$ dan $\Gamma = 1$, dengan skor validasi rata-rata sebesar 86,16%.

4.4. Model Evaluation


Setelah melalui tahap pelatihan dengan parameter optimal, kinerja model SVM dievaluasi menggunakan data uji sebanyak 9.476 *tweet*. Berdasarkan hasil pengujian, model berhasil mencapai tingkat Akurasi Akhir sebesar 88.05%. Angka ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dalam memetakan *tweet* baru ke dalam 6 topik isu #IndonesiaGelap. Rincian performa model untuk setiap kelas topik dapat dilihat pada

	precision	recall	f1-score	support
1	0.89	0.88	0.89	1307
2	0.86	0.91	0.88	2065
3	0.86	0.82	0.84	1367
4	0.87	0.84	0.85	1217
5	0.91	0.92	0.92	1908
6	0.88	0.88	0.88	1612
accuracy			0.88	9476
macro avg	0.88	0.87	0.88	9476
weighted avg	0.88	0.88	0.88	9476

Gambar 4. 3
Classification Report

Analisis mendalam terhadap Gambar 4. 3 menunjukkan bahwa Topik 5 (Dukungan Moral dan Semangat) merupakan kelas dengan kinerja terbaik, mencapai F1-Score tertinggi sebesar 0.92. Tingginya skor ini disebabkan oleh karakteristik kosa kata pada Topik 5 yang sangat distingtif dan bermuatan emosi spesifik (seperti "tolol", "allah", "polisi"), sehingga mudah dibedakan oleh SVM dari topik lain yang lebih bermuatan politis.

Sebaliknya, Topik 3 (Pemilu, Pemimpin, dan Demokrasi) mencatatkan skor terendah dengan F1-Score 0.84, meskipun angka ini masih tergolong dalam kategori kinerja "Baik". Untuk memahami penyebab rendahnya performa pada topik ini, dilakukan analisis kesalahan menggunakan *Confusion Matrix* sebagaimana ditampilkan pada Gambar 4. 4.



Gambar 4. 4
Confusion Matrix Model SVM

Visualisasi *Confusion Matrix* pada Gambar 4. 4, memberikan gambaran komprehensif mengenai model SVM dalam mengklasifikasikan 9.476 *tweet* uji, di mana dominasi warna biru gelap pada garis diagonal utama menunjukkan konsistensi prediksi yang

tinggi dengan mayoritas data tertebak secara benar (*True Positive*). Analisis spesifik pada setiap kelas menunjukkan bahwa Topik 5 (Dukungan Moral dan Semangat) menjadi kategori dengan kinerja paling optimal, di mana model berhasil memprediksi dengan tepat 1.757 *tweet* dari total 1.908 data aktual. Tingginya akurasi pada topik ini didorong oleh karakteristik leksikal yang sangat khas, di mana kata-kata bermuatan emosi spesifik seperti "semangat", "doa", dan "hati" memiliki fitur pembeda yang kuat, sehingga memudahkan *hyperplane* SVM memisahkannya dari topik lain yang bernuansa politik atau hukum.

Di sisi lain, dari 1.367 data aktual pada Topik 3, sebanyak 107 *tweet* salah diprediksi oleh model ke dalam Topik 2 (Sumber Daya & Korupsi). Fenomena ini besar kemungkinan terjadi karena narasi kritik terhadap figur pemimpin (Topik 3) sering kali disampaikan beriringan dengan isu kegagalan ekonomi atau korupsi (Topik 2) dalam satu kalimat, menyebabkan ambiguitas kontekstual yang menyulitkan model menarik garis batas tegas. Pola serupa juga terlihat pada Topik 6 (Kecaman Moral), dengan 59 *tweet* yang meleset ke Topik 2, disebabkan oleh banyaknya makian (fitur Topik 6) yang ditujukan langsung kepada objek permasalahan korupsi (fitur Topik 2).

Meskipun terdapat tantangan pada topik-topik yang beririsan, capaian akurasi 88,05% dalam penelitian ini menunjukkan keunggulan kompetitif jika dibandingkan dengan sejumlah penelitian terdahulu yang juga menerapkan metode *Support Vector Machine* (SVM) untuk klasifikasi teks media sosial. Sebagai perbandingan utama, penelitian yang berfokus pada klasifikasi *tweet* berdasar topik sosial menggunakan SVM memperoleh akurasi sebesar 84% [4], kemudian penelitian yang berfokus untuk melakukan klasifikasi *tweet* pencemaran nama baik sebesar 87.7% [3], dan klasifikasi *tweet influencer* yang juga menggunakan data dari *twitter* yang memperoleh akurasi sebesar 77.28% [16].

Berdasarkan hasil evaluasi didapatkan dapat disimpulkan bahwa kinerja model klasifikasi SVM pada data teks Twitter yang dilabeli secara otomatis menggunakan LDA terbukti bisa dilakukan. Pencapaian akurasi sebesar

88,05% tidak hanya memvalidasi efektivitas alur kerja (*pipeline*) yang dibangun tetapi juga menunjukkan keunggulan kompetitif dibandingkan penelitian-penelitian terdahulu. Temuan ini menegaskan bahwa integrasi antara metode *unsupervised* dan *supervised learning* merupakan strategi yang sangat efisien untuk memetakan narasi publik di media sosial, sekaligus menjadi solusi efektif untuk mengatasi kendala pelabelan manual yang memakan waktu.

5. KESIMPULAN

- a. Penerapan *Latent Dirichlet Allocation* (LDA) sebagai metode pelabelan otomatis (*automated labeling*) terbukti efektif dalam mengatasi kendala efisiensi waktu pada pengolahan dataset berskala besar. Metode ini berhasil mentransformasi data mentah menjadi dataset berlabel yang terbagi ke dalam 6 kelas topik secara sistematis.
- b. Penerapan algoritma *Support Vector Machine* (SVM) untuk mengklasifikasikan *tweet* berdasarkan label otomatis dari LDA menunjukkan performa yang terkategori *good fit*. Melalui proses optimasi *hyperparameter* (*Grid Search*) dengan Kernel RBF, parameter $C=10$, dan $\gamma=1$, model berhasil mencapai akurasi akhir sebesar **88,05%**.

UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan atas semua pihak yang membantu penulis dalam penyusunan artikel ini, khususnya kepada pembimbing, serta keluarga penulis yang telah memberikan dukungan dan bantuan sehingga artikel ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] A. Clairine, E. I. D. Lestari, E. N. Wiyono, and M. W. R., "Eksresi Keresahan Pemuda melalui Media Sosial: Studi Kritik terhadap Narasi Indonesia Gelap," *Moderasi: Jurnal Studi Ilmu Pengetahuan Sosial*, vol. 6, no. 1, pp. 36–51, Jun. 2025, doi: 10.24239/MODERASI.VOL6.ISS1.491.
- [2] A. M. Nur, E. Kurniawan, and R. Supriadi, "Unveiling Public Sentiment and Ideation Patterns in the #IndonesiaGelap Discourse through Appraisal Theory: A Corpus-Based Analysis," *IJLECR (International Journal of Language Education and Cultural Review)*,

- vol. 11, no. 1, pp. 48–58, Jun. 2025, doi: 10.21009/IJLECR.V11I1.55014.
- [3] F. Abdusyukur, “Penerapan Algoritma Support Vector Machine (Svm) Untuk Klasifikasi Pencemaran Nama Baik Di Media Sosial Twitter,” *Komputa: Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, pp. 73–82, May 2023, doi: 10.34010/KOMPUTA.V12I1.9418.
- [4] P. Studi Informatika, F. Matematika dan Ilmu Pengetahuan Alam, J. Raya Kampus Udayana, B. Jimbaran, and K. Selatan, “Analisis Klasifikasi *Tweet* Berdasarkan Topik Sosial Menggunakan SVM,” *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 3, no. 4, pp. 855–864, Aug. 2025, doi: 10.24843/JNATIA.2025.V03.I04.P15.
- [5] A. K. Dewi, N. F. Rahmadani, R. Syahputri, L. R. Nasution, and M. Furqon, “Deteksi Berita Hoax Pada Platform X Menggunakan Pendekatan Text Mining dan Algoritma Machine Learning,” *Data Sciences Indonesia (DSI)*, vol. 5, no. 1, pp. 33–46, Jul. 2025, doi: 10.47709/DSI.V5I1.6011.
- [6] G. Aditra Pradnyana, I. Gede, and M. Darmawiguna, “Web-Based System for Bali Tourism Sentiment Analysis during The Covid-19 Pandemic using Django Web Framework and Naive Bayes Method,” *Proceedings of the 4th International Conference on Innovative Research Across Disciplines (ICIRAD 2021)*, vol. 613, pp. 316–320, Dec. 2021, doi: 10.2991/ASSEHR.K.211222.050.
- [7] R. Rakhmat Sani, Y. Ayu Pratiwi, S. Winarno, E. Devi Udayanti, and dan Farrikh Al Zami, “Analisis Perbandingan Algoritma Naive Bayes Classifier dan Support Vector Machine untuk Klasifikasi Berita Hoax pada Berita Online Indonesia,” *Jurnal Masyarakat Informatika*, vol. 13, no. 2, pp. 85–98, Nov. 2022, doi: 10.14710/JMASIF.13.2.47983.
- [8] I. N. S. W. Wijaya, K. A. Seputra, and N. P. N. P. Dewi, “Fine Tuning Model Indobert Untuk Analisis Sentimen Berita Pariwisata Indonesia,” *Jurnal Pendidikan Teknologi dan Kejuruan*, vol. 22, no. 2, pp. 195–204, Jul. 2025, doi: 10.23887/JPTK-UNDIKSHA.V22I2.104056.
- [9] B. Yin and C. H. Yuan, “Detecting latent topics and trends in blended learning using LDA topic modeling,” *Educ Inf Technol (Dordr)*, vol. 27, no. 9, pp. 12689–12712, Nov. 2022, doi: 10.1007/S10639-022-11118-0/FIGURES/1.
- [10] O. Ozyurt, H. Özköse, and A. Ayaz, “Evaluating the latest trends of Industry 4.0 based on LDA topic model,” *Journal of Supercomputing*, vol. 80, no. 13, pp. 19003–19030, Sep. 2024, doi: 10.1007/S11227-024-06247-X/METRICS.
- [11] G. A. Pradnyana, I. G. M. Darmawiguna, D. K. S. Suditresna Jaya, and A. Sasmita, “Performance analysis of support vector machines with polynomial kernel for sentiment polarity identification: A case study in lecturer’s performance questionnaire,” *J Phys Conf Ser*, vol. 1810, no. 1, p. 012033, Mar. 2021, doi: 10.1088/1742-6596/1810/1/012033.
- [12] N. L. P. R. Dewi, I. N. S. W. Wijaya, I. K. Purnamawan, and N. W. Marti, “Model Classifier Judul Berita Pariwisata Indonesia Berdasarkan Sentimen,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, pp. 117–124, Feb. 2024, doi: 10.25126/JTIK.20241117617.
- [13] S. Berliani and S. Lestari, “Analisis Sentimen Masyarakat Terhadap Isu Pecat Sri Mulyani Pada Twitter Menggunakan Metode Naive Bayes Dan Support Vector Machine,” *Jurnal Sains dan Teknologi*, vol. 5, no. 3, pp. 951–960, Apr. 2024, doi: 10.55338/SAINTEK.V5I3.2746.
- [14] S. Nauli, S. S. Berutu, H. Budiati, and F. Maedjaja, “Klasifikasi Kalimat Perundungan Pada Twitter Menggunakan Algoritma Support Vector Machine,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 1, pp. 107–122, Jan. 2025, doi: 10.29100/JUPI.V10I1.5749.
- [15] A. Fatmawati, U. Latifah, A. S. B. Suryadi, and T. K. Zuhriya, “Klasifikasi Emosi Teks Pengguna Twitter Menggunakan Metode SVM,” in *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 2025, pp. 1999–2007.
- [16] M. Ihsan, M. Ihsan, and D. Desmulyati, “Klasifikasi *Tweet* Influencer NU Dengan GNPF-Ulama Menggunakan Naive Bayes Dan Support Vector Machine,” *Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)*, vol. 5, no. 3, pp. 358–363, Jun. 2022, doi: 10.32672/jnkti.v5i3.4276.
- [17] imelda amuis and M. Affandes, “Penerapan Metode Support Vector Machine (Svm) Menggunakan Kernel Radial Basis Faunction (Rbf) Pada Klasifikasi *Tweet*,” *SITEKIN: Jurnal Sains, Teknologi dan Industri*, vol. 12, no. 2, pp. 189–197, Jun. 2015, doi: 10.24014/SITEKIN.V12I2.1010.
- [18] Y. Matira, Junaidi, and I. Setiawan, “Pemodelan Topik pada Judul Berita Online Detikcom Menggunakan Latent Dirichlet Allocation,” *ESTIMASI: Journal of Statistics*

- and Its Application, pp. 53–63, Feb. 2023, doi: 10.20956/EJSA.VI.24843.
- [19] U. M. Sholihah, Y. Findawati, and U. Indahyanti, “Topic Modeling In Covid-19 Vaccination Refusal Cases Using Latent Dirichlet Allocation And Latent Semantic Analysis,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 5, pp. 1063–1074, Oct. 2023, doi: 10.52436/1.JUTIF.2023.4.5.951.
- [20] D. M. Blei, A. Y. Ng, and M. I. Jordan, “Latent Dirichlet Allocation,” *Journal of Machine Learning Research*, vol. 3, 2003.
- [21] T. Irawan, L. Mutawalli, S. Fadli, and W. Bagye, “Topic Modelling Pola Komunikasi Pilpres 2024 Focus Web Scraping Dan Latent Dirichlet Allocation,” *Jurnal Manajemen Informatika dan Sistem Informasi*, vol. 7, no. 2, pp. 186–194, Jul. 2024, doi: 10.36595/MISI.V7I2.1183.
- [22] E. Puspita, F. Shiddieq, and F. F. Roji, “Pemodelan Topik pada Media Berita Online Menggunakan Latent Dirichlet Allocation (Studi Kasus Merek Somethinc),” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 481–489, Feb. 2024, doi: 10.57152/MALCOM.V4I2.1204.
- [23] U. N. Khadijah and N. Cahyono, “Analisis Topic Modelling Pariwisata Yogyakarta Menggunakan Latent Dirichlet Allocation (LDA),” *The Indonesian Journal of Computer Science*, vol. 13, no. 4, Jul. 2024, doi: 10.33022/IJCS.V13I4.3816.
- [24] K. Pramayasa, I. Md, D. Maysanjaya, G. Ayu, and A. Diatri Indradewi, “Analisis Sentimen Program Mbkm Pada Media Sosial Twitter Menggunakan KNN Dan SMOTE,” *SINTECH (Science and Information Technology) Journal*, vol. 6, no. 2, pp. 89–98, Aug. 2023, doi: 10.31598/SINTECHJOURNAL.V6I2.1372.
- [25] D. Puspitasari and T. Sutabri, “Analisis Sentimen Berdasarkan pada Twitter (X) terhadap Layanan Indihome Menggunakan Algoritma Support Vector Machine (SVM),” *JUMINTAL: Jurnal Manajemen Informatika dan Bisnis Digital*, vol. 3, no. 2, pp. 58–71, Nov. 2024, doi: 10.55123/JUMINTAL.V3I2.4449.