

ID: 26

Penerapan Metode Machine Learning untuk Deteksi Emosi pada Analisis Sentimen Teks Media Sosial

Application of Machine Learning Methods for Emotion Detection in Sentiment Analysis of Social Media Texts

Maria Claudia¹, Sae Khatami², Valentinus Paramarta^{3*}

¹Departemen Teknik Informatika, Perbanas Institute

²Departemen Sistem Informasi, Perbanas Institute

³Departemen Sains Data, Perbanas Institute

Jl Karet Kuningan, Setiabudi , Jakarta Selatan

maria.claudia@perbanas.id¹, sae.khatami@perbanas.id², valentinus13@perbanas.id^{3*}

Abstrak – *Media sosial telah menjadi sumber data penting untuk memahami opini dan emosi masyarakat terhadap berbagai isu. Analisis sentimen dan deteksi emosi berbasis teks memungkinkan identifikasi ekspresi emosional pengguna secara otomatis menggunakan metode machine learning. Penelitian ini bertujuan membandingkan kinerja tiga algoritma, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF), dalam mendekripsi emosi pada teks media sosial berbahasa Indonesia. Proses penelitian meliputi tahapan pra-pemrosesan teks, pembobotan fitur dengan Term Frequency–Inverse Document Frequency (TF-IDF), serta evaluasi model menggunakan metrik akurasi, presisi, recall, dan F1-score. Dataset diperoleh dari platform Kaggle dan dibagi menjadi 75% data latih dan 25% data uji. Hasil penelitian menunjukkan bahwa SVM memberikan performa terbaik dibandingkan DT dan RF. Sebelum optimasi, akurasi SVM sebesar 78%, sedangkan setelah optimasi hyperparameter dengan GridSearchCV, meningkat menjadi 82% dengan precision 0.80, recall 0.78, dan F1-score 0.79. Model DT dan RF masing-masing mencapai akurasi 77% dan 80% setelah optimasi. Dari hasil tersebut dapat disimpulkan bahwa SVM merupakan algoritma paling efektif untuk deteksi emosi teks karena mampu menangani data berdimensi tinggi dengan baik dan memberikan hasil yang stabil.*

Kata Kunci: Analisis Sentimen, Deteksi Emosi, Machine Learning, SVM, Decision Tree, Random Forest

Abstract – *Social media has become a valuable source of data for understanding public opinions and emotions on various issues. Sentiment analysis and emotion detection based on textual data enable the automatic identification of users' emotional expressions using machine learning techniques. This study aims to compare the performance of three algorithms Support Vector Machine (SVM), Decision Tree (DT), and Random Forest (RF) in detecting emotions from Indonesian-language social media texts. The research process includes text preprocessing, feature weighting using Term Frequency–Inverse Document Frequency (TF-IDF), and model evaluation based on accuracy, precision, recall, and F1-score metrics. The dataset was obtained from the Kaggle platform and divided into 75% training data and 25% testing data. Experimental results show that the SVM algorithm achieves the best performance compared to DT and RF. Before optimization, SVM achieved 78% accuracy, and after hyperparameter optimization using GridSearchCV, its accuracy increased to 82%, with precision 0.80, recall 0.78, and F1-score 0.79. Meanwhile, DT and RF reached 77% and 80% accuracy, respectively, after optimization. These findings indicate that SVM is the most effective algorithm for emotion detection in social media texts due to its robustness in handling high-dimensional data and delivering stable results.*

Keywords: Sentiment Analysis, Emotion Detection, Machine Learning, SVM, Decision Tree, Random Forest

1. Pendahuluan

Perkembangan teknologi informasi dan komunikasi yang pesat telah mengubah secara signifikan cara manusia berinteraksi dan berkomunikasi di era digital saat ini [1]. Salah satu wujud transformasi tersebut adalah meningkatnya penggunaan media sosial sebagai sarana utama masyarakat untuk berbagi informasi, mengekspresikan pendapat, dan mengungkapkan emosi. Platform seperti Twitter, Instagram, dan Facebook menjadi ruang publik di mana pengguna dapat menuliskan pikiran dan perasaan mereka secara bebas [2]. Media sosial kini tidak hanya menjadi alat komunikasi, tetapi juga sumber data yang kaya untuk memahami perilaku, opini, dan kondisi emosional masyarakat [3]. Melalui analisis data teks yang dihasilkan dari media sosial, peneliti dapat memperoleh wawasan mengenai sentimen dan emosi publik terhadap isu-isu tertentu. Namun, menafsirkan emosi dari teks merupakan tantangan tersendiri karena sifat bahasa alami yang ambigu, subjektif, dan kontekstual [4].

Analisis sentimen (sentiment analysis) merupakan teknik dalam Natural Language Processing (NLP) yang digunakan untuk menilai kecenderungan emosional suatu teks, apakah bersifat positif, negatif, atau netral [5]. Sementara itu, deteksi emosi (emotion detection) bertujuan mengidentifikasi kategori emosi spesifik seperti marah, sedih, bahagia, takut, dan cinta yang terkandung dalam teks [6]. Kedua pendekatan ini memiliki keterkaitan erat karena sama-sama berfokus pada interpretasi subjektivitas dari data tekstual. Dalam konteks Indonesia, analisis sentimen dan deteksi emosi dari teks media sosial memiliki urgensi yang tinggi. Banyak isu sosial, politik, dan ekonomi mencerminkan dinamika emosional masyarakat yang diekspresikan melalui media sosial [7]. Oleh karena itu, kemampuan untuk mengidentifikasi dan mengklasifikasikan emosi pengguna dapat membantu lembaga pemerintah, perusahaan, maupun peneliti sosial dalam memahami persepsi publik secara real time.

Berbagai metode machine learning telah diterapkan dalam analisis sentimen dan deteksi emosi. Salah satu algoritma yang paling banyak digunakan adalah Support Vector Machine (SVM) karena kemampuannya dalam menangani data berdimensi tinggi dan menghasilkan performa yang stabil [8]. Selain itu, algoritma Decision Tree (DT) dan Random Forest (RF) juga terbukti efektif dalam klasifikasi teks karena kemampuannya mengekstraksi pola dari data non-linear dengan kompleksitas rendah [9]. Penelitian ini bertujuan untuk menerapkan dan membandingkan ketiga algoritma machine learning SVM, Decision Tree, dan Random Forest dalam mendeteksi emosi berdasarkan teks media sosial yang diperoleh dari dataset publik. Analisis ini dilakukan melalui tahapan preprocessing teks, ekstraksi fitur menggunakan TF-IDF, serta evaluasi performa model menggunakan metrik akurasi, presisi, recall, dan F1-score.

Melalui penelitian ini, diharapkan dapat diperoleh model terbaik dalam mengklasifikasikan emosi pengguna media sosial berdasarkan teks yang mereka tulis. Selain itu, hasil penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem analisis sentimen berbahasa Indonesia yang lebih akurat, serta mendukung pemanfaatan machine learning untuk pemahaman emosi masyarakat di era digital.

2. Metode Penelitian

2.1. Desain Penelitian

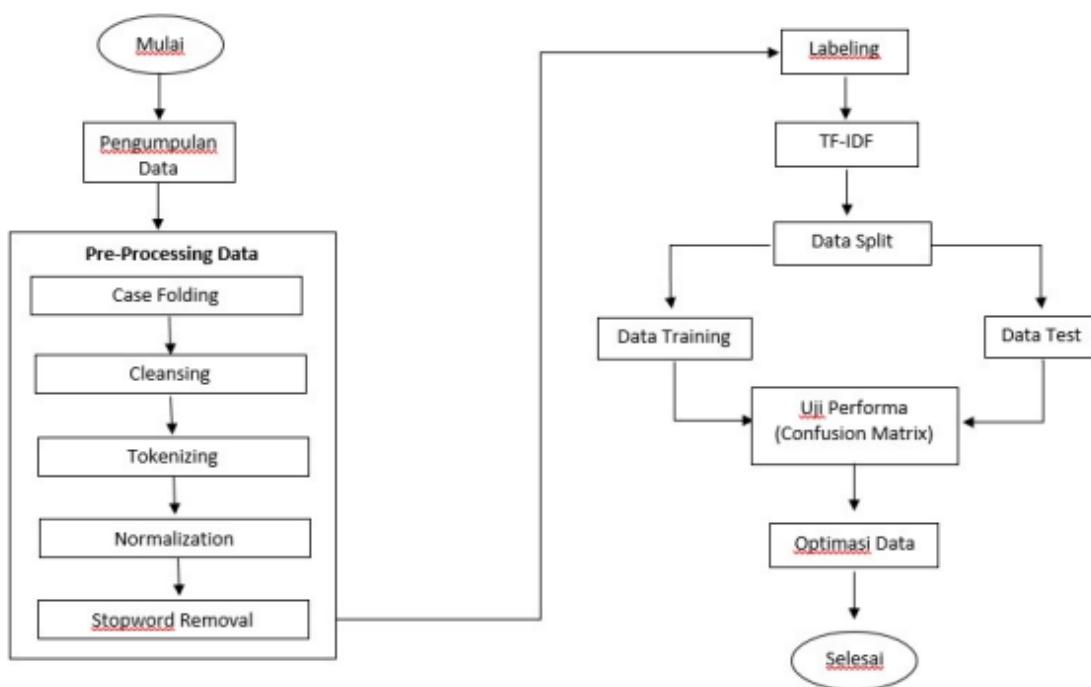
Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tujuan untuk membandingkan performa tiga algoritma machine learning, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF), dalam mendeteksi emosi pada teks media sosial berbahasa Indonesia. Desain penelitian disusun secara sistematis mulai dari pengumpulan data, pra-pemrosesan (pre-processing), pembobotan kata, pelatihan model, hingga evaluasi performa [1]. Proses utama penelitian ini melibatkan tahapan analisis sentimen dan deteksi emosi berbasis teks, di mana model dilatih untuk mengenali tiga kategori emosi, yaitu senang, sedih, dan marah, berdasarkan data teks yang dikumpulkan dari platform media sosial [2].

2.2. Sumber Data

Data yang digunakan dalam penelitian ini merupakan data publik yang diunduh dari platform Kaggle, dengan konten berupa teks komentar media sosial berbahasa Indonesia yang telah memiliki label emosi [3]. Dataset ini terdiri atas ribuan baris teks dengan proporsi distribusi kelas yang seimbang untuk setiap label emosi. Format data mencakup dua kolom utama: kolom teks (berisi konten komentar) dan kolom label (berisi kategori emosi). Data tersebut dipilih karena mewakili ragam ekspresi pengguna media sosial dalam konteks bahasa informal, slang, serta penggunaan tanda baca yang khas di media sosial Indonesia, yang menambah kompleksitas proses deteksi emosi [4].

2.3. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama seperti terlihat pada Gambar 1, yang menggambarkan alur sistem mulai dari data mentah hingga evaluasi performa model. Penelitian ini dilaksanakan melalui beberapa tahapan utama yang terstruktur secara sistematis. Tahap pertama adalah pengumpulan data, di mana dataset diambil dari platform publik Kaggle yang berisi kumpulan teks komentar pengguna media sosial berbahasa Indonesia dengan label emosi yang telah ditentukan sebelumnya [5]. Sebelum digunakan, data tersebut dibersihkan dari duplikasi, baris kosong, serta karakter non-alfabet agar kualitas data tetap terjaga.



Gambar 1. Langkah Penelitian

Tahap berikutnya adalah pra-pemrosesan teks (text pre-processing) yang bertujuan untuk menyiapkan data mentah menjadi bentuk yang dapat diproses oleh algoritma machine learning. Proses ini melibatkan beberapa langkah, yaitu cleaning untuk menghapus karakter khusus seperti angka, tanda baca, dan tautan; case folding untuk menyeragamkan semua huruf menjadi huruf kecil; normalization untuk mengubah kata tidak baku menjadi bentuk baku; stopword removal untuk menghapus kata-kata umum yang tidak relevan seperti “yang”, “dan”, atau “di”; stemming untuk mengubah kata berimbuhan menjadi kata dasar menggunakan pustaka Sastrawi; serta

tokenization untuk memecah kalimat menjadi satuan kata (token) [6]. Hasil akhir dari proses pra-pemrosesan ini berupa teks bersih dan terstruktur yang siap dikonversi ke bentuk numerik.

Langkah selanjutnya adalah pembobotan fitur (feature extraction) menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF). Teknik ini memberikan bobot yang lebih tinggi pada kata yang jarang muncul namun relevan terhadap konteks dokumen, dan menurunkan bobot pada kata umum yang sering muncul di seluruh korpus [7]. Hasil representasi TF-IDF berupa vektor numerik yang digunakan sebagai masukan (input) bagi model klasifikasi. Tahap berikutnya adalah pemisahan data (data splitting), di mana dataset dibagi menjadi dua bagian dengan proporsi 75% data latih (training set) dan 25% data uji (testing set). Pembagian dilakukan secara acak dengan metode stratified sampling agar distribusi label emosi tetap seimbang [8].

Setelah data siap, dilakukan tahap penerapan algoritma machine learning, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF). Algoritma SVM digunakan dengan kernel linear dan parameter C hasil tuning, sementara Decision Tree diterapkan dengan kriteria Gini Index dan batas kedalaman pohon (max_depth) tertentu. Random Forest digunakan dengan konfigurasi 100 estimator (n_estimators = 100) untuk meningkatkan akurasi dan mengurangi risiko overfitting [9]. Semua model diimplementasikan menggunakan pustaka scikit-learn (sklearn) pada bahasa pemrograman Python.

Tahap terakhir adalah evaluasi performa model dengan menggunakan Confusion Matrix. Evaluasi dilakukan berdasarkan empat metrik utama, yaitu akurasi, presisi, recall, dan F1-score, yang masing-masing digunakan untuk mengukur tingkat ketepatan, sensitivitas, dan keseimbangan antara keduanya dalam hasil prediksi [10]. Nilai-nilai metrik tersebut menjadi dasar perbandingan kinerja ketiga algoritma untuk menentukan model terbaik dalam mendekripsi emosi pada teks media sosial.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil dari penerapan tiga algoritma machine learning, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF) dalam mendekripsi emosi pada teks media sosial berbahasa Indonesia. Analisis dilakukan untuk mengevaluasi performa masing-masing algoritma dalam mengklasifikasikan emosi berdasarkan data yang telah melalui tahap pra-pemrosesan dan pembobotan TF-IDF. Hasil penelitian ini disajikan dalam bentuk tabel, grafik, dan analisis deskriptif yang menggambarkan kinerja model berdasarkan metrik akurasi, presisi, recall, dan F1-score. Selain itu, pembahasan juga dilakukan untuk menjelaskan perbandingan performa antar model serta faktor-faktor yang memengaruhi tingkat akurasi deteksi emosi.

Melalui hasil evaluasi yang diperoleh, penelitian ini berupaya menjawab pertanyaan utama terkait efektivitas algoritma machine learning dalam mendekripsi emosi pada teks media sosial berbahasa Indonesia serta menentukan model yang paling optimal untuk konteks analisis sentimen berbasis emosi.

3.1. Hasil Eksperimen dan Evaluasi Model

Eksperimen dilakukan untuk mengevaluasi kinerja tiga algoritma machine learning, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF), dalam mendekripsi emosi berdasarkan teks media sosial. Setiap model diuji dalam dua tahap, yaitu sebelum dan sesudah dilakukan optimasi parameter. Pengujian menggunakan data uji sebesar 25% dari total dataset, sedangkan 75% data digunakan untuk pelatihan. Evaluasi dilakukan menggunakan empat metrik utama, yaitu akurasi, presisi, recall, dan F1-score.

A. Hasil Sebelum Optimasi

Pada tahap awal, pengujian dilakukan terhadap ketiga algoritma Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF) tanpa melakukan penyesuaian (tuning) terhadap parameter model. Seluruh algoritma dilatih menggunakan data latih sebesar 75% dan diuji dengan 25% data uji yang telah melalui proses pra-pemrosesan dan pembobotan fitur menggunakan TF-IDF. Tujuan dari tahap ini adalah untuk mengamati performa dasar (baseline performance) masing-masing algoritma dalam mengklasifikasikan emosi pada teks media sosial berbahasa Indonesia sebelum dilakukan optimasi hyperparameter. Pengujian dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk memberikan gambaran menyeluruh mengenai kinerja model.

Berdasarkan hasil pengujian, algoritma SVM menunjukkan performa paling baik dibandingkan dua algoritma lainnya. Model SVM menghasilkan akurasi sebesar 78%, dengan nilai rata-rata precision 0.76, recall 0.74, dan F1-score 0.75. Hal ini menunjukkan bahwa SVM mampu mengidentifikasi pola antar kata yang merepresentasikan emosi dengan cukup baik.

Sementara itu, algoritma Decision Tree mencatat akurasi sebesar 73% dengan nilai precision dan recall yang relatif rendah dibandingkan SVM. Kondisi ini disebabkan oleh sifat dasar DT yang cenderung overfitting terhadap data latih ketika parameter `max_depth` tidak dibatasi. Model Random Forest memiliki performa lebih baik daripada Decision Tree, dengan akurasi sebesar 76%, karena pendekatan ensemble learning yang digunakan mampu mengurangi risiko overfitting dengan menggabungkan hasil prediksi dari beberapa pohon keputusan [11]. Hasil lengkap evaluasi ketiga algoritma sebelum dilakukan optimasi disajikan pada Tabel 1 berikut.

Tabel 1. Hasil Evaluasi Model Sebelum Optimasi

Model	Accuracy	Precision	Recall	F1-Score
Support Vector Machine (SVM)	0.78	0.76	0.74	0.75
Decision Tree (DT)	0.73	0.70	0.68	0.69
Random Forest (RF)	0.76	0.74	0.72	0.73

Dari hasil tersebut dapat dilihat bahwa algoritma SVM memiliki kinerja paling konsisten di antara ketiganya, terutama dalam menjaga keseimbangan antara presisi dan recall. Model ini unggul karena kemampuannya dalam memisahkan kelas menggunakan margin optimal, sehingga cocok untuk data berdimensi tinggi seperti representasi TF-IDF [12]. Sementara itu, model Decision Tree menghasilkan nilai recall yang paling rendah, yang mengindikasikan bahwa model ini kurang mampu mengenali seluruh data dengan label yang benar pada kelas minoritas, seperti emosi “marah”. Hal ini selaras dengan karakteristik DT yang sering kali membangun model terlalu spesifik terhadap data latih.

Random Forest mampu memperbaiki sebagian kekurangan tersebut karena pendekatan agregasi beberapa pohon (bagging) menghasilkan model yang lebih stabil. Namun, dibandingkan SVM, RF masih memiliki keterbatasan dalam menangani data dengan representasi sparsity tinggi seperti teks media sosial yang sangat bervariasi dalam panjang dan bentuk kalimat [13]. Secara umum, hasil sebelum optimasi ini menunjukkan bahwa SVM merupakan model paling potensial untuk tugas deteksi emosi berbasis teks, sementara Decision Tree dan Random Forest memerlukan penyesuaian parameter lebih lanjut agar dapat memberikan hasil yang kompetitif. Tahap berikutnya akan membahas hasil setelah dilakukan optimasi hyperparameter untuk meningkatkan akurasi dan efisiensi ketiga model.

B. Hasil Setelah Optimasi

Setelah dilakukan pengujian awal, tahap selanjutnya adalah melakukan optimasi hyperparameter (hyperparameter tuning) untuk meningkatkan performa model. Proses ini dilakukan dengan menggunakan teknik GridSearchCV, yaitu metode pencarian kombinasi parameter terbaik berdasarkan proses cross-validation secara otomatis [14]. Optimasi ini bertujuan untuk menemukan konfigurasi parameter paling optimal yang mampu memberikan akurasi dan generalisasi terbaik bagi model.

Setiap algoritma memiliki parameter utama yang disesuaikan dalam proses tuning. Pada algoritma SVM, parameter yang dioptimalkan meliputi nilai C (regularization parameter), kernel (linear dan RBF), serta gamma (scale dan auto). Pada algoritma Decision Tree, parameter yang disesuaikan antara lain max_depth, criterion (gini dan entropy), serta min_samples_split. Sedangkan pada Random Forest, parameter yang dioptimasi meliputi n_estimators, max_depth, dan criterion. Dari hasil optimasi, model SVM dengan konfigurasi terbaik $C = 10$, kernel = linear, dan gamma = scale berhasil memberikan peningkatan performa yang signifikan. Akurasi meningkat dari 78% menjadi 82%, dengan nilai rata-rata precision 0.80, recall 0.78, dan F1-score 0.79. Model ini menunjukkan peningkatan paling tinggi di kelas "Marah", yang sebelumnya memiliki nilai recall rendah karena ketidakseimbangan data antar kelas.

Untuk model Decision Tree, hasil tuning terbaik diperoleh dengan parameter max_depth = 10, criterion = entropy, dan min_samples_split = 4, yang menghasilkan peningkatan akurasi dari 73% menjadi 77%, serta peningkatan pada seluruh metrik evaluasi rata-rata. Sementara itu, Random Forest menunjukkan peningkatan paling stabil setelah dioptimasi dengan parameter n_estimators = 100, max_depth = 8, dan criterion = gini, menghasilkan akurasi sebesar 80%. Hasil perbandingan performa ketiga algoritma setelah optimasi disajikan dalam Tabel 2 berikut.

Tabel 2. Hasil Evaluasi Model Setelah Optimasi

Model	Parameter Terbaik	Accuracy	Precision	Recall	F1-Score
SVM (GridSearchCV)	$C=10$, kernel=linear, gamma=scale	0.82	0.80	0.78	0.79
Decision Tree (Optimized)	max_depth=10, criterion=entropy	0.77	0.74	0.72	0.73
Random Forest (Optimized)	n_estimators=100, max_depth=8, criterion=gini	0.80	0.78	0.76	0.77

Berdasarkan tabel di atas, terlihat bahwa seluruh model mengalami peningkatan performa setelah dilakukan optimasi hyperparameter. Model SVM tetap menjadi yang paling unggul dengan peningkatan akurasi sebesar 4%, diikuti oleh Random Forest (+4%) dan Decision Tree (+3%). Hal ini menunjukkan bahwa proses tuning parameter sangat berpengaruh terhadap kinerja model, terutama dalam menangani kompleksitas data teks media sosial yang memiliki karakteristik high-dimensional dan sparse [15].

Secara keseluruhan, peningkatan performa pada model SVM disebabkan oleh kemampuan metode ini dalam menyesuaikan margin pemisah antar kelas melalui nilai parameter C, serta penggunaan kernel linear yang lebih sesuai dengan representasi TF-IDF yang linier. Sedangkan Decision Tree dan Random Forest menunjukkan peningkatan karena penyesuaian kedalaman pohon (max_depth) dan jumlah estimator yang optimal, sehingga model mampu menyeimbangkan antara bias dan varians secara lebih baik. Dengan demikian, hasil eksperimen setelah optimasi memperkuat temuan bahwa SVM merupakan algoritma yang paling efektif untuk tugas klasifikasi emosi berbasis teks media sosial pada penelitian ini, karena menghasilkan performa yang paling tinggi dan stabil dibandingkan dua algoritma lainnya.

3.2. Analisis Perbandingan Kinerja Algoritma

Analisis perbandingan dilakukan untuk memahami secara mendalam perbedaan performa ketiga algoritma machine learning, yaitu Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF), baik sebelum maupun sesudah dilakukan optimasi hyperparameter. Pembandingan dilakukan berdasarkan empat metrik utama, yaitu akurasi, presisi, recall, dan F1-score, yang masing-masing memberikan pandangan komplementer terhadap kemampuan model dalam mendeteksi emosi berdasarkan teks media sosial.

Dari hasil pengujian, SVM menunjukkan performa paling unggul baik sebelum maupun sesudah optimasi, dengan akurasi meningkat dari 78% menjadi 82%. Hal ini mengindikasikan bahwa SVM mampu menangani karakteristik data teks yang memiliki dimensi fitur tinggi dan tingkat sparsity besar secara efisien. Algoritma ini bekerja dengan mencari hyperplane optimal yang memisahkan kelas dengan margin terbesar, sehingga lebih tahan terhadap noise dan variasi kata dalam teks [16]. Decision Tree, di sisi lain, memperlihatkan kinerja yang lebih fluktuatif dengan akurasi yang relatif lebih rendah, yaitu 73% sebelum optimasi dan 77% setelah optimasi. Hal ini disebabkan oleh kecenderungan DT untuk membentuk struktur pohon yang terlalu kompleks pada data latih (overfitting), terutama ketika kedalaman pohon tidak dikontrol. Meskipun optimasi pada parameter `max_depth` dan `criterion` berhasil meningkatkan performa, model ini masih kurang stabil ketika diuji pada data baru [17]. Sementara itu, Random Forest menunjukkan performa yang lebih seimbang dan konsisten. Dengan menggunakan pendekatan bagging (bootstrap aggregating) dari banyak pohon keputusan, RF berhasil mengurangi varians dan meningkatkan kemampuan generalisasi model. Peningkatan akurasi dari 76% menjadi 80% menunjukkan bahwa RF memiliki keunggulan dalam menyeimbangkan antara kompleksitas model dan stabilitas prediksi [18].

Dari segi presisi dan recall, model SVM juga menghasilkan keseimbangan terbaik dengan rata-rata nilai presisi 0.80 dan recall 0.78 setelah optimasi. Hal ini menunjukkan bahwa SVM mampu meminimalkan kesalahan dalam mendeteksi emosi yang benar (false positive rendah) dan juga tidak kehilangan banyak instance dari kelas sebenarnya (false negative rendah). Pada Decision Tree, nilai recall yang lebih rendah dibandingkan presisi menandakan bahwa model cenderung gagal mengenali beberapa data dari kelas minoritas, seperti emosi “marah” yang jumlahnya lebih sedikit dalam dataset. Sementara pada Random Forest, nilai presisi dan recall cukup seimbang (0.78 dan 0.76), yang mencerminkan kemampuan model dalam mengenali variasi pola tanpa kehilangan akurasi secara signifikan [19]. F1-score, yang merupakan rata-rata harmonik dari presisi dan recall, memperkuat hasil tersebut: SVM memiliki skor tertinggi 0.79, disusul RF (0.77) dan DT (0.73). Artinya, kombinasi antara ketepatan dan kelengkapan prediksi paling optimal diperoleh melalui SVM.

Proses optimasi hyperparameter memberikan dampak positif yang konsisten terhadap seluruh model. Kenaikan akurasi dan nilai F1-score menunjukkan bahwa pemilihan parameter yang tepat memainkan peran penting dalam meningkatkan performa algoritma klasifikasi teks. Pada SVM, pemilihan parameter $C = 10$ dan kernel linear menghasilkan keseimbangan antara margin pemisah yang optimal dan kemampuan generalisasi model. Pada Decision Tree, penyesuaian `max_depth` berhasil mengurangi overfitting yang sebelumnya menyebabkan penurunan akurasi. Sementara pada Random Forest, peningkatan jumlah pohon (`n_estimators = 100`) membantu memperkuat kestabilan model terhadap variasi data pelatihan [20]. Dengan demikian, dapat disimpulkan bahwa SVM unggul dalam hal akurasi dan stabilitas prediksi, Random Forest lebih unggul dalam generalisasi dan ketahanan terhadap noise, sedangkan Decision Tree memiliki keunggulan dari sisi interpretabilitas namun kurang stabil dalam data teks berfitur tinggi.

Perbedaan performa antar algoritma dapat dijelaskan melalui karakteristik dasar dan mekanisme kerja masing-masing model. Algoritma Support Vector Machine (SVM) bekerja secara efektif pada data berdimensi tinggi karena memanfaatkan prinsip maximum margin classifier, yaitu mencari garis atau bidang pemisah terbaik yang memaksimalkan jarak antar kelas. Dengan konsep ini, SVM

mampu tetap menghasilkan prediksi yang akurat meskipun data memiliki banyak fitur yang tidak relevan seperti halnya hasil representasi TF-IDF pada data teks media sosial yang bersifat sparse dan berukuran besar.

Berbeda dengan SVM, algoritma Decision Tree (DT) membangun model klasifikasi berdasarkan pemisahan berbasis aturan (rule-based splits) yang diambil dari nilai atribut tertentu pada setiap simpul pohon keputusan. Pendekatan ini membuat DT lebih mudah diinterpretasikan, tetapi juga menjadikannya sensitif terhadap variasi kecil dalam data. Akibatnya, model cenderung overfitting dan kurang mampu menangkap hubungan non-linear yang kompleks antar kata dalam teks. Sementara itu, algoritma Random Forest (RF) dikembangkan sebagai solusi atas kelemahan Decision Tree dengan menerapkan prinsip ensemble learning, yaitu menggabungkan banyak pohon keputusan secara bersamaan untuk menghasilkan prediksi yang lebih stabil. Setiap pohon dilatih menggunakan subset data dan fitur yang berbeda, sehingga variasi model dapat menurunkan tingkat varians keseluruhan dan meningkatkan kemampuan generalisasi model terhadap data baru. Dengan demikian, RF lebih tahan terhadap noise dan ketidakseimbangan data dibandingkan Decision Tree tunggal [21]. Perbandingan performa akhir ketiga model dapat dirangkum sebagai berikut pada Tabel 3.

Tabel 3. Ringkasan Peningkatan Kinerja Model Sebelum dan Sesudah Optimasi

Model	Accuracy Sebelum	Accuracy Sesudah	Δ Akurasi	F1-Score Sebelum	F1-Score Sesudah
SVM	0.78	0.82	+0.04	0.75	0.79
Decision Tree	0.73	0.77	+0.04	0.69	0.73
Random Forest	0.76	0.80	+0.04	0.73	0.77

Berdasarkan hasil pada tabel di atas, seluruh algoritma mengalami peningkatan performa setelah dilakukan optimasi hyperparameter. Namun, SVM tetap menjadi model paling unggul secara keseluruhan, dengan nilai akurasi dan F1-score tertinggi di antara ketiganya. Peningkatan konsisten pada semua model menegaskan bahwa tuning parameter merupakan tahap krusial dalam pipeline machine learning untuk klasifikasi emosi berbasis teks media sosial.

4. Kesimpulan

Berdasarkan hasil penelitian mengenai penerapan metode machine learning untuk deteksi emosi pada analisis sentimen teks media sosial, dapat disimpulkan bahwa algoritma Support Vector Machine (SVM) menunjukkan performa terbaik dibandingkan dengan Decision Tree (DT) dan Random Forest (RF). Pada tahap sebelum optimasi, model SVM menghasilkan akurasi sebesar 78%, dengan nilai rata-rata precision 0.76, recall 0.74, dan F1-score 0.75. Setelah dilakukan optimasi hyperparameter menggunakan teknik GridSearchCV, performa model meningkat signifikan dengan akurasi mencapai 82%, serta rata-rata precision 0.80, recall 0.78, dan F1-score 0.79. Hasil ini menunjukkan bahwa pemilihan parameter yang tepat, khususnya pada nilai C dan kernel, berpengaruh besar terhadap kemampuan model dalam mengklasifikasikan emosi dengan akurat.

Sementara itu, algoritma Decision Tree mencatatkan akurasi sebesar 73% sebelum optimasi dan meningkat menjadi 77% setelah penyesuaian parameter `max_depth` dan `criterion`. Model ini unggul dari sisi interpretabilitas namun memiliki kelemahan pada kestabilan prediksi akibat kecenderungan overfitting. Adapun algoritma Random Forest menunjukkan hasil yang cukup kompetitif, dengan peningkatan akurasi dari 76% menjadi 80%, serta keseimbangan nilai precision dan recall yang baik, berkat kemampuannya dalam menggabungkan prediksi dari banyak pohon keputusan (ensemble learning).

Secara keseluruhan, penelitian ini menegaskan bahwa SVM merupakan algoritma yang paling efektif untuk deteksi emosi pada teks media sosial berbahasa Indonesia, karena mampu

menangani data dengan dimensi tinggi serta memberikan hasil yang stabil pada setiap kategori emosi. Temuan ini juga memperlihatkan bahwa optimasi hyperparameter berperan penting dalam meningkatkan kinerja model, terutama untuk algoritma dengan kompleksitas tinggi seperti SVM dan RF.

Sebagai saran untuk penelitian selanjutnya, terdapat beberapa arah pengembangan yang dapat dilakukan. Pertama, penggunaan metode balancing data seperti SMOTE atau ADASYN dapat membantu mengatasi ketidakseimbangan kelas emosi, terutama pada kategori dengan jumlah data lebih sedikit. Kedua, eksplorasi algoritma deep learning seperti LSTM (Long Short-Term Memory) atau BERT (Bidirectional Encoder Representations from Transformers) berpotensi meningkatkan akurasi dengan kemampuan memahami konteks semantik yang lebih dalam. Ketiga, penelitian mendatang dapat memperluas cakupan data dengan menggunakan berbagai sumber media sosial, serta melakukan analisis multibahasa untuk memperkaya generalisasi model. Dengan demikian, penelitian ini diharapkan dapat menjadi landasan dalam pengembangan model analisis sentimen dan deteksi emosi berbasis machine learning di Indonesia, serta mendorong penerapan kecerdasan buatan yang lebih luas dalam memahami persepsi dan emosi masyarakat di ruang digital.

Referensi

- [1] S. Safrudin, A. Hidayat, dan F. Ramadhan, "Confusion Matrix untuk Evaluasi Model Klasifikasi pada Machine Learning," *Jurnal Teknologi Informasi dan Komputer (JTIK)*, vol. 9, no. 2, pp. 55–62, 2024.
- [2] A. Hokijuliandy, D. Pramudito, dan I. Wulandari, "Analisis Sentimen Menggunakan Algoritma Support Vector Machine," *Jurnal Ilmiah Informatika*, vol. 8, no. 1, pp. 23–30, 2023.
- [3] M. Adiyanto, R. F. Ananda, dan Y. H. Putra, "Deteksi Emosi Berbasis Teks untuk Menganalisis Kuliah Daring Selama Masa Pandemi Menggunakan Algoritme Support Vector Machine," *Jurnal Teknologi Informasi dan Komunikasi (JTIKOM)*, vol. 10, no. 3, pp. 201–210, 2022.
- [4] F. Syah dan R. Witanti, "Analisis Sentimen Masyarakat terhadap Vaksinasi Covid-19 pada Media Sosial Twitter Menggunakan Algoritma Support Vector Machine," *Jurnal Sains dan Teknologi Komputer (JSTK)*, vol. 4, no. 2, pp. 122–131, 2022.
- [5] D. Yahya, M. Deswandi, dan A. Lubis, "Analisis Sentimen untuk Deteksi Ujaran Kebencian pada Media Sosial Terkait Pemilu 2024 Menggunakan Metode Support Vector Machine," *Jurnal Teknologi dan Sistem Informasi Indonesia (JTSII)*, vol. 12, no. 1, pp. 11–20, 2024.
- [6] N. Indriani dan H. Nurmalsari, "Penerapan Text Preprocessing pada Analisis Sentimen Twitter Menggunakan Metode TF-IDF," *Jurnal Informatika dan Komputer Indonesia (JIKOM)*, vol. 7, no. 2, pp. 45–52, 2023.
- [7] A. Prasetyo dan T. W. Sari, "Analisis Emosi Pengguna Media Sosial Twitter Menggunakan Metode Machine Learning," *Jurnal Teknologi dan Sistem Informasi*, vol. 11, no. 2, pp. 134–141, 2023.
- [8] K. Puspitasari dan R. Firmansyah, "Klasifikasi Sentimen Menggunakan Support Vector Machine dengan Pembobotan TF-IDF," *Jurnal Ilmiah Informatika Global (JIIG)*, vol. 9, no. 1, pp. 17–26, 2022.
- [9] F. Rahmawati, M. F. Rachman, dan D. S. Nugroho, "Implementasi Decision Tree dan Random Forest untuk Analisis Sentimen Ulasan Pengguna," *Jurnal Komputer dan Aplikasi*, vol. 8, no. 4, pp. 210–219, 2023.
- [10] D. Kurniawan, "Evaluasi Model Machine Learning Menggunakan Metrik Accuracy, Precision, Recall, dan F1-Score," *Jurnal Teknologi Informasi (JTIIN)*, vol. 6, no. 3, pp. 67–75, 2023.
- [11] I. M. Al Fajri, "Perbandingan Kinerja SVM dan Random Forest dalam Klasifikasi Teks," *Jurnal Sistem Cerdas dan Komputasi*, vol. 5, no. 2, pp. 56–64, 2022.
- [12] S. Wibowo, "Analisis Efektivitas Metode Support Vector Machine untuk Klasifikasi Teks Bahasa Indonesia," *Jurnal Ilmu Komputer Terapan*, vol. 7, no. 1, pp. 23–31, 2022.
- [13] R. Handayani dan F. Chandra, "Implementasi Ensemble Learning Menggunakan Random Forest untuk Analisis Sentimen," *Jurnal Teknologi dan Informasi (JTI)*, vol. 10, no. 2, pp. 88–96, 2023.
- [14] M. Suryadi dan D. P. Lestari, "Optimasi Hyperparameter Model Machine Learning Menggunakan GridSearchCV," *Jurnal Teknologi dan Sistem Cerdas (JTSC)*, vol. 9, no. 1, pp. 12–20, 2023.
- [15] E. N. Dewi dan L. Putra, "Pengaruh Optimasi Hyperparameter terhadap Akurasi Klasifikasi Menggunakan Support Vector Machine," *Jurnal Informatika Indonesia (JII)*, vol. 8, no. 2, pp. 34–42, 2024.
- [16] N. S. Rahman dan B. Mahendra, "Analisis Model Margin pada Support Vector Machine untuk Data Berdimensi Tinggi," *Jurnal Matematika dan Komputasi*, vol. 10, no. 1, pp. 75–84, 2023.
- [17] D. P. Ramadhan, "Pengaruh Parameter Max Depth terhadap Overfitting pada Model Decision Tree," *Jurnal Ilmiah Komputer dan Data Sains (JIKODS)*, vol. 3, no. 2, pp. 102–109, 2023.
- [18] F. Hartono dan M. Yuliana, "Kinerja Algoritma Random Forest dalam Mengatasi Overfitting pada Data Teks," *Jurnal Teknologi dan Analitika Data*, vol. 5, no. 2, pp. 81–89, 2023.

- [19] A. Wibisono dan H. Ramli, “Analisis Perbandingan Precision dan Recall pada Algoritma Klasifikasi Teks,” *Jurnal Teknologi dan Sains Komputer (JTSC)*, vol. 6, no. 3, pp. 59–68, 2022.
- [20] T. Setiawan dan Y. K. Nugraha, “Pengaruh Hyperparameter terhadap Kinerja Random Forest untuk Data Klasifikasi,” *Jurnal Sains Komputer dan Sistem Informasi*, vol. 9, no. 1, pp. 44–51, 2024.
- [21] H. S. Widodo, “Analisis Ensemble Learning untuk Peningkatan Generalisasi Model Klasifikasi,” *Jurnal Sistem Informasi dan Kecerdasan Buatan (JSIKA)*, vol. 8, no. 2, pp. 101–110, 2023.