

Analisis Sentimen terhadap Kebijakan *Food Estate* Menggunakan Algoritma *Support Vector Machine*

Ratna Mufidah^{1*}, Heru Triana², Savina³

^{1,2,3}Informatika, Universitas Singaperbangsa Karawang
Email: *ratna.mufidah@cs.unsika.ac.id

Abstrak. Kebijakan *Food Estate* menjadi topik penting dalam diskusi publik di Indonesia terkait ketahanan pangan. Namun, implementasinya memicu reaksi di media sosial, baik positif, negatif, maupun netral. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terkait kebijakan *Food Estate* dengan menggunakan algoritma *Support Vector Machine* (SVM). Algoritma SVM dipilih karena kinerjanya yang terbukti efektif dalam klasifikasi teks, serta hasil penelitian sebelumnya menunjukkan akurasi yang tinggi dalam analisis sentimen. Data dikumpulkan dari media sosial X menggunakan teknik *scraping*, kemudian dilakukan pra-pemrosesan data. Data yang telah diproses diklasifikasikan ke dalam tiga kategori sentimen (positif, negatif, netral) menggunakan SVM dengan kernel linear, RBF, polinomial, dan sigmoid. Hasil evaluasi menunjukkan bahwa SVM dengan kernel linear dan parameter $C=2$ memberikan performa terbaik, dengan akurasi sebesar 79%, *precision* 80%, *recall* 79%, dan *F1-score* 79%. Hasil ini menunjukkan bahwa SVM mampu mengklasifikasikan sentimen masyarakat dengan cukup baik sehingga diharapkan dapat memberikan wawasan penting bagi pembuat kebijakan dalam mengevaluasi dampak sosial dari kebijakan tersebut.

Kata kunci: *analisis sentimen, food estate, support vector machine, media sosial.*

1 Pendahuluan

Kebijakan *food estate* telah menjadi topik diskusi yang signifikan di Indonesia dalam beberapa tahun terakhir, seiring dengan upaya pemerintah untuk meningkatkan ketahanan pangan dan memaksimalkan penggunaan lahan pertanian [1]. *Food estate* merupakan sebuah konsep yang mengedepankan pengembangan produksi pangan secara menyeluruh dan terintegrasi, yang mencakup berbagai sektor utama seperti pertanian, perkebunan, dan peternakan [2],[3]. Dalam penerapannya, konsep ini dirancang untuk diimplementasikan pada lahan yang luas, dengan tujuan menciptakan sinergi antara berbagai komponen produksi pangan [4]. Namun, implementasi kebijakan ini mendapat beragam tanggapan dari masyarakat, baik positif, negatif maupun netral. Tanggapan tersebut dapat dilihat melalui reaksi publik di media sosial, di mana sentimen masyarakat terhadap kebijakan ini dapat memberikan wawasan berharga bagi pembuat kebijakan. Oleh karena itu, analisis sentimen terhadap kebijakan *food estate* di media sosial menjadi semakin relevan untuk dilakukan.

Analisis sentimen adalah teknik yang digunakan untuk mengidentifikasi emosi dan sentimen yang terkandung dalam suatu teks [5],[6]. Analisis sentimen melibatkan prediksi sentimen menggunakan algoritma klasifikasi dan teknik pra-pemrosesan teks [7]. Salah satu algoritma yang dapat digunakan dalam melakukan prediksi sentimen adalah algoritma *Support Vector Machine* (SVM). SVM merupakan salah satu algoritma pembelajaran mesin untuk melakukan klasifikasi data berdasarkan label yang telah ditentukan sebelumnya [8].

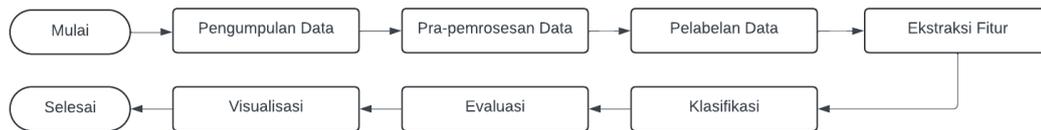
Dalam penelitian Cam dkk [9], beberapa algoritma pembelajaran mesin diterapkan untuk melakukan analisis sentimen terhadap postingan terkait keuangan dalam bahasa Turki pada media sosial twitter. Hasil penelitian tersebut menunjukkan bahwa algoritma SVM mendapatkan nilai akurasi tertinggi (89%) dibandingkan dengan algoritma yang lain. Sedangkan dalam penelitian Jannah dan Kasnawi, algoritma SVM dan Naïve Bayes diterapkan untuk melakukan analisis sentimen terhadap kebijakan subsidi kendaraan listrik berbasis data X [10]. Penelitian tersebut menunjukkan bahwa tingkat akurasi rata-rata pada algoritma SVM lebih tinggi (82,88%) dibandingkan dengan algoritma Naïve Bayes (69,75%). Hal serupa juga ditunjukkan dalam penelitian Nurwanda dkk, di mana algoritma SVM dibandingkan dengan algoritma Naïve Bayes untuk klasifikasi *lifestyle* pada media sosial Twitter [11]. Pada penelitian tersebut didapatkan bahwa akurasi pada algoritma SVM (61%) lebih tinggi daripada algoritma Naïve Bayes (59%). Adapun penelitian yang dilakukan oleh Nurkholis dkk [12] menunjukkan bahwa SVM sangat baik dalam melakukan prediksi sentimen terhadap kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat (PKKM) pada media sosial twitter. Perpaduan SVM metode *One Against Rest* (OAR) dengan kernel *polynomial* menghasilkan akurasi 98,9%, *precision* 97%, *recall* 98%, dan *F1-score* 97%.

Berdasarkan hasil penelitian sebelumnya, algoritma SVM telah menunjukkan kinerja yang sangat baik dalam analisis sentimen. Oleh karena itu, penelitian ini bertujuan untuk mengaplikasikan SVM pada analisis sentimen terhadap kebijakan *Food Estate* pada media sosial X. Dengan demikian, penelitian ini tidak hanya akan menguji kembali efektivitas SVM pada domain baru, tetapi juga akan memberikan wawasan penting mengenai persepsi masyarakat terhadap kebijakan yang memiliki dampak luas pada sektor pangan dan pertanian. Hasil penelitian ini diharapkan dapat menjadi referensi bagi pemerintah, pembuat kebijakan, dan pihak terkait lainnya dalam mengambil keputusan yang lebih baik terkait kebijakan tersebut.

2 Metodologi

Metode analisis sentimen pada penelitian ini dapat dilihat pada Gambar 1. Pertama, pengumpulan data mentah pada media sosial X. Kedua, pra-pemrosesan

data teks yang meliputi *case folding*, pembersihan data, tokenisasi, penghapusan *stopword*, serta *stemming*. Ketiga, pelabelan (positif, negatif, dan netral). Keempat, ekstraksi fitur menggunakan TF-IDF. Kelima, klasifikasi menggunakan SVM. Keenam, evaluasi hasil. Dan yang terakhir adalah visualisasi sentimen terhadap kebijakan *Food Estate*.



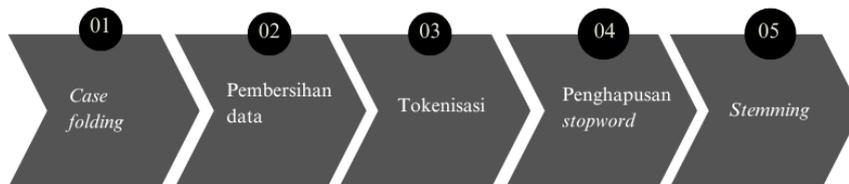
Gambar 1. Metode Analisis Sentimen

2.1 Pengumpulan Data

Pada penelitian ini, pengumpulan data dilakukan dengan teknik *scraping* pada data media sosial X dengan kata kunci sebagai berikut: “kebijakan food estate”, “food estate Indonesia”, “food estate pemerintah”, “food estate kementerian pertanian”, serta “pengembangan pusat pangan”. Adapun rentang waktu pengambilan data dimulai dari bulan Oktober 2023 sampai dengan Maret 2024.

2.2 Pra-pemrosesan Data

Pra – pemrosesan data dilakukan setelah proses pengumpulan data teks selesai. Pra-pemrosesan data merupakan serangkaian langkah untuk mempersiapkan data teks mentah untuk dianalisis [13]. Adapun langkah – langkah dari pra-pemrosesan data tersebut dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Pra-Pemrosesan Data

Gambar 2 menunjukkan bahwa langkah – langkah dalam pra-pemrosesan data terdiri dari:

1. *Case-folding*
Case-folding merupakan pemrosesan data teks dengan mengubah teks menjadi bentuk yang sama. Dalam penelitian ini, *case folding* ditunjukkan dengan mengubah semua huruf menjadi huruf kecil (*lowercase*).

2. Pembersihan data
Pembersihan data merupakan langkah krusial dalam pra-pemrosesan data teks. Pembersihan data bertujuan untuk menghilangkan data yang tidak relevan [14]. Dalam penelitian ini pembersihan yang dilakukan meliputi: penghapusan tanda baca, kode ASCII, *Unicode*, serta garis baru (*newline*).
3. Tokenisasi
Tokenisasi dilakukan untuk melakukan pemecahan kalimat ke dalam kata/token.
4. Penghapusan *stopword*
Penghapusan *stopword* dilakukan untuk menghilangkan kata-kata yang tidak memiliki makna signifikan dalam analisis teks berdasarkan pustaka Sastrawi.
5. *Stemming*
Stemming merupakan tahap mengubah kata-kata yang terikat atau berinfleksi (seperti kata kerja dalam berbagai bentuk) menjadi bentuk dasarnya atau "akar katanya." Tujuan dari *stemming* adalah untuk menyederhanakan kata-kata dengan menghilangkan imbuhan seperti awalan, akhiran, atau sisipan, sehingga semua variasi kata tersebut dapat dianalisis sebagai satu entitas yang sama.

2.3 Pelabelan Data

Setelah pra – pemrosesan data dilakukan, langkah selanjutnya adalah pelabelan data. Pelabelan data teks pada penelitian ini dilakukan secara otomatis dengan memanfaatkan Indonesian BERT base model. Model ini telah dilatih dengan 522MB Wikipedia bahasa Indonesia dan 1GB surat kabar berbahasa Indonesia. Model tersebut merupakan model *Bidirectional Encoder Representations from Transformers* (BERT) yang khusus dirancang untuk Bahasa Indonesia [15]. Pelabelan dilakukan untuk menentukan kategori teks dengan memperhitungkan konteks kata dari kedua arah (sebelum dan sesudah kata tersebut dalam kalimat) [16]. Penelitian ini melakukan pelabelan pada data teks dalam 3 kategori, yaitu: positif, negatif, dan netral.

2.4 Ekstraksi Fitur

Dalam penelitian ini, ekstraksi fitur dilakukan dengan menggunakan metode *Term Frequency - Inverse Document Frequency* (TF-IDF) untuk mengidentifikasi kata-kata kunci yang merepresentasikan sentimen positif, negatif, atau netral terhadap kebijakan *Food Estate*. Metode ini dipilih karena kemampuannya dalam memberikan bobot yang lebih tinggi pada kata-kata yang khas untuk setiap dokumen. TF mengukur seberapa sering sebuah kata muncul dalam dokumen, sedangkan IDF menilai seberapa umum atau langka kata tersebut di seluruh dokumen [7].

2.5 Klasifikasi

Setelah ekstraksi fitur dilakukan menggunakan TF-IDF, hasilnya berupa matriks fitur yang akan digunakan sebagai masukan bagi *Support Vector Machine* (SVM). Dalam penelitian ini, algoritma SVM digunakan untuk klasifikasi sentimen publik terhadap kebijakan *Food Estate*, yang dibagi menjadi tiga kategori: positif, negatif, dan netral. SVM adalah metode klasifikasi yang bekerja dengan mencari *hyperplane* optimal untuk memisahkan data ke dalam beberapa kategori sentimen. Karena SVM pada dasarnya adalah algoritma biner, pendekatan yang digunakan untuk mengklasifikasikan sentimen menjadi tiga kelas (positif, negatif, dan netral) adalah *one-vs-rest*. Pada pendekatan ini, beberapa model biner SVM dilatih, di mana setiap model memisahkan satu kelas sentimen dari dua kelas lainnya. Sebagai contoh, model pertama akan memisahkan kelas positif dari kelas negatif dan netral, model kedua memisahkan kelas negatif dari kelas positif dan netral, dan model ketiga memisahkan kelas netral dari kelas positif dan negatif.

Pengujian model dilakukan terhadap empat kernel pada SVM, yaitu: linear, *Radial Basis Function* (RBF), polinomial, dan sigmoid. Selain itu, untuk mendapatkan hasil klasifikasi yang optimal, dilakukan pula pengujian terhadap tiga skenario pembagian data latih dan data uji. Skenario pertama menggunakan 90% data latih dan 10% data uji, skenario kedua menggunakan 80% data latih dan 20% data uji, dan skenario ketiga menggunakan 70% data latih dan 30% data uji. Setiap kombinasi kernel dan skenario pembagian data dievaluasi berdasarkan kinerja model pada data uji.

2.6 Evaluasi

Proses evaluasi model SVM dilakukan dengan menghitung beberapa metrik evaluasi utama, yaitu akurasi, *precision*, *recall*, dan *F1-score*. Metrik-metrik ini digunakan untuk mengukur performa model dalam mengklasifikasikan sentimen positif, negatif, dan netral berdasarkan data yang telah diproses. Masing-masing metrik memiliki fokus dan tujuan yang berbeda dalam mengevaluasi hasil klasifikasi, sehingga memberikan pandangan komprehensif mengenai kualitas model yang dibangun. Akurasi dihitung sebagai proporsi prediksi yang benar terhadap total prediksi yang dibuat. *Precision* mengukur seberapa banyak prediksi sentimen positif yang benar dibandingkan dengan semua prediksi sentimen positif, sementara *recall* mengukur seberapa banyak sentimen positif yang berhasil diidentifikasi dibandingkan dengan total data sentimen positif sebenarnya. *F1-score* adalah rata-rata harmonis dari *precision* dan *recall* yang memberikan keseimbangan antara kedua metrik tersebut. Hasil dari evaluasi ini digunakan untuk memilih konfigurasi terbaik dalam klasifikasi sentimen menggunakan SVM.

2.7 Visualisasi

Visualisasi hasil analisis sentimen (positif, negatif, dan netral) terhadap kebijakan Food Estate dilakukan dengan menggunakan teknik *word cloud*. *Word cloud* merupakan representasi grafis dari kata-kata yang muncul dalam ulasan publik, di mana ukuran setiap kata mencerminkan frekuensi kemunculannya dalam teks [17]. Kata-kata yang paling sering muncul dalam ulasan dengan sentimen positif, negatif, dan netral kemudian divisualisasikan dalam bentuk *word cloud* terpisah untuk setiap sentimen. Kata-kata dengan frekuensi kemunculan yang lebih tinggi ditampilkan dengan ukuran font yang lebih besar, sehingga memberikan gambaran visual mengenai tema dan kata kunci yang dominan dalam setiap kategori sentimen. Visualisasi *word cloud* ini membantu dalam memahami pola linguistik yang terkait dengan pandangan masyarakat terhadap kebijakan Food Estate, serta memudahkan identifikasi topik utama yang mendorong sentimen positif, negatif, atau netral.

3 Hasil dan Pembahasan

Bagian ini menyajikan hasil analisis sentimen terhadap kebijakan *Food Estate* menggunakan algoritma SVM. Bagian ini akan membahas hasil pengumpulan data, pra-pemrosesan data, pelabelan data, ekstraksi fitur, klasifikasi, evaluasi, sampai dengan visualisasi.

3.1 Pengumpulan Data

Data penelitian diperoleh melalui teknik *scraping* pada platform media sosial X. Proses *scraping* dilakukan dengan menggunakan kata kunci spesifik terkait kebijakan *Food Estate*, yang dikumpulkan dalam rentang waktu Oktober 2023 hingga Maret 2024. Setelah dilakukan pembersihan data untuk menghilangkan duplikasi, diperoleh 1513 data unik yang siap untuk dianalisis lebih lanjut. Duplikasi data dapat terjadi karena penulis menggunakan beberapa kata kunci dengan tema serupa, seperti: “kebijakan *food estate*”, “*food estate* Indonesia”, “*food estate* pemerintah”, “*food estate* kementerian pertanian”, serta “pengembangan pusat pangan”. Selain itu proses *scraping* yang dilakukan beberapa kali di waktu berbeda juga turut mempengaruhi terjadinya duplikasi data. Proses *scraping* dilakukan secara berulang dan bertahap karena adanya batas *scraping* dalam setiap sesinya. Adapun beberapa hasil pengumpulan data dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pengumpulan Data dari Media Sosial X

No	Data teks
1	"@tvOneNews Gak perlu waspada kok? Kalo gak ada beras kan bisa beralih ke singkong atau jagung dari food estate. Selain itu ada makan siang gratis, juga susu supaya ""binatangnya gemuk"" Krn kan cawapresnya gak mau berburu di kebun binatang, tapi digemukakan dulu binatangnya."
2	@CNNIndonesia Gk usah food estate, petani biasa juga bisa panen jagung. Apa hebatnya
3	@satrio_tone @kaimsasikul @tvOneNews @prabowo Ketika food estate yang dia jalankan gagal food estate kementerian pertanian lah yang diklaim nya seenggaknya perbaikilah kegagalan sendiri jangan cuma omon omon
4	@hakimrbg @pemudaidamanid Dengan masuknya Demokrat ke koalisi 02 semoga tdk menghentikan pak amal utk mengkritisi food estate. Dulu pak amal sering mengkritisi kebijakan food estate. Dan tidak ada salahnya kalau saya dan calon pemilihnya pak amal utk mengetahui komentarnya lagi ttg food estate
5	@Michojo2 @noegrahaha @brandal_baru food estate itu harusnya tanggungjawab kementerian pertanian sebenarnya inti tujuan food estate itu bagus biar ga banyak impor. eksekusinya aja kurang.

3.2 Pra-pemrosesan Data

Pra-pemrosesan data dimulai dengan *case-folding*, yaitu mengubah seluruh teks menjadi huruf kecil untuk memastikan konsistensi dalam analisis. Selanjutnya, dilakukan pembersihan data untuk menghapus tanda baca, angka, dan simbol yang tidak relevan. Tahap tokenisasi digunakan untuk memecah teks menjadi kata-kata atau token yang lebih mudah dianalisis. Setelah itu, dilakukan penghapusan *stopword* guna mengeliminasi kata-kata umum yang tidak signifikan dalam analisis sentimen, serta *stemming* untuk mengembalikan setiap kata ke bentuk dasarnya. Tabel 2 menunjukkan beberapa hasil dari pra-pemrosesan data.

Tabel 2. Hasil Pra-Pemrosesan Data

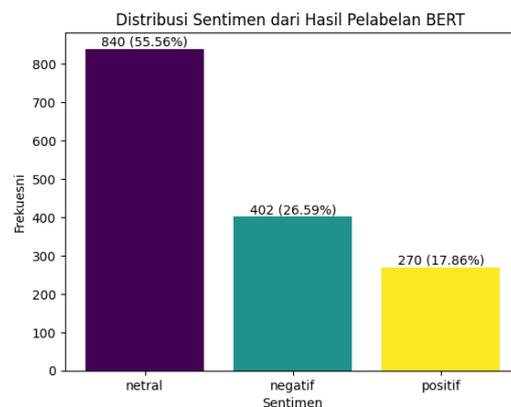
No	Data teks
1	tvonenews gak perlu waspada kok kalo gak beras kan alih singkong jagung food estate itu makan siang gratis susu binatang gemuk krn kan cawapresnya gak mau buru kebun binatang gemuk dulu binatang
2	cnindonesia gk usah food estate tani biasa bisa panen jagung apa hebat
3	satrio tone kaimsasikul tvonenews prabowo food estate dia jalan gagal food estate menteri tani lah klaim nya enggak baik gagal sendiri jangan cuma omon omon
4	hakimrbg pemudaidamanid masuk demokrat koalisi 02 moga tdk henti pak amal utk mengkritisi food estate dulu pak amal sering mengkritisi bijak food estate tidak salah kalau dan calon pilih pak amal utk tahu komentar ttg food estate

- 5 michojo2 noegrahaha brandal baru food estate harus tanggungjawab menteri tani sebenarnya inti tuju food estate bagus biar ga banyak impor eksekusi aja kurang
-

Hasil dari serangkaian tahap pra-pemrosesan data memastikan bahwa data teks telah siap digunakan untuk tahap ekstraksi fitur dan klasifikasi sentimen menggunakan algoritma SVM dengan tujuan mampu memberikan hasil yang lebih akurat dan reliabel.

3.3 Pelabelan Data

Pelabelan data dilakukan secara otomatis menggunakan Indonesian BERT base model untuk mengklasifikasikan sentimen ulasan terkait kebijakan *Food Estate* ke dalam tiga kategori utama: positif, negatif, dan netral. Indonesian BERT base model telah dilatih khusus untuk memahami bahasa Indonesia. Dalam proses pelabelan ini, model secara otomatis mengidentifikasi sentimen berdasarkan pola-pola kata dan frasa yang relevan, tanpa perlu intervensi manual. Adapun hasil pelabelan data menunjukkan distribusi sentimen sebagai berikut: 840 data memiliki sentimen netral, 402 data memiliki sentimen negatif, dan 270 data memiliki sentimen positif seperti yang terlihat pada Gambar 3.



Gambar 3. Distribusi Sentimen

Gambar 3 memperlihatkan bahwa sebagian besar pendapat yang diungkapkan terkait kebijakan *Food Estate* cenderung netral. Jumlah sentimen netral jauh lebih banyak dibandingkan dengan sentimen negatif atau positif. Jika kita lihat persentasenya pada Gambar 4, sekitar 55,56% merupakan sentimen netral, diikuti oleh sentimen negatif sebesar 26,59%, dan sentimen positif hanya sebesar 17,86%.

3.4 Ekstraksi Fitur

Setelah pra-pemrosesan data, data teks diubah menjadi representasi numerik melalui teknik TF-IDF menggunakan *library* TfidfVectorizer pada Python sehingga didapatkan 4191 fitur dari setiap baris data. Matriks fitur yang dihasilkan kemudian digunakan sebagai input untuk melatih model SVM. Dengan memberikan bobot yang sesuai pada setiap kata, diharapkan model SVM dapat lebih akurat dalam mengklasifikasikan sentimen dari data teks. Fitur

3.5 Klasifikasi

Klasifikasi sentimen dilakukan dengan menggunakan algoritma SVM. Untuk mendapatkan model terbaik maka dilakukan beberapa skenario uji coba. Pertama, data teks dibagi menjadi data latih dan data uji dengan tiga komposisi seperti yang terlihat pada Tabel 3.

Tabel 3. Daftar Komposisi Pembagian Data (*train-test split model*)

Jumlah Data	90:10		80:20		70:30	
	Data Latih	Data Uji	Data Latih	Data Uji	Data Latih	Data Uji
1513	1361	152	1210	303	1059	454

Selanjutnya, parameter C pada *library* SVC diatur pada nilai 1 dan 2. Parameter C berfungsi sebagai pengatur regularization dalam model SVM. Fungsi pengaturan parameter ini untuk meminimalkan kesalahan klasifikasi dan memaksimalkan margin pemisah. Selain itu beberapa kernel SVM juga digunakan untuk mendapatkan model SVM yang optimal dalam melakukan klasifikasi sentimen pada kebijakan *Food Estate*. Adapun skenario optimalisasi model tersebut dapat dilihat pada Tabel 4.

Tabel 4. Skenario Optimalisasi Model SVM

Parameter C	Kernel
1	Linear
	RBF
	Polinomial
	Sigmoid
2	Linear
	RBF
	Polinomial
	Sigmoid

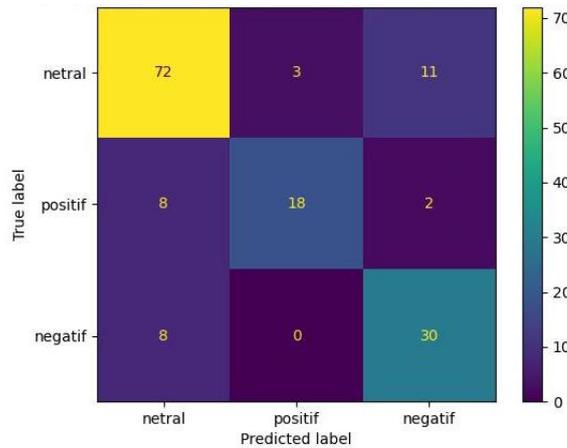
3.6 Evaluasi

Evaluasi model SVM dilakukan dengan menghitung akurasi, *F1-score*, *precision*, dan *recall*. Hasil evaluasi ini memberikan gambaran komprehensif tentang efektivitas model dalam mengidentifikasi sentimen positif, negatif, dan netral dari ulasan yang dianalisis. Hasil evaluasi dapat dilihat pada Tabel 5.

Tabel 5. Hasil Evaluasi Model SVM

Parameter C	Kernel	Rasio	Akurasi	F1-score	Precision	Recall
1	Linear	90:10	0.76	0.75	0.79	0.76
1	Linear	80:20	0.75	0.74	0.76	0.75
1	Linear	70:30	0.75	0.74	0.75	0.75
1	Polinomial	90:10	0.61	0.51	0.66	0.61
1	Polinomial	80:20	0.60	0.48	0.65	0.60
1	Polinomial	70:30	0.60	0.49	0.63	0.60
1	RBF	90:10	0.75	0.74	0.77	0.75
1	RBF	80:20	0.75	0.72	0.77	0.75
1	RBF	70:30	0.73	0.71	0.73	0.73
1	Sigmoid	90:10	0.76	0.74	0.79	0.76
1	Sigmoid	80:20	0.74	0.72	0.76	0.74
1	Sigmoid	70:30	0.74	0.73	0.74	0.74
2	Linear	90:10	0.79	0.79	0.80	0.79
2	Linear	80:20	0.75	0.74	0.74	0.75
2	Linear	70:30	0.75	0.75	0.75	0.75
2	Polinomial	90:10	0.63	0.54	0.66	0.63
2	Polinomial	80:20	0.60	0.51	0.56	0.60
2	Polinomial	70:30	0.61	0.51	0.62	0.61
2	RBF	90:10	0.78	0.77	0.80	0.78
2	RBF	80:20	0.74	0.73	0.74	0.74
2	RBF	70:30	0.76	0.75	0.75	0.76
2	Sigmoid	90:10	0.78	0.77	0.79	0.78
2	Sigmoid	80:20	0.75	0.74	0.74	0.75
2	Sigmoid	70:30	0.74	0.74	0.74	0.74

Tabel 5 menunjukkan bahwa akurasi tertinggi sebesar 0,79 (79%) diperoleh model SVM pada kernel linear dengan parameter $C = 2$ serta rasio 90% data latih dan 10% data uji. Tingginya akurasi berbanding lurus dengan nilai *F1-score* sebesar 0,79 (79%), *precision* sebesar 0,80 (80%), serta *recall* sebesar 0,79 (79%). Hasil tersebut selaras dengan *confusion matrix* pada Gambar 5, dimana *confusion matrix* dapat menunjukkan kinerja model dengan lebih mendetail serta mampu mengidentifikasi kesalahan klasifikasi spesifik.



Gambar 5. *Confusion Matrix* pada Model SVM dengan Parameter C=2, Kernel Linear, dan Rasio 90:10

Nilai akurasi yang diperoleh mengindikasikan kemampuan model dalam mengklasifikasi sentimen secara umum. Nilai *F1-score* menunjukkan keseimbangan yang baik antara *precision* dan *recall*, yang berarti model mampu mengidentifikasi sebagian besar data yang relevan dengan kategori sentimen yang benar. Selain itu, nilai *precision* sebesar 80% menunjukkan tingkat kepercayaan yang tinggi terhadap hasil prediksi model, sementara nilai *recall* sebesar 79% menunjukkan kelengkapan model dalam mengidentifikasi semua data yang relevan. Dengan akurasi, *F1-score*, *precision*, dan *recall* yang semuanya mendekati 0,80, model ini menunjukkan performa yang seimbang dan efisien dalam mengolah data sentimen.

3.7 Visualisasi

Hasil analisis sentimen terhadap kebijakan *Food Estate* divisualisasikan dalam bentuk *word cloud*. *Word cloud* menampilkan kata-kata yang paling sering muncul dalam tiap kategori sentimen, yaitu positif, negatif, dan netral. Dengan memvisualisasikan frekuensi kata-kata ini, pola sentimen yang berkembang di masyarakat terkait kebijakan *Food Estate* dapat lebih mudah dipahami. Adapun *word cloud* dari tiga kategori sentimen dapat dilihat pada Gambar 6.



Selanjutnya, visualisasi hasil analisis sentimen melalui teknik *word cloud* mengungkapkan pola yang mendalam terkait persepsi publik terhadap kebijakan *Food Estate*. Dengan mengidentifikasi kata-kata kunci yang muncul dalam sentimen positif, negatif, dan netral, pembuat kebijakan dapat lebih memahami tema yang mendasari opini masyarakat. Kemampuan SVM dalam ekstraksi fitur yang efektif, mampu menyoroti isu-isu penting yang menjadi perhatian publik, seperti dampak sosial ekonomi dari kebijakan ini. Dengan demikian, implementasi SVM dalam analisis sentimen tidak hanya meningkatkan pemahaman tentang persepsi masyarakat, tetapi diharapkan mampu membantu dalam merumuskan kebijakan yang lebih responsif terhadap kebutuhan dan harapan masyarakat.

4 Kesimpulan

Penelitian ini berhasil menerapkan algoritma Support Vector Machine (SVM) untuk analisis sentimen kebijakan Food Estate, dengan akurasi tertinggi mencapai 79% menggunakan kernel linear dan parameter $C=2$. Model SVM menunjukkan kinerja yang seimbang antara akurasi, F1-score, precision, dan recall, yang mengindikasikan bahwa SVM merupakan metode yang efektif untuk mengklasifikasikan sentimen positif, negatif, dan netral dari ulasan publik di media sosial. Meskipun demikian, akurasi model masih berpotensi ditingkatkan dengan memperluas ukuran dataset, mengeksplorasi variasi parameter yang lebih luas, serta menerapkan teknik penanganan ketidakseimbangan data pada penelitian selanjutnya.

5 Referensi

- [1] A. N. Hamidah, M. C. Tjahjana, dan A. B. Aliansyah, "Analisis Ekonomi Politik : Studi Kasus Proyek Food Estate Menuju Ketahanan Pangan Di Indonesia," *Jurnal Suara Politik*, vol. 2, no. 2, 2023, doi: <https://doi.org/10.31869/jsp.v2i2.4921>.
- [2] W. H. S. Widodo, A.H. Imaduddin, dan I. Soewarni, "Kajian Penentuan Komoditas Unggulan Penunjang Food Estate di Kabupaten Malang," *Journal of Demography, Ethnography, and Social Transformation*, vol. 3, no. 2, 2023, doi: <https://doi.org/10.30631/demos.v3i2.1969>.
- [3] R. Diffa, Imamulhadi, S. Sekarwati, "Analisis Yuridis terhadap Program Pembangunan Food Estate di Kawasan Hutan Ditinjau dari Eco-Justice," *LITRA: Jurnal Hukum Lingkungan Tata Ruang dan Agraria*, vol. 2, no. 1, doi: <https://doi.org/10.23920/litra.v2i1.1014>.
- [4] O. Athallah dan R. K. Rajib, "Implementasi Food Estate Sebagai Tantangan Menjaga Ketahanan Pangan dan Melestarikan Lingkungan," *Jurnal Ilmiah Penelitian Mahasiswa*, vol. 2, no. 3, 2024, doi: <https://doi.org/10.61722/jipm.v2i3.57>.

- [5] N. R. Ram dkk, "Social Media Sentiment Analysis Using Twitter Dataset, " 2024 1st International Conference on Cognitive, Green and Ubiquitous Computing (IC-CGU), IEEE, doi: 10.1109/IC-CGU58078.2024.10530694.
- [6] T. A. Khan dkk, "Sentiment Analysis using Support Vector Machine and Random Forest, " Journal of Informatics and Web Engineering, vol. 3, no. 1, 2024, doi: <https://doi.org/10.33093/jiwe.2024.3.1.5>.
- [7] K. Mathur dkk, "Sentiment Analysis Framework of Social Media Text by Feature Extraction and Machine Learning Model," Indian Journal of Science and Technology, 2023, doi: <https://doi.org/10.17485/IJST/v16i29.1537>.
- [8] S. H. Imanuddin, K. Adi, dan R. Gernowo, "Sentiment Analysis on Satuselat Application Using Support Vector Machine Method, " Journal of Electronics, Electromedical Engineering, and Medical Informatics, vol. 5, no. 3, 2023, doi: <https://doi.org/10.35882/jeemi.v5i3.304>.
- [9] H. Cam dkk, "Sentiment Analysis of Financial Twitter Posts on Twitter with The Machine Learning Classifiers, " Heliyon 10, 2024, doi: <https://doi.org/10.1016/j.heliyon.2023.e23784>.
- [10] IWD Wiguna dkk, "Comparison of SVM & Naïve Bayes Methods in Sentiment Analysis of Electric Vehicle Subsidy Policy Based on X Data, " Journal of Engineering and Scientific Research, vol. 6, issue 1, 2024, doi: <http://dx.doi.org/10.23960/jesr.v6i1.158>.
- [11] F. Nurwanda dkk, "Comparative Analysis Of Performance Levels Of Svm And Naïve Bayes Algorithm For Lifestyle Classification On Twitter Social Media, " Proceeding of International Conference on Digital Advance Tourism, Management and Technology, vol. 1, no. 1, 2023, doi: <https://doi.org/10.56910/ictmt.v1i1.65>.
- [12] A. Nurkholis, D. Alita, A. Munandar, "Comparison of Kernel Support Vector Machine Multi-Class in PPKM Sentiment Analysis on Twitter, " Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi), vol. 6, no. 2, 2022, doi: <https://doi.org/10.29207/resti.v6i2.3906>.
- [13] N. Garg dan K. Sharma, "Text Pre-Processing of Multilingual for Sentiment Analysis Based on Social Network Data," International Journal of Electrical and Computer Engineering, vol. 2, no.1, 2022, doi: <http://doi.org/10.11591/ijece.v12i1.pp776-784>.
- [14] M. Kunilovskaya dan A. Plum, "Text Preprocessing and its Implications in a Digital Humanities Project, " Proceedings of the Student Research Workshop associated with RANLP-2021, pages 85–93, 2021, doi: https://doi.org/10.26615/issn.2603-2821.2021_013.
- [15] A. Simanjuntak dkk, "Studi dan Analisis Hyperparameter Tuning IndoBERT dalam Pendeteksian Berita Palsu, " Jurnal Nasional Teknik Elektro dan Teknologi Informasi, vol. 13, no. 1, 2024, doi: 10.22146/jnteti.v13i1.8145.
- [16] B. Juarto dan Yulianto, "Indonesian News Classification Using IndoBert, " International Journal of Intelligent Systems and Applications in Engineering, vol. 11, no.2, 2023.
- [17] S.I. Jung, S.D. Ho, dan J. Kim, "Word Cloud Techniques for Data Analysis," Proceedings of the International Conference on Industrial Engineering and Operations Management, 2023, doi: <https://doi.org/10.46254/EV01.20230123>.