

ANALISIS KOMPARASI METODE SUPPORT VECTOR MACHINE (SVM) DAN LONG-SHORT TERM MEMORY (LSTM) BERBASIS GREY WOLF OPTIMIZER (GWO) UNTUK ANALISIS SENTIMEN KOPERASI DESA MERAH PUTIH

Eva Rodhiyatun Ningsih, Virgania Sari

Program Studi Matematika, Universitas Negeri Semarang
Sekaran, Gunungpati, Kota Semarang, Indonesia
evarodhiyatunningsih@gmail.com

ABSTRAK

Program Koperasi Desa Merah Putih merupakan kebijakan strategis pemerintah dalam memperkuat perekonomian desa yang memunculkan beragam opini publik di media sosial, khususnya YouTube. Banyaknya komentar masyarakat menghasilkan data teks yang besar sehingga diperlukan metode analisis sentimen yang mampu mengklasifikasikan opini secara akurat. Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja metode *Support Vector Machine* (SVM) dan *Long Short-Term Memory* (LSTM) yang dioptimasi menggunakan *Grey Wolf Optimizer* (GWO) dalam mengidentifikasi sentimen komentar YouTube terkait program tersebut. Dataset yang digunakan sebanyak 7.727 komentar yang diklasifikasikan ke dalam sentimen positif dan negatif. Tahapan penelitian meliputi *preprocessing*, *labelling*, *feature extraction* menggunakan TF-IDF dan *Word2Vec*, pembagian dataset, serta validasi model dengan *Stratified K-Fold Cross Validation* (5-fold). Optimasi parameter dilakukan menggunakan GWO untuk memperoleh kinerja model yang optimal. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa metode LSTM-GWO memberikan kinerja terbaik dengan *accuracy* 89,33%, *precision* 89,35%, *recall* 89,33%, dan *F1-score* 89,32%, sehingga metode ini dinilai lebih efektif dan stabil dalam merepresentasikan opini publik terhadap Program Koperasi Desa Merah Putih di platform YouTube.

Kata kunci : Analisis Sentimen, Support Vector Machine (SVM), Long Short-Term Memory (LSTM), Grey Wolf Optimizer (GWO), Koperasi Desa Merah Putih

1. PENDAHULUAN

Koperasi merupakan pilar penting dalam sistem perekonomian nasional Indonesia yang berlandaskan prinsip ekonomi kerakyatan sebagaimana diamanatkan dalam Pasal 33 Undang-Undang Dasar 1945 serta berperan dalam pemerataan kesejahteraan masyarakat. Sebagai upaya penguatan sektor koperasi, pemerintah meluncurkan program Koperasi Desa Merah Putih melalui Instruksi Presiden Nomor 9 Tahun 2025 dengan target pembentukan 80.000 koperasi desa di seluruh Indonesia guna memperkuat ekonomi pedesaan melalui prinsip gotong royong, partisipasi, dan inklusivitas yang didukung pendampingan, pelatihan, serta akses terhadap sumber daya dan teknologi. Sejak peluncurannya, program ini memunculkan beragam opini masyarakat di platform YouTube, baik berupa dukungan maupun kritik terkait implementasi, transparansi, tata kelola, dan keberlanjutan program. Banyaknya opini dalam bentuk data teks tidak terstruktur menjadikan analisis manual kurang efektif, sehingga diperlukan analisis sentimen untuk mengolah opini publik secara sistematis dan objektif dengan mengidentifikasi kecenderungan pandangan masyarakat terhadap program tersebut [1].

Berbagai penelitian sebelumnya telah menerapkan metode *machine learning* dan *deep learning* dalam analisis sentimen. *Support Vector Machine* (SVM) dan *Long Short-Term Memory* (LSTM) telah digunakan dalam berbagai studi dengan hasil kinerja yang kompetitif [2][3][4][5]. Tidak hanya

berfokus pada penggunaan model secara terpisah, sejumlah penelitian juga mengintegrasikan teknik optimasi, seperti *Grey Wolf Optimizer* (GWO), yang terbukti mampu meningkatkan kinerja model klasifikasi sentimen [6][7]. Kinerja model klasifikasi sangat dipengaruhi oleh konfigurasi parameter yang tepat. Ketidaktepatan dalam proses penentuan parameter dapat membatasi kemampuan model dalam menghasilkan performa optimal. Oleh karena itu, diperlukan metode optimasi yaitu GWO untuk meningkatkan kinerja model serta menjaga keseimbangan antara eksplorasi dan eksploitasi dalam proses pencarian solusi terbaik. Meskipun demikian, belum adanya penelitian yang secara khusus membandingkan kinerja SVM dan LSTM pada konteks opini publik terkait program Koperasi Desa Merah Putih di platform YouTube, khususnya dengan pendekatan optimasi parameter menggunakan GWO.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja metode SVM dan LSTM dalam menganalisis sentimen masyarakat di YouTube terhadap program Koperasi Desa Merah Putih, baik sebelum maupun sesudah dilakukan optimasi menggunakan *Grey Wolf Optimizer* (GWO), sehingga dapat diperoleh model yang paling efektif dalam konteks analisis sentimen kebijakan publik berbasis media sosial.

Untuk mencapai tujuan tersebut, penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan dataset komentar YouTube, *preprocessing* teks, *labelling*, *feature extraction*

menggunakan TF-IDF dan *Word2Vec*, pembagian dataset, serta penerapan metode klasifikasi SVM dan LSTM. Selanjutnya dilakukan optimasi parameter menggunakan *Grey Wolf Optimizer* (GWO) untuk meningkatkan performa model. Validasi model dilakukan menggunakan *Stratified K-Fold Cross Validation* (5-fold), sedangkan evaluasi kinerja model diukur menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

Melalui rangkaian tahapan tersebut, penelitian ini diharapkan mampu memberikan gambaran mengenai perbandingan kinerja metode SVM dan LSTM, baik sebelum maupun setelah optimasi menggunakan *Grey Wolf Optimizer* (GWO), dalam menganalisis sentimen publik terhadap Program Koperasi Desa Merah Putih di platform YouTube.

2. TINJAUAN PUSTAKA

2.1. Analisis Sentimen

Analisis sentimen adalah salah satu topik kajian dalam *text mining* yang berkembang pesat sejak tahun 2013. Metode ini bertujuan untuk secara otomatis mengekstrak dan mengolah data teks guna mendeteksi sentimen dalam sebuah pendapat terkait isu, kejadian, organisasi, produk, maupun layanan tertentu. Melalui analisis sentimen, informasi berharga dapat digali dari data teks tidak terstruktur, di mana opini-opini tersebut kemudian digolongkan menjadi sentimen positif atau negatif berdasarkan muatan emosionalnya [8]. Proses klasifikasi dalam analisis sentimen lebih kompleks dibandingkan klasifikasi biasa, sebab bahasa yang digunakan sering mengandung kata ambigu, tidak adanya intonasi dalam teks, serta dinamika perkembangan bahasa itu sendiri.

2.2. Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode *supervised learning* yang digunakan untuk tugas klasifikasi dan regresi. SVM bekerja dengan menentukan *hyperplane* optimal yang memaksimalkan margin antar kelas sehingga menghasilkan pemisahan data yang efektif [9]. Metode ini dikenal memiliki kemampuan generalisasi yang baik meskipun menggunakan jumlah data latih yang terbatas, namun pada dasarnya lebih efektif untuk data yang bersifat linear [10].

Tujuan utama SVM adalah memisahkan dua kelas dengan margin maksimum, yang diperoleh melalui proses optimasi dengan meminimalkan vektor bobot dan memenuhi batasan pemisahan kelas. Permasalahan optimasi tersebut diselesaikan menggunakan metode *Lagrange multiplier* untuk mendapatkan solusi optimal.

Pada kasus data yang tidak dapat dipisahkan secara linear, SVM menggunakan fungsi kernel untuk memetakan data ke ruang fitur berdimensi lebih tinggi agar dapat dipisahkan secara linear, suatu proses yang dikenal sebagai kernel *trick*. Fungsi kernel yang umum digunakan antara lain kernel *Linear*, *Polynomial*, *Radial Basis Function* (RBF), dan *Sigmoid* [11].

2.3. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *Recurrent Neural Network* (RNN) yang dikembangkan untuk mengatasi permasalahan *vanishing gradient* pada pemrosesan data sekuensial panjang [12]. Diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, LSTM dirancang untuk mempelajari ketergantungan jangka panjang sehingga banyak digunakan dalam tugas klasifikasi berbasis data temporal, seperti analisis sentimen, klasifikasi teks, dan analisis deret waktu [13].

Arsitektur LSTM terdiri dari lapisan input, lapisan tersembunyi, dan lapisan output. Lapisan tersembunyi memiliki sel memori yang dilengkapi tiga gerbang utama, yaitu *input gate*, *forget gate*, dan *output gate* [14]. *Input gate* mengontrol informasi yang disimpan ke dalam sel memori, *forget gate* menentukan informasi yang dipertahankan atau dihapus, sedangkan *output gate* mengatur informasi yang digunakan untuk menghasilkan keluaran akhir. Mekanisme ketiga gerbang tersebut memungkinkan LSTM mengelola aliran informasi secara efektif dan mempertahankan konteks penting dalam data sekuensial.

2.4. Grey Wolf Optimizer (GWO)

Grey Wolf Optimizer (GWO) merupakan metode optimasi *metaheuristic* yang terinspirasi dari perilaku sosial dan strategi perburuan serigala abu-abu, yang diperkenalkan oleh Mirjalili et al. pada tahun 2014 sebagai algoritma optimasi global [15]. GWO meniru struktur hierarki kepemimpinan dalam kawanan serigala yang terdiri atas empat tingkatan, yaitu alpha, beta, delta, dan omega.

Dalam mekanisme optimasi, serigala alpha, beta, dan delta merepresentasikan tiga solusi terbaik yang diperkirakan memiliki posisi mangsa paling optimal, sedangkan serigala omega bertindak sebagai agen pencari lainnya yang memperbarui posisinya berdasarkan ketiga solusi tersebut. Pendekatan ini memungkinkan GWO menyeimbangkan eksplorasi dan eksploitasi secara efektif, sehingga memiliki keunggulan dalam konvergensi yang cepat, kemudahan implementasi, serta kemampuan menangani ruang pencarian berdimensi tinggi [16][17].

2.5. Penelitian Terdahulu


Beberapa penelitian terdahulu telah memanfaatkan metode *machine learning* dan *deep learning* dalam berbagai konteks analisis sentimen. SVM telah digunakan untuk menganalisis tingkat kepuasan pengguna Sirekap dari Google Play Store, di mana SVM menghasilkan akurasi 92.30% dan mengungguli LSTM yang memperoleh akurasi 90.85% [2]. Selain itu, SVM juga digunakan dalam analisis sentimen komentar lagu di YouTube dan menghasilkan akurasi sebesar 84.09%, yang lebih unggul dibandingkan Naïve Bayes dan LSTM [3].

Di sisi lain, LSTM juga banyak dimanfaatkan dalam penelitian analisis sentimen. LSTM telah diterapkan untuk menganalisis sentimen pengguna Twitter terhadap perkembangan AI dan menghasilkan akurasi sebesar 74.25% [4]. Dalam penelitian komparatif yang membandingkan SVM, *Logistic Regression*, dan LSTM pada data *tweet* dari Twitter, LSTM terbukti menghasilkan kinerja lebih unggul dengan akurasi 90%, dibandingkan SVM sebesar 85% dan *Logistic Regression* sebesar 83% [5].

Selain penggunaan metode tunggal, beberapa penelitian juga telah menerapkan teknik optimasi untuk meningkatkan performa model. Penelitian oleh Mahmood dan Qasim, menunjukkan bahwa penerapan GWO terhadap metode SVM mampu meningkatkan akurasi dari 87.885% menjadi 91.053%, yang menjadikan GWO sebagai metode paling akurat dibandingkan optimizer PSO dan MPSO [6]. Sejalan dengan hal tersebut, penelitian oleh Jain dkk, menerapkan GWO pada metode LSTM untuk analisis sentimen multibahasa dan menghasilkan peningkatan akurasi dari 93.8% menjadi 95.98% setelah optimasi [7]. Hasil dari kedua penelitian tersebut menunjukkan bahwa GWO memiliki potensi yang signifikan dalam meningkatkan performa model klasifikasi sentimen.

3. METODE PENELITIAN

Pendekatan kuantitatif digunakan dalam penelitian ini untuk membandingkan kinerja dua metode, yaitu *Support Vector Machine* (SVM) dan *Long Short-Term Memory* (LSTM), yang keduanya dioptimalkan dengan *Grey Wolf Optimizer* (GWO) untuk menganalisis sentimen publik terkait program Koperasi Desa Merah Putih di YouTube. Rangkaian tahapan penelitian disusun secara terstruktur, mencakup proses pengumpulan data sampai dengan evaluasi model. Berikut skema alur kerja tahapan penelitian ini.



Gambar 1. Alur penelitian

3.1. Pengumpulan Data

Data dalam penelitian ini diperoleh dari komentar di platform Youtube terkait Koperasi Desa Merah Putih, yang dikumpulkan melalui teknik *web scrapping* menggunakan YouTube Data API v3 bersama *Google Colab*. Kemudian, data yang diperoleh diunduh dalam format .csv agar dapat diolah sesuai kebutuhan penelitian.

3.2. Preprocessing Data

Proses *preprocessing* dilakukan untuk membersihkan dan menyiapkan teks agar siap dianalisis. Tahapan yang dilakukan meliputi *case folding*, yaitu mengubah seluruh huruf menjadi huruf kecil; *cleaning*, yaitu menghapus berbagai elemen yang tidak relevan seperti, *tab*, *newline*, *carriage return*, *backslash*, URL, *mention*, *hashtag*, karakter non-ASCII atau *unicode*, serta tanda baca dan simbol tertentu; *normalization*, yaitu mengubah kata tidak baku atau singkatan menjadi bentuk baku; *tokenizing*, yaitu memecah teks menjadi unit kata (token); *stopwords removal*, yaitu menghapus kata umum yang tidak memiliki makna signifikan; dan *stemming*, yaitu mengubah kata ke bentuk dasarnya dengan menghilangkan imbuhan [18].

3.3. Labelling

Penelitian ini menerapkan pendekatan *lexicon-based* untuk melakukan *labelling* atau pelabelan, yaitu menggunakan kamus kata yang telah diberi pembobotan sentimen positif dan negatif [19]. Berdasarkan skor polaritas yang dihasilkan, setiap komentar diklasifikasikan ke dalam dua kategori, yaitu sentimen positif dan negatif. Hasil pelabelan ini selanjutnya digunakan sebagai data berlabel pada proses *supervised learning*, di mana konsistensi dan akurasi pelabelan sangat penting untuk menjamin kualitas dan performa model klasifikasi sentimen yang dibangun.

3.4. Feature Extraction

Tahap *feature extraction* merupakan proses identifikasi *term* atau atribut penting dalam data teks yang bertujuan untuk merepresentasikan dokumen dalam bentuk numerik agar dapat diproses oleh model klasifikasi. Dalam penelitian ini, digunakan dua pendekatan berbeda untuk merepresentasikan data teks dalam bentuk numerik, yaitu TF-IDF dan *Word2Vec*.

TF-IDF adalah metode pembobotan *term* yang berfungsi untuk merepresentasikan teks dalam format numerik dengan memberikan bobot pada setiap kata sesuai dengan tingkat kepentingannya dalam suatu dokumen [20]. TF-IDF dihitung dengan mengalikan nilai *Term Frequency* (TF), yang mengukur frekuensi kemunculan *term* dalam suatu dokumen, dengan nilai *Inverse Document Frequency* (IDF), yang mengukur tingkat kepentingan *term* berdasarkan distribusinya di seluruh dokumen.

Word2Vec adalah salah satu metode *word embedding* yang mengubah kata-kata dalam teks

menjadi vektor numerik berdasarkan hubungan semantik dan konteks kemunculannya [21]. Terdapat dua arsitektur utama dalam *Word2Vec*, yaitu *Continuous Bag of Words* (CBOW) yang memprediksi kata target dengan memanfaatkan kata-kata konteks, dan *Skip-gram* yang memprediksi kata-kata konteks dengan memanfaatkan kata target. Pada penelitian ini *Word2Vec* diterapkan dengan arsitektur *Skip-gram*.

3.5. Pembagian Data

Dataset komentar tentang Koperasi Desa Merah Putih yang telah diolah kemudian dibagi menjadi dua bagian, yaitu data *training* dan data *testing* dengan menerapkan metode *Stratified K-Fold Cross Validation*. Metode ini membagi dataset menjadi lima bagian (5-fold) dengan proporsi kelas sentimen yang seimbang pada setiap *fold*, yaitu 80% data *training* dan 20% data *testing*.

3.6. Evaluasi Model

Proses evaluasi dilakukan untuk mengukur performa model klasifikasi sentimen terhadap Koperasi Desa Merah Putih. Untuk memastikan hasil evaluasi yang lebih reliabel dan mengurangi risiko *overfitting*, penelitian ini menerapkan *5-fold cross validation*, di mana pada proses evaluasi setiap *fold* secara bergantian digunakan sebagai data *testing* sementara empat *fold* lainnya digunakan sebagai data *training*. Proses evaluasi pada setiap *fold* dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang perhitungannya didasarkan pada *confusion matrix*, dan selanjutnya hasil dari kelima *fold* dirata-ratakan untuk memperoleh representasi kinerja model secara menyeluruh.

Confusion matrix, yaitu sebuah tabel yang menunjukkan jumlah data uji yang diprediksi benar dan salah oleh model klasifikasi pada masing-masing kelas, seperti yang terlihat pada Tabel 1.

Tabel 1. *Confusion Matrix*

Prediksi	Aktual	
	Positive	Negative
Positive	True Positive (TP)	False Positive (FP)
Negative	False Negative (FN)	True Negative (TN)

Formula perhitungan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* ditunjukkan pada Tabel 2.

Tabel 2. Formula perhitungan *Accuracy*, *Precision*, *Recall*, dan *F1-score*

Metriik	Formula	
<i>Accuracy</i>	$\frac{TP + TN}{TP + TN + FP + FN}$	
<i>Precision</i>	<i>Positive</i>	<i>Negative</i>
	$\frac{TP}{TP + FP}$	$\frac{TN}{TN + FN}$
<i>Recall</i>	<i>Positive</i>	<i>Negative</i>
	$\frac{TP}{TP + FN}$	$\frac{TN}{TN + FP}$
<i>F1-Score</i>	<i>Positive</i>	<i>Negative</i>
	$\frac{2 \times \text{Precision kelas } i \times \text{Recall kelas } i}{\text{Precision kelas } i + \text{Recall kelas } i}$	

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Dataset

Dataset pada penelitian ini berupa komentar publik dari platform YouTube yang diperoleh melalui proses *web scraping* menggunakan YouTube Data API v3 dengan bantuan *Google Colab*. Pengambilan data dilakukan dengan memanfaatkan API Key dari *Google Cloud* platform yang diintegrasikan ke dalam skrip *Python* untuk mengakses komentar pada berbagai video YouTube dari kanal tvOne, Metro TV, dan Kompas TV dengan kata kunci “Koperasi Desa Merah Putih”. Dataset yang diperoleh sebanyak 7.844 komentar yang dikumpulkan pada rentang waktu 3 Maret hingga 15 Oktober 2025. Seluruh data hasil *scraping* kemudian digabungkan ke dalam satu *DataFrame* dan disimpan dalam format *.csv* untuk memudahkan proses analisis selanjutnya. Gambar 2 menunjukkan sebagian hasil pengumpulan data yang dilakukan melalui *web scraping*.

	video_id	video_title	publishdate	authorDisplayName	textDisplay	likecount
0	VseVnE9tE	Presiden Prabowo Bakal Bikin 70.000 Koperasi M.	2025-03-07T17:53:17Z	@randadipati64	Matang	6
1	VseVnE9tE	Presiden Prabowo Bakal Bikin 70.000 Koperasi M.	2025-03-07T17:55:58Z	@berjantungmuda7	mending bikin bapak mudi atau t	1
2	VseVnE9tE	Presiden Prabowo Bakal Bikin 70.000 Koperasi M.	2025-03-07T17:36:14Z	@AggagCanevce1nfq	Fx xh 8C--8C--8C--8C7C4C2C7C gik ada bawanya	0
3	VseVnE9tE	Presiden Prabowo Bakal Bikin 70.000 Koperasi M.	2025-03-07T17:59:08Z	@un_gel62	Membuat lagi	1
4	VseVnE9tE	Presiden Prabowo Bakal Bikin 70.000 Koperasi M.	2025-03-07T17:59:12Z	@ahmadSenaD3C	Ga usah nyabun sendiri 8C7C--8C--8C7C4C2C--8C--	0
7629	BQcYJFsuKl	[FULL] Basas Konsep-Tarpet Koperasi Desa Merah.	2025-10-14T16:21:50Z	@rustamumini153	Saya tahu apa yang mau bebodis dikeper..	0
7640	5mXcmH7BMA	Program Koperasi Desa Merah Putih &One	2025-10-15T01:27:42Z	@crowd49968	o kmpet saya malah bisa bangun prangk..	0
7641	5mXcmH7BMA	Program Koperasi Desa Merah Putih &One	2025-10-15T01:27:42Z	@crowd49968	di @@deandend737 lah kalau anggap malah bu	0
7642	UfW-ZZZOU	Begini Jalannya Koperasi Merah Putih yang Muka.	2025-10-15T01:26:29Z	@crowd49968	Lah kok kayak jodog? test bisek kuhal don?	0
7643	G6du6wLr8G	Apa Itu Koperasi Merah Putih dan Bagaimana Cara.	2025-10-15T02:21:04Z	@hasmadia36952	Wacana dengan pemerintah pusat mau mendirikan k	0

Gambar 2. Hasil *Scrapping* Data

4.2. Hasil Preprocessing data

Setelah dilakukan *preprocessing data*, jumlah data komentar yang layak dan siap digunakan menjadi 7727 data komentar. Tahap *preprocessing data* meliputi *case folding*, *cleaning*, *normalization*, *tokenization*, *stopwords removal*, dan *stemming*.

Tabel 3. Contoh data komentar yang sudah dibersihkan

Sebelum <i>preprocessing</i>	Setelah <i>preprocessing</i>
Koperasi sdh banyak yg gulung tikar, akibat oknum pengurus korupsi, ini mau bikin yg baru, Siap-siap aja	koperasi banyak gulung tikar akibat oknum urus korupsi ingin bikin baru siap siap
Sejak dulu koperasi unit desa jg ada tp (tau sendiri wkwk) ??? Sejak dulu koperasi unit desa tahu sendiri wkwk program ajang ladang korupsi ayo sadar masyarakat indonesia	sejak dulu koperasi unit desa tahu sendiri wkwk program ajang ladang korupsi ayo sadar masyarakat indonesia
Mantap pak Mentri mudah-mudahan bisa berjalan dan sukses KDMP	mantap pak menteri mudah mudah jalan sukses koperasi desa merah putih

4.3. Hasil Labelling

Pada tahap ini dilakukan proses *labelling* atau pelabelan sentimen terhadap dataset yang telah melalui tahap *preprocessing*. Pelabelan dilakukan secara otomatis menggunakan kamus *Lexicon* berbahasa Indonesia yang terdiri dari daftar kata positif dan negatif beserta nilai polaritasnya sebagai acuan penentuan sentimen setiap dokumen. Hasil pelabelan menghasilkan dua kelas sentimen, yaitu positif dan negatif. Tabel 4 menunjukkan jumlah data pada masing-masing kelas sentimen.

Tabel 4. Hasil *labelling*

Kelas Sentimen	Jumlah
Positif	3641
Negatif	4086

4.4. Hasil Feature Extraction

Setelah dataset dilabeli selanjutnya dilakukan ekstraksi fitur dengan dua pendekatan yaitu, TF-IDF dan *Word2Vec* untuk merepresentasikan teks dalam bentuk numerik agar dapat diproses oleh model klasifikasi.

4.5. TF-IDF

Metode ini mengonversi data teks menjadi representasi numerik berdasarkan frekuensi kemunculan kata dan tingkat keunikannya dalam korpus. Proses ekstraksi fitur dilakukan menggunakan *Python* pada *Google Colab*. Tabel 5 dan Tabel 6 menampilkan hasil analisis sepuluh kata dengan bobot TF-IDF tertinggi dan terendah.

Tabel 5. Kata dengan Bobot TF-IDF Tertinggi

Kata	TF-IDF	Kata	TF-IDF
wkwkwk	0.574613	menteri judi	0.519308
nyala	0.561135	projo	0.519173
sia	0.556812	oposisi	0.513304
ruwet	0.540679	omon	0.506771
abal	0.520756	istimewa	0.504828

Tabel 6. Kata dengan Bobot TF-IDF Terendah

Kata	TF-IDF	Kata	TF-IDF
banyak	0.197287	saran	0.177005
usaha	0.192288	merah	0.176773
desa	0.191791	merah putih	0.174591
putih	0.177904	hak	0.173640
jadi	0.177342	koperasi	0.170031

4.6. Word2Vec

Word2Vec dalam prosesnya dilakukan dengan arsitektur *Skip-Gram* untuk menghasilkan representasi vektor kata berdimensi 300 yang mampu menangkap hubungan semantik antar kata dalam komentar publik terkait program Koperasi Desa Merah Putih. Hasil pelatihan menghasilkan kosakata dengan ribuan kata yang dipetakan ke dalam ruang vektor semantik. Pengujian kemiripan kata menunjukkan bahwa kata-kata yang berkaitan dengan konteks sosial dan kebijakan publik memiliki tingkat kedekatan makna yang tinggi, sebagaimana ditunjukkan pada hasil

similarity kata pada Tabel 7 dengan mengambil contoh kata “rakyat”. Hasil ini menunjukkan bahwa *Word2Vec* efektif dalam merepresentasikan makna semantik data teks dalam analisis sentimen.

Tabel 7 *Similarity* kata rakyat

Kata	Similarity	Kata	Similarity
masyarakat	0.5809	asbun	0.5432
lebay	0.5636	senayan	0.5418
mengatasnamakan	0.5577	topeng	0.5410
slogan	0.5558	wkwkwk	0.5332
revisi	0.5453	sengsara	0.5317

4.7. Hasil Pembagian Dataset

Dataset yang sudah dikonversi ke bentuk numerik, kemudian dibagi dengan menerapkan *stratified 5-fold cross validation*. Pada setiap *fold* dihasilkan pembagian data *training* dan data *testing* yang bervariasi, namun tetap mempertahankan keseimbangan proporsi kelas pada masing-masing *fold*. Data *training* dan data *testing* memiliki proporsi 80% banding 20% dengan jumlah yang relatif sama. Hasil pembagian dataset ditunjukkan pada Tabel 8.

Tabel 8. Jumlah data *training* dan data *testing*

Data	Jumlah data pada <i>fold</i> ke-				
	1	2	3	4	5
Data <i>training</i>	6175	6175	6175	6175	6176
Data <i>testing</i>	1544	1544	1544	1544	1543

4.8. Klasifikasi Metode

Pada tahap ini, dataset yang telah direpresentasikan dalam bentuk numerik dan dibagi menjadi data *training* dan *testing* digunakan untuk melatih model SVM dan LSTM, baik sebelum maupun sesudah dioptimasi menggunakan *Grey Wolf Optimizer* (GWO). Evaluasi kinerja model dilakukan pada data *testing* untuk membandingkan kinerja masing-masing metode.

Model SVM dilatih menggunakan empat kernel, yaitu *Linear* ($C = 1$), *RBF*, *Polynomial* (derajat 3), dan *Sigmoid*. Selanjutnya, optimasi parameter SVM dilakukan menggunakan GWO dengan 10 serigala dan 20 iterasi. Nilai *fitness* dihitung berdasarkan *weighted F1-score* pada data validasi. Tiga solusi terbaik ditetapkan sebagai α , β , dan δ untuk memperbarui posisi serigala lainnya hingga diperoleh parameter optimal. Parameter hasil optimasi kemudian digunakan untuk melatih kembali model SVM pada setiap *fold*.

Model LSTM dibangun dengan arsitektur yang terdiri dari *embedding layer*, dua lapisan LSTM (64 dan 32 unit), serta *output layer* beraktivasi *sigmoid* untuk klasifikasi biner. Untuk mengurangi *overfitting*, diterapkan *dropout* dan mekanisme *early stopping*, dengan optimizer Adam (*learning rate* 0.0003). Optimasi parameter LSTM menggunakan GWO difokuskan pada *learning rate*, jumlah unit LSTM, *dropout*, dan regularisasi L2. Proses optimasi dilakukan dengan 12 serigala selama 10 iterasi, di mana setiap solusi dievaluasi berdasarkan fungsi

fitness yang mempertimbangkan kinerja model dan potensi *overfitting*. Parameter terbaik hasil optimasi kemudian digunakan untuk melatih model LSTM pada setiap *fold* sebelum dilakukan evaluasi akhir.

4.9. Evaluasi Model

Model yang telah dilatih kemudian di evaluasi menggunakan data *testing* pada setiap *fold* yang terdiri dari 5-*fold*. Evaluasi dilakukan berdasarkan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* pada seluruh *fold*. Hasil evaluasi dari 5-*fold* kemudian dirangkum dalam sebuah tabel dan dihitung nilai rata-ratanya.

4.10. Support Vector-Machine (SVM)

Hasil evaluasi menggunakan metode SVM dengan 5-*fold* dihitung rata-rata keseluruhannya pada setiap kernel menghasilkan nilai metrik evaluasi yang ditunjukkan pada Tabel 9.

Tabel 9. Hasil evaluasi setiap kernel SVM

Kernel	Rata-rata			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Linear</i> ($C = 1$)	0.8651	0.8666	0.8651	0.8652
RBF	0.8471	0.8479	0.8471	0.8471
<i>Polynomial</i>	0.7809	0.7832	0.7809	0.7810
<i>Sigmoid</i>	0.8580	0.8599	0.8580	0.8581

Berdasarkan Tabel 9 SVM kernel *Linear* dengan parameter $C = 1$ memberikan kinerja terbaik untuk metode SVM dengan *accuracy* 86.51%, *precision* 86.66%, *recall* 86.51%, dan *F1-score* 86.52%.

4.11. SVM-GWO

Pada pengujian sebelumnya dihasilkan bahwa SVM dengan kernel *Linear* ($C = 1$) menunjukkan kinerja paling optimal, sehingga evaluasi pada metode SVM-GWO dilakukan pada SVM kernel *Linear*. Hasil parameter C terbaik dari optimasi GWO digunakan untuk melatih model SVM kernel *Linear* dan di evaluasi pada 5-*fold* kemudian dirangkum dalam sebuah tabel dan dihitung nilai rata-ratanya sebagai representasi kinerja keseluruhan SVM-GWO kernel *Linear*. Hasil evaluasi SVM-GWO ditunjukkan pada Tabel 10.

Tabel 10. Hasil evaluasi SVM-GWO

Fold	Best C	Rata-rata			
		<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	37.5	0.8651	0.8666	0.8651	0.8652
2	5.5	0.8471	0.8479	0.8471	0.8471
3	11.9	0.7809	0.7832	0.7809	0.7810
4	6.8	0.8580	0.8599	0.8580	0.8581
5	7.7	0.8658	0.8672	0.8658	0.8660
Rata-rata	13.9	0.8737	0.8746	0.8737	0.8738

Berdasarkan hasil pada Tabel 10, terlihat bahwa nilai parameter C bervariasi pada setiap *fold*, menunjukkan bahwa proses validasi silang menghasilkan konfigurasi parameter yang berbeda-beda sesuai dengan karakteristik data latih pada masing-masing *fold*. Secara keseluruhan, hasil evaluasi SVM dengan optimasi GWO mengalami peningkatan kinerja dengan rata-rata *accuracy* 87.37%, *precision* 87.46%, *recall* 87.37%, dan *F1-score* 87.38%.


4.12. Long Short-Term Memory (LSTM)

Evaluasi kinerja LSTM dilakukan pada 5-*fold* sehingga diperoleh nilai performa yang berbeda untuk masing-masing metrik evaluasi. Hasil evaluasi dari 5-*fold* kemudian dirangkum dalam sebuah tabel dan dihitung nilai rata-ratanya sebagai representasi kinerja keseluruhan metode LSTM. Hasil evaluasi LSTM ditunjukkan pada Tabel 11.

Tabel 11. Hasil evaluasi LSTM

Fold	LSTM			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.8957	0.8960	0.8957	0.8956
2	0.8627	0.8631	0.8627	0.8628
3	0.8886	0.8892	0.8886	0.8887
4	0.8892	0.8892	0.8892	0.8892
5	0.8684	0.8691	0.8684	0.8685
Rata-rata	0.8809	0.8813	0.8809	0.8810

Berdasarkan Tabel 11, model LSTM menunjukkan kinerja yang konsisten pada setiap *fold* dengan nilai rata-rata *accuracy* 88.09%, *precision* 88.13%, *recall* 88.09%, dan *F1-score* 88.10%, yang mengindikasikan kemampuan klasifikasi sentimen yang baik dan stabil. Hasil ini sejalan dengan grafik *accuracy* dan *loss* pada Gambar 3, di mana model mengalami konvergensi yang optimal selama proses pelatihan. Peningkatan akurasi yang stabil dan penurunan *loss* yang terkendali menunjukkan bahwa model mampu mempelajari pola data secara efektif tanpa indikasi *overfitting* yang signifikan.



Gambar 3. Grafik *accuracy-loss* LSTM


4.13. LSTM-GWO

Evaluasi metode LSTM-GWO dilakukan untuk mengetahui peningkatan kinerja model LSTM setelah proses optimasi parameter menggunakan GWO. Evaluasi dilakukan pada 5-*fold* kemudian dirangkum dalam sebuah tabel dan dihitung nilai rata-ratanya sebagai representasi kinerja keseluruhan LSTM-GWO. Hasil evaluasi LSTM-GWO ditunjukkan pada Tabel 12.

Tabel 12. Hasil evaluasi LSTM-GWO

Fold	LSTM-GWO			
	Accuracy	Precision	Recall	F1-Score
1	0.9119	0.9124	0.9119	0.9118
2	0.8769	0.8769	0.8769	0.8769
3	0.8931	0.8937	0.8931	0.8932
4	0.8944	0.8947	0.8944	0.8943
5	0.8898	0.8898	0.8898	0.8898
Rata-rata	0.8933	0.8935	0.8933	0.8932

Berdasarkan Tabel 12, metode LSTM-GWO menunjukkan kinerja yang konsisten pada seluruh fold dengan nilai rata-rata *accuracy* 89.33%, *precision* 89.35%, *recall* 89.33%, dan *F1-score* 89.32%, yang menandakan peningkatan kinerja setelah dilakukan optimasi parameter menggunakan GWO. Hasil ini sejalan dengan grafik *accuracy* dan *loss* pada Gambar 4, di mana model mengalami konvergensi yang baik selama proses pelatihan. Stabilitasnya akurasi validasi serta selisih *loss* yang masih dalam batas wajar menunjukkan bahwa model mampu melakukan pembelajaran secara efektif tanpa indikasi *overfitting* yang signifikan.

Gambar 4. Grafik *accuracy-loss* LSTM-GWO

4.14. Perbandingan Hasil Evaluasi

Berdasarkan evaluasi yang telah dilakukan, dihasilkan bahwa setiap metode memiliki tingkat kinerja yang berbeda. Metode SVM memberikan performa yang cukup baik, namun mengalami peningkatan setelah dilakukan optimasi parameter menggunakan GWO pada metode SVM-GWO. Hal serupa juga terjadi pada LSTM, di mana penerapan GWO pada LSTM-GWO mampu meningkatkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* secara konsisten. Secara keseluruhan, metode LSTM-GWO menghasilkan kinerja terbaik, yang menunjukkan bahwa kombinasi *deep learning* dengan optimasi parameter mampu memberikan hasil klasifikasi sentimen yang lebih optimal dan stabil.

Tabel 13. Perbandingan Hasil Evaluasi

Metode	Accuracy	Precision	Recall	F1-Score
SVM Kernel Linear	0.8651	0.8666	0.8651	0.8652
SVM- GWO	0.8737	0.8746	0.8737	0.8738
LSTM	0.8809	0.8813	0.8809	0.8810
LSTM- GWO	0.8933	0.8935	0.8933	0.8932

5. KESIMPULAN DAN SARAN

Penelitian ini menganalisis sentimen masyarakat terhadap Program Koperasi Desa Merah Putih menggunakan metode *Support Vector Machine* (SVM) dan *Long Short-Term Memory* (LSTM), serta menerapkan *Grey Wolf Optimizer* (GWO) untuk optimasi parameter. Hasil evaluasi sebelum optimasi GWO menunjukkan bahwa LSTM menghasilkan kinerja yang lebih baik dibandingkan SVM pada seluruh metrik evaluasi. Setelah diterapkan GWO pada kedua metode terbukti mampu meningkatkan performa model secara konsisten. Dengan demikian, secara keseluruhan hasil evaluasi menunjukkan bahwa LSTM-GWO lebih unggul dibandingkan SVM, SVM-GWO, serta LSTM dengan *accuracy* 89.33%, *precision* 89.35%, *recall* 89.33%, dan *F1-score* 89.32%. Temuan ini menunjukkan bahwa kombinasi *deep learning* dan teknik optimasi parameter efektif dalam meningkatkan kualitas analisis sentimen berbasis data media sosial berbahasa Indonesia. Penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan beragam, menerapkan pelabelan manual atau semi-manual, serta membandingkan GWO dengan teknik optimasi lainnya atau model *deep learning* yang lebih kompleks guna memperoleh hasil yang lebih optimal.

DAFTAR PUSTAKA

- [1] R. N. Muhammad, L. Wulandari S, and B. Tanggahma, "Pengaruh Media Sosial Pada Persepsi Publik Terhadap Sistem Peradilan: Analisis Sentimen di Twitter," vol. 7, no. 1, 2024, doi: 10.31933/unesrev.v7i1.
- [2] E. Cahyono and S. Kacung, "ANALISIS TINGKAT KEPUASAN PENGGUNA SIREKAP MENGGUNAKAN METODE SUPPORT VECTOR MACHINE DAN LONG SHORT TREM MEMORY," vol. 7, no. 2, 2025.
- [3] E. L. Utari and S. H. Wibowo, "ANALISIS KOMPARATIF ALGORITMA SVM NAIVE BAYES DAN LSTM PADA SENTIMEN KOMENTAR LAGU LABOUR," *Jurnal Informatika Teknologi dan Sains*, vol. 7, no. 3, 2025.
- [4] A. Azrul, A. I. Purnamasari, and I. Ali, "ANALISIS SENTIMEN PENGGUNA TWITTER TERHADAP PERKEMBANGAN ARTIFICIAL INTELLIGENCE DENGAN PENERAPAN ALGORITMA LONG SHORT-TERM MEMORY (LSTM)," 2024.
- [5] S. A. Oladipupo, S. O. Olabiyisi, W. O. Ismaila, A. O. Oyedele, and O. J. Toyobo, "Comparative Performance Analysis of Selected Machine Learning Techniques for Social Media Sentiment Analysis," *INTERNATIONAL JOURNAL OF RESEARCH AND INNOVATION IN APPLIED SCIENCE (IJRIAS)*, vol. 10, pp. 601–607, May 2025, doi: 10.51584/IJRIAS.
- [6] S. A. Mahmood and Q. Q. Qasim, "Big Data Sentimental Analysis Using Document to Vector

- and Optimized Support Vector Machine,” *UHD Journal of Science and Technology*, vol. 4, no. 1, pp. 18–28, Feb. 2020, doi: 10.21928/uhdjst.v4n1y2020.pp18-28.
- [7] V. Jain, L. Malviya, and A. .S, “Optimized hybrid deep learning for cross-linguistic sentiment analysis: a novel approach,” *Journal of Cloud Computing*, vol. 14, no. 1, Dec. 2025, doi: 10.1186/s13677-025-00753-w.
- [8] R. N. Ikhsani and F. F. Abdulloh, “Optimasi SVM dan Decision Tree Menggunakan SMOTE Untuk Mengklasifikasi Sentimen Masyarakat Mengenai Pinjaman Online,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 4, p. 1667, Oct. 2023, doi: 10.30865/mib.v7i4.6809.
- [9] H. C. Husada and A. S. Paramita, “Analisis Sentimen Pada Maskapai Penerbangan di Platform Twitter Menggunakan Algoritma Support Vector Machine (SVM),” *Teknika*, vol. 10, no. 1, pp. 18–26, Feb. 2021, doi: 10.34148/teknika.v10i1.311.
- [10] T. Meisya, P. Aulia, N. Arifin, and R. Mayasari, “PERBANDINGAN KERNEL SUPPORT VECTOR MACHINE (SVM) DALAM PENERAPAN ANALISIS SENTIMEN VAKSINISASI COVID-19,” 2021, [Online]. Available: <https://doi.org/10.31598>
- [11] N. Arifin, U. Enri, and N. Sulistiyowati, “PENERAPAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) DENGAN TF-IDF N-GRAM UNTUK TEXT CLASSIFICATION,” *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 6(2), 2021.
- [12] T. B. Sianturi, I. Cholissodin, and N. Yudistira, “Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum,” 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [13] D. I. Puteri, “Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah,” *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [14] A. Saikhu, C. V. Hudiyanti, and A. Y. Wijaya, “Input Feature Selection in ECG Signal Data Modelling using Long Short Term Memory,” in *2021 4th International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 229–234. doi: 10.1109/ISRITI54043.2021.9702810.
- [15] S. Mirjalili, S. M. Mirjalili, and A. Lewis, “Grey Wolf Optimizer,” *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [16] Q. Al-Tashi, S. J. Abdul Kadir, H. M. Rais, S. Mirjalili, and H. Alhussian, “Binary Optimization Using Hybrid Grey Wolf Optimization for Feature Selection,” *IEEE Access*, vol. 7, pp. 39496–39508, 2019, doi: 10.1109/ACCESS.2019.2906757.
- [17] S. N. Makhadmeh *et al.*, “Recent Advances in Grey Wolf Optimizer, its Versions and Applications: Review,” *IEEE Access*, vol. 12, pp. 22991–23028, 2024, doi: 10.1109/ACCESS.2023.3304889.
- [18] T. Ridwansyah, “Implementasi Text Mining Terhadap Analisis Sentimen Masyarakat Dunia Di Twitter Terhadap Kota Medan Menggunakan K-Fold Cross Validation Dan Naïve Bayes Classifier,” *Media Online*, vol. 2, no. 5, pp. 178–185, 2022, [Online]. Available: <https://djournals.com/klik>
- [19] N. Y. Prasetya and D. Winarso, “Penerapan Lexicon Based Untuk Analisis Sentimen Pada Twiter Terhadap Isu Covid-19,” *JURNAL FASILKOM*, vol. 11, no. 2, pp. 97–103, Aug. 2021.
- [20] R. Aryanti, T. Misriati, and A. Sagiyanto, “Analisis Sentimen Aplikasi Primaku Menggunakan Algoritma Random Forest dan SMOTE untuk Mengatasi Ketidakseimbangan Data,” *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 1, pp. 218–227, Nov. 2023, doi: 10.47065/josyc.v5i1.4562.
- [21] M. D. Rahman, A. Djunaidy, and F. Mahananto, “Penerapan Weighted Word Embedding pada Pengklasifikasian Teks Berbasis Recurrent Neural Network untuk Layanan Pengaduan Perusahaan Transportasi,” 2021