

Analisis Sentimen Terhadap Kenaikan Harga Bahan Bakar Minyak Menggunakan Long Short-Term Memory

Muhammad Ikhsan¹ dan Sri Ngudi Wahyuni²

^{1,2)} *Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta
Jl. Padjajaran, Ring Road Utara, Kel. Condongcatur, Kec. Depok, Kab. Sleman, Prop. Daerah Istimewa
Yogyakarta 55283*

Author Emails

¹⁾ Corresponding author: muhammad.1904@students.amikom.ac.id

Abstract. *In 2022 there will be an increase in world fuel prices. The increase in the price of fuel oil will indirectly affect material prices, inflation and the cost of living. The increase in the price of fuel oil became controversial, leading to demonstrations in various regions. This fuel price hike policy received various responses from Twitter users. This study aims to determine the accuracy of the predictions and sentiment patterns of the LSTM (Long Short-Term Memory) model from the opinions of Twitter users on the topic of rising fuel prices in July 2022. The data used is English data with two sentiment classes, negative and positive. The LSTM model was tested five times. The results of this study indicate that the highest accuracy is found in the 1st and 3rd trials, namely 90% and sentiment patterns tend to be positive.*

Keywords: *Fuel Prices, Twitter, Long Short-Term Memory*

Abstraksi. Pada tahun 2022 terjadi kenaikan harga bahan bakar minyak dunia. Dengan naiknya harga bahan bakar minyak ini secara tidak langsung akan berpengaruh terhadap harga material, inflasi, dan biaya hidup. Kenaikan harga bahan bakar minyak menjadi kontroversi hingga terjadi demo di berbagai wilayah. Kebijakan dinaikan harga bahan bakar minyak ini mendapat berbagai respons dari pengguna Twitter. Penelitian ini bertujuan untuk mengetahui akurasi prediksi dan pola sentimen model LSTM (*Long Short-Term Memory*) dari opini pengguna Twitter terhadap topik kenaikan harga bahan bakar minyak pada bulan Juli 2022. Data yang digunakan adalah data berbahasa *English* dengan dua kelas sentimen yaitu *negative* dan *positive*. Model LSTM dilakukan percobaan sebanyak lima kali. Hasil penelitian ini menunjukkan bahwa akurasi tertinggi terdapat pada percobaan ke-1 dan ke-3 yaitu 90% dan pola sentimen cenderung positif.

Kata Kunci : Harga Bahan Bakar Minyak, Twitter, Long Short-Term Memory

PENDAHULUAN

Teknologi informasi telah berkembang sangat cepat. Hingga saat ini teknologi-teknologi sudah semakin maju. Perkembangan teknologi ini salah satunya yaitu *deep learning*. Perkembangan teknologi *deep learning* sudah mencapai pada penerapan analisis sentimen. Analisis sentimen merupakan riset komputasional dari suatu dokumen teks untuk memprediksi atau menganalisis suasana publik dari internet, contohnya seperti jejaring sosial [1]. Pada jaman sekarang, jejaring sosial sudah tidak asing lagi bagi orang. Berjalan dengan seiringan waktu, pengguna jejaring

sosial akan terus meningkat. Pengguna jejaring sosial yang terus meningkat akan menjadi salah satu faktor utama dalam percepatan penyebaran informasi [2]. Saat ini banyak sekali jejaring sosial yang populer, antara lain Facebook, Instagram, Twitter dan Youtube. Pada penelitian ini menggunakan jejaring sosial Twitter.

Twitter merupakan layanan *micro-blogging* populer di dunia. Di Twitter, pengguna dapat mengunggah suatu pesan status yang disebut *tweet*, untuk memberi tahu pengikutnya apa yang pengguna pikirkan, apa yang pengguna lakukan, atau apa yang terjadi di sekitar pengguna. Selain itu, pengguna dapat berinteraksi dengan pengguna lain dengan membalas atau mengunggah ulang *tweetnya*. Jumlah data yang tersedia dari Twitter terus bertambah, menggali polaritas sentimen pengguna yang diekspresikan dalam teks Twitter telah menjadi topik penelitian yang hangat dalam beberapa tahun ini, dikarenakan aplikasinya yang luas [3]. Misalnya, dengan menganalisis polaritas sentimen pengguna Twitter terhadap maskapai penerbangan pada suatu *platform*, kebijakan penanganan COVID-19 di Indonesia [4], [5]. Organisasi atau perusahaan bisnis juga menggunakan analisis sentimen Twitter sebagai cara cepat dan efektif untuk memantau perasaan orang terhadap produk mereka [3]. Berdasarkan hal tersebut, penelitian ini akan menggunakan dataset dari Twitter untuk mengetahui prediksi dan pola sentiment model LSTM (*Long Short-Term Memory*) dari opini pengguna Twitter terhadap topik kenaikan harga bahan bakar minyak pada bulan Juli 2022.

TINJAUAN PUSTAKA

Peneliti bernama Widi Widayat pada Analisis Sentimen Movie Review menggunakan Word2Vec dan metode LSTM *deep learning* melakukan eksperimen terhadap beberapa ukuran dimensi dari *word vector* yaitu dimensi 50, 60, 100, 150, 200 dan 500. Eksperimen dari beberapa ukuran dimensi *word vector* tersebut untuk melihat pengaruhnya terhadap akurasi yang dihasilkan. Pada penelitian ini menggunakan metode klasifikasi sentimen LSTM. Akurasi terbaik diperoleh pada ukuran dimensi *word vector* 100 sebesar 88.17% dan akurasi terendah sebesar 85.86% pada ukuran dimensi *word vector* 500 [6]. Penelitian bernama Anton Borg dan Martin Boldt menggunakan pelabelan VADER dan dua model SVM untuk memprediksi respons pelanggan. Hasil eksperimen menunjukkan bahwa model LinearSVM mampu mengekstraksi sentimen dengan mean F1-score 0,834 dan mean AUC 0,896 [7]. Penelitian oleh Kartikasari Kusuma Agustiningsih, Ema Utami, Omar Muhammad Altoumi Alsyabani yang berjudul Sentiment Analysis of COVID-19 Vaccines in Indonesia on Twitter Using Pre-Trained and Self-Training Word Embeddings mendapat akurasi tertinggi dari grup skenario GloVe yaitu 92.55% yang dihasilkan oleh model menggunakan self-trained GloVe dan dilatih pada dataset *unstemmed*. Disisi lain pada grup skenario fastText yaitu 92.33% yang dihasilkan oleh model menggunakan self-trained fastText dan dilatih pada dataset *stemmed* [8].

Deep Learning

Deep learning mengadaptasi pendekatan multilayer ke lapisan tersembunyi jaringan saraf. Dalam pendekatan tradisional *machine learning*, fitur didefinisikan dan diekstraksi baik secara manual atau dengan menggunakan metode pemilihan fitur. Namun, dalam model *deep learning*, fitur dipelajari dan diekstraksi secara otomatis, mencapai akurasi dan kinerja yang lebih baik. Secara umum, parameter hiper model pengklasifikasi juga diukur secara otomatis. *Artificial neural networks* dan *deep learning* saat ini memberikan solusi terbaik untuk banyak masalah di bidang pengenalan gambar dan ucapan, serta dalam NLP (*Natural Language Processing*) [9].


Analisis Sentimen

Analisis sentimen adalah proses penggalian informasi tentang suatu entitas dan secara otomatis mengidentifikasi subjektivitas entitas tersebut. Tujuannya adalah untuk menentukan apakah teks yang dihasilkan oleh pengguna menyampaikan pendapat positif, negatif, atau netral. Klasifikasi sentimen dapat dilakukan pada tiga tingkat ekstraksi: tingkat aspek atau fitur, tingkat kalimat, dan tingkat dokumen. Saat ini, ada tiga pendekatan untuk mengatasi masalah analisis sentimen [10]: (1) teknik berbasis leksikon, (2) teknik berbasis *machine learning*, dan (3) pendekatan *hybrid*. Teknik berbasis leksikon adalah yang pertama digunakan untuk analisis sentimen. Dibagi menjadi dua pendekatan: berbasis kamus dan berbasis korpus [11]. Pada tipe sebelumnya, klasifikasi sentimen dilakukan dengan menggunakan kamus istilah, seperti yang ditemukan di SentiWordNet dan WordNet. Meskipun demikian, analisis sentimen berbasis korpus tidak bergantung pada kamus yang telah ditentukan tetapi pada analisis statistik isi kumpulan dokumen, menggunakan teknik berdasarkan *K-Nearest Neighbor* (KNN) [12], *Conditional Random Field* (CRF) [13], dan

Hidden Markov Models (HMM) [14], antara lain. Teknik berbasis *machine learning* [15] yang diusulkan untuk masalah analisis sentimen dapat dibagi menjadi dua kelompok: (1) *traditional models* dan (2) *deep learning models*. *Traditional models* mengacu pada teknik pembelajaran mesin klasik, seperti pengklasifikasi *Naïve Bayes* [16], *Maximum Entropy Classifier* [17], atau *Support Vector Machine* (SVM) [18]. Masukan untuk algoritma tersebut mencakup fitur leksikal, fitur berbasis leksikon sentimen, bagian ucapan, atau kata sifat dan kata keterangan. Keakuratan sistem ini bergantung pada fitur mana yang dipilih. Model *deep learning* dapat memberikan hasil yang lebih baik daripada model tradisional. Berbagai jenis model *deep learning* dapat digunakan untuk analisis sentimen, termasuk CNN, DNN, dan RNN. Pendekatan semacam itu mengatasi masalah klasifikasi pada tingkat dokumen, tingkat kalimat, atau tingkat aspek.

Long Short-Term Memory

LSTM (*Long Short-Term Memory*) adalah bagian dari keluarga RNN (*Recurrent Neural Networks*), yang merupakan jaringan saraf yang dibangun untuk menangani data sekuensial dengan berbagi bobot internal di seluruh urutan [19]. RNN menangkap hubungan temporal antara kata-kata dalam sebuah kalimat. Informasi tekstual adalah data deret waktu dimana urutan kata memainkan peran penting dalam menentukan arti kata dan kalimat. LSTM adalah implementasi dari RNN dengan tautan khusus antar *node*. Komponen khusus di dalam unit LSTM meliputi *input*, *output*, dan *forget gate* [20]. Gambar 1 menunjukkan satu unit LSTM.



GAMBAR 1. Arsitektur LSTM

Keterangan:

x_t : *Vector input* saat ini

h_t : *Hidden state* saat ini

C_t : *Cell state* saat ini

Gambar 1 adalah arsitektur dari LSTM. Pada LSTM terdapat empat komponen yang berfungsi untuk memproses data. Komponen-komponen tersebut adalah *forget gate*, *input gate*, *update gate*, dan *output gate*. Proses pertama yaitu *forget gate*. *Forget gate* dihitung dari gabungan *hidden state* sebelumnya (h_t) dan *input gate* sekarang (x_t). *Forget gate* akan dikalikan dengan *cell state timestep* sebelumnya (C_{t-1}). Persamaan 1 merupakan operasi matematika *forget gate*.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Kemudian selanjutnya adalah proses pada *input gate*. Pada *input gate* ini, terdapat opsi atau pemilihan informasi yang akan diperbaharui untuk ke bagian *cell state*. Proses pemilihan informasi ini menggunakan fungsi *sigmoid* juga. Berikut adalah persamaan dari proses *input gate*.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t]) + b_c \quad (3)$$

Proses yang ketiga adalah *update gate*. Pada tahap ini akan menggunakan *output* dari *input gate*. *Output* dari *update gate* akan menghasilkan *cell state* terbaru (C_t). Berikut adalah cara menghitung proses *update gate*.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

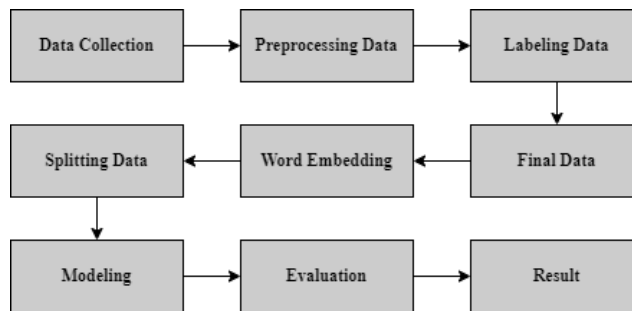
Proses yang terakhir yaitu *output gate* (o_t). Pada proses ini akan menghasilkan nilai *output* dan nilai *hidden state* (h_t). Setelah mendapat hasil dari proses *output gate*, maka hasil tersebut akan dilanjutkan ke *timestep* berikutnya ($t+1$).

$$o_t = \sigma(W_o \cdot [h_{t-1}, \chi_t] + b_o) \quad (5)$$

$$h_t = \tanh(C_t) \quad (6)$$

METODE PENELITIAN

Adapun langkah-langkah atau alur penelitian sebagai berikut.



GAMBAR 2. Alur Penelitian

Data Collection

Pengumpulan data dilakukan dengan cara mengikis data di media sosial Twitter. Pengikisan ini menggunakan modul *snsrape*. *Snsrape* adalah *scraper* untuk *Social Networking Services* (SNS). *Scraper* ini dapat mengikis hal-hal seperti profil pengguna, tagar, atau pencarian dan mengembalikan item yang ditemukan, misalnya postingan yang relevan. Data Twitter hasil *scraping* dari tanggal 1 Juli 2022 sampai dengan tanggal 30 Juli 2022 terkumpul sebanyak 6602 data berbahasa *English*. Pengambilan data dari Twitter ini menggunakan *keyword* #fuelpricehike, #petrolprice, #fuelprice, #fuelprices, #fuelcrisis.


Preprocessing Data

Data yang berhasil dikumpulkan merupakan data yang masih tidak terstruktur. Masih terdapat kata singkatan, simbol, angka, emoji, pengulangan kata serta karakter khusus. Oleh sebab itu dilakukan *preprocessing data* untuk mendapatkan data yang bersih agar proses klasifikasi lebih akurat. *Preprocessing data* terdiri atas beberapa metode untuk membersihkan dan menstandarisasi data teks yang akan diolah. Beberapa metode tersebut diantaranya *cleaning*, *remove duplicates*, *case folding*, *tokenizing*, *filtering*, dan *stemming*. Alur dari *preprocessing data* terdapat pada gambar 4.

Labeling Data

Pelabelan data menggunakan VADER dengan dua kategori sentimen (*negative* dan *positive*). VADER (*Valence Aware Dictionary and sEntiment Reasoner*) adalah leksikon berbasis aturan dan alat analisis sentimen yang secara khusus disesuaikan dengan sentimen yang diekspresikan di media sosial. VADER menggunakan leksikon sentimen

yang merupakan daftar fitur leksikal yang umumnya diberi label berdasarkan orientasi semantiknya sebagai positif atau negatif. VADER peka terhadap polaritas dan intensitas (seberapa positif atau negatif sentimen itu) emosi, dan disesuaikan dengan konten jejaring sosial yang umumnya menggunakan tulisan informal (beberapa tanda baca, akronim, emotikon, bahasa gaul). Beberapa heuristik yang digunakan oleh VADER untuk memasukkan dampak setiap subteks pada intensitas sentimen yang dirasakan dalam teks adalah bagian dari gaya penulisan di jejaring sosial, dalam hal ini tanda baca (seperti tanda seru yang meningkatkan besaran dari intensitas yang dirasakan) dan kapitalisasi yang menekankan kata penting untuk sentimen di hadapan kata nonkapital lainnya [21].



GAMBAR 3. Alur Preprocessing Data

Cleaning: Tahap pertama yang dilakukan pada *preprocessing data* yaitu *cleaning*. Tahap ini adalah tahap eliminasi komponen-komponen yang tidak dibutuhkan dengan tujuan untuk menurunkan *noise*. Komponen-komponen yang dihapus adalah tulisan ‘RT’ untuk *retweet*, simbol ‘@’ untuk *username*, simbol ‘#’ untuk *hashtag*, alamat website (http, https, www), emoji, mengganti pengulangan kata dengan satu kejadian (aaaa menjadi a), mengganti kontraksi dengan *extended forms* (I’ll menjadi I will), menyisakan alfabet saja yang dimana angka dan karakter khusus tidak termasuk atau dihapus, serta menghapus spasi pada awal dan akhir teks.

Remove Duplicates: *Remove duplicates* merupakan tahap penghapusan data duplikat setelah melalui proses *cleaning*.

Case Folding: *Case folding* adalah tahap mengubah teks menjadi *lowercase* atau huruf kecil semua.

Tokenizing: Pada tahap *tokenizing* ini berfungsi sebagai pemecah kalimat menjadi kata, yang disebut term atau token.

Filtering: Tahap *filtering* merupakan tahap untuk mengambil kata-kata penting atau kata-kata yang memiliki makna dari hasil token tadi (*tokenizing*). Kata-kata yang tidak memiliki makna akan dihapus. Kata-kata yang tidak memiliki makna disebut *stopword*. Kata-kata yang dihapus seperti kata penghubung (*and, to, from, or*).

Stemming: *Stemming* adalah proses mengubah kata-kata yang terdapat imbuhan menjadi bentuk kata dasar. Kata dalam perubahan memiliki arti dan makna yang sama dengan kata tersebut. Aturan-aturan bahasa *English* seperti *grammar, tenses* dihilangkan agar kata tersebut menjadi kata dasar. Contoh dari *stemming* pada bahasa *English* antara lain kata *cleaning, cleaned, cleaner* berubah menjadi *clean*.

Word Embedding

Pada *word embedding* menggunakan GloVe (*Global Vectors for Word Representation*) berdimensi 50. Penggunaan GloVe merupakan representasi kata untuk menghasilkan *word embedding* untuk dapat digunakan menangani *word similarity*.

Splitting Data

Splitting data merupakan proses pembagian data menjadi dua bagian yaitu data latih (*train data*) dan data uji (*test data*). Pembagian data dilakukan pada kategori sentimen (*positive* dan *negative*). Untuk data latih 90% dan data uji 10%.

Modeling

Modeling yaitu pembangunan model *Long Short-Term Memory* yang akan digunakan untuk mengetahui performa akurasi dan pola sentimen.

Evaluasi

Evaluasi adalah proses evaluasi dari model. Pada tahap ini terdapat beberapa hal dari pencapaian model antara lain Accuracy, Precision, Recall, F1-Score serta Confusion Matrix. *Accuracy* merupakan proporsi prediksi yang benar dari semua prediksi yang dibuat. Perhitungan *accuracy* dilakukan dengan cara membagi jumlah data sentimen yang diprediksi benar dengan total data uji. *Precision* merupakan proporsi prediksi positif yang benar dari semua prediksi positif yang dibuat. Perhitungan *precision* dilakukan dengan cara membagi jumlah data benar yang bernilai positif dibagi dengan jumlah data benar yang bernilai positif dan data salah yang bernilai positif. *Recall* merupakan proporsi prediksi positif sebenarnya dari semua kasus positif aktual. Perhitungan *recall* dilakukan dengan cara membagi data benar bernilai positif dengan hasil penjumlahan dari data benar yang bernilai positif dan data salah yang bernilai negatif. *F1-score (F-measure)* merupakan rata-rata *precision* dan *recall* yang harmonis, digunakan sebagai metrik tunggal untuk menyeimbangkan kedua metrik. Ini memberikan bobot yang sama untuk *precision* dan *recall*. Nilai *F-measure* didapat dari perhitungan hasil perkalian *precision* dan *recall* dibagi dengan hasil penjumlahan *precision* dan *recall* kemudian dikalikan dua. Metrik ini biasanya digunakan dalam mengevaluasi kinerja model *machine learning*, khususnya dalam masalah klasifikasi biner. Pilihan metrik bergantung pada persyaratan khusus dan prioritas masalah, karena akurasi yang tinggi mungkin tidak menyiratkan *precision* atau *recall* yang tinggi, dan sebaliknya. Tabel 1 merupakan operasi matematika untuk *Accuracy*, *Precision*, *Recall*, *F1-Score* dan tabel 2 untuk *Confusion Matrix*.

Tabel 1. Evaluation Measure Formula

Evaluation Measure	Formula
Accuracy	$(TN + TP) / (TN + FN + TP + FP)$
Precision	$TP / (TP + FP)$
Recall	$TP / (TP + FN)$
F1-Score	$2 * (Precision * Recall) / (Precision + Recall)$

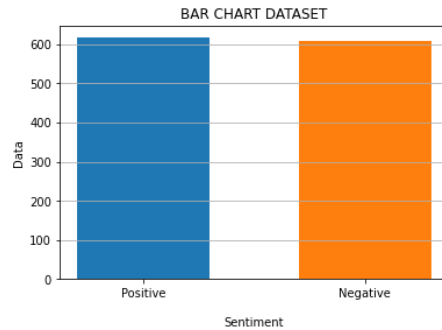
Tabel 2. Confusion Matrix

		Predictions	
		Class	
Actual	Negative	True Negative	False Positive
	Positive	False Negative	True Positive

TP (*True Positive*) merupakan data positif yang diprediksi benar. TN (*True Negative*) merupakan data negatif yang diprediksi benar. FP (*False Positive*) merupakan data negatif namun diprediksi sebagai data positif. FN (*False Negative*) merupakan data positif namun diprediksi sebagai data negatif.

HASIL DAN PEMBAHASAN

Dari dataset hasil *scraping* di Twitter kemudian melalui tahap prapemrosesan data serta melalui tahap pelabelan data menggunakan VADER maka menghasilkan *dataset* baru berjumlah 1225 data dengan sentimen *positive* berjumlah 617 data dan sentimen *negative* berjumlah 608 data.




GAMBAR 4. Diagram Batang Dataset

Pada model *Long Short-Term Memory* dilakukan percobaan sebanyak lima kali. Performa akurasi dari model *Long Short-Term Memory* ditunjukkan pada Tabel 3 dan Gambar 5.

Tabel 3. Akurasi LSTM

Percobaan	Akurasi LSTM
1	90%
2	87%
3	90%
4	86%
5	88%



GAMBAR 5. Akurasi Model LSTM

Berikut adalah tabel evaluasi performa dari lima kali percobaan pada model *Long Short-Term Memory* terhadap pencapaian *precision*, *recall*, *f1-score* beserta *confusion matrix*.

Tabel 4. Evaluasi Performa LSTM Percobaan 1

Sentiment	Precision	Recall	F1-score
Negative	0.87	0.93	0.90
Positive	0.94	0.88	0.91

Tabel 5. Confusion Matrix LSTM Percobaan 1

		Prediction	
		Class	Negative
Actual	Negative	52	4
	Positive	8	59

Tabel 6. Evaluasi Performa LSTM Percobaan 2

Sentiment	Precision	Recall	F1-score
Negative	0.87	0.84	0.85
Positive	0.87	0.90	0.88

Tabel 7. Confusion Matrix LSTM Percobaan 2

		Prediction	
		Class	Negative
Actual	Negative		
	Positive		

Tabel 8. Evaluasi Performa LSTM Percobaan 3

Sentiment	Precision	Recall	F1-score
Negative	0.91	0.88	0.89
Positive	0.90	0.93	0.91

Tabel 9. Confusion Matrix LSTM Percobaan 3

		Prediction	
		Class	Negative
Actual	Negative	52	4
	Positive	8	59

Tabel 10. Evaluasi Performa LSTM Percobaan 4

Sentiment	Precision	Recall	F1-score
Negative	0.79	0.95	0.86
Positive	0.95	0.79	0.86

Tabel 11. Confusion Matrix LSTM Percobaan 4

	Prediction		
	Class	Negative	Positive
Actual	Negative	52	4
	Positive	8	59

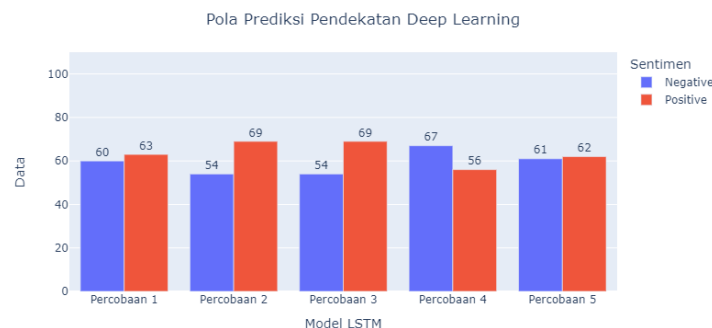
Tabel 12. Evaluasi Performa LSTM Percobaan 5

Sentiment	Precision	Recall	F1-score
Negative	0.84	0.91	0.87
Positive	0.92	0.85	0.88

Tabel 13. Confusion Matrix LSTM Percobaan 5

	Prediction		
	Class	Negative	Positive
Actual	Negative	52	4
	Positive	8	59

Pola prediksi model *Long Short-Term Memory* tidak berbeda jauh pada percobaan ke-5 terhadap prediksi sentimen *negative* dan *positive*. Prediksi model *Long Short-Term Memory* pada sentimen *negative* yaitu sebanyak 61 data dan sentimen *positive* sebanyak 62 data. Pola prediksi model *Long Short-Term Memory* dengan lima kali percobaan ditunjukkan pada Gambar 7.



GAMBAR 6. Pola Prediksi Model LSTM

Dengan lima kali percobaan, sentimen *negative* cenderung lebih rendah dibanding sentimen *positive* kecuali pada percobaan ke-4. Pada percobaan ke-4, prediksi sentimen *negative* lebih tinggi dibanding sentimen *positive*. Sentimen *negative* sebanyak 67 data dan sentimen *positive* sebanyak 56 data.

KESIMPULAN

Penelitian ini menggunakan pelabelan VADER untuk menghasilkan *dataset* yang baru sebagai *dataset* untuk melatih dan menguji model *Long Short-Term Memory*. Hasil evaluasi akurasi tertinggi dari model *Long Short-Term Memory* yaitu 90% pada percobaan ke1 dan ke-3. Pola prediksi dalam 5 kali percobaan cenderung lebih tinggi sentimen *positive* dibanding sentimen *negative*. Jadi dapat disimpulkan bahwa penggunaan model *Long Short-Term Memory* dengan pembagian data latih 90% dan data uji 10% menunjukkan akurasi yang baik dan pola prediksi sentimen yang baik. Peneliti selanjutnya disarankan menggunakan pelabelan data yang lain untuk menghasilkan *dataset* serta penggunaan *word embedding* GloVe berdimensi di atas 50 untuk mengetahui akurasi prediksi dan pola sentimen model *Long Short-Term Memory*.

TINJAUAN PUSTAKA

- [1] F. Ratnawati, "Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Opini Film Pada Twitter," *INOVTEK Polbeng - Seri Inform.*, vol. 3, no. 1, p. 50, 2018, doi: 10.35314/isi.v3i1.335.
- [2] N. A. Azmi, A. T. Fathani, D. P. Sadayi, and I. Fitriani, "Social Media Network Analysis (SNA) : Identifikasi Komunikasi dan Penyebaran Informasi Melalui Media Sosial Twitter," vol. 5, pp. 1422–1430, 2021, doi: 10.30865/mib.v5i4.3257.
- [3] L. Wang, J. Niu, and S. Yu, "SentiDiff: Combining Textual Information and Sentiment Diffusion Patterns for Twitter Sentiment Analysis," *IEEE Trans. Knowl. Data Eng.*, vol. 32, no. 10, pp. 2026–2039, 2020, doi: 10.1109/TKDE.2019.2913641.
- [4] 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, 2021, doi: 10.34148/teknika.v10i1.311.
- [5] N. Putu, G. Naraswati, D. C. Rosmilda, D. Desinta, P. D. Statistika, and P. S. Stis, "Analisis Sentimen Publik dari Twitter Tentang Kebijakan Penanganan Covid-19 di Indonesia dengan Naive Bayes Classification," vol. 10, pp. 228–238, 2021.
- [6] W. Widayat, "Analisis Sentimen Movie Review menggunakan Word2Vec dan metode LSTM Deep Learning," *J. Media Inform. Budidarma*, vol. 5, no. 3, p. 1018, 2021, doi: 10.30865/mib.v5i3.3111.
- [7] A. Borg and M. Boldt, "Using VADER sentiment and SVM for predicting customer response sentiment," *Expert Syst. Appl.*, vol. 162, p. 113746, 2020, doi: 10.1016/j.eswa.2020.113746.
- [8] K. K. Agustiningasih, E. Utami, O. Muhammad, and A. Alsyabani, "Sentiment Analysis of COVID-19 Vaccines in Indonesia on Twitter Using Pre-Trained and Self-Training Word Embeddings," *J. Ilmu Komput. dan Inf. (Journal Comput. Sci. Information)*, vol. 15, no. 1, pp. 39–46, 2022.
- [9] A. Chamekh, M. Mahfoudh, and G. Forestier, "Sentiment Analysis Based on Deep Learning in E-Commerce," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 13369 LNAI, pp. 498–507, 2022, doi: 10.1007/978-3-031-10986-7_40.
- [10] B. K. Bhavitha, A. P. Rodrigues, and N. N. Chiplunkar, "Comparative study of machine learning techniques in sentimental analysis," *Proc. Int. Conf. Inven. Commun. Comput. Technol. ICICCT 2017*, no. Icicct, pp. 216–221, 2017, doi: 10.1109/ICICCT.2017.7975191.
- [11] M. D. P. Salas-Zárate, J. Medina-Moreira, K. Lagos-Ortiz, H. Luna-Aveiga, M. Á. Rodríguez-García, and R. Valencia-García, "Sentiment Analysis on Tweets about Diabetes: An Aspect-Level Approach," *Comput. Math. Methods Med.*, vol. 2017, 2017, doi: 10.1155/2017/5140631.
- [12] M. Rezwanul, A. Ali, and A. Rahman, "Sentiment Analysis on Twitter Data using KNN and SVM," *Int. J. Adv. Comput. Sci. Appl.*, vol. 8, no. 6, pp. 19–25, 2017, doi: 10.14569/ijacsa.2017.080603.
- [13] D. Pinto, A. McCallum, X. Wei, and W. Bruce Croft, "Table Extraction Using Conditional Random Fields," *SIGIR Forum (ACM Spec. Interes. Gr. Inf. Retrieval)*, no. SPEC. ISS., pp. 235–242, 2003, doi: 10.1145/860476.860479.

-
- [14] S. Soni and A. Sharaff, "Sentiment analysis of customer reviews based on Hidden Markov Model," *ACM Int. Conf. Proceeding Ser.*, vol. 06-07-March-2015, 2015, doi: 10.1145/2743065.2743077.
- [15] X. Zhang and X. Zheng, "Comparison of text sentiment analysis based on machine learning," *Proc. - 15th Int. Symp. Parallel Distrib. Comput. ISPDC 2016*, pp. 230–233, 2017, doi: 10.1109/ISPDC.2016.39.
- [16] R. Ardianto, T. Rivanie, Y. Alkhalifi, F. S. Nugraha, and W. Gata, "Sentiment Analysis on E-Sports for Education Curriculum Using Naive Bayes and Support Vector Machine," *J. Ilmu Komput. dan Inf.*, vol. 13, no. 2, pp. 109–122, 2020, doi: 10.21609/jiki.v13i2.885.
- [17] N. Mehra, S. Khandelwal, and P. Patel, "Sentiment Identification Using Maximum Entropy Analysis of Movie Reviews," p. 7, 2002, [Online]. Available: <https://web.stanford.edu/class/cs276a/projects/reports/nmehra-kshashi-priyank9.pdf>
- [18] A. L. F. Alves, C. De S. Baptista, A. A. Firmino, M. G. De Oliveira, and A. C. De Paiva, "A comparison of SVM versus naive-bayes techniques for sentiment analysis in tweets: A case study with the 2013 FIFA confederations cup," *WebMedia 2014 - Proc. 20th Brazilian Symp. Multimed. Web*, pp. 123–130, 2014, doi: 10.1145/2664551.2664561.
- [19] H. Elfaik and E. H. Nfaoui, "Deep Bidirectional LSTM Network Learning-Based Sentiment Analysis for Arabic Text," *J. Intell. Syst.*, vol. 30, no. 1, pp. 395–412, 2021, doi: 10.1515/jisys-2020-0021.
- [20] A. Setyanto *et al.*, "Arabic Language Opinion Mining Based on Long Short-Term Memory (LSTM)," *Appl. Sci.*, vol. 12, no. 9, pp. 1–18, 2022, doi: 10.3390/app12094140.
- [21] M. Chiny, M. Chihab, Y. Chihab, and O. Bencharef, "LSTM, VADER and TF-IDF based Hybrid Sentiment Analysis Model," *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 7, pp. 265–275, 2021, doi: 10.14569/IJACSA.2021.0120730.