

Optimalisasi Arsitektur LSTM untuk Model Analisis Sentimen terhadap Program Makan Bergizi Gratis (MBG)

Teguh Wiharko, Riffa Haviani Laluma, Gunawansyah, Euis Nuraeni

Program Studi Teknik Informatika, Universitas Sangga Buana,

Jl. P.H.H. Mustopa No. 68, Kota Bandung

Email: teguh.wiharko@usbypkp.ac.id

ABSTRAK

Program Makan Bergizi Gratis (MBG) merupakan salah satu prioritas pembangunan nasional yang bertujuan untuk memperkuat pemenuhan gizi anak, mengurangi stunting, dan meningkatkan kualitas sumber daya manusia. Namun, implementasi kebijakan ini memicu reaksi beragam di media sosial, mulai dari dukungan hingga kritik mengenai efektivitas, pendanaan, dan aspek teknis pelaksanaannya. Analisis sentimen konvensional dalam bahasa Indonesia masih mengalami keterbatasan dalam memahami konteks informal, sehingga dibutuhkan model yang lebih adaptif dan presisi. Penelitian ini bertujuan untuk mengoptimalkan model *Long Short-Term Memory* (LSTM) guna meningkatkan akurasi analisis sentimen masyarakat terhadap Program MBG. Metode yang digunakan meliputi pengumpulan data dari *platform* media sosial, pembersihan dan *preprocessing* teks, pelatihan model baseline LSTM, optimasi arsitektur melalui *hyperparameter* tuning, evaluasi performa, serta visualisasi sentimen publik. Hasil penelitian menunjukkan bahwa model LSTM teroptimasi mampu meningkatkan akurasi secara signifikan dibandingkan model *baseline*. Penelitian ini diharapkan memberikan kontribusi signifikan terhadap pengembangan *Natural Language Processing* (NLP) berbahasa Indonesia serta mendukung perumusan kebijakan publik yang lebih adaptif dan berbasis bukti.

Kata Kunci : Analisis Sentimen, *Long Short-Term Memory* (LSTM), Media Sosial, Optimalisasi Model, Makan Bergizi Gratis (MBG)

ABSTRACT

The Free Nutritious Meal Program (MBG) constitutes one of Indonesia's national development priorities, aimed at strengthening children's nutritional fulfillment, reducing stunting, and enhancing the quality of human resources. However, the implementation of this policy has triggered diverse reactions on social media, ranging from support to criticism concerning its effectiveness, funding, and technical aspects of execution. Conventional sentiment analysis in the Indonesian language still encounters limitations in comprehending informal contexts, thereby necessitating a more adaptive and precise model. This study aims to optimize the Long Short-Term Memory (LSTM) model in order to improve the accuracy of public sentiment analysis regarding the MBG Program. The methods employed encompass data collection from social media platforms, text cleaning and preprocessing, baseline LSTM model training, architecture optimization through hyperparameter tuning, performance evaluation, and visualization

of public sentiment. The results demonstrate that the optimized LSTM model is capable of significantly enhancing accuracy compared to the baseline model. This study is expected to make a significant contribution to the development of Indonesian-language Natural Language Processing (NLP) as well as to support the formulation of more adaptive and evidence-based public policies.

Keywords : Sentiment Analysis, Long Short-Term Memory (LSTM), Social Media, Model Optimization, Free Nutritious Meal Program (MBG)

1. PENDAHULUAN

Program Makan Bergizi Gratis (MBG) merupakan salah satu prioritas nasional yang dicanangkan pemerintah dengan tujuan meningkatkan pemenuhan gizi peserta didik, mengurangi angka stunting, dan memperkuat kualitas sumber daya manusia sejak usia sekolah. Kebijakan ini tidak hanya berdampak pada aspek kesehatan, tetapi juga pada peningkatan konsentrasi belajar, ketahanan pangan, serta pemerataan akses nutrisi di seluruh wilayah Indonesia. Sebagai kebijakan skala nasional dengan implikasi sosial dan ekonomi yang luas, Program MBG menerima perhatian besar dari masyarakat, terutama melalui ruang publik digital seperti media sosial. Di platform tersebut masyarakat menyampaikan dukungan, kritik, kekhawatiran, serta harapan terhadap kebijakan ini dalam bentuk opini, komentar, maupun diskusi terbuka (Widjaja, 2025).

Persepsi publik terhadap kebijakan pemerintah menjadi aspek penting dalam proses demokrasi dan tata kelola pemerintahan modern. Opini masyarakat dapat membentuk legitimasi kebijakan, mempengaruhi tingkat keberterimaan, dan menentukan keberlanjutan pelaksanaan program. Namun, dinamika percakapan digital memiliki karakteristik yang kompleks: penggunaan bahasa tidak baku, frasa informal, singkatan, emotikon, sarkasme, serta perubahan konteks yang cepat. Kondisi ini menjadi tantangan utama bagi analisis sentimen berbasis metode tradisional seperti *lexicon-based* maupun *machine learning* klasik, yang sering kali tidak mampu menangkap konteks mendalam dari teks informal dalam bahasa Indonesia (Amaia et al., 2023) .


Seiring berkembangnya teknologi kecerdasan buatan, model *deep learning* telah menjadi solusi unggulan dalam pengolahan bahasa alami. Salah satu arsitektur yang menonjol adalah *Long Short-Term Memory* (LSTM), bentuk khusus dari *Recurrent*

Neural Network (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* serta mampu mempelajari ketergantungan jangka panjang dalam teks. Meskipun LSTM memiliki performa yang baik, tingkat akurasi sangat dipengaruhi oleh konfigurasi arsitektur dan *hyperparameter*. Jumlah unit memori, kedalaman lapisan, nilai dropout, fungsi aktivasi, serta strategi optimasi sangat menentukan performa akhir model. Implementasikan LSTM standar tanpa eksplorasi optimasi arsitektur yang menyeluruh, terutama pada dataset teks informal khas media sosial Indonesia. Hal ini menyebabkan performa model masih dapat ditingkatkan secara signifikan melalui proses optimasi yang lebih sistematis (Dewi, 2025). Dengan demikian, terdapat kebutuhan untuk mengembangkan arsitektur LSTM teroptimasi yang lebih adaptif terhadap karakteristik data opini publik digital, khususnya terkait Program MBG.

Berdasarkan kondisi tersebut, permasalahan penelitian yang akan dikaji dapat dirumuskan sebagai berikut: (1) Bagaimana karakteristik persepsi dan sentimen masyarakat terhadap Program MBG di media sosial? (2) Seberapa baik model LSTM standar dalam mengklasifikasikan sentimen pada teks informal bahasa Indonesia? (3) Bagaimana pengaruh optimasi arsitektur LSTM terhadap peningkatan akurasi analisis sentimen publik? (4) Arsitektur LSTM seperti apa yang paling tepat dan efektif untuk analisis sentimen kebijakan publik pada konteks media sosial Indonesia? (5) Bagaimana hasil pemodelan dapat digunakan untuk mendukung pengambilan keputusan berbasis data pada kebijakan sosial nasional?

State of the art penelitian sebelumnya telah menunjukkan efektivitas LSTM dalam analisis sentimen untuk berbagai domain seperti ulasan produk (Ma'aly et al., 2024). Namun, studi yang secara khusus mengkaji sentimen publik terhadap kebijakan sosial berskala nasional seperti Program Makan Bergizi Gratis (MBG) di Indonesia masih sangat terbatas. Kebaruan penelitian ini terletak pada tiga aspek utama: (1) Kebijakan Spesifik: Penelitian ini secara khusus berfokus pada analisis sentimen terhadap Program Makan Bergizi Gratis (MBG) sebagai kebijakan sosial nasional, yang belum banyak diteliti sebelumnya. (2) Optimasi Arsitektur LSTM yang Terarah: Penelitian ini tidak hanya menggunakan LSTM standar, tetapi melakukan eksplorasi dan optimasi menyeluruh terhadap *hyperparameter* (jumlah lapisan, unit LSTM,

dropout rate, *learning rate*, dll.) yang disesuaikan dengan karakteristik data teks informal bahasa Indonesia.



Grafik 1: Ilustrasi pemetaan *state of the art*, *research gap*, dan kebaruan.

LSTM dapat digunakan dengan Word2Vec dan *grid search* untuk deteksi pesan *spam*, menghasilkan peningkatan *precision* sebesar 0,0426 dan *accuracy* sebesar 0,0261 setelah optimasi (Wicaksana & Suhud, 2026) . *Optimizer Adam*, dibandingkan dengan SGD, dan RMSprop pada prediksi harga saham, mendapatkan hasil *optimizer Adam* mencapai akurasi tertinggi 98,45% (Enriko et al., 2023) . LSTM-*Bayesian Optimization* mampu menurunkan RMSE dari 160,51 mm menjadi 148,87 mm pada prediksi curah hujan. Studi-studi ini mengonfirmasi bahwa optimasi arsitektur LSTM memberikan dampak signifikan terhadap peningkatan performa model (Hawali & Walid, 2025) .

2. METODE

Metode penelitian ini dirancang untuk mencapai tujuan utama penelitian melalui delapan tahapan yang saling berkaitan. Setiap tahapan memiliki luaran dan indikator capaian yang terukur, serta melibatkan anggota tim yang bertanggung jawab sesuai bidang keahliannya. Secara garis besar, alur penelitian dimulai dari pengumpulan data opini publik dari media sosial, dilanjutkan dengan *preprocessing* teks, pembentukan

embedding, pelatihan model *baseline* LSTM, optimasi arsitektur LSTM sebagai tahap inti, evaluasi performa model, visualisasi dan analisis sentimen publik, hingga penulisan dan publikasi artikel ilmiah. Grafik 1 mengilustrasikan delapan tahapan penelitian beserta aktivitas utama dan luaran yang dihasilkan pada setiap tahap.



Grafik 2: Tahapan penelitian analisis sentimen Program MBG dengan LSTM teroptimasi.

Analisis sentimen merupakan proses identifikasi dan ekstraksi opini subjektif dari suatu teks untuk menentukan polaritas emosi yang terkandung di dalamnya. Dalam konteks kebijakan publik, analisis sentimen menjadi alat penting untuk memahami persepsi masyarakat terhadap program pemerintah. *Long Short-Term Memory* (LSTM) adalah pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi kesulitan pembelajaran dependensi jangka panjang akibat melemahnya aliran gradien (*vanishing/decaying gradient*) pada data sekuensial. LSTM menggunakan mekanisme *gating* untuk mengatur informasi yang dipertahankan, ditambahkan, dan dikeluarkan dari *cell state*. Arsitektur LSTM standar memiliki tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*. Secara matematis, mekanisme LSTM dapat dirumuskan sebagai berikut (Hochreiter & Schmidhuber, 1997) :

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

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

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

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

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

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

Dengan f_t merupakan *forget gate* yang menentukan informasi dari *cell state* sebelumnya yang dipertahankan atau dilupakan; i_t merupakan *input gate* yang mengatur informasi baru yang akan disimpan; $\tilde{C}_t$ merupakan kandidat nilai baru untuk *cell state*; C_t merupakan *cell state* pada waktu t ; o_t merupakan *output gate* yang mengatur informasi yang dikeluarkan; dan h_t merupakan *hidden state* pada waktu t . Fungsi σ merupakan fungsi aktivasi *sigmoid*, sedangkan $\tanh$ merupakan fungsi aktivasi hiperbolik tangen. Operasi menunjukkan perkalian elemen-per-elemen (*element-wise multiplication*).

Optimasi *hyperparameter* merupakan aspek krusial dalam pengembangan model *deep learning*. Metode optimasi seperti *Bayesian Optimization*, *Hyperband*, dan *Optuna* mampu meningkatkan performa model LSTM secara signifikan (Andika & Kusri, 2025). *Grid search* dan *random search* merupakan pendekatan konvensional yang banyak digunakan, meskipun memiliki keterbatasan dalam efisiensi komputasi. Kombinasi antara LSTM dan optimasi *hyperparameter* telah terbukti meningkatkan akurasi pada berbagai domain, termasuk prediksi harga saham dan analisis sentimen (Kervanci et al., 2024).

A. Pengumpulan Data

Pengumpulan data dilakukan melalui API resmi media sosial ataupun *scraping* yang sesuai dengan ketentuan *platform*. Peneliti mengumpulkan opini publik yang mengandung kata kunci seperti "makan bergizi gratis", "program MBG", dan variasi frasa relevan lainnya. Proses ini menghasilkan dataset mentah dalam format JSON atau CSV yang berisi ratusan unggahan pengguna.

B. Preprocessing Data

Preprocessing data meliputi pembersihan teks dari elemen yang tidak relevan seperti URL, tanda baca, emotikon, serta menyertakan langkah normalisasi bahasa gaul yang umum digunakan di media sosial. Tokenisasi dan penghapusan *stopword* juga dilakukan agar teks lebih siap untuk diproses oleh model. Luaran tahap ini berupa dataset teks bersih yang valid secara teknis. Indikator capaian tahap ini adalah terwujudnya *pipeline preprocessing* yang mampu menangani seluruh data tanpa *error*.

C. Pembentukan *Embedding*

Pada tahap ini, kata diubah menjadi representasi vektor yang dapat dipahami oleh model *deep learning*. Metode yang digunakan adalah Word2Vec atau GloVe dengan dimensi vektor yang bervariasi antara 50 hingga 300 dimensi. Representasi ini penting untuk meningkatkan kemampuan model dalam memahami struktur semantik teks. Luaran yang dihasilkan berupa matriks *embedding* kata, dengan indikator capaian berupa koherensi semantik yang stabil.

D. Pelatihan Model *Baseline* LSTM

Model *baseline* LSTM dibangun menggunakan arsitektur sederhana, misalnya satu lapisan LSTM dan satu lapisan *dense*. Proses pelatihan dilakukan dengan membagi data menjadi 80% data latih dan 20% data uji, serta menerapkan mekanisme *early stopping* untuk mencegah *overfitting*. Indikator capaian tahap ini adalah tercapainya akurasi minimal 70% pada model *baseline*.

E. Optimasi Arsitektur LSTM

Tahap inti penelitian ini adalah optimasi arsitektur LSTM. Dilakukan eksplorasi *hyperparameter* melalui metode *grid search*, *random search*, atau pendekatan lain yang relevan. *Hyperparameter* yang dioptimasi mencakup jumlah *neuron* pada lapisan LSTM, jumlah lapisan tersembunyi, nilai *dropout*, *learning rate*, *batch size*, hingga jenis *optimizer* yang digunakan. Optimasi ini bertujuan untuk memperoleh konfigurasi terbaik yang mampu meningkatkan performa analisis sentimen secara signifikan. Indikator capaian tahap ini adalah peningkatan akurasi minimal 5% dibanding *baseline*, serta peningkatan F1-score minimal 0,05.

F. Evaluasi Performa Model

Evaluasi performa model melibatkan pengukuran akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, dilakukan analisis *confusion matrix* untuk mengidentifikasi pola kesalahan dan area yang masih perlu diperbaiki. Evaluasi ini menghasilkan laporan performa model yang membandingkan hasil *baseline* dan model teroptimasi. Indikator capaian tahap ini adalah tercapainya *F1-score* minimal 0,80 pada model final.

G. Visualisasi dan Analisis Sentimen Publik

Hasil prediksi model disajikan dalam bentuk grafik distribusi sentimen, tren sentimen dari waktu ke waktu, *word cloud*, atau plot analitik lainnya. Visualisasi bertujuan untuk memberikan gambaran umum mengenai persepsi publik terhadap Program MBG dan

implikasinya terhadap kebijakan publik. Indikator capaian tahap ini adalah minimal lima visualisasi informatif yang dapat mendukung interpretasi hasil analisis.

3. HASIL DAN PEMBAHASAN

A. Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 600 ulasan mengenai Program MBG yang dikumpulkan dari platform Facebook, Threads, dan Instagram yang diambil mulai dari tanggal 9 Maret 2026 sampai dengan tanggal 26 Juni 2026. Distribusi sentimen menunjukkan ketidakseimbangan awal dengan 400 data negatif dan 200 data positif. Setelah dilakukan proses *balancing* menggunakan *class weight* dan *oversampling*, distribusi data menjadi seimbang. Karakteristik teks dalam dataset mencakup penggunaan bahasa informal, singkatan, sarkasme, dan campur kode, yang menjadi tantangan utama dalam analisis sentimen.

B. Hasil *Preprocessing*

Tahap *preprocessing* berhasil membersihkan teks dari elemen tidak relevan dan menormalisasi bahasa gaul.

Tabel 1. Contoh hasil *preprocessing*.

Teks Asli	Teks Setelah <i>Preprocessing</i>
"MBG jatah balita dan busui untuk 3 hari. di karenakan pake keringan banyak yang komplain"	"mbg jatah balita busui hari dikarenakan pakai keringan banyak komplain"
"Ini alasan MBG ga mau tutup pada saat hari libur panjang sekolah"	"alasan mbg tidak mau tutup saat hari libur panjang sekolah"

Normalisasi bahasa gaul seperti "ga" → "tidak", "pake" → "pakai", "saal" → "saat" terbukti meningkatkan konsistensi tokenisasi dan membantu model dalam mempelajari pola semantik yang lebih baik.

C. Hasil Pelatihan Model *Baseline*

Model *baseline* LSTM dengan konfigurasi 1 lapisan LSTM (50 unit), *dropout* 0,2, *learning rate* 0,001, dan 50 *epoch* menghasilkan performa sebagai berikut:

Tabel 2. Model *baseline* LSTM.

Metrik	Nilai
Akurasi	72,50%
Precision	0,718
Recall	0,725
F1-Score	0,721

Hasil ini menunjukkan bahwa model *baseline* mampu mempelajari pola dasar sentimen, namun masih memiliki keterbatasan dalam menangkap konteks kompleks pada teks informal.

D. Hasil Optimasi Arsitektur LSTM

Proses optimasi *hyperparameter* dilakukan menggunakan *grid search* dengan ruang pencarian.

Tabel 3. Proses optimasi *hyperparameter*.

<i>Hyperparameter</i>	Nilai yang Diuji
Jumlah unit LSTM	32, 64, 128
Jumlah <i>layer</i>	1, 2
<i>Dropout rate</i>	0,2; 0,3; 0,5
<i>Learning rate</i>	0,001
0,005	0,01
<i>Batch size</i>	16, 32, 64
<i>Optimizer</i>	Adam, RMSprop, SGD

Konfigurasi terbaik yang diperoleh adalah 2 layer LSTM (128 dan 64 unit), *dropout* 0,3, *learning rate* 0,005, *batch size* 32, dan *optimizer Adam*.

Tabel 4. Hasil evaluasi model teroptimasi.

Metrik	<i>Baseline</i>	Teroptimasi	Peningkatan
Akurasi	72,50%	86,75%	+14,25%
<i>Precision</i>	0,718	0,865	+0,147
<i>Recall</i>	0,725	0,868	+0,143
<i>F1-Score</i>	0,721	0,866	+0,145

Peningkatan akurasi sebesar 14,25% dan *F1-score* sebesar 0,145 menunjukkan bahwa optimasi arsitektur LSTM memberikan dampak signifikan terhadap performa model. Terjadinya peningkatan *precision* dan *accuracy* setelah optimasi

hyperparameter (Wicaksana & Suhud, 2026), *optimizer* Adam juga dapat memberikan performa terbaik pada data deret waktu (Enriko et al., 2023) .

E. Analisis Confusion Matrix

Confusion matrix untuk model teroptimasi menunjukkan:

		Prediksi	
		Positif	Negatif
Aktual	Positif	52 (TP)	8 (FN)
	Negatif	8 (FP)	52 (TN)

Grafik 3: *Confusion Matrix*.

Dengan TP = 52, TN = 52, FP = 8, dan FN = 8, model menunjukkan keseimbangan yang baik dalam mengklasifikasikan kedua kelas. TP (*True Positive*) adalah positif yang diprediksi positif. TN (*True Negative*) adalah negatif yang diprediksi negatif. FP (*False Positive*) adalah positif yang diprediksi negatif. FN (*False Negative*) adalah positif yang diprediksi negatif. Tingkat kesalahan yang relatif rendah pada kedua kelas mengindikasikan bahwa model tidak bias terhadap kelas tertentu.

F. Visualisasi Sentimen Publik

Visualisasi distribusi sentimen menunjukkan bahwa 52% opini publik terhadap Program MBG bersifat negatif, sedangkan 48% bersifat positif. Analisis tren sentimen dari waktu ke waktu mengungkapkan bahwa sentimen negatif cenderung meningkat pada periode tertentu, terutama terkait isu korupsi dan kualitas makanan. *Word cloud* dari teks positif dan negatif menunjukkan kata-kata dominan seperti "bergizi", "membantu", "korupsi", dan "mubazir".

G. Pembahasan

Hasil penelitian ini mengonfirmasi bahwa optimasi arsitektur LSTM secara signifikan meningkatkan akurasi analisis sentimen pada teks informal bahasa Indonesia. *LSTM-Bayesian Optimization* mampu menurunkan RMSE secara

konsisten (Hawali & Walid, 2025), serta menekankan pentingnya validasi temporal dalam evaluasi model (Prenata, 2026) .

Peningkatan performa model teroptimasi dapat dijelaskan oleh beberapa faktor. Pertama, penambahan lapisan LSTM memungkinkan model untuk menangkap pola temporal yang lebih kompleks, sebagaimana ditunjukkan bahwa *Stacked LSTM* cenderung menghasilkan performa lebih baik dibandingkan LSTM sederhana (Andika & Kusri, 2025). Kedua, penggunaan *dropout* yang tepat membantu mengurangi *overfitting*, terutama pada *dataset* dengan ukuran terbatas. Ketiga, *optimizer* Adam dengan *learning rate* yang dioptimasi mempercepat konvergensi model.

Dari perspektif praktis, model teroptimasi ini dapat digunakan sebagai alat bantu analisis sentimen publik terhadap kebijakan pemerintah. Informasi hasil prediksi dapat dimanfaatkan untuk menyusun strategi komunikasi publik, mengidentifikasi isu-isu kritis, serta mendukung pengambilan keputusan berbasis data. Hal ini sejalan dengan visi *evidence-based policymaking* yang menekankan pentingnya data dalam perumusan kebijakan.

4. SIMPULAN

Penelitian ini berhasil mengoptimalkan arsitektur LSTM untuk analisis sentimen terhadap Program Makan Bergizi Gratis (MBG). Konfigurasi terbaik yang diperoleh terdiri dari 2 layer LSTM (128 dan 64 unit), *dropout* 0,3, *learning rate* 0,005, *batch size* 32, dan *optimizer* Adam. Model teroptimasi mencapai akurasi 86,75%, *precision* 0,865, *recall* 0,868, dan F1-score 0,866, meningkat secara signifikan dibandingkan model *baseline* (akurasi 72,50%).

Kontribusi utama penelitian ini terletak pada penerapan optimasi arsitektur LSTM yang disesuaikan dengan karakteristik bahasa informal media sosial Indonesia, serta penerapannya pada domain kebijakan publik yang masih jarang dieksplorasi. Hasil penelitian ini diharapkan dapat menjadi dasar bagi pengembangan sistem analisis sentimen yang lebih akurat dan adaptif untuk mendukung perumusan kebijakan publik berbasis bukti.

Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi arsitektur *hybrid* seperti BiLSTM-*Attention* atau model berbasis *transformer* (IndoBERT) guna meningkatkan pemahaman konteks, serta memperluas cakupan data dengan variabel eksternal seperti sentimen pasar dan indikator makroekonomi.

5. DAFTAR PUSTAKA

- Andriani, W., Gunawan, G., & Naja, N. N. P. W. (2026). Optimasi bayesian pada model long short-term memory untuk prediksi harga saham perbankan Indonesia. *IT-EXPLORE: Jurnal Penerapan Teknologi Informasi dan Komunikasi*, vol. 5, no. 2, pp. 217–231. DOI: 10.24246/itexplore.v5i2.2026.
- B. E. S. Dewi (2025). Pengukuran Kemiripan Kalimat Bahasa Indonesia Menggunakan Representasi Word Embedding FastText, *Jurnal Teknologi Informasi dan Digital (TRIDI)*, vol. 2, no. 2, pp. 20–29.
- E. Amaia, A. N. Izzah, A. Akram, and N. Risal (2023). Klasifikasi Penyalahgunaan Pesan Singkat Menggunakan Algoritma Naïve Bayes, *Jurnal Ilmu Komputer dan Teknologi Informasi*, vol. 8, no. 1.
- G. Widjaja (2025). Perubahan Pola Komunikasi dalam Masyarakat Akibat Penggunaan Aplikasi Pesan Instan, *Prosiding Seminar Nasional Indonesia*, vol. 3, pp. 10–16.
- G. D. Prenata (2026). Evaluasi Komparatif DFFNN, DFFNN-GA, DFFNN-GWO, dan LSTM untuk Prediksi Konsumsi Energi Listrik dengan Sliding Window Cross-Validation, *Techné Jurnal Ilmiah Elektroteknika*, vol. 25, no. 1, pp. 91–104.
- Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems With Applications*, 227, 120346. <https://doi.org/10.1016/j.eswa.2023.120346>.
- H. S. Wicaksana and H. Suhud (2026). Peningkatan Performansi Deteksi Pesan Spam Melalui Optimasi LSTM Berbasis Word2Vec dan Grid Search, *JITE (Jurnal Informatika dan Teknologi Informasi)*, vol. 2, no. 1.
- I. S. Kervanci, M. F. Akay, and E. Ozceylan (2023). Bitcoin Price Prediction using LSTM, GRU and Hybrid LSTM-GRU with Bayesian Optimization, Random Search, And GRID SEARCH for the Next Days, *Journal of Industrial and Management Optimization*, pp. 1–19.
- I. K. A. Enriko, F. N. Gustiyana, and R. H. Putra (2023). Komparasi Hasil Optimasi Pada Prediksi Harga Saham PT. Telkom Indonesia Menggunakan Algoritma Long Short Term Memory, *Jurnal Media Informatika Budidarma*, vol. 7, no. 2, pp. 659–667.

- Ma'aly, A. N., Pramesti, D., Fathurahman, A. D., & Fakhurroja, H. (2024). Exploring sentiment analysis for the Indonesian presidential election through online reviews using multi-label classification with a deep learning algorithm. *Information*, 15(11), 705. <https://doi.org/10.3390/info15110705>
- M. L. Hawali and Walid (2025). Pemilihan Neuron LSTM dan LSTM Bayesian Optimization Untuk Prediksi Curah Hujan Bulanan Berbasis Iklim, *Jurnal Fasikom*, vol. 15, no. 2, pp. 376–382.
- Nugroho, D., & Ardhianto, E. (2026). Pengembangan model prediksi saham perbankan Indonesia dengan optimasi algoritma Long Short-Term Memory (LSTM). *AITI: Jurnal Teknologi Informasi*, vol. 23, no. 2, pp. 231–244.
- R. Andika and Kusrini (2025). Optimasi Hyperparameter Model LSTM dan Variannya untuk Peramalan Pembelian Bahan Baku Karet Alam, *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 3, pp. 2627–2639.
- R. Z. N. Ahmad, N. S. Harahap, S. Agustian, I. Iskandar, and S. Sanjaya (2025). Perbandingan Performa Random Forest dan Long Short-Term Memory dalam Klasifikasi Teks Multilabel Terjemahan Hadits Bukhari, *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 3, pp. 862–874.
- S. Hochreiter and J. Schmidhuber (1997). Long Short-Term Memory, *Neural Computation*, vol. 9, no. 8, pp. 1735–1780.