

ANALISIS SENTIMEN OPINI PUBLIK TERHADAP PROGRAM MAKAN BERGIZI GRATIS (MBG) DI MEDIA SOSIAL MENGGUNAKAN MAMBA (*SELECTIVE STATE SPACE MODEL*)

daerobby@polka.ac.id,^{1*} dedy.arisandi@polka.ac.id,² shodik.nuryadhin@polka.ac.id,³

¹ Politeknik Krakatau Cilegon

² Politeknik Krakatau Cilegon

³ Politeknik Krakatau Cilegon

*Corresponding author: daerobby@polka.ac.id

Article history

Received:

04-01-2026

Accepted:

25-02-2026

Published:

01-03-2026

Copyright © 2026
Jurnal Manajemen
dan Teknik

Open Access

Abstrak

Program Makan Bergizi Gratis (MBG) merupakan salah satu kebijakan pemerintah Indonesia yang menuai beragam respons dari masyarakat di media sosial. Penelitian ini bertujuan untuk menganalisis sentimen opini publik terhadap program MBG menggunakan pendekatan deep learning berbasis Mamba (*Selective State Space Model*). Dataset yang digunakan terdiri dari 6.270 komentar *YouTube* yang telah melalui proses *preprocessing* dan pelabelan semi-otomatis menggunakan IndoBERT dan *lexicon-based*. Arsitektur Mamba dipilih karena memiliki kompleksitas komputasi linear $O(n)$ yang lebih efisien dibandingkan Transformer. Hasil eksperimen menunjukkan bahwa model Mamba mampu mencapai performa yang unggul dengan *accuracy* 63,16% dan *F1-Score* 0,6466 dalam klasifikasi sentimen tiga kelas (positif, negatif, netral), mengungguli model *baseline* BiLSTM-Attention (*accuracy* 56,46%) dan TextCNN (*accuracy* 59,49%). Penelitian ini memberikan kontribusi berupa penerapan arsitektur Mamba yang masih jarang digunakan dalam domain analisis sentimen berbahasa Indonesia.

Kata Kunci: Analisis Sentimen, Mamba, *Selective State Space Model*, Deep Learning, Makan Bergizi Gratis, NLP

Abstract

The Free Nutritious Meal Program (Makan Bergizi Gratis/MBG) is one of the Indonesian government's policies that has drawn a wide range of public responses on social media. This study aims to analyze public sentiment toward the MBG program using a deep learning approach based on Mamba (*Selective State Space Model*). The dataset used consists of 6,270 YouTube comments that underwent preprocessing and semi-automatic labeling using IndoBERT and a lexicon-based approach. The Mamba architecture was selected for its linear computational complexity $O(n)$, which is more efficient than that of the Transformer. The experimental results show that the Mamba model achieved superior performance with an accuracy of 63.16% and an F1-Score of 0.6466 in three-class sentiment classification (positive, negative, neutral), outperforming the baseline models BiLSTM-Attention (56.46% accuracy) and TextCNN (59.49% accuracy). This study contributes the application of the Mamba architecture, which remains rarely used in the domain of Indonesian-language sentiment analysis.

Keywords: Sentiment Analysis, Mamba, *Selective State Space Model*, Deep Learning, Free Nutritious Meal Program, NLP

1.0 PENDAHULUAN

Program Makan Bergizi Gratis (MBG) merupakan salah satu program unggulan pemerintahan Presiden Prabowo Subianto yang diluncurkan pada tahun 2025. Program ini bertujuan untuk meningkatkan gizi anak-anak sekolah di seluruh Indonesia melalui penyediaan makanan bergizi secara gratis [1]. Sejak

peluncurannya, program ini menuai beragam respons dari masyarakat, mulai dari dukungan atas manfaat gizi yang dirasakan hingga kritik terkait tata kelola, transparansi anggaran, dan potensi penyimpangan [2].

Media sosial, khususnya *YouTube*, menjadi salah satu wadah utama bagi masyarakat untuk menyampaikan opini terkait program MBG. Analisis sentimen terhadap opini publik ini menjadi penting untuk memahami

persepsi masyarakat secara luas dan memberikan masukan bagi evaluasi kebijakan [3].

Dalam bidang Natural Language Processing (NLP), analisis sentimen telah banyak dilakukan menggunakan berbagai pendekatan deep learning seperti Long Short-Term Memory (LSTM) [4], *Convolutional Neural Network* (CNN) [5], dan model berbasis Transformer seperti *BERT* [6]. Namun, arsitektur Transformer memiliki keterbatasan berupa kompleksitas kuadratik $O(n^2)$ yang menjadi bottleneck pada pemrosesan sekuens panjang [7].

Pada tahun 2023, Gu dan Dao memperkenalkan arsitektur Mamba (*Selective State Space Model*) yang menawarkan kompleksitas linear $O(n)$ dengan kemampuan pemodelan sekuens yang kompetitif terhadap Transformer [8]. Arsitektur ini menggunakan mekanisme seleksi input-dependent pada parameter state space, sehingga mampu memfilter informasi secara kontekstual tanpa memerlukan mekanisme attention yang mahal secara komputasi.

Penelitian ini bertujuan untuk: (1) menganalisis sentimen opini publik terhadap program MBG di YouTube; (2) menerapkan arsitektur Mamba untuk klasifikasi sentimen teks berbahasa Indonesia; dan (3) membandingkan performa Mamba dengan model *baseline BiLSTM-Attention* dan TextCNN.

2.0 TINJAUAN PUSTAKA

2.1 Analisis Sentimen

Analisis sentimen adalah proses komputasi untuk mengidentifikasi dan mengkategorikan opini yang diekspresikan dalam teks, khususnya untuk menentukan apakah sikap penulis terhadap suatu topik bersifat positif, negatif, atau netral [3]. Dalam konteks media sosial berbahasa Indonesia, analisis sentimen menghadapi tantangan tambahan berupa penggunaan bahasa informal, singkatan, bahasa daerah, dan campuran kode (*code-mixing*) [9].

2.2 Long Short-Term Memory (LSTM)

LSTM merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah vanishing gradient [4]. *Bidirectional LSTM* (BiLSTM) memproses sekuens dari dua arah sehingga mampu menangkap konteks yang lebih kaya. Penambahan mekanisme attention pada BiLSTM terbukti meningkatkan performa pada tugas klasifikasi teks [10].

2.3 Convolutional Neural Network untuk Teks (TextCNN)

Kim (2014) memperkenalkan *TextCNN* yang menggunakan operasi konvolusi satu dimensi dengan *multiple filter sizes* untuk mengekstrak fitur *n-gram* dari teks [5]. *TextCNN* memiliki keunggulan dalam kecepatan komputasi dan kemampuan menangkap pola lokal dalam teks.

2.4 Transformer dan Keterbatasannya

Arsitektur Transformer yang diperkenalkan oleh Vaswani et al. (2017) menggunakan mekanisme self-attention yang mampu menangkap dependensi jarak

jauh [7]. Namun, *self-attention* memiliki kompleksitas kuadratik $O(n^2)$ terhadap panjang sekuens, yang menjadi kendala pada pemrosesan teks panjang.

2.5 Mamba (Selective State Space Model)

Mamba diperkenalkan oleh Gu dan Dao (2023) sebagai arsitektur *sequence modeling* generasi baru [8]. Berbeda dari *State Space Model* (SSM) tradisional yang menggunakan parameter tetap, Mamba menggunakan mekanisme seleksi di mana parameter B (*input*), C (*output*), dan Δ (*discretization step*) di-generate secara input-dependent. Hal ini memungkinkan model untuk secara selektif memfilter informasi yang relevan dengan kompleksitas linear $O(n)$.

Komponen utama arsitektur Mamba meliputi:

- Selective Scan:** Mekanisme inti yang melakukan *state space computation* secara input-dependent.
- Causal Convolution:** Konvolusi satu dimensi untuk menangkap pola lokal
- Gating Mechanism:** Menggunakan *SiLU activation* untuk mengontrol aliran informasi
- Residual Connection:** Koneksi residual untuk memfasilitasi training yang stabil

2.6 Penelitian Terkait

Beberapa penelitian terkait analisis sentimen berbahasa Indonesia menggunakan *deep learning* antara lain:

- Koto et al. (2020) mengembangkan IndoBERT, model bahasa *pre-trained* untuk Bahasa Indonesia, yang mencapai *state-of-the-art* pada berbagai tugas NLP Indonesia [11].
- Purwarianti dan Crisdayanti (2019) melakukan analisis sentimen pada teks berbahasa Indonesia menggunakan BiLSTM dengan word embedding [12].
- Wongso et al. (2022) membandingkan performa CNN, LSTM, dan BERT untuk analisis sentimen teks media sosial Indonesia [13].

Sejauh pengetahuan penulis, belum terdapat penelitian yang menerapkan arsitektur Mamba untuk analisis sentimen teks berbahasa Indonesia, sehingga penelitian ini memiliki kebaruan (*novelty*) yang signifikan.

3.0 METODOLOGI

3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari komentar *YouTube* terkait program Makan Bergizi Gratis (MBG). Data dikumpulkan menggunakan *YouTube Data API v3* dari berbagai *video* berita dan diskusi tentang MBG. *Detail dataset:*

Tabel 3.1 Karakteristik Dataset Penelitian

Parameter	Nilai
Sumber	Komentar <i>YouTube</i>
Topik	Program MBG
Jumlah data mentah	6.419 komentar
Jumlah setelah cleaning	6.270 komentar
Rentang waktu	April 2025 – Maret 2026
Jumlah author unik	5.860

3.2 Preprocessing

Tahapan preprocessing yang dilakukan meliputi:

1. *Decode HTML entities* : Mengubah '&' menjadi '&', '"' menjadi '"', dll.
2. Penghapusan HTML *tags* : Menghapus tag '
', '<a>', '', dll.
3. Penghapusan URL: Menghapus tautan yang terdapat dalam komentar.
4. Penghapusan *mention*: Menghapus pola '@username'.
5. Penghapusan emoji: Menghapus karakter emoji *Unicode*.
6. Normalisasi teks: *Case-folding* ke huruf kecil, penghapusan karakter khusus, dan normalisasi spasi.
7. Penghapusan duplikasi: Menghapus 80 komentar duplikat.
8. Filter panjang minimum: Menghapus 69 komentar dengan panjang kurang dari 5 karakter.

3.3 Pelabelan Sentimen


Pelabelan dilakukan secara semi-otomatis menggunakan pendekatan *ensemble*:

1. **IndoBERT Sentiment Classifier** : Menggunakan model pre-trained 'mdhugol/indonesia-bert-sentiment-classification' untuk melabeli sentimen secara otomatis [11].
2. **Lexicon-Based**: Menggunakan kamus sentimen Bahasa Indonesia (diadaptasi dari InSet - Indonesia *Sentiment Lexicon*) yang berisi 95 kata positif dan 120 kata negatif beserta skornya [14].
3. **Ensemble Voting**: Menggabungkan hasil kedua metode dengan prioritas pada *IndoBERT* (*confidence* > 0.85) dan *Lexicon* (skor absolut > 3).

Distribusi hasil pelabelan:

Tabel 3.2. Distribusi Sentimen Komentar *YouTube* Program MBG.

Sentimen	Jumlah	Persentase
Negatif	4.132	65,9%
Positif	1.253	20,0%
Netral	885	14,1%
Total	6.270	100%



Gambar 3.1 Distribusi Sentimen

Sebagaimana terlihat pada Gambar 3.1, dataset menunjukkan ketidakseimbangan kelas (*class imbalance*) yang cukup signifikan. Kelas negatif mendominasi dengan 4.132 data (65,9%), jauh melampaui kelas positif (1.253 data, 20,0%) dan netral

(885 data, 14,1%). Ketidakseimbangan ini mencerminkan kecenderungan pengguna *YouTube* untuk lebih aktif menyuarakan ketidakpuasan dibandingkan dukungan terhadap program MBG. Kondisi ini juga menjadi tantangan teknis dalam pelatihan model, sehingga diatasi dengan penerapan *class weighting* pada fungsi *loss*.

3.4 Arsitektur Model

3.4.1 Mamba Sentiment Classifier (Model Utama)

Arsitektur model Mamba yang diusulkan terdiri dari:

- a. **Embedding Layer**: *Word embedding* ($d = 128$) + *positional embedding*.
- b. **Mamba Blocks**: 4 blok Mamba berturut-turut, masing-masing terdiri dari *LayerNorm*, *SelectiveSSM*, dan *residual connection*.
- c. **Global Average Pooling**: Agregasi representasi sekuens dengan masking pada *padding*.
- d. **Classification Head**: MLP dua lapis dengan aktivasi GELU.

Parameter Selective SSM:

- a. Dimensi *state space* (d_{state}): 16
- b. Kernel konvolusi (d_{conv}): 4
- c. *Expansion factor*: 2

3.4.2 BiLSTM-Attention (Baseline 1)

Model *baseline* pertama menggunakan arsitektur *Bidirectional LSTM* dua lapis dengan mekanisme *self-attention* dan *classification head* MLP.

3.4.3 TextCNN (Baseline 2)

Model *baseline* kedua menggunakan arsitektur *TextCNN* dengan tiga kernel konvolusi paralel berukuran 3, 4, dan 5, masing-masing menghasilkan 128 *feature maps*, diikuti *max pooling* dan *classification head* MLP.

3.5 Konfigurasi Training

Tabel 3.4. Konfigurasi Hyperparameter Model CNN-LSTM

Parameter	Nilai
<i>Vocabulary size</i>	15.000
<i>Max sequence length</i>	128
<i>Dimensi embedding</i>	128
<i>Batch size</i>	64
<i>Learning rate</i>	0,001
<i>Optimizer</i>	AdamW (<i>weight decay</i> = $1e-4$)
<i>Scheduler</i>	<i>Cosine Annealing</i>
<i>Epochs</i>	20 (+ <i>early stopping</i> , <i>patience</i> = 5)
<i>Split data</i>	80% train / 10% validasi / 10% test
<i>Loss function</i>	<i>Cross-Entropy</i> dengan <i>class weighting</i>

Class weighting digunakan untuk menangani ketidakseimbangan kelas (*imbalanced dataset*).

3.6 Metrik Evaluasi

Evaluasi dilakukan menggunakan empat metrik standar:

- Accuracy*: Proporsi prediksi benar dari keseluruhan data.
- Precision (Weighted)*: Rata-rata tertimbang presisi per kelas.
- Recall (Weighted)*: Rata-rata tertimbang *recall* per kelas.
- F1-Score (Weighted)*: Rata-rata harmonik tertimbang dari *precision* dan *recall*

4.0 HASIL DAN PEMBAHASAN

4.1 Distribusi Sentimen

Hasil analisis menunjukkan bahwa mayoritas opini publik terhadap program MBG bersifat negatif (65,9%), diikuti oleh positif (20,0%) dan netral (14,1%). Dominasi sentimen negatif ini mengindikasikan bahwa sebagian besar masyarakat di platform YouTube memiliki kekhawatiran atau ketidakpuasan terhadap berbagai aspek program MBG, termasuk tata kelola, transparansi anggaran, dan kualitas makanan yang disajikan.


Sentimen positif umumnya berkaitan dengan apresiasi terhadap manfaat gizi bagi anak sekolah, dampak ekonomi bagi UMKM dan pelaku usaha lokal, serta dukungan terhadap visi program. Sementara itu, sentimen netral meliputi komentar informatif, pertanyaan, dan opini yang tidak menunjukkan keberpihakan jelas.

4.2 Perbandingan Performa Model

Tabel 4.1 Perbandingan Performa Model

Model	Parameter	Accuracy	F1-Score	Precision	Recall
Mamba (S6)	2.298 .115	63,16 %	0,64 66	0,6728	0,63 16
BiLSTM-Attention	2.612 .996	56,46 %	0,59 17	0,6626	0,56 46
TextCNN	2.166 .659	59,49 %	0,62 10	0,6758	0,59 49

Hasil perbandingan pada Tabel 1 menunjukkan bahwa model Mamba (S6) unggul pada metrik *Accuracy* dan *F1-Score* dibandingkan kedua *baseline*. Visualisasi perbandingan keempat metrik evaluasi antar model serta kurva *validation accuracy* disajikan pada Gambar 2.




Gambar 4.1 Perbandingan metrik evaluasi antar model

Pada panel kiri Gambar 3.1, model Mamba (S6) secara konsisten mengungguli BiLSTM-Attention dan TextCNN pada Accuracy (63,16% vs. 56,46% vs. 59,49%) dan *F1-Score* (0,6466 vs. 0,5917 vs. 0,6210). Untuk metrik *Precision*, ketiga model menunjukkan nilai yang relatif berdekatan (0,67–0,68), mengindikasikan tingkat ketepatan prediksi per kelas yang serupa.

Perbedaan paling signifikan terlihat pada *Recall*, di mana Mamba (0,6316) jauh lebih unggul dibandingkan *BiLSTM-Attention* (0,5646). Panel kanan memperlihatkan kurva *validation accuracy* model baseline selama pelatihan, di mana TextCNN menunjukkan konvergensi yang lebih cepat namun dengan fluktuasi yang lebih tinggi dibandingkan *BiLSTM-Attention*.

Grafik riwayat pelatihan model Mamba disajikan pada Gambar 4.2 berikut.




Gambar 4.2 Kurva *loss* (kiri) dan *accuracy* (kanan)

model Mamba selama proses pelatihan

Gambar 4.2 memperlihatkan dua fenomena penting selama pelatihan model Mamba. Pertama, kurva *training loss* (biru) menunjukkan penurunan yang konsisten dari ~1,16 hingga ~0,75, mengindikasikan bahwa model berhasil meminimalkan kesalahan pada data latih secara bertahap. Kedua, kurva *validation loss* (merah) cenderung stagnan dan meningkat setelah epoch ke-5, yang merupakan gejala awal *overfitting*. Sejalan dengan itu, *training accuracy* terus meningkat hingga di atas 75%, sementara *validation accuracy* stabil di kisaran 58–63%. Selisih performa antara data latih dan validasi (~14%) mengindikasikan bahwa model perlu regularisasi tambahan atau data yang lebih bervariasi. Mekanisme *early stopping* diterapkan untuk memastikan model yang disimpan adalah model dengan performa validasi terbaik.

4.3 Analisis Confusion Matrix

Berdasarkan hasil pengujian pada data uji (*test set*), *confusion matrix* untuk model Mamba ditampilkan pada Gambar 4.3.




Gambar 4.3 Confusion Matrix

- Kelas Negatif:** Memiliki *recall* tertinggi sebesar 69,5% (287 dari 413 data). Hal ini dikarenakan kelas negatif merupakan kelas mayoritas, sehingga model memiliki data latih yang cukup untuk mengenali pola sentimen negatif secara akurat.
- Kelas Positif:** Model berhasil mengenali 50,4% data positif. Kesalahan klasifikasi paling banyak terjadi

pada kelas ini, di mana 41 data positif diprediksi sebagai negatif. Hal ini kemungkinan disebabkan oleh penggunaan kata-kata bermakna positif dalam konteks kalimat yang ambigu atau mengandung sarkasme.

- c. **Kelas Netral:** Berhasil diklasifikasikan dengan akurasi 51,7%. Meskipun jumlah datanya paling sedikit, model Mamba menunjukkan kemampuan yang cukup baik dalam membedakan komentar netral dari sentimen negatif.

Perbandingan *confusion matrix* antara kedua model baseline disajikan pada Gambar 4.5.



Gambar 4.5 *Confusion matrix* model baseline: *BiLSTM-Attention* (kiri) dan *TextCNN* (kanan) pada data uji

Dari Gambar 4.5, terlihat perbedaan yang mencolok dibandingkan model Mamba (Gambar 4.3). Model *BiLSTM-Attention* hanya mampu mengklasifikasikan 243 data negatif dengan benar (vs. 287 pada Mamba) dan menunjukkan *misclassification* tertinggi pada kelas negatif-netral dengan 110 data negatif diprediksi sebagai netral. Model *TextCNN* memiliki prediksi negatif yang sedikit lebih baik (269 benar), namun masih lebih rendah dari Mamba. Pada kelas positif, kedua baseline (55/125 untuk *BiLSTM-Attention* dan 54/125 untuk *TextCNN*) juga lebih lemah dibandingkan Mamba (63/125), mengkonfirmasi bahwa mekanisme selektif Mamba lebih efektif dalam menangani ambiguitas leksikal pada teks bahasa Indonesia.

4.4 Pembahasan

Arsitektur Mamba menunjukkan performa yang unggul dibandingkan model baseline *BiLSTM-Attention* dan *TextCNN*, dengan peningkatan akurasi masing-masing sebesar 6,7% dan 3,67%. Beberapa temuan penting dari penelitian ini:

1. **Efektivitas *Selective Mechanism*:** Keunggulan Mamba terletak pada mekanisme seleksi yang memungkinkan model untuk memfilter informasi yang tidak relevan secara dinamis. Dalam analisis sentimen teks informal, kemampuan ini sangat krusial untuk menangani *noise* seperti *slang* dan singkatan.
2. **Performa per Kelas:** Meskipun dataset tidak seimbang, penggunaan *class weighting* membantu model untuk tidak terlalu bias pada kelas mayoritas. Mamba terbukti lebih unggul dalam mengenali sentimen positif dibandingkan *baseline*, yang menunjukkan kemampuan pemodelan sekuens yang lebih tajam.
3. **Efisiensi Parameter:** Mamba mencapai performa tertinggi dengan jumlah parameter (~2,3 juta) yang lebih efisien dibandingkan *BiLSTM-Attention* (~2,6 juta). Hal ini membuktikan bahwa arsitektur *State Space Model* (SSM) generasi baru ini menawarkan

trade-off yang sangat baik antara performa dan kompleksitas model.

4. **Tantangan *Overfitting*:** Meskipun telah diterapkan berbagai teknik regularisasi (dropout 0.4, label smoothing 0.1, *weight decay* $1e-4$), model masih menunjukkan gejala *overfitting* ringan dengan selisih akurasi *train-val* sekitar 14%. Hal ini menunjukkan tantangan dalam generalisasi pada dataset media sosial yang sangat dinamis.

5.0 KESIMPULAN

Penelitian ini telah berhasil menerapkan arsitektur Mamba (*Selective State Space Model*) untuk analisis sentimen opini publik terhadap program Makan Bergizi Gratis (MBG) di media sosial *YouTube*. Dari 6.270 komentar yang dianalisis, mayoritas opini bersifat negatif (65,9%), menunjukkan bahwa masyarakat memiliki kekhawatiran signifikan terhadap implementasi program ini.

Model Mamba menunjukkan performa yang unggul dengan *accuracy* 63,16% dan *F1-Score* 0,6466, melampaui performa model baseline *BiLSTM-Attention* (56,46%) dan *TextCNN* (59,49%). Hasil ini membuktikan bahwa arsitektur Mamba memiliki kemampuan pemodelan sekuens yang sangat efektif untuk tugas *Natural Language Processing*, khususnya pada teks berbahasa Indonesia yang informal.

DAFTAR PUSTAKA

- [1] Badan Gizi Nasional, "Program Makan Bergizi Gratis: Panduan Pelaksanaan," Jakarta: Kementerian Kesehatan RI, 2025.
- [2] Indonesia Corruption Watch (ICW), "Laporan Investigasi: Tata Kelola Program Makan Bergizi Gratis," Jakarta: ICW, 2026.
- [3] B. Liu, "Sentiment Analysis and Opinion Mining," *Synthesis Lectures on Human Language Technologies*, vol. 5, no. 1, pp. 1–167, 2012. doi: 10.2200/S00416ED1V01Y201204HLT016.
- [4] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997. doi: 10.1162/neco.1997.9.8.1735.
- [5] Y. Kim, "Convolutional Neural Networks for Sentence Classification," in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1746–1751, 2014. doi: 10.3115/v1/D14-1181.
- [6] J. Devlin, M. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding," in *Proceedings of NAACL-HLT*, pp. 4171–4186, 2019.
- [7] A. Vaswani *et al.*, "Attention Is All You Need," in *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 30, 2017.
- [8] A. Gu and T. Dao, "Mamba: Linear-Time Sequence Modeling with Selective State Spaces," *arXiv preprint arXiv:2312.00752*, 2023.
- [9] F. Koto, A. Rahimi, J. H. Lau, and T. Baldwin, "IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP," in *Proceedings of COLING*, pp. 757–770, 2020.

- [10] P. Zhou *et al.*, "Attention-Based Bidirectional Long Short-Term Memory Networks for Relation Classification," in *Proceedings of ACL*, pp. 207–212, 2016.
- [11] M. D. Hugol, "Indonesia BERT Sentiment Classification," HuggingFace Model Hub, 2023. [Online]. Available: <https://huggingface.co/mdhugol/indonesia-bert-sentiment-classification>
- [12] A. Purwarianti and I. A. P. A. Crisdayanti, "Improving Bi-LSTM Performance for Indonesian Sentiment Analysis Using Paragraph Vector," in *Proceedings of ICOICT*, pp. 1–5, 2019. doi: 10.1109/ICOICT46769.2019.8987469.
- [13] R. Wongso, F. A. Luwinda, B. C. Trisnajaya, O. Rusli, and D. Rudy, "News Sentiment Analysis Using BERT, LSTM, and CNN," *Procedia Computer Science*, vol. 216, pp. 150–159, 2022. doi: 10.1016/j.procs.2022.12.122.
- [14] F. N. Fajri and M. L. Khodra, "InSet Lexicon: Evaluation of a Word List for Indonesian Sentiment Analysis in Microblogs," in *Proceedings of IALP*, pp. 391–394, 2017. doi: 10.1109/IALP.2017.8300625.
- [15] A. Gu, K. Goel, and C. Ré, "Efficiently Modeling Long Sequences with Structured State Spaces," in *International Conference on Learning Representations (ICLR)*, 2022.
- [16] A. Gu and T. Dao, "Mamba-2: Structured State Space Duality," *arXiv preprint arXiv:2405.21060*, 2024.
- [17] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in *Proceedings of ICLR*, 2015.
- [18] I. Loshchilov and F. Hutter, "Decoupled Weight Decay Regularization," in *Proceedings of ICLR*, 2019.