

Pengembangan Model Deteksi Hoaks Berbahasa Indonesia Menggunakan Kombinasi *IndoBERT* dan *BiLSTM*

Lim Bodhi Wijaya¹, Yosef Nuraga Wicaksana², Sri Saraswati Widhiasari³, Ari Saptawijaya⁴

¹Fakultas Ilmu Komputer Universitas Indonesia, Depok, 16425 Indonesia, email: lim.bodhi@ui.ac.id

²Fakultas Ilmu Komputer Universitas Indonesia, Depok, 16425 Indonesia, email: yosef.nuraga@ui.ac.id

³Fakultas Ilmu Komputer Universitas Indonesia, Depok, 16425 Indonesia, email: sri.saraswati21@ui.ac.id

⁴Fakultas Ilmu Komputer Universitas Indonesia, Depok, 16425 Indonesia, email: saptawijaya@cs.ui.ac.id

Corresponding Author: Ari Saptawijaya

ABSTRAK — Hoaks merupakan informasi yang secara sengaja dibuat untuk menyesatkan pembaca. Hoaks umumnya mempunyai karakteristik struktur bahasa yang tidak rapi dan penggunaan kosakata yang bernuansa emosional. Penyebaran hoaks yang cepat dan masif membuat pendeteksian hoaks secara otomatis melalui pendekatan *machine learning* dibutuhkan. Pendeteksian hoaks merupakan salah satu bentuk implementasi klasifikasi teks yang dapat dilakukan dengan pemrosesan linguistik secara kontekstual. Penelitian terdahulu memanfaatkan *Convolutional Neural Network (CNN)* dan *Long-Short Term Memory (LSTM)* untuk melakukan klasifikasi teks. Dalam penelitian selanjutnya, *Bidirectional Encoder Representation from Transformers (BERT)* mulai diperkenalkan dan banyak digunakan dalam melakukan klasifikasi teks. *Indonesian Bidirectional Encoder Representation from Transformers (IndoBERT)* merupakan BERT yang dikembangkan untuk dapat melakukan klasifikasi teks dalam bahasa Indonesia. Penelitian kali ini bertujuan untuk mengeksplorasi potensi peningkatan performa model *machine learning* dalam mendeteksi hoaks dengan mengkombinasikan IndoBERT dan *Bidirectional LSTM (BiLSTM)*. Peneliti mengusulkan dan menguji tiga model yang berbeda: IndoBERT-BC menggunakan *fine tuning approach*, IndoBERT-BiC menggunakan *feature-based approach*, dan IndoBERT-CC menggunakan kombinasi dari dua pendekatan tersebut. *Dataset* yang digunakan berasal dari portal berita CNN Indonesia untuk berita bukan hoaks dan TurnBackHoax.ID untuk berita hoaks. Dalam menentukan model terbaik kami melakukan evaluasi dengan menggunakan skor akurasi, skor F1, serta skor *Receiver Operating Characteristic Area Under the Curve (ROC_AUC)*. Dari tiga model tersebut, model IndoBERT-CC menghasilkan rata-rata skor ROC_AUC sebesar 0,999, serta rata-rata skor F1 dan akurasi masing - masing sebesar 0,988. Nilai ini lebih tinggi dibandingkan nilai skor F1, akurasi, dan ROC_AUC dari IndoBERT-BC dan IndoBERT-BiC.

KATA KUNCI — IndoBERT, BiLSTM, Deteksi Hoaks, Klasifikasi Teks

ABSTRACT — Hoaxes are information that is intentionally created to mislead readers. Hoaxes are generally characterized by sloppy language structure and emotionally charged vocabulary. The rapid and massive spread of hoaxes makes automatic hoax detection through machine learning approaches necessary. Hoax detection is one form of text classification that can be done with contextual linguistic processing. Previous research utilized *Convolutional Neural Network (CNN)* and *Long-Short Term Memory (LSTM)* to perform text classification. Subsequently, *Bidirectional Encoder Representation from Transformers (BERT)* was introduced and widely used in text classification. *Indonesian Bidirectional Encoder Representation from Transformers (IndoBERT)* is a BERT developed to perform text classification for Indonesian language. This research aims to explore the possibility of improving the performance of machine learning models in detecting hoaxes by combining IndoBERT and *Bidirectional LSTM (BiLSTM)*. We proposed and tested three different models: IndoBERT-BC using a *fine tuning approach*, IndoBERT-BiC using a *feature-based approach*, and IndoBERT-CC using a combination of the aforementioned two approaches. We used the dataset from CNN Indonesia news portal for non hoax news and TurnBackHoax.ID for hoax news. In finding out the best model, we took into account the accuracy score, F1 score, and *Receiver Operating Characteristic Area Under the Curve (ROC_AUC)* score. Of the three models, the IndoBERT-CC model produced an average ROC_AUC score of 0.999, along with average F1 score and accuracy of 0.988. This value is higher than the F1 score, accuracy, ROC_AUC score of IndoBERT-BC and IndoBERT-BiC.

KEYWORD — IndoBERT, BiLSTM, Hoax Detection, Text Classification

I. PENDAHULUAN

Sebagai makhluk sosial, manusia membutuhkan makhluk lain dalam menjalani kehidupannya. Penyebaran informasi menjadi faktor utama pendukung akan kebutuhan interaksi tersebut. Informasi tidak benar yang disebarluaskan secara masif dapat memicu permasalahan yang krusial. Hoaks adalah informasi yang tidak berdasarkan fakta atau data, tetapi tipuan untuk memperdaya masyarakat dengan model penyebaran yang masif [1]. Penyebaran hoaks seperti kasus Ratna Sarumpaet yang terjadi pada tahun 2018 [2], mengakibatkan kegaduhan di masyarakat yang ditandai dengan banyak tokoh publik dan masyarakat tertipu serta semakin memanasnya suasana politik saat itu. Penyebaran hoaks yang cepat dan masif berdampak pada kebutuhan akan model *machine learning* yang dapat mendeteksi hoaks secara akurat.

Pada penelitian sebelumnya, *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) pada *Natural Language Processing* (NLP) telah digunakan untuk melakukan deteksi hoaks dalam bahasa Indonesia [3, 4]. Meskipun CNN dan LSTM sudah cukup baik dalam melakukan klasifikasi teks, model-model tersebut memiliki kekurangan dalam hal pemahaman konteks antarkata. *Bidirectional Long-Short Term Memory* (BiLSTM) kemudian hadir sebagai solusi dari permasalahan tersebut. BiLSTM memungkinkan *concatenation* antara konteks kata di sebelah kiri dan kanan sehingga dapat meningkatkan pemahaman kontekstual. Seiring berjalannya waktu, *Bidirectional Representation from Transformers* (BERT) yang merupakan model berbasis *Transformers* hadir dengan beberapa kelebihan utama, seperti kemampuan untuk melakukan *parallel training* yang berdampak pada efisiensi waktu untuk *training model*, serta kemampuan memahami konteks secara lebih baik secara dua arah. Untuk dapat menangkap konteks kalimat dalam bahasa Indonesia dengan lebih baik, khususnya pada tugas-tugas NLP, IndoBERT [5] diperkenalkan sebagai model dengan arsitektur BERT-Base yang dilatih menggunakan dataset bahasa Indonesia.

II. TUJUAN

Tujuan penelitian ini adalah untuk melakukan eksplorasi potensi peningkatan kemampuan deteksi hoaks pada model yang mengkombinasikan IndoBERT dan BiLSTM. Terdapat tiga model berbeda yang diusulkan dan dievaluasi, yaitu IndoBERT-BC menggunakan *fine tuning approach*, IndoBERT-BiC menggunakan *feature-based approach*, dan IndoBERT-CC menggunakan kombinasi dari dua pendekatan tersebut. Peningkatan performa dievaluasi dengan menggunakan skor akurasi, skor F1, serta skor *Receiver Operating Characteristic Area Under the Curve* (ROC_AUC).

III. METODOLOGI

Bagian ini menjelaskan *dataset* yang digunakan untuk *training* dan validasi, penentuan parameter, penjelasan mengenai tiga model yang dibuat, serta metrik yang digunakan untuk mengevaluasi performa model dalam mendeteksi hoaks.

A. DATASET dan PARAMETER

Dataset yang digunakan dalam penelitian berjumlah 15.000 artikel yang berupa kumpulan artikel dari portal berita CNN Indonesia sebanyak 7537 artikel sebagai data bukan

hoaks dan dari TurnBackHoax.ID sebanyak 7463 artikel sebagai data hoaks. Data yang telah dikumpulkan kemudian dibersihkan dari potongan kode *HyperText Markup Language* (HTML). Pada *dataset*, data hoaks diberi label 1, sedangkan data bukan hoaks diberi label 0.

Semua eksperimen dieksekusi pada *environment* yang menggunakan GPU Nvidia DGX-1. Kerangka eksperimen dibuat dengan PyTorch (Torch 1.11, Python 3.11). Beberapa parameter diatur oleh peneliti, seperti *random_seed* dengan nilai 42, *pad_size* sebesar 512, *batch_size* sebesar 32, *num_epochs* sebesar 10, *learning_rate* sebesar 2×10^{-5} , *epsilon* sebesar 1×10^{-5} , *loss function* menggunakan *binary cross entropy*, *optimizer* menggunakan AdamW, dan *score_threshold* sebesar 0,5.


B. MODEL

IndoBERT [4] merupakan model yang dibuat dengan mengikuti konfigurasi BERT-Base [5] sehingga memiliki dua belas *encoder layer* yang masing-masing memiliki dua belas *self attention* dan *feedforward* dengan dimensi sebesar 768 untuk menangkap konteks kalimat dari kanan dan kiri. Dalam BERT, terdapat dua *output* yang dapat digunakan yakni *pooled output* dan *hidden states*. *Pooled output* merupakan representasi dari kontekstualisasi *input* yang diproses oleh seluruh *encoder layer*, sedangkan *hidden states* merupakan representasi seluruh *encoder layer*.

Langkah awal yang dilakukan oleh tim peneliti sebelum melatih model IndoBERT adalah mengolah *input* menjadi kumpulan token. Pengolahan dilakukan dengan memanfaatkan salah satu fitur *Transformers* yakni BERT *Tokenizer* dengan konfigurasi IndoBERT tipe "indobert-base-p2". BERT *Tokenizer* bekerja dengan memecah artikel *input* menjadi kata-kata terpisah. Kata yang terdapat pada kamus "indobert-base-p2" akan langsung diubah menjadi token, sedangkan kata yang belum ada pada kamus akan dipecah menjadi subkata terlebih dahulu. Kemudian sebuah token khusus akan ditambahkan di rangkaian token yakni '[CLS]' di awal dan '[SEP]' di akhir. Apabila jumlah token kurang dari *pad_size* yang ditentukan maka akan ditambahkan *padding* terlebih dahulu. Langkah terakhir adalah membuat *attention mask* untuk tiap rangkaian token agar model dapat fokus pada token-token yang memiliki informasi penting. Terdapat dua pendekatan yang dapat digunakan dalam melakukan tugas klasifikasi menggunakan model IndoBERT. Sesuai dengan pendekatan pada BERT [6], IndoBERT dapat digunakan dengan menggunakan *fine tuning approach* dan *feature-based approach*. *Fine tuning approach* merupakan pendekatan yang dilakukan dengan mengubah nilai parameter pada model sebagai hasil pelatihan *dataset*, sedangkan *feature-based approach* merupakan pendekatan yang tidak mengubah nilai parameter model namun menggunakan nilai pada *hidden states* sebagai *features* untuk pemrosesan lebih lanjut. Berikut dijelaskan tiga model yang diusulkan.

1) *IndoBERT-BC*

Peneliti melatih model IndoBERT dengan menggunakan *fine tuning approach* untuk dapat melakukan deteksi hoaks. Pendekatan ini diimplementasikan sesuai dengan ilustrasi pada Gambar 1 yang dimulai dengan memproses *input* menggunakan IndoBERT Tokenizer untuk menjadi *features* berupa token *input* dan *attention masks*. *Features* dan *attention masks* kemudian diolah oleh model IndoBERT sehingga menghasilkan *pooled output*. Nilai representasi dari token khusus '[CLS]' pada indeks pertama *pooled output* kemudian diambil sebagai *class score*. *Class score* kemudian diolah dengan fungsi *sigmoid* untuk klasifikasi biner yang ditentukan oleh *score_threshold*. *Class score* dengan nilai kurang dari *score_threshold* akan diberi label 0 (bukan hoaks) dan lainnya akan diberi label 1 (hoaks). Alur *fine tuning approach* yang memanfaatkan *pooled output* akan menjadi *baseline* dari penelitian sebagai IndoBERT Base Classification (IndoBERT-BC).




Gambar 1. Arsitektur Model IndoBERT-BC

2) *IndoBERT-BiC*

Selain *fine tuning approach* dalam melatih IndoBERT, pendekatan lain yang digunakan adalah *feature-based approach* yang memanfaatkan *hidden states* tanpa mengubah parameter model. Pendekatan *feature-based* melalui penggabungan empat *hidden state* terakhir sebagai fitur dalam melakukan tugas klasifikasi telah ditunjukkan mendapatkan skor F1 tertinggi dibandingkan pendekatan lainnya [6]. Pada penelitian ini, *feature based approach* juga dilakukan dengan menggunakan empat *hidden state* terakhir yang berisi informasi kontekstual teks secara menyeluruh sebagai fitur. Fitur ini perlu diproses lebih lanjut terlebih dahulu untuk dapat menemukan konteks kalimat melalui hubungan token - token dalam urutan yang panjang. Salah satu model yang dapat digunakan adalah LSTM, karena model ini mampu memperhitungkan korelasi antara token. LSTM memperhitungkan bobot token untuk token selanjutnya sehingga model ini dapat menangkap konteks kalimat dari satu arah urutan (*forward features*) [7]. Namun, LSTM masih memiliki keterbatasan dalam mengatasi ketergantungan terhadap urutan yang membutuhkan pemahaman konteks baik dari token sebelumnya (*backward features*) dan token setelahnya (*forward features*). Untuk mendapatkan pemahaman konteks yang lebih kaya, BiLSTM yang mampu memahami konteks kalimat dari kedua arah urutan secara bersamaan digunakan [8]. Dalam penelitian sebelumnya, penggabungan model BERT dengan BiLSTM juga telah menunjukkan keberhasilannya dalam meningkatkan performa skor F1 [9]. Seperti yang ditunjukkan pada Gambar 2, perbedaan model IndoBERT *BiLSTM Classification* (IndoBERT-BiC) dengan model IndoBERT-BC terletak pada


proses *feature extraction* dalam penggunaan empat *hidden state* terakhir yang disatukan lalu diproses menggunakan BiLSTM. Kontekstualisasi hasil BiLSTM kemudian direduksi dimensinya menggunakan *dense layer* dan menambahkan *dropout* untuk mengurangi kemungkinan *overfitting*. Hasil dari *dense layer* kemudian dihitung menggunakan fungsi *sigmoid* untuk menentukan *class score* sehingga *input* dapat diklasifikasikan menggunakan *score threshold* yang telah ditentukan.



Gambar 2. Arsitektur Model IndoBERT-BiC

3) *IndoBERT-CC*

Penggabungan *fine tuning approach* dengan *feature-based approach* memiliki potensi untuk meningkatkan performa model [10]. Gambar 3 menunjukkan arsitektur model IndoBERT *Concatenation Classification* (IndoBERT-CC) yang merupakan penggabungan dua pendekatan yang dijelaskan sebelumnya. Pembentukan model ini diawali dengan melakukan *fine tuning* parameter pada model IndoBERT melalui pelatihan *dataset*. Langkah selanjutnya adalah menjalankan kedua proses yang dilakukan oleh model sebelumnya yakni mengekstraksi representasi token '[CLS]' pada *pooled output* dan melakukan *feature extraction* pada empat *hidden state* terakhir untuk diolah menggunakan BiLSTM. Berbeda dengan model IndoBERT-BC dan IndoBERT-BiC, terdapat - tahapan penggabungan kedua hasil proses tersebut yang kemudian diikuti dengan reduksi dimensi menggunakan 1 *Dimension average pooling* (1D *average pooling*). Hasil reduksi tersebut kemudian dihitung menggunakan fungsi *sigmoid* sehingga didapatkan *class score* untuk melakukan klasifikasi biner.



Gambar 3. Arsitektur Model IndoBERT-CC

C. METRIK

Beberapa metrik digunakan untuk mengevaluasi performa model dalam melakukan deteksi hoaks. Metrik yang digunakan adalah akurasi, skor F1, dan ROC_AUC. Perhitungan hasil uji ketiga metrik tersebut berbasiskan pada *confusion matrix* seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Ilustrasi *Confusion Matrix* Klasifikasi Biner

		Nilai Prediksi	
		Hoaks	Bukan Hoaks
Nilai Aktual	Hoaks	<i>True Positive</i> (TP)	<i>False Negative</i> (FN)
	Bukan Hoaks	<i>False Positive</i> (FP)	<i>True Negative</i> (TN)

$$False\ Positive\ Rate = \frac{FP}{FP + TN} \quad (6)$$

Grafik ROC menyatakan perbandingan antara tingkat *true positive rate* dan *false positive rate*. ROC_AUC menghitung luas area di bawah kurva ROC dengan variasi nilai *threshold*. Nilai ROC_AUC berada di rentang antara 0 hingga 1. Nilai ROC_AUC sebesar 0.5 menunjukkan performa model yang acak, sedangkan nilai 1 menunjukkan performa yang sempurna dalam melakukan deteksi hoaks.

D. VALIDASI MODEL

Untuk memastikan model tidak *overfitting* pada *dataset*, tim peneliti melakukan *K-fold cross validation* sebanyak lima *fold* dengan sepuluh *epoch* untuk tiap *fold*. Dengan demikian, setiap model perlu melakukan tahap *training* sebanyak 50 kali dan tahap *validation* sebanyak 5 kali.

IV. HASIL DAN PEMBAHASAN

Tabel 2 mengilustrasikan hasil rata - rata pengujian model menggunakan metode *K-fold cross validation* terhadap *validation data*. Dari hasil rata - rata diperoleh bahwa model IndoBERT-CC memiliki kemampuan terbaik dalam mendeteksi hoaks dibandingkan model IndoBERT-BC dan IndoBERT-BiC untuk semua metrik pengujian.

Tabel 2. Hasil Evaluasi Model

Model	Akurasi	F1	ROC_AUC
IndoBERT-BC	0,98567	0,98558	0,99193
IndoBERT-BiC	0,97509	0,97462	0,99626
IndoBERT-CC	0,98798	0,98787	0,99869

Selanjutnya, dilakukan uji statistik menggunakan Mann-Whitney U *test* untuk mengetahui seberapa signifikan perbedaan performa model dalam mendeteksi hoaks yang terdiri dari tiga metrik uji, yaitu skor akurasi, F1, serta ROC_AUC. Tabel 3 menunjukkan hasil Mann-Whitney U *test* antara model IndoBERT-BC dengan IndoBERT-BiC. Hipotesis awal (H_0) adalah tidak terdapat perbedaan yang signifikan antara kemampuan IndoBERT-BC dengan IndoBERT-BiC dalam mendeteksi hoaks. Selanjutnya, hipotesis alternatif (H_1) yang digunakan adalah terdapat perbedaan kemampuan deteksi hoaks yang signifikan antara kedua model. Karena nilai *p-value* yang diperoleh kurang dari *significance level* (α) yaitu 0,05 untuk semua metrik uji, maka dapat disimpulkan bahwa terdapat perbedaan signifikan antara model IndoBERT-BC dengan IndoBERT-BiC.

1) Akurasi

Akurasi merupakan metrik yang merepresentasikan performa model dalam melakukan deteksi hoaks dan bukan hoaks dengan benar. Akurasi pada model dapat dihitung sebagai berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

2) Skor F1

Skor F1 merupakan gabungan dari dua metrik: *precision* dan *recall*. Presisi merupakan proporsi sampel positif yang diprediksi dengan benar. *Recall* menyatakan kemampuan model dalam mengenali semua sampel positif. Nilai skor F1 yang mendekati 1 mengindikasikan model semakin bagus untuk mendeteksi hoaks dan bukan hoaks.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$Skor\ F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4)$$

3) ROC_AUC

ROC_AUC (*Receiver Operating Characteristic Area Under the Curve*) adalah metrik yang mengukur kemampuan model dalam membedakan antara kelas positif dan negatif. Metrik ROC merupakan representasi grafis dari perbandingan antara *true positive rate* (TPR) dan *false positive rate* (FPR) dengan variasi *threshold* prediksi. TPR menyatakan proporsi hoaks yang diklasifikasikan sebagai hoaks terhadap jumlah hoaks sebenarnya.

$$True\ Positive\ Rate = \frac{TP}{TP + FN} \quad (5)$$

FPR menyatakan proporsi berita bukan hoaks yang diklasifikasikan sebagai hoaks terhadap jumlah berita bukan hoaks sebenarnya.

Tabel 3. Mann-Whitney U test IndoBERT-BC dengan IndoBERT-BiC

Mann-Whitney U test IndoBERT-BC dengan IndoBERT-BiC		
	<i>p-value</i>	Hasil
Akurasi	0,011925	H ₁ Diterima
Skor F1	0,0079365	H ₁ Diterima
ROC_AUC	0,0079365	H ₁ Diterima

Kemudian dilakukan juga Mann-Whitney U test terhadap IndoBERT-BC dengan IndoBERT-CC. Hipotesis awal (H₀) adalah tidak terdapat perbedaan yang signifikan antara IndoBERT-BC dengan IndoBERT-CC dalam hal kemampuan deteksi hoaks. Selanjutnya, hipotesis alternatif (H₁) yang digunakan adalah terdapat perbedaan kemampuan deteksi hoaks yang signifikan antara kedua model. Tabel 4 menunjukkan nilai *p-value* untuk ROC_AUC kurang dari *significance level* (α) yang digunakan (0.05). Hal ini menandakan adanya perbedaan yang signifikan pada kedua model. Namun, nilai *p-value* untuk metrik akurasi dan skor F1 lebih dari α , sehingga berdasarkan kedua metrik tersebut, perbedaan antara IndoBERT-BC dengan IndoBERT-CC tidak terlalu signifikan.

Tabel 4. Mann-Whitney U test IndoBERT-BC dengan IndoBERT-CC

Mann-Whitney U test IndoBERT-BC dengan IndoBERT-CC		
	<i>p-value</i>	Hasil
Akurasi	0,059327	H ₀ Diterima
Skor F1	0,15079	H ₀ Diterima
ROC_AUC	0,0079365	H ₁ Diterima

V. KESIMPULAN

Pada penelitian ini, peneliti telah melakukan eksplorasi model IndoBERT-CC, yakni model yang menggunakan kombinasi BiLSTM dan IndoBERT. Secara khusus, model yang diusulkan menggabungkan *fine tuning approach* dan *feature-based approach*, masing-masing dilakukan oleh model IndoBERT-BC dan IndoBERT-BiC. Ketiga model ini dievaluasi menggunakan metrik akurasi, skor F1, dan ROC_AUC.

Hasil evaluasi menunjukkan bahwa model IndoBERT-CC memiliki kemampuan mendeteksi hoaks terbaik pada skor F1, skor akurasi, dan ROC_AUC dibandingkan dengan dua model lainnya. IndoBERT-CC mempunyai skor ROC_AUC sebesar 99,9%, skor F1 dan akurasi masing-masing sebesar 98,8%. Hasil uji statistik dengan Mann-Whitney U test juga menunjukkan bahwa terdapat perbedaan signifikan dalam peningkatan kemampuan deteksi hoaks pada model IndoBERT-CC terhadap model baseline IndoBERT-BC berdasarkan metrik ROC_AUC.

VI. REFERENSI

- [1] G. G. Heryanto, Media Komunikasi Politik : Relasi Kuasa Media di Panggung Politik. Yogyakarta, Indonesia: IRCiSoD, 2018.
- [2] S. Pora, R. Pora, dan D. Muksin, "Hoax Ratna Serumpaet dan perang wacana di media sosial: Ratna Serumpaet Hoax and discourse war on social media," *Journal of Government Science (GovSci) : Jurnal Ilmu Pemerintah*, Vol. 3(1), hal. 22-34, 2022, doi: 10.54144/govsci.v3i1.28.
- [3] R. Yusuf dan S. Suyanto, "Hoax Detection on Indonesian Text using Long Short-Term Memory," *Proc. 2022 5th International Conference on Information and Communications Technology (ICOIACT'22)*, 2022, hal. 268-271, doi: 10.1109/ICOIACT55506.2022.9972086.
- [4] A. Z. M. Noor, R. Gernowo, dan O. D. Nurhayati, "Data Augmentation for Hoax Detection through the Method of Convolutional Neural Network in Indonesian News," *Penelitian Pendidikan IPA*, Vol 9(7), hal. 5078-5084, 2023, doi: 10.29303/jppipa.v9i7.4214
- [5] F. Koto, A. Rahimi, J. H. Lau, dan T. Baldwin, "IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NL," *Proc. 28th International Conference on Computational Linguistics (ICCL'20)*, 2020, hal. 757-770, doi :10.18653/v1/2020.coling-main.66
- [6] J. Delvin, M-W. Chang, K. Lee, dan K. Toutanova, "BERT: Pre-Trained of Deep Bidirectional Transformer for Language Understanding," *Proc. 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL)*, Vol. 1, 2019, hal. 4171-4186, doi : 10.18653/v1/N19-1423
- [7] S. Hochreiter dan J. Schmidhuber, "Long Short-Term Memory," *Neural Comput*, Vol. 9(8), hal. 1735-1780, 1997, doi: 10.1162/neco.1997.9.8.1735
- [8] A. Graves dan J. Schmidhuber, "Framewise phoneme classification with bidirectional LSTM networks," *Proc. IEEE International Joint Conference on Neural Networks*, 2005, hal. 2047-2052, doi: 10.1109/IJCNN.2005.1556215.
- [9] X. Li, Y. Lei, dan S. Ji, "BERT-and BiLSTM-Based Sentiment Analysis of Online Chinese Buzzwords," *Future Internet*, Vol. 14(11), hal. 332, 2022, doi: 10.3390/fi14110332.
- [10] X. Wang, H. Xu, X. Sun, dan G. Tao, "Combining Fine-Tuning with a Feature-Based Approach for Aspect Extraction on Reviews (Student Abstract)," *Proc. The AAAI Conference on Artificial Intelligence*, 2020, paper 34, doi: 10.1609/aaai.v34i10.7248.