

IMPLEMENTASI ALGORITMA BI-LSTM DALAM MENDETEKSI ENTITAS WAKTU DAN LOKASI KEBAKARAN HUTAN

Dwi Ahmad Dzulhijjah ¹, Kusrini ^{2*}, Kumara Ari Yuana ³
^{1,2,3} Magister Informatika, Universitas Amikom Yogyakarta
kusrini@amikom.ac.id

ABSTRAK

Penelitian ini berfokus pada penerapan algoritma Bidirectional Long Short-Term Memory (Bi-LSTM) untuk identifikasi entitas waktu dan lokasi dalam konteks kebakaran hutan menggunakan teks berbahasa Indonesia. Melalui eksperimen, model dievaluasi dengan mengukur akurasi dan loss, khususnya terkait data teks yang berkaitan dengan kebakaran hutan. Hasil penelitian menunjukkan peningkatan kinerja model selama proses pelatihan, dengan mencapai tingkat akurasi tertinggi pada 75.2% pada epoch terakhir. Kurva loss menunjukkan penurunan yang konsisten hingga mencapai nilai minimum pada 0.801. Evaluasi model pada data uji menghasilkan nilai loss sebesar 0.8750 dan akurasi sebesar 70.49%. Temuan ini menegaskan efektivitas model dalam mendeteksi entitas waktu dan lokasi kebakaran hutan, memberikan kontribusi signifikan pada pengembangan teknologi deteksi dini bencana alam, terutama dalam konteks kebakaran hutan di Indonesia.

Keyword : LSTM, NER, Kebakaran Hutan, Entitas Waktu, Entitas Lokasi.

1. PENDAHULUAN

Indonesia merupakan negara dengan hutan tropis yang memiliki keanekaragaman hayati dan kelimpahan alam yang sangat tinggi (*high biodiversity*) [1]. Namun, hutan-hutan ini sering menghadapi ancaman serius, seperti kebakaran hutan, yang dapat membahayakan ekosistemnya, serta kesehatan dan kehidupan manusia. Kebakaran hutan telah menjadi masalah yang sering terjadi di berbagai wilayah Indonesia, khususnya pada musim kemarau. Selain itu, kebakaran hutan juga dapat menimbulkan masalah serius terkait kualitas udara, kehilangan habitat satwa liar, dan kerugian ekonomi yang signifikan [2].

Dalam upaya menanggulangi kebakaran hutan, keterangan mengenai waktu dan lokasi menjadi aspek yang sangat krusial. Cepat dan akuratnya penentuan waktu dan lokasi kebakaran hutan menjadi hal yang sangat dibutuhkan untuk mengkoordinasikan langkah-langkah pemadaman, memberi informasi kepada masyarakat, dan merencanakan tindakan selanjutnya. Keterangan mengenai waktu dan lokasi kejadian kebakaran hutan menjadi informasi pertama yang harus diketahui dalam upaya penanganan kebakaran hutan [3].

Pemanfaatan teknologi Pemrosesan Bahasa Alami (Natural Language Processing - NLP) dalam mendeteksi entitas lokasi dan waktu pada data teks dapat membantu dalam mempercepat pengumpulan informasi yang diperlukan untuk penanggulangan kebakaran hutan [4]. Salah satu metode yang umum digunakan dalam NLP adalah penggunaan model berbasis *Long Short-Term Memory (LSTM)* [5], yang mampu memahami konteks dan urutan dalam teks [6]. Terdapat variasi dan perkembangan model LSTM seperti LSTM-GRU, LSTM-CRF, Bi-LSTM yang memungkinkan untuk dilakukan eksplorasi eksperimen model [7].

Oleh karena itu penelitian ini mengimplementasikan *Bidirectional LSTM* atau juga disebut *Bi-LSTM* untuk mendeteksi entitas waktu dan lokasi dalam teks yang mengandung narasi atau kata “kebakaran hutan”. Selanjutnya hasil deteksi akan dievaluasi dengan menghitung nilai akurasi model Bidirectional LSTM. Penelitian ini berkontribusi dalam pengembangan model pengenalan entitas waktu dan lokasi kebakaran hutan guna mitigasi bencana menggunakan algoritma rekuren yang efektif yakni Bi-LSTM.

2. TINJAUAN PUSTAKA

Tinjauan pustaka pada penelitian ini memperkenalkan serangkaian penelitian terkait di bidang *Named Entity Recognition (NER)* dan penggunaan algoritma *Long Short-Term Memory (LSTM)* dalam pemrosesan teks. Penelitian sebelumnya menyoroti pentingnya *Named Entity Recognition (NER)* dalam mengambil informasi dari dokumen teks [8]. Metode *LSTM* mampu mendeteksi entitas-entitas yang sudah diberikan label dan *dichunking* [6]. Selanjutnya, penelitian terkait NER dengan model Bi-LSTM+CRF memberikan kontribusi yang signifikan, meskipun cakupan kurang pada bahasa Indonesia dan optimalisasi parameter LSTM [9].

Terdapat penelitian membahas peran teknik *Deep Neural Network (DNN)*, terutama model *Bidirectional LSTM-CRF*, dalam ekstraksi entitas bernama dari teks. Penelitian ini mengeksplorasi penggunaan *word embedding (Glove dan Fasttext)* dan kombinasi fitur input kata dan karakter pada model *Convolutional Neural Network (CNN)* dan *Bidirectional LSTM* dengan atau tanpa *Conditional Random Field (CRF)*. Hasilnya menunjukkan potensi kombinasi fitur *input* [10].

Sebuah inovasi baru dalam meningkatkan *Named Entity Recognition (NER)* diperkenalkan

oleh melalui model *Adversarial Trained LSTM-CNN (ASTRAL)* dengan *Gated-CNN* dan pelatihan *adversarial* [11]. Evaluasi pada tiga benchmark menunjukkan bahwa ASTRAL mencapai hasil terbaik, menonjolkan kemampuannya dalam mencapai konvergensi yang lebih cepat dan ketahanan terhadap *overfitting*. Sementara itu terdapat pembahasan NER dalam konteks biomedis dengan mempresentasikan model berbasis Bi-LSTM-CRF yang menerapkan mekanisme perhatian untuk mengatasi tantangan ketergantungan jangka panjang [12]. Kontribusi studi ini terletak pada pengembangan model NER biomedis dengan fokus khusus pada jenis entitas baru dan tidak terlihat dalam data biomedis yang terus berkembang.

Dari berbagai penelitian LSTM berikut kombinasi dan variannya mampu mendeteksi entitas bernama mulai dari entitas biomedis [12], secara umum [8] dan untuk data yang *dichunking* [6]. Tinjauan pustaka ini mendukung penelitian implementasi Bi-LSTM dalam mendeteksi entitas lokasi dan waktu dalam konteks kebakaran hutan. Penelitian terkini dalam mendeteksi entitas bernama kebakaran menggunakan *Bi-LSTM* dilakukan dengan menggunakan teks berita daring dan berfokus pada wilayah Jakarta [13], penelitian tersebut sangat dekat dengan penelitian yang dilakukan yakni mendeteksi entitas lokasi kebakaran hutan menggunakan model Bi-LSTM, sehingga dapat menjadi bukti efektivitas model dalam mendeteksi teks atau artikel bahasa dalam bentuk sekuensial, berikut mendeteksi entitas waktunya juga dapat dilakukan..


3. METODE PENELITIAN

Penelitian yang dilakukan merupakan penelitian eksperimental melibatkan uji coba implementasi algoritma bidirectional LSTM untuk mendeteksi entitas waktu dan lokasi kebakaran hutan selanjutnya dievaluasi dengan hasil akurasi dan *lossnya*. Penelitian ini mencakup tahapan lengkap dalam pelatihan model *Named Entity Recognition (NER)* menggunakan jaringan syaraf rekurensi (RNN) dengan lapisan LSTM [13].

Dalam penelitian ini, proses penelitian dimulai dengan teliti mengumpulkan dataset yang terdiri dari 19.845 kata yang diambil dari 1.103 kalimat. Data tersebut berasal dari diskusi Twitter yang khusus terkait dengan kebakaran hutan. Dataset mencakup lanskap linguistik yang beragam, mencakup berbagai subtleties yang umumnya ditemukan dalam tweet yang membahas kejadian kebakaran hutan. Kurasi dataset ini dilakukan secara sengaja, mengingat sifat adaptifnya, untuk memastikan bahwa model menghadapi berbagai gaya bahasa yang umumnya digunakan selama keadaan darurat.

Selama tahap pra-pemrosesan data, skema *encoding BIO* [14] diterapkan, sebuah metode yang telah mapan dalam Pengenalan Entitas Bernama (NER). Sebagai contoh, dalam kalimat "Terjadi

Kebakaran Hutan 17.00 Sore," kata "Terjadi," "Kebakaran," dan "Hutan" diberi label "O," yang berarti "Outside" dari entitas bernama. Sementara itu, kata "17:00" diberi label "B-Time" sebagai "Beginning" dari entitas waktu, dan kata "Sore" diberi label "I-Time" sebagai "Inside" dari entitas waktu. Pendekatan ini memungkinkan model untuk mengenali batas dan komponen dari entitas bernama, serta memberikan informasi kontekstual yang penting selama proses pelatihan. Skema *encoding BIO* membantu pemahaman model terhadap kata-kata masukan dan tag yang terkait, meningkatkan kemampuan model untuk mengenali struktur kalimat yang lebih kompleks [14]. Ilustrasi penerapan konsep ini dapat dilihat pada Gambar 1..



Gambar 1. Implementasi Skema BIO dalam Teks Kebakaran Hutan

Setelah penerapan *encoding BIO*, langkah-langkah pra-pemrosesan tambahan dilakukan untuk memformat data dengan tepat untuk pelatihan. Dua kamus, yaitu `word2idx` dan `tag2idx`, dibuat untuk memetakan kata-kata dan tag ke indeks numerik masing-masing. Transformasi ini memudahkan pemahaman model terhadap kata-kata masukan dan tag yang terkait sepanjang proses pelatihan.

Setelah menerapkan skema *encoding BIO*, dilanjutkan dengan langkah-langkah pra-pemrosesan tambahan untuk memformat data dengan tepat untuk keperluan pelatihan. Tahap ini melibatkan pembentukan dua kamus penting, yaitu `word2idx` dan `tag2idx`, yang dirancang untuk memetakan kata-kata dan tag ke indeks numerik masing-masing. Transformasi ini terbukti krusial dalam meningkatkan pemahaman model terhadap kata-kata masukan dan tag yang terkait sepanjang seluruh proses pelatihan.

Untuk menyiapkan data masukan, modul yang digunakan `tensorflow.keras.preprocessing.sequence` [15]. Urutan kata-kata diubah menjadi indeks numerik dengan merujuk pada kamus `word2idx`. Setelah itu, urutan-urutan ini mengalami padding hingga panjang maksimum 50 menggunakan fungsi `'pad_sequences'`, memastikan ukuran masukan yang seragam untuk model. Padding diterapkan di akhir setiap urutan, dengan nilai khusus `num_words-1` yang ditetapkan untuk mewakili padding dalam ruang indeks numerik.

Demikian pula, urutan-urutan tag mengalami transformasi sejajar. Dengan memanfaatkan kamus `'tag2idx'`, proses konversi label tag ke indeks numerik difasilitasi. Urutan-urutan tag ini juga dipadding hingga panjang maksimum yang sama menggunakan fungsi `'pad_sequences'`. Penting

dicatat bahwa tag khusus "O" (Outside) diberi indeks numerik yang sesuai dengan tag2idx["O"]

Pipeline pra-pemrosesan yang teliti ini memainkan peran kunci dalam menyiapkan data untuk pelatihan yang efektif. Ini membekali model dengan urutan masukan terstruktur dan tag yang sesuai, memberikan dasar yang diperlukan agar model dapat belajar pengenalan entitas bernama, terutama dalam konteks percakapan di Twitter yang berkaitan dengan kebakaran hutan. Format masukan yang seragam memastikan bahwa model dapat efektif menangkap nuansa dan variasi dalam bahasa yang umumnya ditemukan dalam diskusi semacam itu, berkontribusi pada kekokohan dan adaptabilitasnya selama pelatihan.

Arsitektur model yang diusulkan mencakup berbagai lapisan yang dirancang secara cermat untuk menangkap informasi yang relevan dari data. Lapisan-lapisan tersebut termasuk lapisan *embedding*, *dropout spasial*, *Bi-LSTM*, dan lapisan *time-distributed dense* untuk *output softmax*. Pengaturan spesifik untuk lapisan LSTM dapat dilihat pada Tabel 1, yang memberikan detail tentang jenis lapisan, jumlah unit, dan *dropout* rekuren yang digunakan.


Tabel 1. *Setting Model LSTM*

Lapisan	Jenis	Jumlah Unit	Dropout Recurrent
Input Layer (Embedding)	Embedding	-	-
Hidden Layer (LSTM Bidirectional)	Bidirectional LSTM	100	0.1

Model ini dikompilasi menggunakan pengoptimal Adam, fungsi kerugian *sparse_categorical_crossentropy*, dan metrik akurasi. Pelatihan model dilakukan selama 10 *epoch* dengan ukuran batch sebesar 32. Selama proses pelatihan, beberapa *callback* digunakan untuk meningkatkan efisiensi dan kualitas model. *ModelCheckpoint* digunakan untuk menyimpan bobot terbaik selama pelatihan, *'PlotLossesCallback'* memantau perubahan *loss* selama pelatihan, dan *'EarlyStopping'* digunakan untuk menghentikan pelatihan jika akurasi pengujian tidak meningkat setelah satu *epoch*.

Secara keseluruhan, arsitektur model ini dirancang dengan cermat untuk memastikan bahwa model dapat belajar dengan baik dari data yang diberikan. Penggunaan *Bi-LSTM* memungkinkan model untuk mengakses konteks dari kedua arah dalam urutan data, sementara lapisan *embedding* membantu mengonversi kata-kata menjadi representasi vektor yang bermakna. Pengaturan *dropout* dan *callback* yang diterapkan dalam pelatihan bertujuan untuk mencegah *overfitting* dan memastikan konvergensi yang baik selama proses

pembelajaran. Ringkasan arsitektur model ini dapat dilihat pada Gambar 1, yang memberikan gambaran visual tentang struktur dan hubungan antar-lapisan dalam model.



Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 50)]	0
embedding (Embedding)	(None, 50, 50)	291700
spatial_dropout1d (Spatial Dropout1D)	(None, 50, 50)	0
bidirectional (Bidirectional)	(None, 50, 200)	120800
time_distributed (TimeDistributed)	(None, 50, 14)	2814

Total params: 415314 (1.58 MB)
 Trainable params: 415314 (1.58 MB)
 Non-trainable params: 0 (0.00 Byte)

Gambar 1. *Summary Model*

Sehingga, penggunaan LSTM bidireksional dalam arsitektur model ini bertujuan utama untuk menangkap konteks temporal yang mungkin melibatkan informasi dari kedua arah dalam urutan data. Hal ini memungkinkan model untuk lebih baik memahami hubungan antar kata-kata dan konteks sekitarnya. Selain itu, lapisan *time-distributed dense* digunakan untuk menghasilkan *output softmax*, yang memberikan probabilitas untuk setiap kategori entitas pada setiap langkah waktu.

Perlu ditekankan bahwa jumlah total parameter model sebanyak 415,314 memberikan kompleksitas yang cukup untuk model dapat mempelajari representasi yang mendalam dari data pelatihan selama proses pelatihan. Penggunaan LSTM bidireksional dan lapisan *time-distributed dense* ini bersinergi untuk mencapai pemahaman yang lebih baik terhadap entitas terkait kebakaran hutan dalam teks.

Proses evaluasi model pada data pengujian menjadi langkah kritis untuk mengevaluasi kinerja model yang telah dilatih. Dengan menggunakan fungsi `model.evaluate`, kita dapat memperoleh informasi tentang *loss* dan akurasi model pada data pengujian. Hasil eksperimen ini menjadi landasan yang penting dalam mengukur sejauh mana model dapat mengenali entitas terkait kebakaran hutan dengan akurat dalam konteks teks.

Selanjutnya, pendekatan sistematis ini membawa manfaat tambahan karena memungkinkan pengembang untuk mendapatkan wawasan yang mendalam tentang kinerja model, melibatkan analisis terhadap *loss* dan akurasi pada data pengujian. Dengan demikian, eksperimen ini memberikan sumbangan signifikan dalam mengembangkan model NER yang efektif sesuai dengan tujuan penelitian, yaitu mengidentifikasi entitas terkait kebakaran hutan secara akurat dalam teks. Pendekatan ini menciptakan dasar yang kuat untuk pengembangan model NER yang dapat

diandalkan dalam menangani tugas-tugas serupa di masa depan.


4. HASIL DAN PEMBAHASAN

4.1. Performa Model Bidirectional LSTM

Dalam eksperimen ini, diimplementasikan model *Bidirectional LSTM* untuk mendeteksi entitas waktu dan lokasi terkait kebakaran hutan. Implementasi model melibatkan variasi parameter dan iterasi untuk mengoptimalkan kinerja model. Hasil pelatihan menunjukkan evolusi akurasi dan *loss* pada set pelatihan dan validasi selama 10 *epochs*.

Pada tahap pelatihan, teramati bahwa akurasi pada set pelatihan mengalami peningkatan yang signifikan seiring dengan berjalannya *epochs*. Dimulai dari nilai awal sebesar 63.4% pada *epoch* pertama, akurasi terus meningkat hingga mencapai puncaknya pada 75.2% pada *epoch* terakhir. Sementara itu, akurasi pada set validasi mencapai tingkat maksimal sebesar 71.6%, dan tetap stabil di sekitar 70.5% pada akhir proses pelatihan.

Selanjutnya, jika kita melihat kurva *loss* pada set pelatihan, terlihat penurunan yang konsisten selama seluruh *epochs*. Kurva ini mencapai nilai minimum pada 0.801, mencerminkan kemampuan model dalam mengurangi tingkat kesalahan pada data pelatihan. Hal serupa juga terjadi pada kurva *loss* pada set validasi, yang menurun hingga mencapai nilai minimum pada 0.875. Ini mengindikasikan bahwa model mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.



Gambar 2. Grafik Performa Training

Ketika model dievaluasi pada data uji, ditemukan bahwa *loss* pada data uji adalah sebesar 0.8750, mencerminkan tingkat kesalahan model pada data tersebut. Sementara itu, akurasi pada data uji mencapai 70.49%, memberikan gambaran tentang sejauh mana model dapat menggeneralisasi informasi dari data pelatihan ke data yang baru. Visualisasi metrik-metrik ini dapat dilihat pada Gambar 2, yang merepresentasikan perubahan akurasi dan *loss* selama proses pelatihan dan evaluasi model. Hasil eksperimen ini memberikan wawasan mendalam tentang kemampuan model

Bidirectional LSTM dalam mengenali entitas terkait kebakaran hutan, memperkuat dasar pengetahuan dalam pengembangan model NER untuk tugas serupa di masa depan.

Penampilan grafik di Gambar 2 merepresentasikan secara visual metrik-metrik tersebut selama proses *training* dan evaluasi model. Hal ini membantu dalam pemahaman yang lebih baik terhadap kinerja model secara keseluruhan.

4.2. Analisis

Dalam membandingkan akurasi pada set pelatihan dan validasi, perbedaan yang diamati memberikan indikasi penting tentang sejauh mana model mampu beradaptasi dengan data baru. Meskipun terdapat perbedaan antara kedua metrik tersebut, tingginya nilai akurasi pada kedua set menunjukkan bahwa model memiliki kemampuan yang baik untuk memahami dan mengenali pola dalam data. Hal ini mencerminkan bahwa model mampu melakukan generalisasi dengan baik terhadap informasi yang terdapat pada set pelatihan, bahkan pada data yang belum pernah dilihat pada set validasi.

Selanjutnya, nilai *loss* yang rendah pada kedua set memberikan indikasi bahwa model Bidirectional LSTM berhasil mengurangi tingkat kesalahan dengan efektif. Penurunan konsisten pada kurva *loss* menunjukkan bahwa model telah mampu mengoptimalkan parameter dan memahami struktur data dengan baik selama proses pelatihan. Hal ini menegaskan kemampuan model dalam menghasilkan representasi yang akurat dari informasi yang terkandung dalam set pelatihan dan validasi.

Dalam konteks performa model, meskipun akurasi pada set validasi tidak mencapai tingkat yang sama dengan set pelatihan, model tetap memberikan hasil yang baik dan dapat diandalkan pada data baru. Perbaikan pada nilai *val_loss* pada epoch 3, yang diikuti dengan penyimpanan model terbaik, menunjukkan kemampuan adaptasi model sepanjang proses pelatihan. Ini memberikan keyakinan bahwa model dapat menghasilkan hasil yang konsisten dan dapat diandalkan dalam mendeteksi entitas waktu dan lokasi kebakaran hutan.

Namun, untuk memberikan wawasan yang lebih mendalam, evaluasi model pada data uji menjadi langkah penting. Hasil evaluasi ini memberikan pemahaman yang lebih baik tentang sejauh mana model dapat digeneralisasikan ke data yang belum pernah dilihat sebelumnya. Meskipun hasilnya cukup baik dengan *loss* sebesar 0.8750 dan akurasi 70.49%, pertimbangan lebih lanjut perlu dilakukan terkait faktor-faktor seperti keseimbangan kelas dan penyesuaian parameter untuk potensi pengembangan lebih lanjut.

Dengan demikian, hasil dan analisis ini memberikan wawasan komprehensif tentang kinerja

model Bidirectional LSTM dalam mendeteksi entitas waktu dan lokasi kebakaran hutan. Evaluasi yang cermat dan pemahaman mendalam terhadap hasil eksperimen ini menjadi kunci untuk mengoptimalkan model dan menyusun rekomendasi bagi pengembangan masa depan. Keseluruhan, eksperimen ini menggambarkan langkah-langkah kritis dalam mengembangkan model NER yang dapat diandalkan dan adaptif dalam menghadapi tugas klasifikasi entitas pada teks terkait kebakaran hutan.

5. KESIMPULAN DAN SARAN

Penelitian ini mengimplementasikan algoritma *Bidirectional LSTM* untuk mendeteksi entitas waktu dan lokasi kebakaran hutan. Hasil eksperimen menunjukkan bahwa model mampu meningkatkan akurasi dari 63.4% pada *epoch* pertama hingga mencapai 75.2% pada *epoch* terakhir pada set pelatihan. Meskipun terdapat perbedaan dengan akurasi set pelatihan, model tetap memberikan performa yang baik pada set validasi dengan akurasi stabil di sekitar 70.5%. Kurva *loss* pada kedua set menunjukkan penurunan yang konsisten, mencapai nilai minimum pada 0.801 untuk set pelatihan dan 0.875 untuk set validasi. Evaluasi pada data uji memberikan pemahaman yang lebih mendalam tentang kemampuan model menggeneralisasikan informasi ke data yang belum pernah dilihat sebelumnya, dengan *loss* sebesar 0.8750 dan akurasi 70.49%. Untuk pengembangan lebih lanjut disarankan untuk mempertimbangkan keseimbangan kelas dan penyesuaian parameter guna meningkatkan performa model. Pemilihan dataset yang lebih representatif dan peningkatan jumlah data pelatihan juga dapat memperkuat generalisasi model. Selain itu, eksplorasi lebih lanjut terhadap metode pengoptimalan parameter, seperti algoritma genetika, dapat menjadi langkah potensial untuk meningkatkan efisiensi dan ketepatan model dalam mendeteksi entitas waktu dan lokasi kebakaran hutan dalam konteks bahasa Indonesia. Keseluruhan, penelitian ini memberikan dasar yang kuat untuk pengembangan lebih lanjut dalam upaya meningkatkan kinerja model dalam penanganan kebakaran hutan di Indonesia.

DAFTAR PUSTAKA

- [1] K. von Rintelen, E. Arida, and C. Häuser, "A Review of Biodiversity-Related Issues and Challenges in Megadiverse Indonesia And Other Southeast Asian Countries," *Research Ideas and Outcomes*, vol. 3, p. e20860, Sep. 2017, doi: <https://doi.org/10.3897/rio.3.e20860>.
- [2] M. Pasai, "Dampak Kebakaran Hutan dan Penegakan Hukum," *Jurnal Pahlawan*, vol. 3, no. 1, pp. 36–46, Mar. 2020, doi: <https://doi.org/10.31004/jp.v3i1.609>.
- [3] H. N. Salsabila, A. F. Sahitya, and P. Mahyatar, "Spatio-Temporal Pattern Analysis of Forest Fire Event in South Kalimantan Using Integration Remote Sensing Data And Gis for Forest Fire Disaster Mitigation," *IOP Conference Series: Earth and Environmental Science*, vol. 540, p. 012011, Aug. 2020, doi: <https://doi.org/10.1088/1755-1315/540/1/012011>.
- [4] A. A. Nuruddin, "Mempersiapkan Pengendalian Kebakaran Hutan di Masa Datang: Teknologi dan Inovasi Baru," *Journal of Tropical Silviculture*, vol. 13, no. 01, pp. 29–36, Jun. 2022, doi: <https://doi.org/10.29244/j-siltrop.13.01.29-36>.
- [5] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [6] B. G. Pallavi, E. R. Kumar, R. Karnati and R. A. Kumar, "LSTM Based Named Entity Chunking and Entity Extraction," *2022 First International Conference on Artificial Intelligence Trends and Pattern Recognition (ICAITPR)*, Hyderabad, India, 2022, pp. 1-4, doi: 10.1109/ICAITPR51569.2022.9844180.
- [7] A. Priyadarshi and S. K. Saha, "A Study on The Performance of Recurrent Neural Network Based Models in Maithili Part of Speech Tagging," *ACM Transactions on Asian and Low-Resource Language Information Processing*, Jun. 2022, doi: <https://doi.org/10.1145/3540260>.
- [8] Y. Zheng, Z. Gao, J. Shen and X. Zhai, "Optimizing Automatic Text Classification Approach in Adaptive Online Collaborative Discussion—A Perspective of Attention Mechanism-Based Bi-LSTM," *IEEE Transactions on Learning Technologies*, vol. 16, no. 5, pp. 591-602, Oct. 2023, doi: 10.1109/TLT.2022.3192116.
- [9] A. Xu and C. Wang, "The Study of NER Methods Based on Bi-LSTM+CRF Model," *CIBDA 2022; 3rd International Conference on Computer Information and Big Data Applications*, Wuhan, China, 2022, pp. 1-8.
- [10] C. Ronran and S. Lee, "Effect of Character and Word Features in Bidirectional LSTM-CRF for NER," *2020 IEEE International Conference on Big Data and Smart Computing (BigComp)*, Busan, Korea (South), 2020, pp. 613-616, doi: 10.1109/BigComp48618.2020.00132.
- [11] J. Wang, W. Xu, X. Fu, G. Xu, and Y. Wu, "ASTRAL: Adversarial Trained LSTM-CNN for Named Entity Recognition," *Knowledge-Based Systems*, vol. 197, p. 105842, Jun. 2020, doi: <https://doi.org/10.1016/j.knsys.2020.105842>.

- [12] M. Cho, J. Ha, C. Park, and S. Park, "Combinatorial feature embedding based on CNN and LSTM for biomedical named entity recognition," *Journal of Biomedical Informatics*, vol. 103, p. 103381, Mar. 2020, doi: <https://doi.org/10.1016/j.jbi.2020.103381>.
- [13] A. A. Putra and R. Kurniawan, "Bidirectional Lstm-Cnns untuk Ekstraksi Entity Lokasi Kebakaran pada Berita Online Berbahasa Indonesia," *Seminar Nasional Official Statistics*, vol. 2020, no. 1, pp. 319–327, Jan. 2021, doi: <https://doi.org/10.34123/semnasoffstat.v2020i1.601>.
- [14] J. C.-W. Lin, Y. Shao, J. Zhang, and U. Yun, "Enhanced Sequence Labeling Based on Latent Variable Conditional Random Fields," *Neurocomputing*, vol. 403, pp. 431–440, Aug. 2020, doi: <https://doi.org/10.1016/j.neucom.2020.04.102>.
- [15] Q. E. Abbas and S.-B. Jang, "A Comparative Study of Machine Learning Algorithms Based on Tensorflow for Data Prediction," *KIPS Transactions on Computer and Communication Systems*, vol. 10, no. 3, pp. 71–80, 2021, doi: <https://doi.org/10.3745/KTCCS.2021.10.3.71>.