



Klasifikasi Komentar Judol pada Media Sosial Dengan Menggunakan Metode Recurrent Neural Network dan Long Short-Term Memory

Ilham Saputra¹, Anita Qoiriah²

¹⁻²Teknik Informatika, Universitas Negeri Surabaya, Indonesia

Email: ilham.22055@mhs.unesa.ac.id¹, anitaqoiriah@unesa.ac.id²

*Penulis Korespondensi: ilham.22055@mhs.unesa.ac.id

Abstract. The proliferation of online gambling promotional comments on Indonesian social media has become a serious issue requiring fast and accurate automated handling. This study aims to implement a Hybrid Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) method to classify online gambling comments and compare its performance with standalone RNN and LSTM models. The research utilized a dataset of 10,230 comments subjected to comprehensive preprocessing stages, including the normalization of non-standard language using a slang dictionary. Testing was conducted across three data-splitting scenarios: 90:10, 80:20, and 70:30. Experimental results demonstrate that the standalone LSTM model achieved the highest average accuracy of 97.45%. However, the Hybrid RNN–LSTM model showed significant superiority in terms of performance stability, yielding the lowest standard deviation (0.0027) and the smallest Coefficient of Variation (0.28%) across all scenarios. These findings indicate that while the LSTM architecture is highly effective at capturing short-text context, the Hybrid approach provides better robustness against fluctuations in data proportions, making it highly relevant for implementation as an automated detection system on social media.

Keywords: Hybrid RNN-LSTM; Long Short-Term Memory; Online Gambling; Recurrent Neural Network; Text Classification.

Abstrak. Maraknya komentar promosi judi *online* di media sosial Indonesia telah menjadi masalah serius yang memerlukan penanganan otomatis yang cepat dan akurat. Penelitian ini bertujuan untuk menerapkan metode *Hybrid Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) untuk mengklasifikasikan komentar judi *online* serta membandingkan kinerjanya dengan model tunggal RNN dan LSTM. Penelitian menggunakan dataset sebanyak 10.230 komentar yang melalui tahapan *preprocessing* komprehensif, termasuk normalisasi bahasa tidak baku menggunakan kamus slang. Pengujian dilakukan dengan tiga skenario pembagian data, yaitu 90:10, 80:20, dan 70:30. Hasil eksperimen menunjukkan bahwa model LSTM tunggal menghasilkan akurasi rata-rata tertinggi sebesar 97,45%. Namun, model *Hybrid RNN–LSTM* menunjukkan keunggulan signifikan dalam aspek stabilitas performa dengan nilai deviasi standar terendah (0,0027) dan Koefisien Variasi (CV) terkecil (0,28%) di seluruh skenario. Temuan ini mengindikasikan bahwa meskipun arsitektur LSTM sangat efektif dalam menangkap konteks teks pendek, penggabungan metode *Hybrid* memberikan ketangguhan (*robustness*) yang lebih baik terhadap fluktuasi proporsi data, sehingga sangat relevan untuk diimplementasikan sebagai sistem deteksi otomatis pada media sosial.

Kata kunci: Hybrid RNN-LSTM; Judi Online; Klasifikasi Teks; Long Short-Term Memory; Recurrent Neural Network.

1. LATAR BELAKANG

Perkembangan pesat platform media sosial dalam beberapa tahun terakhir telah menjadikan ruang digital sebagai arena utama bagi interaksi publik. Berbagai topik mulai dari aktivitas sehari-hari hingga isu sensitif seperti perjudian daring mudah diakses dan diperbincangkan oleh jutaan pengguna secara *real-time*. Di satu sisi, kebebasan berpendapat ini memberikan nilai positif pada demokrasi informasi. Namun di sisi lain, penyebaran konten judi *online* menimbulkan risiko normalisasi perilaku berjudi, terutama di kalangan remaja yang masih rentan terhadap pengaruh iklan maupun opini teman sebaya (Humaniora et al., 2024).

Fenomena komentar terkait judi *online* di media sosial kian kompleks, selain promosi eksplisit, terdapat pula komentar yang menyiratkan strategi, testimoni pengalaman, bahkan tautan menuju situs perjudian. Tanpa mekanisme pemantauan otomatis, volume komentar yang besar sulit dikendalikan. Kondisi ini memerlukan solusi cerdas yang mampu mengidentifikasi dan mengklasifikasikan konten berbahaya secara cepat, sekaligus memfasilitasi upaya pencegahan dan penegakan kebijakan oleh pihak berwenang atau platform (Akbar et al., 2024).

Dalam ranah *Natural Language Processing* (NLP), algoritma tradisional seperti TF-IDF + Naïve Bayes telah digunakan pada analisis sentimen judi *online*. Misalnya, studi oleh (Julianti et al., 2024) menggunakan pendekatan ini pada data Twitter dan menunjukkan hasil yang menjanjikan. Namun, karakter data media sosial yang pendek, penuh slang, emoji, dan pola tidak baku menuntut model yang lebih adaptif terhadap konteks sekuensial.

Model RNN dan turunannya, seperti LSTM, menawarkan solusi karena kemampuannya menangani dependensi jangka panjang dalam teks berurutan. Struktur *gate* LSTM—*input gate*, *forget gate*, dan *output gate* dirancang untuk menghindari masalah *vanishing gradient*, sehingga memungkinkan pelacakan informasi selama ribuan langkah waktu (Hochreiter & Schmidhuber, 1997). Sebagai hasilnya, LSTM efektif dalam memahami konteks, slang, dan struktur kalimat tidak baku, seperti yang dibuktikan (Astari & Rozaqi, 2021) dengan akurasi hingga 91,9% pada analisis sentimen multi-kelas.

Di Indonesia, beberapa penelitian telah mengeksplorasi LSTM pada tugas terkait. (Waluyo, 2023) menggunakan LSTM untuk analisis sentimen komentar negatif di media sosial. (Qiu, 2024) mengembangkan model untuk klasifikasi komentar di media sosial berbasis LSTM. Selain itu, (Parfenova, 2023) menunjukkan bahwa model sequential seperti GRU dan LSTM mengungguli BERT dalam prediksi risiko *gambling pathologis* pada data Reddit, terutama jika dikombinasikan dengan fitur temporal dan emosional, menghasilkan *F1-score* tinggi.

Sejalan dengan temuan tersebut, penggabungan RNN dan LSTM atau yang dikenal sebagai *hybrid model* dapat menjadi solusi yang lebih optimal. RNN sederhana unggul dalam menangkap pola jangka pendek dengan perhitungan yang relatif efisien, sedangkan LSTM lebih kuat dalam menjaga informasi jangka panjang melalui mekanisme *gating* (Mahjouby et al., 2025). Namun, perlu dicatat bahwa masing-masing arsitektur memiliki keterbatasan yang perlu dipertimbangkan. RNN konvensional rentan terhadap masalah *vanishing gradient* yang menyulitkan pembelajaran dependensi jangka panjang, sehingga cenderung lebih fokus pada

konteks jangka pendek dan kurang optimal untuk komentar dengan pola bahasa kompleks. Di sisi lain, LSTM meskipun mampu mengatasi keterbatasan RNN melalui mekanisme *gating*, memiliki kompleksitas komputasi yang lebih tinggi, berisiko mengalami *overfitting* pada dataset terbatas, serta memerlukan waktu pelatihan yang lebih lama dibandingkan RNN sederhana.

Dengan menggabungkan keduanya, model mampu memanfaatkan kecepatan dan efisiensi RNN sekaligus ketahanan LSTM terhadap masalah *vanishing gradient*. Mekanisme ini biasanya diterapkan dengan menempatkan lapisan RNN pada tahap awal untuk mengekstraksi pola urutan sederhana, kemudian dilanjutkan dengan lapisan LSTM untuk mengolah dependensi panjang dan konteks emosional yang lebih kompleks.

Penelitian ini memiliki kebaruan dalam beberapa aspek. Pertama, penelitian ini secara spesifik fokus pada klasifikasi komentar judi *online* berbahasa Indonesia, yang merupakan isu aktual dan mendesak di Indonesia. Kedua, penelitian ini melakukan perbandingan komprehensif antara tiga arsitektur model (RNN, LSTM, dan *Hybrid RNN-LSTM*) dengan tiga skenario pembagian data yang berbeda untuk menguji stabilitas model. Ketiga, penelitian ini menerapkan normalisasi bahasa slang yang komprehensif menggunakan kamus kustom yang mencakup istilah-istilah judi *online* spesifik, yang sering kali tidak tertangani oleh penelitian sebelumnya.

Berdasarkan uraian di atas, penelitian ini bertujuan untuk: (1) mengembangkan model klasifikasi berbasis *Hybrid RNN-LSTM* untuk mendeteksi serta mengklasifikasikan komentar judi *online* berbahasa Indonesia pada platform media sosial, dan (2) membandingkan kinerja model RNN, LSTM, dan *Hybrid RNN-LSTM* dalam mengklasifikasikan komentar judi *online*, guna memahami kelebihan dan keterbatasan masing-masing arsitektur dalam konteks data media sosial berbahasa Indonesia.

2. KAJIAN TEORITIS

Komentar Judi *Online* di Media Sosial

Komentar judi *online* di media sosial adalah ungkapan teks dari pengguna yang secara eksplisit atau implisit membahas aktivitas taruhan daring. Hal ini mencakup berbagai bentuk konten, antara lain promosi situs judi, berbagi strategi taruhan, testimoni hasil taruhan, ajakan bergabung, dan tautan afiliasi (Fahrudin et al., 2024). Di Indonesia, penetrasi media sosial sangat tinggi. Pada awal 2025 tercatat ada 212 juta pengguna internet (74,6% dari populasi),

dengan 143 juta akun media sosial aktif (50,2% dari populasi) (Zahra, 2023), sehingga volume komentar judi sangat besar dan hampir mustahil dimoderasi secara manual.

Recurrent Neural Network (RNN)

Arsitektur *Recurrent Neural Network* (RNN) dirancang khusus untuk memproses data berurutan (*sequential*), seperti teks, deret waktu, atau sinyal suara. Berbeda dengan jaringan saraf "*feed forward*" konvensional, RNN memiliki *looping* internal yang memungkinkan informasi dari langkah waktu sebelumnya (*hidden state*) dipertahankan dan digunakan kembali pada langkah berikutnya (Zhang et al., 2019). Secara konseptual, setiap unit RNN menerima dua input pada waktu t : vektor input x_t dan *hidden state* dari waktu sebelumnya h_{t-1} . Proses perhitungan di satu langkah waktu dapat dirangkum dengan persamaan:

$$h_{t-1}: h_t = \sigma_h(Ux_t + Wh_{t-1} + b_h), \quad y_t = \sigma_y(vh_t + b_y)$$

Di mana U , W , V adalah bobot, b_h , b_y bias, serta σ_h , σ_y fungsi aktivasi (misalnya tanh atau ReLU untuk *hidden layer*, *sigmoid* untuk *output*).

Kelebihan RNN meliputi kemampuan memodelkan hubungan antar-token dalam urutan, sehingga sesuai untuk teks yang memiliki dependensi kata-ke-kata, mampu menerima input dengan panjang yang bervariasi, dan informasi baru dan lama digabungkan dalam *hidden state*, membantu prediksi pada tugas seperti klasifikasi teks sekuensial (Zahra, 2023). Namun, RNN memiliki keterbatasan pada masalah *vanishing/exploding gradient* saat melakukan *backpropagation through time* (BPTT), dan sulit mengingat informasi yang sangat jauh di masa lalu (Chuluq & Nudin, 2024).

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah varian khusus dari RNN yang dirancang untuk mengatasi masalah *vanishing gradient* dan mengingat informasi dalam jangka panjang. LSTM diperkenalkan oleh (Hochreiter & Schmidhuber, 1997) dengan menambahkan *gate* yang mengatur aliran informasi ke dalam dan keluar *cell state*.

Setiap sel LSTM memiliki tiga *gate* utama. *Forget Gate* (f_t) memutuskan informasi mana dari *cell state* sebelumnya (C_{t-1}) yang perlu dilupakan. *Input Gate* (i_t) dan *Candidate Cell State* (C'_t) menentukan informasi baru apa yang akan ditambahkan ke *cell state*. *Output Gate* (C_t) berdasarkan *cell state* terkini (C_t), *gate* ini menentukan informasi mana yang akan dijadikan *hidden state* (h_t) (Waluyo, 2023).

Mekanisme *gate* ini memungkinkan LSTM menyimpan dan memanipulasi memori dalam jangka panjang dengan efektif, serta mengurangi efek *vanishing* atau *exploding gradient* saat pelatihan. LSTM memiliki kelebihan dalam memori jangka panjang, penanganan *noise* dengan *gate forget*, dan fleksibilitas input untuk sekuens dengan panjang variabel. Namun, LSTM memiliki kompleksitas komputasi yang lebih tinggi, potensi *overfitting* apabila jumlah data pelatihan tidak mencukupi, dan waktu pelatihan yang lama untuk dataset yang besar (Lee et al., 2023).

Hybrid Model RNN-LSTM

Penggabungan arsitektur Simple RNN dan LSTM (sering disebut "*hybrid model*") terbukti mampu memaksimalkan kelebihan masing-masing serta meminimalkan kelemahan yang ada. Model *hybrid* ini memanfaatkan kemampuan RNN dalam menangani urutan data secara efisien, sekaligus memanfaatkan mekanisme *gating* LSTM untuk mengatasi *vanishing gradient* dan mengingat dependensi jangka panjang.

Sebagai contoh, studi oleh (Aji & Setiawan, 2023) mengevaluasi penggunaan *hybrid* RNN–BiLSTM dan *hybrid* BiLSTM–RNN untuk mendeteksi konten hoaks di Twitter, hasilnya menunjukkan bahwa meskipun metode BiLSTM murni unggul dengan akurasi 96,48%, model *hybrid* RNN–BiLSTM mencapai akurasi 95,34% yang masih sangat kompetitif dan lebih stabil dalam beberapa variasi data. Selain itu, penelitian pada data komentar kasar berbahasa Indonesia menunjukkan penggunaan model RNN-LSTM mampu meningkatkan *F1-score* sebesar sekitar 8 poin dibanding metode Naive Bayes tradisional, dengan *F1-score* mencapai 94% (Sari et al., 2022).

Hybrid model RNN-LSTM bertujuan untuk menangkap pola jangka pendek melalui SimpleRNN yang memproses informasi sekuensial dengan *overhead* komputasi yang relatif rendah, mempertahankan memori jangka panjang melalui LSTM yang melengkapi RNN dengan *forgetting gate* dan *input gate*, serta menggabungkan kekuatan dengan menumpuk (*stacking*) lapisan Simple RNN diikuti LSTM untuk mempelajari fitur lokal (*short term*) sekaligus global (*long term*) dalam satu jaringan (Zahra, 2023).

3. METODE PENELITIAN

Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan dan menguji model klasifikasi komentar judi *online*. Desain penelitian yang digunakan adalah *comparative experimental design* dengan membandingkan tiga arsitektur model *deep learning*: *Recurrent Neural Network* (RNN), *Long Short-Term Memory* (LSTM), dan *Hybrid RNN-LSTM*.

Populasi dan Sampel

Populasi dalam penelitian ini adalah seluruh komentar berbahasa Indonesia yang terkait dengan judi *online* di platform media sosial. Sampel penelitian terdiri dari 10.230 komentar yang diperoleh dari dataset publik Kaggle. Dataset ini telah dilabeli secara biner dengan dua kategori: label 1 untuk komentar yang mengandung unsur judi *online* (4.209 komentar atau 41,1%) dan label 0 untuk komentar non-judi (6.021 komentar atau 58,9%).

Teknik Pengumpulan Data

Data dikumpulkan dari platform Kaggle yang menyediakan dataset berisi kumpulan komentar dari media sosial. Dataset yang digunakan terdiri dari beberapa fitur, yaitu *video_id*, *title*, *channel_name*, tanggal, *author*, komentar, dan label. Namun, dalam proses pemodelan, hanya kolom komentar dan label yang dimanfaatkan karena tujuan penelitian berfokus pada klasifikasi teks komentar berdasarkan kontennya.

Instrumen Penelitian

Instrumen penelitian yang digunakan adalah model *deep learning* yang dibangun menggunakan *framework TensorFlow* dan Keras. Spesifikasi perangkat keras yang digunakan adalah laptop Lenovo Ideapad Gaming 3i dengan prosesor 12th Gen Intel Core i5-12500H 2.50 GHz, RAM 16 GB DDR4, penyimpanan SSD 512 GB, sistem operasi Windows 11 64-bit, dan GPU RTX 3050. Perangkat lunak yang digunakan meliputi *Python*, *Google Colaboratory*, *Jupyter Notebook*, pustaka Sastrawi dan NLTK untuk *preprocessing*, serta *TensorFlow* dan Keras untuk pembangunan model.

Prosedur Penelitian

Tahapan penelitian dimulai dengan pengumpulan data dari dataset Kaggle. Selanjutnya dilakukan preprocessing data yang meliputi *cleaning* (normalisasi *Unicode*, penghapusan mention, URL, *tag* HTML, emoji, dan karakter *non-ASCII*, *lowercasing*, penghapusan tanda baca, dan normalisasi spasi), normalisasi slang dan istilah spesifik menggunakan kamus kustom (SLANG_DICT), validasi data (struktur kolom, kelengkapan data, dan duplikasi), serta tokenisasi dan *padding*.

Setelah *preprocessing*, dataset dibagi menjadi data latih dan data uji dengan tiga skenario pembagian: 90:10 (9.207 data latih dan 1.023 data uji), 80:20 (8.184 data latih dan 2.046 data uji), dan 70:30 (7.161 data latih dan 3.069 data uji). Pembagian data dilakukan menggunakan metode *stratified split* sehingga proporsi kelas komentar judi *online* dan non-judi tetap terjaga pada setiap skenario.

Model Penelitian

Model yang dikembangkan dalam penelitian ini terdiri dari tiga arsitektur. Pertama, model RNN menggunakan lapisan *SimpleRNN* dengan 64 unit sebagai komponen utama. Kedua, model LSTM menggunakan lapisan LSTM tunggal dengan 64 unit. Ketiga, model *Hybrid RNN-LSTM* mengintegrasikan lapisan *SimpleRNN* (64 unit) diikuti lapisan LSTM (64 unit) dengan parameter *return_sequences=True* pada *SimpleRNN*.

Ketiga model dilengkapi dengan *embedding layer* (dimensi 64), *dropout layer* (*rate* 0,2), dan *dense layer output* dengan aktivasi *sigmoid* untuk klasifikasi biner. Proses pelatihan menggunakan *optimizer* Adam dengan *learning rate* 0,001, fungsi *loss Binary Crossentropy*, *batch size* 16, dan *epoch* maksimum 100. Untuk mencegah *overfitting*, digunakan mekanisme *Early Stopping* dengan *patience* sebesar 2 yang akan menghentikan pelatihan apabila *validation loss* tidak mengalami penurunan dalam dua *epoch* berturut-turut.

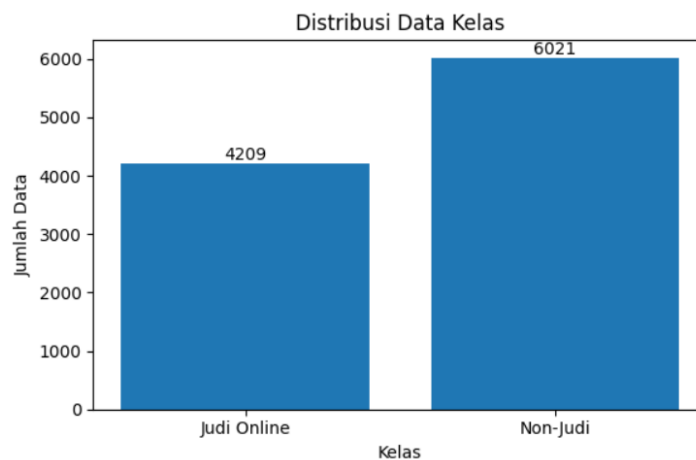
Analisis Data

Evaluasi model dilakukan menggunakan metrik akurasi (*accuracy*), *Precision*, *recall*, *F1-score*, dan *confusion matrix*. Untuk mengukur stabilitas performa model terhadap variasi proporsi pembagian data, dihitung deviasi standar akurasi dan koefisien variasi (CV) pada ketiga skenario. Perhitungan dilakukan menggunakan rumus statistik deskriptif untuk rata-rata, deviasi standar sampel, dan koefisien variasi.

4. HASIL DAN PEMBAHASAN

Deskripsi Data dan *Preprocessing*

Dataset yang digunakan terdiri dari 10.230 komentar dengan distribusi kelas yang ditunjukkan pada Gambar 1. Kelas komentar judi *online* (label 1) berjumlah 4.209 komentar (41,1%), sedangkan kelas komentar non-judi (label 0) berjumlah 6.021 komentar (58,9%). Distribusi ini menunjukkan adanya ketidakseimbangan kelas, namun tidak terlalu ekstrem sehingga masih dapat ditangani oleh model tanpa teknik khusus seperti *oversampling* atau *undersampling*.



Gambar 1. Distribusi Kelas Dataset

Setelah melalui tahap *preprocessing*, dilakukan validasi data untuk memastikan integritas dataset. Kriteria validasi meliputi struktur kolom (memverifikasi bahwa setiap entri memiliki kolom komentar dan label yang lengkap), kelengkapan data (menghapus entri yang kosong atau hanya berisi karakter tidak bermakna), dan duplikasi (mengidentifikasi dan mengeliminasi komentar yang identik secara berulang).

Proses *cleaning* menghasilkan transformasi teks yang signifikan. Sebagai contoh, teks "Makin yakin abis baca review lain tentang 🤬 G188" diubah menjadi "makin yakin abis baca review lain tentang sgi88" setelah melalui proses *case folding*, normalisasi *Unicode*, penghapusan emoji, dan penghapusan tanda baca. Contoh lain, teks "@izurzuhri kocakk emang itu caranya biar komenan judol ga diatas" diubah menjadi "kocakk emang itu caranya biar komenan judol ga diatas" setelah penghapusan mention.

Analisis statistik terhadap panjang komentar menunjukkan bahwa rata-rata panjang komentar adalah 7 kata dengan 99th *percentile* sebesar 16 kata. Berdasarkan hasil tuning parameter, panjang sekuens maksimum (*max_len*) optimal adalah 20 kata. Pengujian dengan *max_len*=25 menghasilkan penurunan signifikan pada performa (akurasi 0,9310; *F1-score* 0,93) dibandingkan *max_len*=20 (akurasi 0,9574; *F1-score* 0,96). Penurunan ini disebabkan oleh peningkatan *padding* berlebihan yang memperkenalkan *noise* pada representasi sekuens, terutama pada komentar pendek yang mendominasi dataset.

Konfigurasi Parameter

Parameter final yang digunakan dalam eksperimen ditentukan melalui proses *tuning* empiris dengan menguji berbagai kombinasi nilai kandidat pada skenario pembagian data 80:20. *Vocabulary size* optimal adalah 8.000, yang menghasilkan performa tertinggi (akurasi 0,9574; *F1-score* 0,96) dibandingkan *vocabulary size* 5.000 (akurasi 0,9432) dan 10.000 (akurasi 0,9407). *Vocabulary size* di bawah 5.000 dan di atas 10.000 justru menurunkan performa karena memperkenalkan *noise* dari kata jarang yang tidak memberikan kontribusi signifikan terhadap klasifikasi.

Dimensi *embedding* optimal adalah 64, yang menghasilkan akurasi tertinggi (0,9574) dan *F1-score* optimal (0,96). Dimensi 32 menghasilkan akurasi 0,9525 (*F1-score* 0,95) yang lebih rendah karena kapasitas representasi semantik terbatas. Dimensi 128 tidak memberikan peningkatan performa (akurasi 0,9535; *F1-score* 0,95) namun meningkatkan waktu pelatihan secara signifikan tanpa keuntungan proporsional pada kemampuan klasifikasi.

Jumlah neuron untuk lapisan RNN dan LSTM adalah 64 unit masing-masing. Eksperimen dengan berbagai kombinasi unit menunjukkan bahwa konfigurasi 64/64 menghasilkan performa tertinggi (akurasi 0,9574; *F1-score* 0,96). Konfigurasi dengan unit lebih rendah (32/32 atau 64/32) menghasilkan akurasi 0,9535-0,9540, sedangkan konfigurasi dengan unit lebih tinggi (64/128, 128/64, atau 128/128) tidak meningkatkan akurasi (0,9525-0,9535).

Dropout rate optimal adalah 0,2, yang menghasilkan akurasi tertinggi (0,9574) dan *F1-score* optimal (0,96). *Dropout rate* 0,1 menghasilkan akurasi 0,9554 (*F1-score* 0,95), sedangkan *dropout rate* 0,3 menurunkan akurasi menjadi 0,9530 (*F1-score* 0,95) karena menghambat kemampuan model mempelajari pola kritis pada dataset berukuran terbatas.

Batch size optimal adalah 16, yang menghasilkan performa tertinggi (akurasi 0,9574; F1-score 0,96) dibandingkan *batch size* 32 (akurasi 0,9559). *Epoch* maksimum ditetapkan sebesar 100, namun berdasarkan observasi pada seluruh eksperimen *tuning*, pelatihan aktual dihentikan lebih awal oleh mekanisme *early stopping* pada *epoch* ke-3 hingga ke-6 karena tidak terjadi peningkatan *validation loss* selama 2 *epoch* berturut-turut.

Hasil Pengujian Model RNN

Model RNN diuji pada tiga skenario pembagian data. Pada skenario 90:10, model RNN mencapai konvergensi optimal pada *epoch* ke-4 dengan akurasi sebesar 97,26% dan *test loss* sebesar 0,1060. *Confusion matrix* menunjukkan *True Negative* (TN) sebesar 598, *False Positive* (FP) sebesar 4, *False Negative* (FN) sebesar 24, dan *True Positive* (TP) sebesar 397. *Precision* untuk kelas judi *online* adalah 0,99, *recall* 0,94, dan F1-score 0,97.

Pada skenario 80:20, model RNN mencapai konvergensi pada *epoch* ke-4 dengan akurasi 97,02% dan *test loss* 0,1007. *Confusion matrix* menunjukkan TN=1192, FP=12, FN=49, dan TP=793. *Precision* untuk kelas judi *online* adalah 0,99, *recall* 0,94, dan F1-score 0,96.

Pada skenario 70:30, model RNN mencapai konvergensi pada *epoch* ke-3 dengan akurasi 95,73% dan *test loss* 0,1286. *Confusion matrix* menunjukkan TN=1722, FP=84, FN=47, dan TP=1216. *Precision* untuk kelas judi *online* adalah 0,94, *recall* 0,96, dan F1-score 0,95.

Hasil Pengujian Model LSTM

Model LSTM menunjukkan performa yang sangat baik pada ketiga skenario. Pada skenario 90:10, model LSTM mencapai konvergensi optimal pada *epoch* ke-4 dengan akurasi sebesar 97,65% dan *test loss* sebesar 0,0767. *Confusion matrix* menunjukkan TN=600, FP=2, FN=22, dan TP=399. *Precision* untuk kelas judi *online* mencapai 1,00 (sempurna), *recall* 0,95, dan F1-score 0,97.

Pada skenario 80:20, model LSTM mencapai performa terbaik di antara ketiga skenario dengan akurasi 97,90% dan *test loss* 0,0859. *Confusion matrix* menunjukkan TN=1180, FP=24, FN=19, dan TP=823. *Precision* untuk kelas judi *online* adalah 0,97, *recall* 0,98, dan F1-score 0,97.

Pada skenario 70:30, model LSTM mencapai konvergensi pada *epoch* ke-4 dengan akurasi 96,81% dan *test loss* 0,1157. *Confusion matrix* menunjukkan TN=1750, FP=56, FN=42, dan TP=1221. *Precision* untuk kelas judi *online* adalah 0,96, *recall* 0,97, dan F1-score 0,96.

Hasil Pengujian Model Hybrid RNN-LSTM

Model Hybrid RNN-LSTM menunjukkan stabilitas performa yang mengesankan pada ketiga skenario. Pada skenario 90:10, model mencapai konvergensi optimal pada *epoch* ke-3 dengan akurasi sebesar 97,65% dan *test loss* sebesar 0,0835. *Confusion matrix* menunjukkan TN=593, FP=9, FN=15, dan TP=406. *Precision* untuk kelas judi *online* adalah 0,98, *recall* 0,96, dan *F1-score* 0,97.

Pada skenario 80:20, model mencapai konvergensi pada *epoch* ke-4 dengan akurasi 97,21% dan *test loss* 0,0945. *Confusion matrix* menunjukkan TN=1175, FP=29, FN=28, dan TP=814. *Precision* untuk kelas judi *online* adalah 0,97, *recall* 0,97, dan *F1-score* 0,97.

Pada skenario 70:30, model menunjukkan ketahanan yang mengesankan dengan akurasi 97,17% dan *test loss* 0,0910. *Confusion matrix* menunjukkan TN=1780, FP=26, FN=61, dan TP=1202. *Precision* untuk kelas judi *online* adalah 0,98, *recall* 0,95, dan *F1-score* 0,97.

Perbandingan Performa Ketiga Model

Tabel 1 menyajikan ringkasan performa komprehensif ketiga model pada berbagai skenario pembagian data. Berdasarkan tabel tersebut, dapat diidentifikasi beberapa pola penting.

Tabel 1. Ringkasan Performa Komprehensif Ketiga Model pada Berbagai Skenario Pembagian Data

Model	Skenario	Accuracy	Precision	Recall	F1-Score	Test loss
RNN	90:10	0,9726	0,99	0,94	0,97	0,1060
	80:20	0,9702	0,99	0,94	0,96	0,1007
	70:30	0,9573	0,94	0,96	0,95	0,1286
	Rata-rata	0,9667	0,97	0,95	0,96	0,1118
LSTM	90:10	0,9765	1,00	0,95	0,97	0,0767
	80:20	0,9790	0,97	0,98	0,97	0,0859
	70:30	0,9681	0,96	0,97	0,96	0,1157
	Rata-rata	0,9745	0,98	0,97	0,97	0,0928
Hybrid	90:10	0,9765	0,98	0,96	0,97	0,0835
RNN-LSTM	80:20	0,9721	0,97	0,97	0,97	0,0945
	70:30	0,9717	0,98	0,95	0,97	0,0910
	Rata-rata	0,9734	0,98	0,96	0,97	0,0897

Model LSTM menunjukkan performa rata-rata tertinggi dengan akurasi 0,9745 dan *F1-score* konsisten 0,97 pada kelas judi *online*. Model ini juga mencatat *test loss* rata-rata terendah (0,0928), mengindikasikan stabilitas pembelajaran yang superior. Namun, model *Hybrid* RNN-LSTM menunjukkan stabilitas *test loss* terbaik dengan deviasi terendah antar skenario (0,0835-0,0945), mengindikasikan bahwa arsitektur *hybrid* mampu mempertahankan konsistensi kualitas pembelajaran meskipun proporsi data berubah.

Model RNN menunjukkan sensitivitas tertinggi terhadap pengurangan data latih, dengan penurunan akurasi 1,53 poin persentase dari skenario 90:10 ke 70:30. Namun, model ini tetap mencapai performa kompetitif pada skenario dengan data latih memadai ($\geq 80\%$).

Analisis Stabilitas Model

Untuk mengukur stabilitas performa model terhadap variasi proporsi pembagian data, dihitung deviasi standar akurasi dan koefisien variasi (CV) pada ketiga skenario. Hasil perhitungan menunjukkan bahwa model *Hybrid RNN-LSTM* memiliki stabilitas tertinggi dengan deviasi standar terkecil (0,0027) dan koefisien variasi hanya 0,28%. Model LSTM menunjukkan stabilitas yang sangat baik dengan deviasi standar 0,0057 (CV = 0,59%). Sementara itu, model RNN menunjukkan stabilitas terendah dengan deviasi standar 0,0082 (CV = 0,85%).

Temuan ini sangat signifikan karena menunjukkan bahwa meskipun memiliki arsitektur lebih kompleks, model *hybrid* justru paling tahan terhadap fluktuasi performa ketika proporsi data latih-uji divariasikan. Rentang *test loss* yang sempit pada model hybrid (0,0835-0,0945) juga mengkonfirmasi konsistensi kualitas pembelajaran model ini.

Pembahasan

Hasil pengujian menunjukkan bahwa model LSTM tunggal mencatatkan rata-rata akurasi tertinggi sebesar 0,9745 dengan *test loss* rata-rata terendah sebesar 0,0928. Hal ini membuktikan bahwa mekanisme gating pada LSTM (khususnya *forget gate*) sangat efektif dalam memfilter informasi relevan pada komentar media sosial yang cenderung singkat namun padat akan kata-kata kunci tertentu. Mekanisme gate LSTM memungkinkan model untuk mempertahankan informasi penting dari urutan panjang serta mengatasi masalah vanishing gradient yang umum terjadi pada RNN konvensional (Hochreiter & Schmidhuber, 1997).

Di sisi lain, model Hybrid RNN-LSTM menunjukkan keunggulan pada aspek stabilitas. Meskipun akurasi rata-ratanya (0,9734) sedikit di bawah LSTM tunggal, model *hybrid* memiliki deviasi standar terkecil (0,0027) dan rentang *test loss* yang paling sempit yaitu 0,0835-0,0945. Integrasi lapisan SimpleRNN di depan lapisan LSTM berperan sebagai pengekstrak fitur sekuensial awal yang membantu LSTM bekerja lebih konsisten, sehingga model ini tidak mudah terpengaruh oleh perubahan proporsi data latih dan uji. Temuan ini sejalan dengan penelitian (Fahrudin et al., 2024) yang menunjukkan bahwa penggabungan RNN dan LSTM meningkatkan stabilitas model pada berbagai kondisi data.

Sementara itu, model RNN terbukti paling sensitif terhadap pengurangan data. Penurunan akurasi sebesar 1,53% dari skenario 90:10 ke 70:30 menunjukkan keterbatasan arsitektur RNN konvensional dalam mempertahankan performa ketika jumlah sampel latihan berkurang. Hal ini disebabkan oleh masalah *vanishing gradient* yang membuat RNN sulit mempelajari dependensi jangka panjang, sehingga model lebih bergantung pada konteks jangka pendek (Chuluq & Nudin, 2024).

Analisis terhadap dataset menunjukkan rata-rata panjang komentar adalah 7 kata dengan *max sequence length* optimal pada 20 kata. Karakteristik teks yang pendek ini menjelaskan mengapa model LSTM dan *Hybrid* mampu mencapai *F1-score* yang sangat tinggi (0,96-0,97) secara konsisten. Pada teks pendek, ketergantungan antar kata tidak terlalu jauh, sehingga masalah *vanishing gradient* pada RNN tidak terlalu ekstrem namun tetap terlihat perbedaannya dibandingkan LSTM. Penggunaan *vocabulary size* sebesar 8.000 dan *embedding dimension* 64 terbukti memberikan representasi ruang vektor yang cukup kaya untuk menangkap istilah-istilah khas judi *online* seperti "gacor", "jackpot", atau "wd" yang telah melalui proses normalisasi.

Eksperimen membuktikan bahwa ketersediaan data latihan yang besar (skenario 90:10) meningkatkan akurasi seluruh model, di mana RNN mencapai titik tertingginya (0,9726). Namun, temuan paling signifikan terdapat pada skenario 70:30, di mana *Hybrid* RNN-LSTM justru mencapai akurasi 0,9717, lebih tinggi dibandingkan RNN (0,9573) dan bahkan LSTM (0,9681). Ini mengindikasikan bahwa arsitektur *hybrid* memiliki kemampuan generalisasi yang lebih kuat pada kondisi data yang lebih terbatas dibandingkan model tunggal. Mekanisme *Dropout* sebesar 0,2 yang diterapkan setelah lapisan LSTM juga terbukti krusial dalam mencegah *overfitting*, sehingga model tetap mampu mengenali pola komentar judi *online* pada data uji yang belum pernah dilihat sebelumnya tanpa hanya menghafal data latihan.

Penggunaan kamus normalisasi slang (SLANG_DICT) dan tahap pembersihan teks yang komprehensif terbukti menjadi faktor kunci keberhasilan model. Mengingat rata-rata panjang komentar judi *online* hanya sekitar 7 kata, pembersihan *noise* seperti URL, emoji, dan karakter non-ASCII memastikan model hanya fokus pada fitur semantik yang esensial. Normalisasi istilah judi *online* seperti "wd" menjadi "withdraw", "depoin" menjadi "deposit", dan "jp" menjadi "jackpot" membantu model mengenali variasi penulisan yang sering digunakan dalam komentar promosi judi.

Implementasi *Early Stopping* dengan patience sebesar 2 dan penggunaan *Dropout* 0,2 berhasil mencegah terjadinya *overfitting*, sehingga model tetap memiliki kemampuan generalisasi yang baik meskipun dievaluasi pada skenario data latih yang lebih sedikit (70:30). Model mencapai konvergensi pada *epoch* ke-3 hingga ke-4 di seluruh skenario, menunjukkan efisiensi pelatihan yang tinggi dan menghemat waktu komputasi secara signifikan dibandingkan pelatihan hingga *epoch* 100.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil eksperimen dan analisis yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Hybrid RNN-LSTM* untuk klasifikasi komentar judi *online* berhasil dikembangkan melalui tahapan preprocessing yang komprehensif, meliputi pembersihan teks, normalisasi kata tidak baku, tokenisasi, dan penggunaan *embedding* dengan dimensi 64. Arsitektur *Hybrid* dibangun dengan mengintegrasikan lapisan SimpleRNN untuk mengekstraksi fitur sekuensial awal, yang kemudian diteruskan ke lapisan LSTM untuk menangkap dependensi jangka panjang. Model ini dioptimalkan menggunakan optimizer Adam, fungsi *loss Binary Crossentropy*, serta mekanisme *Early Stopping* dan *Dropout* 0,2 untuk mencegah *overfitting*.

Perbandingan kinerja menunjukkan bahwa model LSTM tunggal memiliki rata-rata akurasi tertinggi sebesar 97,45%, disusul oleh model *Hybrid RNN-LSTM* sebesar 97,34%, dan model RNN sebesar 96,67%. Berdasarkan metrik lainnya, model *Hybrid* menunjukkan keunggulan signifikan dalam hal stabilitas performa dengan nilai Deviasi Standar terkecil (0,0027) dan Koefisien Variasi (0,28%), yang berarti model ini paling konsisten di berbagai skenario pembagian data (90:10, 80:20, dan 70:30). Ketiga model berhasil mencapai *F1-score* yang sangat baik di atas 95%, namun model *Hybrid RNN-LSTM* terbukti lebih tangguh (robust) terhadap fluktuasi jumlah data latih dibandingkan model tunggal lainnya. Temuan ini mengindikasikan bahwa meskipun arsitektur LSTM sangat efektif dalam menangkap konteks teks pendek, penggabungan metode *Hybrid* memberikan ketangguhan yang lebih baik terhadap fluktuasi proporsi data, sehingga sangat relevan untuk diimplementasikan sebagai sistem deteksi otomatis pada media sosial.

Untuk pengembangan penelitian di masa mendatang, disarankan untuk memperbarui kamus normalisasi secara berkala atau menggunakan metode automated slang detection untuk menangkap istilah-istilah baru yang sering digunakan pelaku judi *online* untuk menghindari pemblokiran. Penelitian selanjutnya juga dapat mengeksplorasi penggunaan metode *Attention Mechanism* atau model berbasis *Transformer* seperti BERT untuk membandingkan efektivitasnya dalam menangkap konteks kalimat yang lebih kompleks dibandingkan arsitektur RNN-LSTM. Selain itu, pengembangan dapat diarahkan pada klasifikasi multi-kelas untuk membedakan antara promosi situs judi, testimoni kemenangan (*bot*), dan diskusi organik pengguna media sosial, sehingga sistem moderasi dapat lebih presisi dalam mengambil tindakan.

DAFTAR REFERENSI

- Aji, H. B., & Setiawan, E. B. (2023). Detecting Hoax Content on Social Media Using Bi-LSTM and RNN. *BITS*, 5(1), 114–125. <https://doi.org/10.47065/bits.v5i1.3585>
- Akbar, G. G., Ulumudin, A., Kania, I., & Nurliawati, N. (2024). *Policy brief: Tackling the social, economic, and*. 3(4), 1017–1035.
- Astari, Y., & Rozaqi, S. W. (2021). *Analisis sentimen multi-class pada sosial media menggunakan metode LSTM*. 4(1), 8–12.
- Chuluq, K., & Nudin, S. R. (2024). *Klasifikasi cyberbullying pada media sosial menggunakan RNN dan LSTM*. 6(19), 501–509.
- Fahrudin, A., Satispi, E., Subardhini, M., Hartini, R., Andayani, R., & Jayaputra, A. (2024). *Online gambling addiction: Problems and solutions for policymakers and stakeholders in Indonesia*. 8(11), 1–17.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Humaniora, P. D., Bawembang, N., & Umboh, J. (2024). *Enforcement of the ITE Law and the impact of online gambling promotion*. 8(2), 2268–2279. <https://doi.org/10.36526/js.v3i2>
- Julianti, O. N., Suarna, N., & Prihartono, W. (2024). *Penerapan NLP pada analisis sentimen judi online di media sosial Twitter*. 8(3), 2936–2941.
- Lee, J., Rajtmajer, S., Srivatsavaya, E., & Wilson, S. (2023). Online Self-Disclosure, Social Support, and User Engagement During the COVID-19 Pandemic. *Trans. Soc. Comput.*, 6(3–4). <https://doi.org/10.1145/3617654>
- Mahjouby, M. E. L., Fahssi, K. El, Bennani, M. T., & Lamrini, M. (2025). Simple RNN-LSTM hybrid deep learning model for forecasting. *TELKOMNIKA*, 23(1), 175–184.

<https://doi.org/10.12928/TELKOMNIKA.v23i1.25925>

Parfenova, A. (2023). *Risk prediction of pathological gambling in social media*.

Qiu, C. (2024). *Classification of comments on social media based on LSTM*. 124–128.
<https://doi.org/10.54254/2755-2721/54/20241432>

Sari, T. I., Ardilla, Z. N., Hayatin, N., & Maskat, R. (2022). Abusive comment identification on Indonesian social media data using hybrid deep learning. *IJAI*, 11(3), 895–904.
<https://doi.org/10.11591/ijai.v11.i3.pp895-904>

Waluyo, I. G. (2023). *Sentiment analysis of negative comments on social media using LSTM with TensorFlow*. 2(7), 1015–1030.

Zahra, A. (2023). *Hoax identification on social media using RNN and LSTM*. 448–451.

Zhang, W., Huang, G., Wang, G., & Wang, Y. (2019). *Prediction high frequency parameters based on neural network*. <https://doi.org/10.1088/1757-899X/631/5/052035>