

Implementasi *Chatbot Multi-Intent* untuk Informasi Penerimaan Mahasiswa Baru Berbasis Jaringan Saraf Tiruan

<http://dx.doi.org/10.28932/jutisi.v12i2.14232>

Riwayat Artikel

Received: 28 Desember 2025 | Final Revision: 23 Juli 2026 | Accepted: 27 Juli 2026

Creative Commons License 4.0 (CC BY – NC)



M Thoriq Panca Mukti^{✉#1}, Safrin^{#2}, Moh Sa'id Ramdhoni^{#3}

[#] Program Studi Ilmu Komputer, Universitas Bumigora

Jl. Ismail Marzuki, Cilinaya, Cakranegara, Kota Mataram, 83127, Indonesia

¹mthoriqpancamukti@gmail.com

²safrinmachi@gmail.com

³dhoni.nuck@gmail.com

✉Corresponding author: mthoriqpancamukti@gmail.com

Abstrak — Transformasi digital pada layanan pendidikan tinggi memerlukan penyediaan layanan informasi Penerimaan Mahasiswa Baru (PMB) yang cepat, akurat, dan tersedia secara berkelanjutan. Akan tetapi, layanan PMB konvensional masih menghadapi permasalahan keterbatasan waktu layanan, beban kerja staf, serta kesulitan dalam menangani pertanyaan pengguna yang bervariasi dan bersifat *multi-intent*. Penelitian ini bertujuan untuk mengimplementasikan *chatbot* layanan informasi PMB berbasis *Artificial Intelligence* yang mampu menangani pertanyaan *multi-intent* secara efektif. Pendekatan yang diusulkan mengintegrasikan model bahasa pra-latih IndoBERT sebagai pengekstraksi fitur semantik dengan *Artificial Neural Network* (ANN) sebagai pengklasifikasi *intent*. Dataset penelitian terdiri dari 1.064 variasi pertanyaan yang dikelompokkan ke dalam 21 kategori *intent*. Hasil pengujian menunjukkan bahwa model mencapai tingkat akurasi sebesar 96%, dengan nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,96. Implementasi sistem membuktikan bahwa *chatbot* mampu memberikan respons yang relevan baik pada skenario *single-intent* maupun *multi-intent*. Dengan demikian, pendekatan ini efektif dalam meningkatkan kualitas dan fleksibilitas layanan informasi PMB berbasis *chatbot*.

Kata kunci— *Artificial Neural Network*; *Chatbot*; *Multi-Intent*; *Natural Language Processing*; Penerimaan Mahasiswa Baru.

Multi-Intent Chatbot for New Student Admission Information Using Artificial Neural Networks

Abstract — Digital transformation in higher education services requires the provision of New Student Admission information (PMB) services that are fast, accurate, and available on an ongoing basis. However, conventional PMB services still face the problem of limited service time, staff workload, and difficulty in handling user inquiries that vary and are *multi-intent*. This study aims to implement a PMB information service chatbot based on Artificial Intelligence that is able to handle *multi-intent* questions effectively. The proposed approach integrates IndoBERT Pre-trained language model as semantic feature extractor with Artificial Neural Network (ANN) as intent classifier. The research Dataset consisted of 1,064 question variations grouped into 21 intent categories. The test results showed that the model achieved an accuracy rate of 96%, with the value of precision, recall, and F1-score of 0.96, respectively. The implementation of the system proves that the chatbot is able to provide relevant responses in both *single-intent* and

multi-intent scenarios. Thus, this approach is effective in improving the quality and flexibility of chatbot-based PMB information services.

Keywords— *Artificial Neural Network; Chatbot; Multi-Intent; Natural Language Processing; New Student Admission.*

I. PENDAHULUAN

Transformasi digital dalam layanan pendidikan tinggi mendorong perguruan tinggi untuk mengadopsi sistem berbasis *Artificial Intelligence* (AI) untuk meningkatkan efisiensi dan kualitas layanan informasi akademik [1], [2]. Salah satu penerapan AI yang banyak digunakan adalah *chatbot*, yaitu sistem dialog otomatis yang mampu berinteraksi dengan pengguna melalui bahasa alami secara *real-time* [3]. Dalam konteks penerimaan mahasiswa baru (PMB), *chatbot* berperan sebagai media layanan informasi selama 24 jam yang dapat mengatasi keterbatasan waktu operasional dan sumber daya manusia pada unit layanan akademik [4].

Layanan PMB memiliki karakteristik pertanyaan yang berulang, beragam, dan bersifat kritis bagi calon mahasiswa, seperti informasi jadwal pendaftaran, biaya pendidikan, program studi, serta prosedur administrasi [5]. Ketergantungan pada layanan manual atau live chat sering menyebabkan keterlambatan respons, inkonsistensi informasi, dan meningkatnya beban kerja staf, khususnya pada masa puncak pendaftaran [6], [7]. Oleh karena itu, pengembangan *chatbot* cerdas yang mampu memahami bahasa alami pengguna secara lebih fleksibel menjadi solusi strategis untuk meningkatkan kualitas layanan PMB secara berkelanjutan [8].

Berbagai penelitian terdahulu telah mengembangkan *chatbot* sebagai asisten virtual layanan penerimaan mahasiswa baru, namun masih menghadapi tantangan dalam fleksibilitas dan pemahaman konteks. Penelitian awal yang menggunakan metode berbasis aturan (*rule-based*) terbukti efektif untuk pertanyaan sederhana, dengan implementasi berbasis AIML mampu mencapai skor penerimaan pengguna sebesar 94,67% [9], serta pendekatan pola kata kunci (*keyword matching*) yang menghasilkan akurasi respon 85,83% [10] dan skor kepuasan 71,93% [11]. Penelitian selanjutnya mulai mengadopsi pendekatan NLP dan *Machine Learning* untuk meningkatkan kinerja, di mana metode *Bi-Directional Long Short-Term Memory* (Bi-LSTM) menghasilkan akurasi 83,67% [12], *Neural Network* dengan *Bag of Words* mencapai akurasi 90,77% [13], dan kombinasi *Naive Bayes* dengan *Levenshtein Distance* mencatatkan akurasi hingga 92% [14]. Meskipun akurasi kuantitatif yang dicapai cukup tinggi, metode-metode tersebut umumnya masih berfokus pada klasifikasi *single-intent* dan sering kali mengalami penurunan performa saat menghadapi kalimat kompleks yang memuat banyak maksud (*multi-intent*) atau ambiguitas semantik yang tinggi, yang menjadi fokus perbaikan mendasar pada penelitian ini.

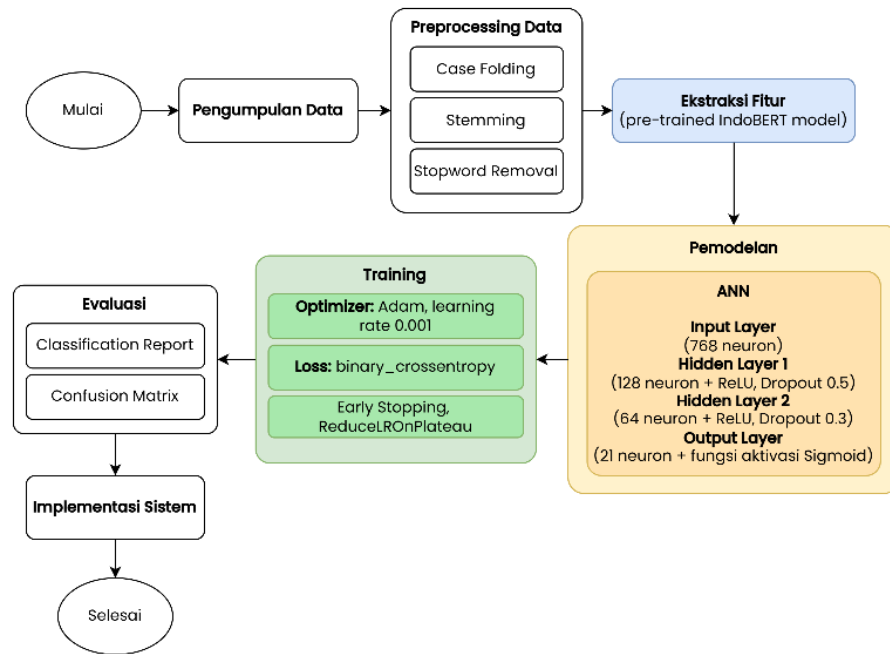
Perkembangan terbaru dalam *Natural Language Processing* (NLP) menunjukkan bahwa *Pre-trained language model* berbasis Transformer, seperti BERT, mampu menangkap representasi semantik kontekstual secara lebih mendalam [15]. IndoBERT, sebagai model bahasa pra-latih khusus Bahasa Indonesia, memiliki keunggulan dalam mempertahankan konteks dan relasi antar kata karena dilatih dengan korpus Bahasa Indonesia dalam skala besar [16]. Namun, pemanfaatan IndoBERT untuk menangani klasifikasi *multi-intent* pada kasus *chatbot* PMB belum banyak dieksplorasi dalam penelitian terdahulu yang masih didominasi oleh metode klasifikasi tradisional [7]–[14].

Berdasarkan tinjauan tersebut, *research gap* yang mendasar pada penelitian-penelitian terdahulu terletak pada keterbatasan sistem yang masih bergantung pada klasifikasi *single-intent* sehingga kurang fleksibel dalam menangani kompleksitas kalimat pengguna. Untuk mengatasi permasalahan tersebut, terdapat kebutuhan mendesak terhadap pendekatan *multi-intent* yang didukung oleh contextual embedding guna menangkap representasi makna secara mendalam. Oleh karena itu, penelitian ini bertujuan untuk mengimplementasi *chatbot* layanan informasi PMB yang mengintegrasikan ekstraksi fitur IndoBERT dengan algoritma Artificial Neural Network (ANN). Penggunaan algoritma ANN dipilih karena kemampuannya dalam memetakan pola non-linear dari vektor berdimensi tinggi [17], serta fleksibilitas pada output layer untuk memprediksi probabilitas beberapa kelas secara independent [18].

Meskipun penggunaan IndoBERT untuk klasifikasi teks telah banyak dieksplorasi secara umum, nilai kebaruan (*novelty*) dan kontribusi dari penelitian ini terletak pada penerapan arsitektur tersebut untuk memecahkan masalah *multi-intent classification* dalam domain spesifik layanan Penerimaan Mahasiswa Baru (PMB). Melalui rumusan ini, kerangka kerja *chatbot* yang diusulkan terbukti secara efektif mampu mendeteksi, mengurai, dan merespons berbagai maksud ganda sekaligus di dalam satu kalimat pengguna, sebuah pendekatan yang belum terakomodasi pada sistem layanan PMB terdahulu.

II. METODE PENELITIAN

Penelitian ini dilakukan dengan langkah-langkah sistematis yang mencakup pengumpulan data, *preprocessing* data, ekstraksi fitur, pemodelan, training, evaluasi, serta implementasi sistem pada antarmuka website. Proses metode penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Alur tahapan penelitian

A. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh melalui proses pengumpulan pengetahuan dengan cara melakukan wawancara langsung kepada panitia Penerimaan Mahasiswa Baru di Universitas Bumigora. Tujuan dari wawancara ini adalah untuk menemukan informasi penting serta pertanyaan yang sering diajukan. Data yang diperoleh diubah menjadi data terstruktur yang berformat *JSON*, yang mencakup elemen-elemen seperti kategori (*intent*), pola kalimat (*pattern*), dan jawaban (*response*). Dari kegiatan tersebut, terkumpul total dataset yang terdiri dari 1.064 variasi kalimat pertanyaan, yang dikelompokkan ke dalam 21 kategori *intent*.

B. Preprocessing Data

Tahap Preprocessing data dilakukan untuk mempersiapkan data teks supaya berada dalam format yang seragam dan optimal sebelum dilakukan proses ekstraksi fitur dan pemodelan. Pada tahapan ini teks akan diproses menggunakan pendekatan *Natural Language Processing* (NLP) untuk mengurangi variasi penulisan, menghilangkan noise linguistik, serta meningkatkan kualitas representasi semantik kalimat yang akan diproses oleh model *Artificial Neural Network* (ANN).

Proses pembersihan teks terdiri dari tiga langkah utama, yaitu *case folding*, *stopword removal*, dan *stemming*. *Case folding* bertujuan untuk mengubah semua teks menjadi huruf kecil untuk menghindari perbedaan makna yang disebabkan oleh variasi penggunaan huruf kapital [19]. Selanjutnya, *stopword removal* digunakan untuk menghapus kata-kata umum yang tidak berkontribusi signifikan terhadap penentuan *intent* [20]. Tahap *stemming* dilakukan menggunakan pustaka Sastrawi untuk mengubah kata berimbuhan dalam Bahasa Indonesia menjadi kata dasarnya sehingga menghasilkan teks yang lebih ringkas dan representatif untuk tahap pemrosesan selanjutnya [21].


C. Ekstraksi Fitur

Tahap ekstraksi fitur dilakukan untuk mengubah teks hasil preprocessing menjadi representasi numerik yang dapat diproses oleh model klasifikasi. Pada penelitian ini digunakan model bahasa pra-latih IndoBERT untuk menghasilkan *embedding* teks yang bersifat kontekstual. Setiap kalimat diproses menggunakan *tokenizer* IndoBERT dan direpresentasikan dalam bentuk vektor berdimensi 768 yang diperoleh dari *mean pooling* pada keluaran *last hidden state*. Pendekatan ini memungkinkan sistem menangkap informasi semantik dan konteks antar kata secara lebih baik dibandingkan metode ekstraksi fitur berbasis frekuensi, sehingga mendukung peningkatan kinerja model *Artificial Neural Network* (ANN) dalam melakukan klasifikasi *intent* pada *chatbot* layanan informasi Penerimaan Mahasiswa Baru [22].

D. Pemodelan

Tahap pemodelan berfokus pada pembangunan arsitektur *Artificial Neural Network* (ANN) untuk mengklasifikasikan *intent* pengguna berdasarkan fitur vektor yang dihasilkan oleh IndoBERT. Penelitian ini merancang struktur jaringan syaraf

tiruan yang terdiri dari empat lapisan utama (layer), yaitu satu *input layer*, dua *hidden layer*, dan satu *output layer*, yang divisualisasikan pada Gambar 2.



Gambar 2. Arsitektur ANN 4 layer

Lapisan input dirancang menerima vektor berdimensi 768, yang kemudian diproses oleh dua lapisan tersembunyi dengan masing-masing 128 dan 64 neuron menggunakan fungsi aktivasi ReLU. Pemilihan arsitektur dengan jumlah neuron yang mengecil menyerupai corong (*funnel architecture*) ini bertujuan untuk mereduksi dimensi fitur secara bertahap dari ruang representasi IndoBERT yang sangat tinggi (768 dimensi). Proses kompresi ini memaksa jaringan untuk mengekstraksi pola fitur yang paling esensial dan membuang informasi redundan sebelum proses klasifikasi. Untuk meningkatkan generalisasi dan mencegah *overfitting*, teknik *Dropout* diterapkan pada kedua lapisan tersembunyi tersebut [23].

Proses klasifikasi diakhiri pada lapisan output yang menggunakan fungsi aktivasi Sigmoid dengan 21 neuron, memungkinkan model untuk mendeteksi probabilitas multi-intent secara independen pada setiap kategori [24]. Pemberian label multi-intent pada penelitian ini diformulasikan sebagai masalah multi-label classification berbasis ambang batas (*threshold-based classification*). Karena menggunakan aktivasi Sigmoid, setiap neuron output akan memancarkan nilai probabilitas antara 0 hingga 1 secara independen. Sistem akan mengevaluasi seluruh 21 kelas, dan setiap kategori kelas yang memiliki nilai probabilitas melebihi ambang batas (*threshold*) standar sebesar 0,5 akan ditetapkan sebagai label intent yang positif/terdeteksi. Mekanisme ini memastikan sistem mampu mendeteksi satu, beberapa, atau bahkan tidak ada maksud sama sekali di dalam sebuah kalimat kompleks.

E. Training

Tahap pelatihan dilakukan untuk melatih model *Artificial Neural Network* (ANN) agar mampu mengklasifikasikan *intent* berdasarkan fitur yang diekstraksi dari IndoBERT. Sebelum pelatihan dimulai, dataset dibagi menggunakan teknik *stratified split* dengan proporsi 80% data latih dan 20% data uji untuk menjaga keseimbangan distribusi kelas. Untuk memastikan proses pembelajaran berjalan optimal dan konsisten, penelitian ini menerapkan konfigurasi *hyperparameter* spesifik yang dirincikan pada Tabel 1.

TABEL 1
KONFIGURASI HYPERPARAMETER PELATIHAN

Parameter	Konfigurasi
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0.001
<i>Loss Function</i>	<i>Binary Crossentropy</i>
<i>Batch Size</i>	16
<i>Epoch</i>	300
<i>Early Stopping Patience</i>	20 epoch
<i>Reduce LR Patience</i>	5 epoch

Proses pelatihan dioptimasi menggunakan algoritma Adam untuk meminimalkan nilai Binary Crossentropy, dengan mekanisme *Early Stopping* dan *Reduce Learning Rate on Plateau* diterapkan untuk mencegah *overfitting* serta menstabilkan konvergensi model saat validasi stagnan. Selama iterasi berlangsung, performa model dipantau secara berkala, dan bobot model dengan akurasi validasi terbaik disimpan secara otomatis untuk digunakan pada tahap pengujian dan implementasi sistem.

F. Evaluasi

Tahap evaluasi dilakukan untuk mengukur kinerja model ANN dalam mengklasifikasikan *intent* pada *chatbot* layanan informasi Penerimaan Mahasiswa Baru. Evaluasi dilakukan menggunakan data uji dengan metrik akurasi, *precision*, *recall*, dan *F1-score* yang diperoleh melalui *classification report*, serta dianalisis lebih lanjut menggunakan *confusion matrix* untuk melihat distribusi prediksi benar dan salah pada setiap kelas. *Confusion matrix* merepresentasikan hubungan antara kelas aktual dan kelas prediksi, yang terdiri dari *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) [25]. Berdasarkan nilai tersebut, metrik evaluasi dihitung menggunakan persamaan sebagai berikut:

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

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

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

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$


G. Implementasi

Tahap implementasi dilakukan dengan mengintegrasikan model ANN yang telah dilatih ke dalam sistem *chatbot* layanan informasi Penerimaan Mahasiswa Baru berbasis website. Model yang telah melalui proses training dan evaluasi disimpan bersama dengan aset pendukung lainnya, meliputi *label encoder*, data respons, serta model dan *tokenizer* IndoBERT, sehingga sistem dapat melakukan inferensi tanpa perlu melakukan pelatihan ulang. Pada tahap ini, input berupa kalimat dari pengguna diproses melalui tahapan preprocessing dan ekstraksi fitur yang sama seperti pada proses pelatihan, kemudian diklasifikasikan oleh model untuk menentukan *intent* yang sesuai. Hasil prediksi *intent* selanjutnya digunakan untuk menampilkan respons yang relevan secara otomatis, sehingga *chatbot* mampu memberikan layanan informasi secara *real-time* dan konsisten kepada pengguna.

III. HASIL DAN PEMBAHASAN

A. Dataset

Analisis dataset dilakukan untuk memberikan gambaran awal mengenai sebaran data pada setiap *intent*. Visualisasi distribusi jumlah sampel data untuk setiap kategori *intent* dapat dilihat pada Gambar 3.



Gambar 3. Distribusi dataset pertanyaan per *intent*

Sebagaimana ditunjukkan pada Gambar 3, sebagian besar kategori *intent* memiliki jumlah data yang relatif seimbang dengan rentang antara 45 hingga 67 kalimat. *Intent* *thank_you* dan *greeting* merupakan kategori dengan jumlah data terbanyak, sedangkan *intent* *unknown* memiliki jumlah data paling sedikit. Meskipun demikian, keberadaan *intent* *unknown* tetap dipertahankan untuk merepresentasikan pertanyaan di luar skenario layanan yang telah ditentukan. Secara keseluruhan, distribusi dataset ini menunjukkan kondisi data yang cukup representatif dan mendukung proses pelatihan model *Artificial Neural Network* (ANN) secara lebih stabil.

B. Preprocessing Data

Hasil preprocessing data menunjukkan adanya perubahan pada bentuk teks kalimat pertanyaan sebelum dan sesudah dilakukan pembersihan. Proses *case folding*, *stemming*, dan *stopword removal* menghasilkan teks yang lebih ringkas dengan struktur kata yang seragam, tanpa menghilangkan makna utama dari setiap kalimat pertanyaan. Contoh hasil preprocessing data ditunjukkan pada Tabel 2.

TABEL 2
SAMPel HASIL PREPROCESSING DATA


No	Kalimat Asli	Hasil Preprocessing
1	Halo!	halo
2	HAI!	hai
3	Halo, ada yang bisa saya bantu?	halo ada yang bisa saya bantu
4	Halo, apa kabar?	halo apa kabar
5	Selamat Pagi!	selamat pagi

C. Ekstraksi Fitur (IndoBERT)

Hasil ekstraksi fitur menunjukkan bahwa seluruh data teks yang telah melalui tahap preprocessing berhasil dikonversi menjadi representasi numerik menggunakan model IndoBERT. Proses *embedding* dilakukan secara bertahap dalam beberapa batch hingga seluruh data selesai diproses. Dari proses ini dihasilkan matriks fitur dengan ukuran 1.064×768 , di mana setiap kalimat direpresentasikan dalam bentuk vektor berdimensi 768. Representasi vektor ini digunakan sebagai masukan pada model *Artificial Neural Network* (ANN) untuk proses pelatihan dan klasifikasi *intent* pada tahap selanjutnya.

D. Pelatihan Model

Hasil pelatihan model *Artificial Neural Network* (ANN) dianalisis berdasarkan perubahan nilai akurasi dan *loss* pada data latih dan data validasi selama proses training. Proses pelatihan dilakukan selama 300 epoch, namun dihentikan lebih awal menggunakan *early stopping* ketika tidak terjadi peningkatan performa pada data validasi. Berdasarkan hasil pelatihan, model mencapai kondisi terbaik pada *epoch* ke-43 dan berhenti pada *epoch* ke-63.




Gambar 4. Grafik akurasi dan *loss* pelatihan serta validasi

Berdasarkan Gambar 4, terlihat bahwa nilai akurasi pada data latih dan data validasi mengalami peningkatan yang signifikan pada awal pelatihan dan mulai stabil setelah *epoch* ke-30. Akurasi validasi mencapai nilai tertinggi sebesar 96,24%, sementara *loss* validasi menurun secara konsisten hingga berada pada kisaran 0,017–0,020. Pola kurva akurasi dan *loss* antara data latih dan validasi menunjukkan kecenderungan yang seimbang tanpa perbedaan yang signifikan, sehingga mengindikasikan bahwa model tidak mengalami *overfitting*. Hasil ini menunjukkan bahwa arsitektur ANN yang digunakan mampu melakukan proses pembelajaran secara efektif dan stabil dalam mengklasifikasikan *intent* pada *chatbot* layanan informasi Penerimaan Mahasiswa Baru.

E. Evaluasi Model

Berdasarkan hasil evaluasi, sebagian besar prediksi berada pada diagonal utama yang menunjukkan klasifikasi yang benar, sedangkan nilai di luar diagonal menunjukkan adanya kesalahan prediksi antar kelas.



Gambar 5. Confusion matrix model klasifikasi intent

Berdasarkan Gambar 5, mayoritas prediksi model berada pada diagonal utama, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data uji secara tepat pada masing-masing kelas *intent*. Namun demikian, masih ditemukan sejumlah kecil kesalahan klasifikasi yang terjadi pada kelas-kelas tertentu dengan kedekatan semantik. Pada kelas *admission_procedure*, terdapat satu data yang salah diprediksi sebagai *admission_financial_aid*, yang mengindikasikan adanya kemiripan konteks pertanyaan terkait prosedur pendaftaran dan informasi bantuan biaya. Kesalahan serupa juga terjadi pada kelas *admission_schedule*, di mana satu data diprediksi sebagai *info_beasiswa*, menunjukkan potensi tumpang tindih makna pada pertanyaan yang membahas jadwal dan informasi pendukung pendaftaran.

Kesalahan klasifikasi paling banyak ditemukan pada kelas *exam_schedule_registration*, dengan dua data yang masing-masing salah diprediksi sebagai *exam_schedule_info* dan *exam_schedule_retake*. Hal ini menunjukkan bahwa perbedaan konteks antara informasi pendaftaran ujian, informasi jadwal ujian, dan ujian ulang masih relatif sulit dipisahkan secara tegas oleh model. Selain itu, pada kelas *exam_schedule_retake* terdapat satu kesalahan prediksi ke kelas *exam_schedule_date*, yang memperkuat indikasi adanya kedekatan semantik antar subkategori jadwal ujian. Kesalahan lain juga ditemukan pada kelas *info_beasiswa* yang satu datanya diprediksi sebagai *most popular course*, serta kelas *university_structure* yang satu datanya diprediksi sebagai *admission_postgraduate*, yang kemungkinan dipengaruhi oleh kemunculan istilah institusional yang serupa dalam kalimat. Secara keseluruhan, pola kesalahan ini menunjukkan bahwa model telah memiliki kemampuan pemisahan kelas yang baik, namun masih menghadapi tantangan pada kelas dengan kemiripan semantik tinggi serta jumlah data yang relatif terbatas, khususnya pada *intent* yang berada dalam domain informasi pendaftaran dan jadwal ujian.

Untuk menganalisis performa setiap kelas secara lebih rinci, nilai metrik *precision*, *recall*, dan *F1-score* dirangkum dalam Tabel 3.

TABEL 3
LAPORAN EVALUASI KLASIFIKASI

<i>Intent</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
admission_exam	1.00	1.00	1.00	10
admission_fee	1.00	1.00	1.00	10
admission_financial_aid	0.92	1.00	0.96	11
admission_postgraduate	0.92	1.00	0.96	12
admission_procedure	1.00	0.91	0.95	11
admission_results	1.00	1.00	1.00	10
admission_schedule	1.00	0.91	0.95	11
campus_facilities	0.91	1.00	0.95	10
contact_person	1.00	1.00	1.00	10
exam_schedule_date	0.91	1.00	0.95	10
exam_schedule_info	0.91	1.00	0.95	10
exam_schedule_registration	1.00	0.80	0.89	10
exam_schedule_retake	0.91	0.91	0.91	11
greeting	1.00	1.00	1.00	13
info_basiswa	0.90	0.90	0.90	10
most_popular_course	0.91	1.00	0.95	10
payment_procedure	1.00	1.00	1.00	10
thank_you	1.00	1.00	1.00	13
tuition_fee	1.00	1.00	1.00	9
university_structure	1.00	0.90	0.95	10
unknown	1.00	0.50	0.67	2
accuracy			0.96	213
macro_avg	0.97	0.94	0.95	213
weighted_avg	0.96	0.96	0.96	213

Berdasarkan Tabel 3, model menunjukkan kinerja yang sangat baik dengan nilai akurasi keseluruhan sebesar 96%. Sebagian besar kelas intent memiliki nilai precision, recall, dan F1-score di atas 0,90, yang menandakan konsistensi model dalam memberikan prediksi yang tepat dan stabil. Kelas seperti greeting, thank_you, admission_exam, dan payment_procedure mencapai nilai sempurna, mencerminkan kejelasan pola bahasa pada data tersebut.


Keberhasilan sistem mencapai performa tinggi pada skenario multi-intent ini pada dasarnya didorong oleh mekanisme self-attention pada arsitektur Transformer IndoBERT. Berbeda dengan ekstraksi fitur tradisional, mekanisme ini memungkinkan model memberikan bobot perhatian (attention weights) secara proporsional ke berbagai bagian kalimat yang berbeda secara bersamaan. Ketika pengguna memasukkan kalimat kompleks (misalnya menanyakan jadwal dan biaya sekaligus), IndoBERT mampu membedakan dan menangkap kedua representasi semantik tersebut tanpa saling menghilangkan makna, yang selanjutnya dipetakan secara akurat oleh fungsi aktivasi Sigmoid pada ANN.

Sebaliknya, kelas unknown memiliki nilai recall yang jauh lebih rendah (0,50) dibandingkan kelas lainnya. Secara teknis, penurunan performa pada kelas ini disebabkan oleh dua faktor utama: ketidakseimbangan data (data imbalance) karena minimnya sampel pengujian (hanya 2 data), serta ketiadaan pola fitur semantik yang konsisten. Kategori unknown secara inheren dirancang untuk menampung pertanyaan di luar domain (Out-of-Domain), sehingga distribusi vektor pada ruang semantiknya sangat tersebar, tidak memiliki pola clustering yang terpusat, dan akibatnya lebih sulit diklasifikasikan oleh model dibandingkan kategori yang memiliki pola kata kunci yang spesifik.

Meskipun penelitian ini tidak secara langsung menyertakan eksperimen komparasi dengan model baseline tradisional (seperti TF-IDF dengan Support Vector Machine atau Naive Bayes), signifikansi performa yang dicapai (96%) dapat dinilai melalui perbandingan terhadap baseline empiris dari penelitian terdahulu. Kinerja ini secara konsisten mengungguli metode keyword matching yang memiliki akurasi 85,83% [10] maupun Neural Network dengan pendekatan statis Bag of Words yang mencapai akurasi 90,77% [13]. Peningkatan margin akurasi ini mengonfirmasi bahwa perpaduan contextual embedding dan arsitektur multi-label ANN memberikan keuntungan komputasional yang nyata dalam menyelesaikan kelemahan pemahaman konteks pada chatbot PMB.

F. Implementasi Sistem Chatbot

Implementasi sistem dilakukan dalam bentuk chatbot berbasis web yang terintegrasi dengan model klasifikasi intent hasil pelatihan. Chatbot menerima input teks dari pengguna, kemudian memprosesnya melalui tahapan Preprocessing, ekstraksi fitur menggunakan IndoBERT, dan klasifikasi intent menggunakan model Artificial Neural Network (ANN) untuk menghasilkan respons yang sesuai dengan konteks pertanyaan.



Gambar 6. Tampilan antarmuka *chatbot* pada pengujian *single-intent*

Pada pengujian *single-intent* sebagaimana ditunjukkan pada Gambar 6, pengguna memberikan pertanyaan yang hanya mengandung satu maksud. Sistem mampu mengenali *intent* dengan tepat dan memberikan respons yang relevan sesuai dengan kategori *intent* yang terdeteksi. Hasil ini menunjukkan bahwa *chatbot* bekerja secara optimal dalam menangani pertanyaan langsung dan spesifik, serta mampu memberikan jawaban secara cepat dan konsisten.



Gambar 7. Pengujian respons *multi-intent* pada *chatbot*

Pengujian *multi-intent* ditunjukkan pada Gambar 7, di mana pengguna menyampaikan pertanyaan dengan lebih dari satu maksud dalam satu kalimat. Pada skenario ini, sistem berhasil mengidentifikasi lebih dari satu *intent* yang terkandung

dalam pertanyaan dan menyajikan respons yang mencakup informasi prosedur pendaftaran serta biaya pendaftaran secara bersamaan. Hasil pengujian ini menunjukkan bahwa *chatbot* mampu memahami konteks kalimat yang kompleks, sehingga meningkatkan kualitas interaksi dan efektivitas layanan informasi Penerimaan Mahasiswa Baru.

G. Pembahasan Perbandingan dengan Penelitian Terdahulu

Penelitian ini menunjukkan bahwa penerapan model *Artificial Neural Network* (ANN) dengan ekstraksi fitur berbasis IndoBERT mampu memberikan kinerja yang lebih baik dibandingkan pendekatan *chatbot* penerimaan mahasiswa baru pada penelitian terdahulu yang umumnya masih menggunakan metode berbasis aturan atau klasifikasi *single-intent* [9]–[14]. Pendekatan berbasis aturan seperti AIML pada penelitian [9] terbukti efektif untuk pertanyaan sederhana, namun memiliki keterbatasan fleksibilitas karena bergantung pada pola kalimat yang telah didefinisikan.

Selain itu, keunggulan signifikan dari penelitian ini terlihat pada perbandingan metode ekstraksi fitur. Penelitian sebelumnya yang menggunakan Bag-of-Words (BoW) [13] memiliki kelemahan mendasar karena memperlakukan setiap kata secara independen dan mengabaikan urutan kata serta makna kontekstualnya. Sebaliknya, pemanfaatan IndoBERT sebagai contextual embedding memungkinkan model untuk memahami relasi antar kata melalui mekanisme self-attention, sehingga kata yang sama dalam konteks kalimat yang berbeda dapat direpresentasikan secara spesifik. Dengan memanfaatkan IndoBERT sebagai representasi fitur kontekstual dan ANN sebagai pengklasifikasi, penelitian ini mampu menangani variasi bahasa alami serta pertanyaan multi-intent secara lebih adaptif dan akurat.

Meskipun sistem yang diusulkan menunjukkan performa yang tinggi, terdapat beberapa keterbatasan teknis yang perlu diperhatikan. Pertama, model ini masih memiliki ketergantungan pada ukuran dataset yang relatif kecil (1.064 sampel data). Hal ini berpotensi menimbulkan bias data, di mana model mungkin sangat akurat mengenali pola bahasa lokal atau istilah spesifik yang digunakan oleh calon mahasiswa di institusi target, namun bisa mengalami penurunan performa jika dihadapkan pada bahasa gaul (slang) atau variasi dialek dari daerah lain yang tidak ada dalam data latih. Kedua, pendekatan klasifikasi intent pada penelitian ini dirancang untuk interaksi single-turn, sehingga model memiliki keterbatasan dalam menangani multi-turn dialogue (dialog berkelanjutan yang mengingat konteks dari percakapan sebelumnya).

Lebih lanjut, jika dikaitkan dengan tren kecerdasan buatan saat ini, pengembangan *chatbot* mulai bergeser pada pemanfaatan Large Language Models (LLMs) generatif seperti GPT. LLMs menawarkan tingkat kealamian interaksi yang sangat tinggi dan mampu menangani dialog kompleks tanpa perlu pelabelan intent secara manual. Namun demikian, pendekatan yang digunakan dalam penelitian ini tetap memiliki relevansi dan keunggulan praktis untuk kasus layanan informasi resmi institusi. Berbeda dengan LLMs yang rentan terhadap fenomena halusinasi (menghasilkan informasi palsu yang tampak meyakinkan), metode klasifikasi multi-intent memastikan bahwa setiap respons yang diberikan oleh *chatbot* sangat terkontrol, prediktif, dan bersumber langsung dari basis pengetahuan resmi PMB. Selain itu, arsitektur ini jauh lebih ringan (lightweight) secara komputasi dan lebih aman dari sisi privasi data karena dapat dijalankan secara lokal di server universitas tanpa harus mengirimkan data pengguna ke pihak ketiga.

IV. SIMPULAN

Penelitian ini bertujuan untuk mengimplementasikan *chatbot* layanan informasi Penerimaan Mahasiswa Baru (PMB) yang mampu memahami konteks bahasa alami secara lebih fleksibel, khususnya dalam menangani pertanyaan multi-intent. Berdasarkan hasil dan pembahasan yang telah dipaparkan, tujuan tersebut berhasil dicapai melalui penerapan model *Artificial Neural Network* (ANN) dengan ekstraksi fitur berbasis IndoBERT. Kebaruan dari penelitian ini secara eksplisit terletak pada keberhasilan integrasi model bahasa pra-latih kontekstual (IndoBERT) dengan arsitektur klasifikasi multi-label (ANN) yang memecahkan hambatan *chatbot* tradisional dengan kemampuannya mendeteksi dan mengurai maksud ganda di dalam satu input kalimat pengguna. Hasil evaluasi menunjukkan bahwa sistem mampu mengklasifikasikan intent pengguna dengan tingkat akurasi sebesar 96%, serta memiliki nilai precision, recall, dan F1-score 0,96. Implementasi sistem membuktikan bahwa *chatbot* dapat memberikan respons yang relevan dan akurat, baik pada skenario single-intent maupun multi-intent.

Secara praktis, hasil penelitian ini memberikan implikasi yang signifikan tidak hanya bagi satu institusi, tetapi juga menawarkan kerangka kerja (*framework*) *chatbot* cerdas yang dapat direplikasi dan diadaptasi oleh berbagai institusi pendidikan tinggi lainnya. Pemanfaatan sistem ini secara langsung mendukung transformasi digital dengan mengotomatisasi penanganan pertanyaan secara *real-time* 24 jam penuh. Hal ini menjadi solusi strategis untuk meningkatkan efisiensi layanan, memastikan konsistensi informasi, serta mereduksi beban kerja staf akademik secara drastis, khususnya pada masa puncak pendaftaran calon mahasiswa baru.

Meskipun hasil yang diperoleh menunjukkan kinerja yang baik, penelitian ini masih memiliki ruang untuk pengembangan lebih lanjut. Penelitian selanjutnya dapat meningkatkan kemampuan *chatbot* dalam menangani konteks percakapan berkelanjutan (*Context-aware dialogue*), melakukan integrasi dengan model bahasa generatif untuk menghasilkan formulasi respons yang lebih natural, serta perluasan dataset agar mencakup variasi pertanyaan administratif

perguruan tinggi yang lebih kompleks. Dengan pengembangan tersebut, diharapkan fleksibilitas layanan interaksi akademik berbasis AI dapat semakin optimal sesuai dengan kebutuhan pengguna yang dinamis.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Bumigora atas dukungan dan fasilitas yang diberikan sehingga penelitian ini dapat dilaksanakan dengan baik. Ucapan terima kasih juga disampaikan kepada panitia Penerimaan Mahasiswa Baru yang telah membantu dalam proses pengumpulan data dan pemberian informasi yang diperlukan selama penelitian berlangsung

DAFTAR PUSTAKA

- [1] A. Rahmawati, S. N. Amirah, and N. Wijaya, "Integrasi Kecerdasan Buatan dalam Pendidikan Tinggi Indonesia: Peluang, Tantangan, dan Kerangka Implementasi," *J. Teknol. Sist. Inf.*, vol. 6, no. 1, pp. 114–126, 2025.
- [2] R. S. Sukorini, A. Marini, and R. N. Aulia, "NEW ERA OF HIGHER EDUCATION: DIGITAL TRANSFORMATION AND INFORMATION SYSTEM MANAGEMENT," *J. Ilm. Untuk Peningkatan Mutu Manaj. Pendidik.*, vol. 11, no. 2, pp. 154–166, 2024.
- [3] A. Alvin, R. Robet, and F. A. Tarigan, "Implementasi Chatbot Otomatis Akademik Berbasis Web Menggunakan LLM dan Rule-Based System Studi Kasus: STMIK Time," *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 3, p. 651, 2025.
- [4] R. Fitria, R. P. Tulodo, and A. Sofyan, "Pemanfaatan chatbot untuk informasi pendaftaran calon mahasiswa baru di perguruan tinggi," *IT-Explore J. Penerapan Teknol. Inf. dan Komun.*, vol. 4, no. 2, pp. 221–232, 2025.
- [5] N. Ariati, S. Suryati, and M. Kurniawan Sobri, "Penerapan Model HOT-FIT dalam Menilai Efektivitas Website Penerimaan Mahasiswa Baru di Universitas Indo Global Mandiri," *JuSiTik J. Sist. dan Teknol. Inf. Komun.*, vol. 8, no. 2, pp. 100–107, 2025.
- [6] A. Aloqayli and H. Abdelhafez, "Intelligent Chatbot for Admission in Higher Education," *Int. J. Inf. Educ. Technol.*, vol. 13, no. 9, pp. 1348–1357, 2023.
- [7] Rangga Wijaya Sugiarto, Petrus Sokibi, and Putri Rizkiyah, "Chatbot Layanan Akademik Calon Mahasiswa UCIC Menggunakan Metode Retrieval-Augmented Generation," *Jural Ris. Rumpun Ilmu Tek.*, vol. 4, no. 3, pp. 246–249, 2025.
- [8] H. P. Tarigan, "Integrasi Chatbot Berbasis NLP pada Sistem Layanan Akademik Universitas," *J. Komput.*, vol. 3, no. 1, pp. 13–18, 2024.
- [9] A. Z. Amrullah, A. S. Anas, and G. Primajati, "Implementasi Chatbot sebagai Virtual Assistant Penerimaan Mahasiswa Baru pada Universitas Bumigora," *J. Bumigora Inf. Technol.*, vol. 4, no. 1, pp. 17–26, 2022.
- [10] F. H. P. Hari and F. Alfarisi, "Perancangan Chatbot WhatsApp untuk Mendukung Layanan Penerimaan Mahasiswa Baru Menggunakan Node.js," *J. SISFOTENIKA*, vol. 15, no. 2, pp. 101–114, 2025.
- [11] A. R. A. Muhammad Rizki Herfian, "ANALISIS DAN PERANCANGAN APLIKASI CHATBOT DALAM PELAYANAN PENERIMAAN MAHASISWA BARU PADA PERGURUAN TINGGI," *J. Inform. Terpadu*, vol. 7, no. 2, pp. 87–93, 2025.
- [12] M. R. Suherlan, A. Asriyani, and A. Pambudi, "UMMIBOT sebagai Media Layanan Informasi Penerimaan Mahasiswa Baru Universitas Muhammadiyah Sukabumi," *J. Inform. Terpadu*, vol. 9, no. 2, pp. 82–91, 2023.
- [13] H. Rahmawati and A. Sudrajat, "Implementasi Chatbot Pada Penerimaan Mahasiswa Baru Di Politeknik Tede Bandung Menggunakan Natural Language Processing," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 1, 2025.
- [14] A. Setiyorini, "Pengembangan Aplikasi Chatbot Untuk Layanan Penerimaan Mahasiswa Baru Berbasis Natural Language Processing," *J. Inform. J. Pengemb. IT*, vol. 10, no. 4, pp. 1115–1126, 2025.
- [15] A. Fardhina, R. M. Siregar, M. R. W. Br Sibarani, I. C. Br Ginting, and A. Pratama, "Sistem Deteksi Berita Hoaks berbasis Algoritma Natural Language Processing (NLP) menggunakan BERT," *J. Manaj. Inform. Sist. Inf. dan Teknol. Komput.*, vol. 4, no. 1, pp. 450–461, 2025.
- [16] V. D. Setiawan, D. U. Iswavigra, and E. Anggiratih, "Implementation of IndoBERT for Sentiment Analysis of the Constitutional Court's Decision Regarding the Minimum Age of Vice Presidential Candidates," *Sci. J. Informatics*, vol. 12, no. 3, pp. 397–406, 2025.
- [17] L. S. Darfiansa, Fitriyani, and S. S. A. Larasati, "Optimizing IndoBERT for Revised Bloom's Taxonomy Question Classification Using Neural Network Classifier," *J. Inf. Syst. Eng. Bus. Intell.*, vol. 11, no. 2, pp. 226–237, 2025.
- [18] G. Nápoles, M. Bello, and Y. Salgueiro, "Long-term Cognitive Network-based architecture for multi-label classification," *Neural Networks*, vol. 140, pp. 39–48, 2021.
- [19] N. Blesyova and F. N. Hasan, "Analisis Sentimen Terhadap Bea Cukai Menggunakan Metode Support Vector Machine dan K-Fold Cross Validation," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 6, pp. 12051–12056, 2024.
- [20] A. A. Pamungkas, C. N. Alam, A. R. Atmadja, and R. Juliansyah, "Integrasi Kamus Multibahasa pada Feed Forward Neural Network dan IndoBERT dalam Pengembangan Chatbot Mobile," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 2, pp. 635–644, 2024.
- [21] J. Pardede and D. Darmawan, "Perbandingan Algoritma Stemming Porter, Sastrawi, Idris, dan Arifin & Setiono Pada Dokumen Teks Bahasa Indonesia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 1, pp. 69–76, 2025.
- [22] T. Iskandar Zulkarnain Maulana Putra, A. Farhan Bukhori, D. Ilmu Pengetahuan Alam, and U. Gadjah Mada, "Model Klasifikasi Berbasis Multiclass Classification dengan Kombinasi Indobert Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia (Classification Model Based on Multiclass Classification with a Combination of Indobert Embedding and Long)," *J. Ilmu Siber dan Teknol. Digit.*, vol. 1, no. 1, pp. 1–28, 2022.
- [23] E. Setia Budi, A. Nofriyaldi Chan, P. Priscillia Alda, and M. Arif Fauzi Idris, "Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network," *RESOLUSI Rekayasa Tek. Inform. dan Inf.*, vol. 4, no. 5, pp. 509–509, 2024.
- [24] G. A. S. Gado and P. N. Primandari, "Sistem Klasifikasi Berbasis Android untuk Penyakit Buah Kakao Menggunakan CNN NasNet-Mobile," *J. Teknol. Terpadu*, vol. 11, no. 1, pp. 27–35, 2025.
- [25] K. Hadi and E. Utami, "Analysis of K-NN with the Integration of Bag of Words, TF-IDF, and N-Grams for Hate Speech Classification on Twitter," *JUITA J. Inform.*, vol. 12, no. 2, p. 289, 2024.