

Pengembangan Chatbot Kesehatan Mental Berbasis Web Menggunakan Model Long Short-Term Memory (LSTM)

Akbar Ilham Ardin, Abu Salam*

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ¹ilhamardinakbar14@gmail.com, ²*abu.salam@dsn.dinus.ac.id

Email Penulis Korespondensi: abu.salam@dsn.dinus.ac.id

Submitted: 05/05/2025; Accepted: 04/06/2025; Published: 06/06/2025

Abstrak—Permasalahan kesehatan mental seperti stres, kecemasan, dan burnout akademik semakin banyak dialami oleh mahasiswa, namun sayangnya masih banyak yang enggan atau kesulitan mengakses layanan konseling karena keterbatasan waktu, stigma sosial, serta kurangnya tenaga profesional. Penelitian ini bertujuan untuk mengembangkan CuraBot, sebuah chatbot berbasis web yang dapat memberikan dukungan emosional awal dan edukasi kesehatan mental secara instan, anonim, serta mudah diakses kapan saja oleh mahasiswa. Pengembangan sistem dilakukan menggunakan algoritma Long Short-Term Memory (LSTM) yang terbukti efektif dalam memahami konteks percakapan berbasis teks. Dataset yang digunakan terdiri dari 1.624 data percakapan dalam 77 kelas intent, disusun dari sumber terbuka dan dimodifikasi secara kontekstual sesuai dengan gaya bahasa dan kebutuhan mahasiswa Indonesia. Proses pengembangan melibatkan tahapan preprocessing data seperti lemmatisasi, tokenisasi, stopword removal, padding, pelatihan model menggunakan TensorFlow, serta deployment ke dalam aplikasi web berbasis Flask. Evaluasi model dilakukan menggunakan data uji (test set) sebanyak 244 data uji terpisah dari data pelatihan dan validasi, dengan hasil akurasi mencapai 89,9%, precision 90,4%, recall 89,1%, dan F1-score 89,8%. Hasil tersebut menunjukkan bahwa model mampu memahami intent pengguna dengan akurasi yang tinggi. Penelitian ini berkontribusi dalam pengembangan solusi digital berbasis AI yang kontekstual, praktis, dan dapat digunakan untuk mendukung akses layanan psikologis awal di lingkungan kampus secara lebih luas dan efisien.

Kata Kunci: Chatbot; Kesehatan Mental; Mahasiswa; LSTM; Natural Language Processing

Abstract—Mental health issues such as stress, anxiety, and academic burnout are increasingly prevalent among university students. However, many students remain reluctant or unable to access counseling services due to time limitations, social stigma, and a lack of available professionals. This study aims to develop CuraBot, a web-based chatbot designed to provide preliminary emotional support and mental health education in an instant, anonymous, and easily accessible manner for students. The system was developed using the Long Short-Term Memory (LSTM) algorithm, which is proven to be effective in understanding contextual text-based conversations. The dataset used consists of 1,624 conversational entries across 77 intent classes, adapted and localized from an open-source corpus to reflect the linguistic style and needs of Indonesian students. The development process involved several stages, including data preprocessing (lemmatization, tokenization, stopword removal, and padding), model training using TensorFlow, and deployment into a Flask-based web application. The model was evaluated using a separate test set of 244 entries, resulting in an accuracy of 89.9%, precision of 90.4%, recall of 89.1%, and an F1-score of 89.8%. These results indicate that the model can classify user intent with high accuracy. This research contributes to the development of a contextual, practical, and AI-based digital solution that supports early access to psychological services within university environments.

Keywords: Chatbot; Mental Health; Students; LSTM; Natural Language Processing

1. PENDAHULUAN

Kesehatan mental mencerminkan kondisi harmonis antara aspek psikologis, emosional, dan sosial yang memungkinkan individu berpikir jernih, merasakan secara wajar, serta menjalin hubungan sosial secara sehat. Sayangnya, keseimbangan ini dapat terganggu oleh berbagai faktor seperti tekanan ekonomi, sosial, maupun kondisi fisik, yang pada akhirnya dapat menyebabkan gangguan mental seperti kecemasan atau depresi [1], [2]. Dampak gangguan tersebut tidak hanya terbatas pada individu, tetapi juga berimplikasi terhadap relasi sosial serta menurunkan produktivitas [3].

Salah satu faktor yang memperburuk kondisi kesehatan mental, khususnya di kalangan mahasiswa dan remaja, adalah cyberbullying, yang meningkatkan tingkat stres dan menghambat kemampuan regulasi emosi [4]. Di lingkungan akademik, mahasiswa menghadapi tekanan studi, ekspektasi keluarga, serta kesulitan dalam proses adaptasi sosial yang turut memicu gangguan psikologis [5], [6]. Studi juga menunjukkan bahwa strategi pengelolaan emosi seperti *mindfulness* dapat mengurangi kecemasan akademik secara signifikan [7], selain pengaruh besar pola pengasuhan orang tua terhadap kondisi psikologis mahasiswa [8], [9].

Meskipun sebagian besar institusi pendidikan tinggi telah menyediakan layanan konseling, seperti Klinik Dinus Konseling di Universitas Dian Nuswantoro, pemanfaatannya masih belum optimal akibat keterbatasan tenaga profesional, jadwal konsultasi yang tidak fleksibel, serta adanya stigma terhadap pencarian bantuan psikologis [10], [11], [12]. Untuk mengatasi hambatan ini, pemanfaatan teknologi digital, khususnya chatbot berbasis AI dan Natural Language Processing (NLP), mulai dilirik sebagai solusi alternatif yang menjanjikan [13].

Chatbot memiliki kemampuan memberikan informasi dasar, dukungan emosional awal, serta tanggapan empatik terhadap keluhan pengguna secara instan dan anonim [14], [15], bahkan mampu mendeteksi emosi dan gejala awal gangguan mental [16]. Salah satu keunggulan chatbot adalah kemampuannya dalam mendeteksi gejala awal gangguan psikologis melalui analisis linguistik, sehingga dapat dimanfaatkan untuk intervensi dini [17], [18]. Namun, sebagian besar chatbot kesehatan mental yang dikembangkan di Indonesia masih berbasis rule-based atau

menggunakan pendekatan template, yang belum mampu menangani keragaman ekspresi bahasa alami mahasiswa [17], [19].

Beberapa studi juga menunjukkan bahwa penerapan model deep learning sekuensial, seperti Long Short-Term Memory (LSTM), menawarkan keunggulan dalam memahami konteks percakapan yang kompleks. LSTM merupakan pengembangan dari arsitektur Recurrent Neural Network (RNN), yang dirancang untuk mengatasi kelemahan RNN dalam mempertahankan informasi jangka panjang [22], [23]. Meski demikian, riset mengenai penerapan LSTM dalam chatbot kesehatan mental dengan konteks lokal mahasiswa Indonesia masih sangat terbatas.

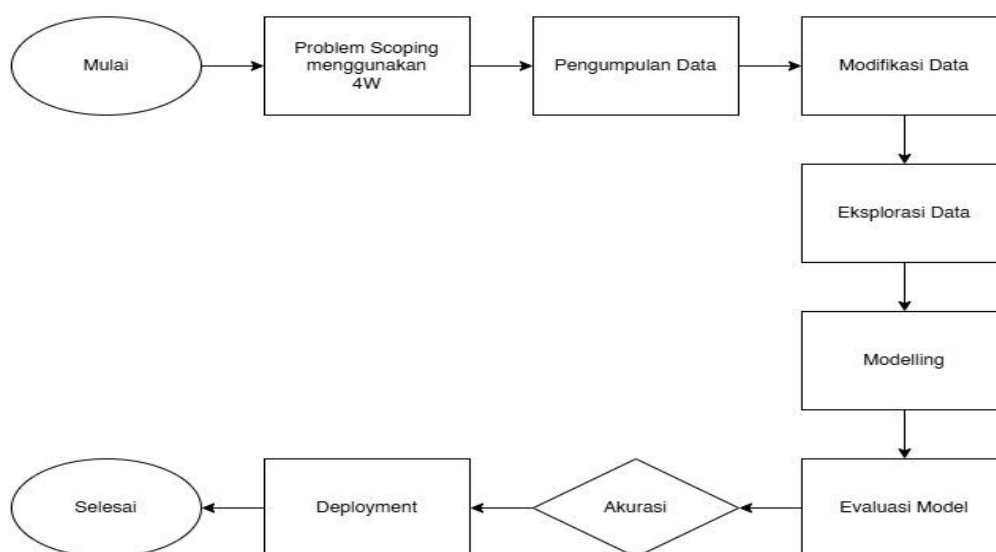
Dalam konteks ini, chatbot dapat digunakan mahasiswa untuk menanyakan tentang stres, teknik regulasi emosi, maupun prosedur konseling, tanpa harus melakukan kontak langsung dengan layanan konvensional. Selain itu, chatbot juga dapat mengurangi beban kerja konselor dengan menangani pertanyaan-pertanyaan dasar secara otomatis [19], [20]. Dengan kemampuan memahami konteks dan memberikan tanggapan yang dipersonalisasi, chatbot juga berfungsi sebagai alat edukatif serta pendukung deteksi risiko gangguan psikologis [12].

Penelitian ini bertujuan untuk mengembangkan CuraBot, chatbot kesehatan mental berbasis LSTM yang dirancang untuk mendukung layanan konseling awal di Klinik Dinus Konseling Universitas Dian Nuswantoro. Sistem ini diharapkan dapat memberikan akses psikologis awal secara fleksibel, anonim, dan efisien. Selain itu, CuraBot juga dirancang untuk mengenali indikasi awal gangguan mental dan mengarahkan pengguna kepada tenaga profesional jika diperlukan [21], [22]. Penelitian ini memberikan kontribusi dalam pengembangan sistem chatbot berbasis AI dengan dataset yang dikontekstualisasikan secara lokal, sebagai solusi awal peningkatan akses layanan kesehatan mental di lingkungan kampus.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Pengembangan chatbot dalam penelitian ini mengacu pada *AI Project Cycle* sebagai kerangka metodologis yang memandu setiap tahap proses pengembangan. Siklus ini terdiri atas beberapa langkah utama, yaitu identifikasi dan perumusan masalah, pengumpulan serta pengolahan data, analisis eksploratif terhadap data yang diperoleh, pembuatan model, serta tahapan evaluasi performa sistem. Pendekatan ini memastikan bahwa proses pengembangan chatbot dilakukan secara sistematis dan menyeluruh, sehingga menghasilkan model yang optimal dan sesuai dengan kebutuhan [23]. Flowchart tahapan penelitian terdapat pada Gambar 1. Selain itu, perancangan chatbot juga dilakukan dengan pendekatan *user-centered* dan *problem-oriented* untuk memastikan sistem mampu memahami dan menjawab kebutuhan mahasiswa terkait isu kesehatan mental. Pendekatan ini menempatkan pengalaman pengguna sebagai fokus utama, dengan menyesuaikan alur percakapan, gaya bahasa, dan konteks permasalahan yang relevan di lingkungan kampus.



Gambar 1. Flowchart tahapan penelitian chatbot

Pada tahap awal, yaitu penentuan ruang lingkup, peneliti mengidentifikasi dan merumuskan permasalahan sekaligus menetapkan fungsi utama dari sistem yang akan dikembangkan. Setelah itu, proses pengumpulan data dilakukan dengan menyusun dataset yang berisi 77 kelas tag percakapan. Pada fase eksplorasi data, dilakukan tahap *preprocessing* terhadap seluruh kelas tersebut sebagai persiapan sebelum memasuki proses pelatihan model. Untuk membangun chatbot ini, digunakan pendekatan Long Short-Term Memory (LSTM) agar model AI dapat memahami pola percakapan dengan lebih baik. Setelah itu, model dievaluasi untuk mengukur tingkat akurasi, sehingga dapat digunakan secara optimal dalam memberikan respons kepada pengguna.



2.1.1 Penentuan Ruang Lingkup Masalah

Pada tahap ini, langkah pertama yang dilakukan adalah memahami skala dan cakupan masalah secara menyeluruh. Proses ini melibatkan identifikasi serta analisis mendalam terhadap permasalahan, yang kemudian dilanjutkan dengan menentukan pendekatan yang paling efektif untuk menyelesaikannya.

Metode 4W (Who, What, Where, Why) digunakan sebagai panduan utama dalam menentukan ruang lingkup masalah dan menyusun solusi yang lebih tepat sasaran. Who (Siapa) yaitu mengidentifikasi pihak-pihak yang terlibat dalam masalah ini, what (Apa) yaitu menganalisis sifat dan pola masalah yang sedang terjadi, where (Di mana) yaitu menentukan lokasi atau lingkungan di mana masalah muncul, why (Mengapa) yaitu Mencari tahu akar penyebab masalah dan faktor yang memicunya. Dengan menjabarkan setiap aspek dari metode 4W secara sistematis, masalah dapat dipahami secara lebih komprehensif, sehingga memungkinkan perumusan solusi yang lebih efektif dan sesuai dengan kebutuhan.

2.1.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini berasal dari salah satu dataset publik di platform Kaggle, yaitu dataset percakapan chatbot kesehatan mental yang terdiri dari berbagai ekspresi emosi dan topik seputar stres, depresi, kecemasan, dan gangguan psikologis lainnya. Dataset ini berbentuk format JSON dan terdiri atas tiga elemen utama, yaitu tag, patterns, dan responses. Elemen tag berfungsi sebagai label atau intent dari percakapan, patterns berisi berbagai ekspresi yang umum diketik oleh pengguna, sedangkan responses merupakan kalimat tanggapan yang akan diberikan oleh chatbot.

Dataset ini dipilih karena memiliki cakupan intent yang relevan dengan topik kesehatan mental, serta memiliki struktur yang mendukung pelatihan model klasifikasi teks berbasis NLP. Namun, karena dataset tersebut menggunakan Bahasa Inggris dan konteks global, maka data tidak digunakan secara langsung. Proses pengumpulan dilanjutkan dengan seleksi dan ekstraksi data yang relevan, serta dilakukan penerjemahan dan penyesuaian terhadap konteks mahasiswa di Indonesia.

Hasil akhir dari pengumpulan dan kurasi data ini berupa dataset berbasis Bahasa Indonesia dengan total 1624 baris data percakapan yang mencakup 77 label intent, yang kemudian digunakan pada tahap preprocessing dan pelatihan model chatbot.

2.1.3 Modifikasi Data

Dataset yang digunakan dalam penelitian ini awalnya diperoleh dari platform sumber terbuka *Kaggle*, yang berisi data percakapan dalam bahasa Inggris terkait isu-isu kesehatan mental. Namun, agar dataset lebih relevan dengan konteks lokal dan kebutuhan mahasiswa di Klinik Dinus Konseling Universitas Dian Nuswantoro, dilakukan beberapa tahapan modifikasi.

Langkah pertama yang dilakukan adalah proses penerjemahan seluruh isi dataset ke dalam Bahasa Indonesia, dengan tetap mempertahankan makna asli dari pertanyaan maupun tanggapan. Proses ini dilakukan secara manual agar hasil terjemahan tidak kehilangan konteks percakapan yang berkaitan dengan kondisi emosional pengguna.

Selanjutnya, dilakukan penyesuaian dan modifikasi pola pertanyaan (patterns) agar mencerminkan gaya bahasa yang umum digunakan oleh mahasiswa di lingkungan kampus, seperti penggunaan frasa informal dan istilah sehari-hari. Selain itu, bagian respons (responses) juga diubah agar lebih empatik, suportif, dan sesuai dengan pendekatan konseling dasar, seperti memberikan afirmasi positif atau anjuran untuk menghubungi konselor. Pada Tabel 1 merupakan perbandingan dataset sebelum dan setelah dimodifikasi.

Tabel 1. Dataset Sebelum dan Sesudah modifikasi

Aspek	Dataset sebelum modifikasi	Dataset setelah modifikasi
Bahasa Utama	Bahasa Inggris	Bahasa Indonesia (natural dan inklusif terhadap gaya tutur informal)
Jumlah Tag	47+ tag intent	70+ tag intent
Tag tambahan	Tidak ada tag seperti `panik`, `pelampiasan`, `motivasi`, `fokus`, dll	Tambahan banyak tag baru terkait kondisi psikologis lokal (panik, pelampiasan, dsb.)
Bahasa Patterns	Formal, khas English native speaker	Campuran formal dan informal (misal: 'gue', 'nggak', 'pengen')
Respons Bot	Singkat dan umum	Lebih ekspresif, empatik, mendalam, dan mendukung konteks konseling
Penyesuaian Konteks Budaya	Tidak ada, cenderung netral/global	Ada, termasuk idiom dan ekspresi khas Indonesia
Fokus Respons	Tanya balik atau ajakan ringan untuk diskusi	Validasi emosi pengguna, ajakan empatik, bahkan saran praktis (relaksasi, meditasi, dll.)
Penanganan Krisis	Ada respons untuk 'suicide', tapi sederhana	Penanganan 'bunuh diri' lebih lengkap dan responsif, menyarankan kontak bantuan darurat



Aspek	Dataset sebelum modifikasi	Dataset setelah modifikasi
Tag Emosi Negatif Baru	Tidak ada tag eksplisit untuk `marah`, `panik`, `pelampiasan`, `tidak bicara`	Ada tag khusus untuk tiap emosi ini, dengan patterns dan respons yang mendalam

Melalui proses ini, struktur dataset tetap mengikuti format awal yang terdiri dari elemen tag, patterns, dan responses, namun seluruh isi konten telah dikontekstualisasikan sesuai kebutuhan lokal. Dengan demikian, dataset yang digunakan dalam penelitian ini dapat dikategorikan sebagai dataset privat yang disesuaikan secara spesifik untuk pengembangan chatbot CuraBot di lingkungan universitas. Dataset yang telah dimodifikasi ini kemudian digunakan untuk tahapan eksplorasi, preprocessing, dan pelatihan model chatbot berbasis LSTM.

2.1.4 Eksplorasi

Tahap eksplorasi data merupakan fase awal yang sangat menentukan kualitas model chatbot yang akan dibangun. Dalam studi ini, proses preprocessing data dilakukan secara sistematis melalui beberapa langkah berikut:

a. *Cleaning Teks*

Langkah awal dalam preprocessing adalah pembersihan teks, yaitu menghapus tanda baca, angka, simbol khusus, serta karakter non-alfabet. Tujuan proses ini adalah mengurangi noise dalam data teks agar model dapat fokus pada kata-kata bermakna.

b. *Case Folding*

Seluruh teks diubah menjadi huruf kecil (lowercase) untuk menyamakan representasi kata, sehingga "Stres" dan "stres" diperlakukan sebagai satu entitas yang sama.

c. *Stopword Removal*

Kata-kata umum yang tidak memiliki kontribusi bermakna terhadap makna kalimat, seperti “yang”, “dan”, “di”, dan sebagainya, dihapus menggunakan daftar stopwords Bahasa Indonesia. Langkah ini bertujuan untuk mengurangi kompleksitas input yang tidak perlu.

d. *Lematisasi*

Penelitian ini menggunakan lemmatisasi, bukan stemming, karena lemmatisasi mempertahankan akar kata yang benar secara linguistik dalam konteks Bahasa Indonesia. Misalnya, kata "berlari", "lari-lari", dan "pelari" akan diubah ke bentuk dasar "lari" secara semantik. Hal ini penting untuk menjaga akurasi dalam pemahaman intent percakapan.

e. *Tokenisasi*

Kalimat dipecah menjadi unit-unit kata atau token, agar dapat dianalisis lebih lanjut oleh model. Tokenisasi dilakukan menggunakan tokenizer Keras yang disesuaikan dengan 2000 kata terbanyak dalam dataset.

f. *Padding*

Karena panjang setiap input bervariasi, dilakukan padding (penambahan token kosong) agar seluruh input memiliki panjang yang seragam. Padding penting untuk memungkinkan LSTM memproses input dalam bentuk sekuensial tetap.

g. *Encoding dan Labeling*

Setelah tokenisasi dan padding, seluruh kata dikonversi menjadi representasi numerik. Sementara itu, label dari setiap kelas intent diubah menjadi format numerik menggunakan one-hot encoding agar dapat dibaca oleh fungsi loss model klasifikasi multikelas.

Seluruh data hasil preprocessing kemudian disimpan dalam format Pickle untuk efisiensi proses pelatihan model. Dengan tahapan preprocessing yang menyeluruh ini, data percakapan yang digunakan diharapkan mampu merepresentasikan struktur bahasa alami mahasiswa secara lebih akurat dan mendukung performa optimal dari model LSTM yang dikembangkan.

2.1.5 Pemodelan Data


Pada tahap ini, data yang telah melalui proses preprocessing digunakan untuk melatih model klasifikasi berbasis deep learning menggunakan arsitektur Long Short-Term Memory (LSTM). Dataset akhir terdiri dari 1624 baris data, yang dibagi menjadi dua bagian: 80% sebagai data pelatihan dan 20% sebagai data validasi, dengan distribusi label yang dijaga secara proporsional (stratified split). Dalam penelitian ini, tidak digunakan data uji (test set) terpisah, sehingga seluruh evaluasi performa model didasarkan pada hasil prediksi terhadap data validasi. Hal ini menjadi salah satu keterbatasan yang diakui dalam studi ini.

Model dikompilasi menggunakan fungsi loss categorical crossentropy, yang sesuai untuk klasifikasi multikelas, dengan fungsi aktivasi output softmax. Proses pelatihan dilakukan selama 400 epoch dengan batch size sebesar 32, menggunakan algoritma Adam optimizer untuk mempercepat konvergensi. Untuk memantau performa selama pelatihan, digunakan metrik accuracy dan loss, baik pada data pelatihan maupun validasi. Model terbaik disimpan secara otomatis (model checkpoint) berdasarkan akurasi validasi tertinggi.

Proses pelatihan dilakukan menggunakan library TensorFlow dan Keras, yang memungkinkan fleksibilitas dalam membangun dan mengatur arsitektur model, serta menyediakan fungsi evaluasi dan visualisasi yang dibutuhkan.

2.1.6 Modelling

Model yang digunakan dalam penelitian ini dibangun menggunakan arsitektur Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). LSTM dipilih karena kemampuannya dalam mengatasi masalah vanishing gradient yang umum terjadi pada Recurrent Neural Network (RNN) biasa, sehingga lebih mampu mengingat dependensi jangka panjang dalam urutan teks. GRU digunakan sebagai tambahan untuk mempercepat proses konvergensi dengan arsitektur yang lebih ringkas.



Gambar 2. Arsitektur LSTM

LSTM bekerja dengan memanfaatkan tiga gerbang utama, yaitu forget gate, input gate, dan output gate, yang berfungsi untuk mengatur aliran informasi di dalam sel memori. Gerbang-gerbang ini memungkinkan LSTM menyimpan informasi penting dan mengabaikan informasi yang tidak relevan selama proses pelatihan, sehingga sangat efektif dalam menangani data sekuensial seperti teks percakapan.

Arsitektur jaringan yang digunakan terdiri dari beberapa lapisan sebagai berikut:

- Embedding Layer – Mengubah token kata menjadi representasi vektor berdimensi tetap untuk memetakan kata-kata ke dalam ruang semantik.
- Bidirectional LSTM Layer – Digunakan untuk menangkap informasi konteks dari arah depan dan belakang dalam sekuens input.
- GRU Layer – Ditambahkan setelah LSTM untuk memperkuat efisiensi pemrosesan sekuens dan mempertahankan representasi temporal.
- Dropout Layer – Digunakan untuk mencegah overfitting dengan menghilangkan sebagian neuron secara acak selama pelatihan.
- Batch Normalization Layer – Membantu menstabilkan dan mempercepat proses pelatihan dengan menormalkan aktivasi antar layer.
- Dense Output Layer dengan Aktivasi Softmax – Menyediakan probabilitas prediksi untuk setiap kelas intent dari total 77 kelas.

Model dikompilasi menggunakan fungsi loss categorical crossentropy yang sesuai untuk klasifikasi multikelas, dengan optimizer Adam dan metrik evaluasi berupa akurasi.

Implementasi dilakukan menggunakan library TensorFlow dan Keras. Model hasil pelatihan serta tokenizer disimpan dalam format Pickle (.pkl), sehingga dapat dimuat kembali (load) pada tahap deployment sebagai bagian dari sistem chatbot CuraBot.

2.1.7 Deployment

Sebelum model dapat digunakan oleh pengguna, langkah pertama yang perlu dilakukan adalah deployment dan hosting agar model dapat diakses secara daring. Dalam penelitian ini, model diterapkan melalui sebuah situs web yang dikembangkan menggunakan bahasa pemrograman Python dengan kerangka kerja Flask. Untuk menciptakan antarmuka yang interaktif dan mudah digunakan, pengembangan tampilan situs memanfaatkan HTML, JavaScript, dan CSS. Desain situs web dibuat sederhana, terdiri dari satu halaman utama dengan elemen interaktif berupa gelembung obrolan. Saat pengguna mengklik gelembung tersebut, sebuah menu chat akan muncul, memungkinkan mereka untuk berinteraksi dan mengajukan pertanyaan.


Dalam proses implementasi model chatbot, model yang telah dilatih disimpan dalam format keras dan diintegrasikan ke dalam aplikasi web menggunakan Flask. Flask dipilih karena merupakan kerangka kerja web ringan yang fleksibel untuk membangun API dan menghubungkan model pembelajaran mesin ke dalam sistem berbasis web. Model chatbot yang telah disimpan kemudian dapat diakses melalui antarmuka API yang disediakan oleh Flask dan ditampilkan dalam elemen HTML yang terintegrasi dalam situs web berbasis seluler. Dengan demikian, pengguna dapat dengan mudah berkomunikasi dengan chatbot melalui aplikasi web di perangkat seluler mereka, menjadikan interaksi lebih praktis dan responsif.

2.2 Arsitektur Deployment

Arsitektur deployment menggambarkan bagaimana komponen sistem chatbot saling terhubung dan berjalan dalam lingkungan produksi. Sistem chatbot ini diakses oleh pengguna melalui antarmuka web (browser) yang dibangun

dengan teknologi HTML, CSS, dan JavaScript. Permintaan dari pengguna dikirim ke backend melalui Flask API, yang bertanggung jawab dalam mengelola alur data, memanggil model LSTM yang telah dilatih (keras), serta mengembalikan respons sesuai dengan intent yang terdeteksi.

Dataset dan proses preprocessing disimpan dan dijalankan terpisah namun tetap terhubung dengan Flask API, yang memungkinkan sistem untuk memperbarui model di masa mendatang jika diperlukan. Gambar 3 menunjukkan arsitektur deployment dari sistem yang dibangun.



Gambar 3. Arsitektur Deployment

3. HASIL DAN PEMBAHASAN

3.1 Ruang Lingkup Masalah

Untuk menjelaskan ruang lingkup permasalahan yang diangkat, peneliti menggunakan pendekatan dengan unsur 4W, yaitu *Who*, *What*, *Where*, dan *Why*. Pendekatan ini digunakan untuk merinci secara jelas siapa yang menjadi sasaran, apa inti permasalahan, di mana konteks permasalahan terjadi, dan mengapa penelitian ini penting dilakukan. Adapun cakupan pengembangan aplikasi ini dijabarkan melalui empat aspek tersebut.

Tabel 2. Konsep 4W

Konsep 4W	Penjelasan
Who	Sasaran utama dalam pengembangan aplikasi ini adalah mahasiswa Universitas Dian Nuswantoro yang ingin melakukan konsultasi dengan psikolog tetapi menghadapi kendala seperti keterbatasan waktu dan jumlah tenaga medis yang tersedia. Aplikasi ini dirancang untuk memberikan solusi yang lebih fleksibel dan mudah diakses bagi mahasiswa yang membutuhkan bantuan terkait kesehatan mental.
What	Bagian ini bertujuan untuk mengidentifikasi dan memverifikasi permasalahan utama yang dihadapi mahasiswa dalam mengakses layanan kesehatan mental. Fokus penelitian ini adalah mengembangkan solusi berbasis teknologi yang dapat meningkatkan aksesibilitas layanan konsultasi psikologis bagi mahasiswa Universitas Dian Nuswantoro, sehingga mereka dapat memperoleh bantuan tanpa terhambat oleh keterbatasan waktu dan tenaga medis.
Where	Permasalahan yang menjadi latar belakang penelitian ini adalah keterbatasan informasi serta akses terhadap layanan kesehatan mental di lingkungan Universitas Dian Nuswantoro. Banyak mahasiswa yang ingin berkonsultasi dengan psikolog tetapi mengalami kendala dalam mendapatkan layanan yang sesuai akibat keterbatasan tenaga medis atau jadwal yang tidak fleksibel. Oleh karena itu, penelitian ini berfokus pada solusi digital yang dapat menjembatani kebutuhan tersebut.
Why	Penelitian ini dilakukan untuk memberikan solusi berupa platform berbasis web yang dapat membantu mahasiswa Universitas Dian Nuswantoro dalam mengakses layanan konsultasi psikologis secara lebih mudah dan efisien. Dengan adanya platform ini, mahasiswa dapat memperoleh informasi dan bantuan terkait kesehatan mental tanpa harus terbatas oleh faktor waktu atau keterbatasan tenaga medis. Tujuan utama penelitian ini adalah meningkatkan kesadaran, menyediakan aksesibilitas yang lebih baik, serta memberikan dukungan kepada mahasiswa dalam menjaga kesehatan mental mereka.

3.2 Perolehan Data

Dalam penelitian ini, data yang digunakan untuk melatih model algoritma chatbot dirancang secara khusus dan disusun dalam format file JSON. Data tersebut diambil dari kebutuhan layanan Klinik Dinus Konseling Universitas Dian Nuswantoro, yang ditujukan untuk mahasiswa. Struktur data ini terdiri dari beberapa elemen utama yang menjadi fondasi pemahaman chatbot terhadap input yang diberikan pengguna. Salah satu elemen penting adalah intents, yang merepresentasikan maksud atau tujuan utama dari sebuah percakapan. Setiap intent diberi label berupa tag untuk mengelompokkannya ke dalam kategori tertentu, sehingga mempermudah proses klasifikasi saat chatbot beroperasi. Selain itu, terdapat bagian patterns, yaitu kumpulan frasa atau kalimat yang kemungkinan besar akan digunakan mahasiswa saat berinteraksi dengan chatbot, seperti pertanyaan seputar jadwal konseling, prosedur pendaftaran, atau keluhan terkait stres akademik. Pola-pola ini membantu chatbot dalam mengenali konteks dan maksud dari input pengguna secara lebih akurat. Sementara itu, bagian responses berisi jawaban yang telah dipersiapkan oleh sistem sebagai respons terhadap intent yang berhasil dikenali.

Dengan memanfaatkan data terstruktur seperti ini, chatbot yang dikembangkan tidak hanya mampu memahami maksud pengguna dengan baik, tetapi juga mampu memberikan respons yang relevan dan kontekstual, sehingga interaksi yang terjadi terasa lebih alami dan mendukung kebutuhan psikologis mahasiswa secara efektif.

Tabel 3. Dataset dalam bentuk JSON

Tag	Patterns (pertanyaan)	Responses (jawaban)
sedih	Aku merasa sangat sedih Kenapa aku selalu merasa sedih?	Aku turut merasakan kesedihanmu. Kamu tidak sendiri, aku ada di sini untukmu.
stres	Saya sangat stres Saya merasa terjebak Saya masih stres	Aku tahu ini pasti terasa berat. Tarik napas dan beri dirimu istirahat.
berharga	Saya merasa sangat tidak berharga Tidak ada yang menyukaiku	Kamu berharga, terlepas dari bagaimana perasaanmu sekarang.
depresi	Saya tidak melihat harapan Saya merasa tidak ada jalan keluar	Kamu tidak sendirian, dan ada orang-orang yang peduli padamu.
bahagia	Saya merasa hebat hari ini Saya bahagia Saya baik-baik saja	Senang mendengar itu! Semoga harimu terus menyenangkan.
anxious	Saya merasa gelisah Kecemasan saya tidak terkendali Saya sangat cemas	Kecemasan bisa terasa berat. Tarik napas dalam dan beri waktu untuk dirimu.

Tabel 3 menampilkan struktur dataset dalam format JSON yang digunakan sebagai basis pengetahuan untuk chatbot kesehatan mental berbasis web. Dataset ini memiliki tiga elemen utama yaitu "tag", "patterns", dan "responses". Elemen "tag" berfungsi sebagai penanda atau kategori yang mewakili topik percakapan, misalnya "stres", "depresi", "motivasi", atau "bahagia". Tag ini membantu chatbot mengidentifikasi jenis emosi atau permasalahan yang sedang dihadapi oleh pengguna.

Setiap tag memiliki "patterns", yaitu kumpulan kalimat yang beragam dan merupakan contoh pernyataan atau pertanyaan yang umum diajukan oleh mahasiswa. Misalnya, pada tag "stres", pattern-nya mencakup kalimat seperti "Saya sangat stres", "Bagaimana cara mengelola stres dengan baik?", atau "Saya merasa terjebak". Kemudian, berdasarkan input dari pengguna yang cocok dengan pattern tersebut, chatbot akan memilih salah satu dari "responses" yang telah dipersiapkan. Contohnya, untuk tag "stres", chatbot dapat merespons dengan kalimat seperti "Aku tahu ini pasti terasa berat. Luangkan waktu sejenak untuk bernapas dalam-dalam dan beri dirimu istirahat yang cukup." Struktur ini memungkinkan chatbot untuk memberikan jawaban yang relevan dan terasa alami bagi mahasiswa yang membutuhkan dukungan awal sebelum melakukan konsultasi langsung ke Dinus Konseling.

3.3 Eksplorasi Data

Tahapan lanjutan dalam pengembangan chatbot kesehatan mental ini dimulai dengan mengunggah dataset berformat JSON yang berisi kumpulan percakapan seputar isu psikologis mahasiswa. Dataset ini kemudian dikonversi ke dalam bentuk dataframe untuk mempermudah pengolahan data secara sistematis. Dalam dataframe tersebut terdapat dua kolom utama, yaitu patterns (berisi contoh pertanyaan atau pernyataan dari pengguna) dan tags (kategori topik seperti "cemas", "stres", atau "bahagia"). Proses ini bertujuan agar setiap teks input bisa dipetakan ke dalam kategori yang relevan secara terstruktur. Selain itu, elemen responses dalam dataset juga diorganisir untuk memberikan tanggapan yang sesuai dengan prediksi model berdasarkan kategori yang telah dikenali. Secara keseluruhan, dataset terdiri dari 1624 baris data yang mencakup 77 topik atau kelas berbeda, mencerminkan beragam ekspresi dan kebutuhan mental mahasiswa yang akan dilayani oleh chatbot ini.

Setelah struktur dataset dianalisis, langkah berikutnya adalah melakukan preprocessing. Tahap pertama adalah case folding, yaitu proses mengubah seluruh teks menjadi huruf kecil agar tidak ada perbedaan akibat penggunaan huruf kapital. Ini penting karena sistem harus bisa mengenali kata-kata tanpa dipengaruhi perbedaan penulisan. Selanjutnya dilakukan lemmatisasi, yaitu proses normalisasi kata agar setiap istilah kembali ke bentuk dasarnya, sesuai dengan Bahasa Indonesia. Dari hasil lemmatisasi, ditemukan 660 kata unik dari total 1624 dokumen yang terdiri dari pola percakapan (patterns) dan kategori (tags). Setelah itu, dilakukan tokenisasi, yaitu memecah kalimat menjadi potongan kata atau token. Proses ini membatasi jumlah kata yang dianalisis hingga 2000 kata paling sering muncul, sementara kata-kata di luar batas tersebut dianggap tidak dikenal. Kemudian, semua token dikonversi menjadi urutan angka agar dapat dibaca oleh model, dan dilakukan padding agar semua urutan kata memiliki panjang yang sama dalam hal ini maksimal 14 kata per dokumen. Terakhir, kolom tags diubah menjadi bentuk numerik menggunakan label encoding, agar model dapat mengenali tiap kategori dengan lebih akurat. Hasil dari tokenisasi dan encoding ini kemudian disimpan ke dalam file pickle, sehingga dapat dipanggil kembali saat proses pelatihan model dimulai.

3.4 Modelling

Langkah awal dalam penyusunan model dilakukan dengan menerapkan *embedding layer* berukuran 100, yang bertugas mengonversi setiap kata dalam dataset menjadi vektor numerik yang merepresentasikan semantik serta relasi antar kata. Selanjutnya, diterapkan *Bidirectional LSTM* dengan 64 unit dan pengaturan `return_sequences=True`, sehingga memungkinkan pemodelan konteks percakapan dari kedua arah baik maju maupun mundur dengan tetap mempertahankan urutan data di setiap langkah waktu.

Untuk meminimalkan risiko *overfitting*, digunakan teknik *dropout* sebesar 0.5, diikuti dengan *batch normalization* untuk menjaga kestabilan distribusi keluaran dari lapisan sebelumnya. Tahapan berikutnya melibatkan penambahan *Bidirectional GRU* dengan 128 unit yang juga dikonfigurasi dengan *return_sequences=True*, guna menangkap dinamika pola sekuensial secara lebih efisien. Hasil dari lapisan ini kemudian diproses oleh *flatten layer*, yang bertugas meratakan output menjadi bentuk satu dimensi agar dapat diolah oleh lapisan berikutnya.

Struktur model dilanjutkan dengan penambahan *dense layer* yang memiliki 100 unit dan menggunakan fungsi aktivasi ReLU. Untuk meningkatkan generalisasi model, diterapkan kembali *dropout* sebesar 0.5, ditambah dengan regularisasi L2 guna menekan kompleksitas model, serta *batch normalization* agar proses pelatihan tetap stabil. Sebagai lapisan akhir, digunakan *dense layer* dengan aktivasi *softmax*, yang berfungsi untuk melakukan klasifikasi ke dalam sejumlah kelas sesuai dengan label yang terdapat dalam dataset.

Dalam tahap kompilasi, model menggunakan optimizer Adam dengan pengaturan default untuk mengatur proses pelatihan secara efisien. Sementara itu, *categorical cross-entropy* digunakan sebagai fungsi kerugian karena tugas ini berkaitan dengan klasifikasi multikelas, di mana output-nya berupa probabilitas untuk setiap kelas. Untuk mengevaluasi performa, metrik yang digunakan adalah akurasi. Setelah semua arsitektur disusun, struktur model dirangkum menggunakan fungsi *model.summary()* untuk melihat detail lapisan dan jumlah parameter yang digunakan.

3.5 Evaluasi

Proses pelatihan model dilakukan dengan cermat dan melalui beberapa kali pengulangan untuk memastikan bahwa model benar-benar mampu mencapai tingkat akurasi yang tinggi. Tujuan dari tahapan ini adalah untuk mengurangi kesalahan (*loss*) selama pelatihan agar model bisa bekerja secara lebih efektif dan efisien. Setiap iterasi pelatihan digunakan untuk menyempurnakan parameter model secara bertahap, sehingga kemampuan model dalam mengenali pola dan menghasilkan prediksi yang tepat semakin meningkat.

Untuk menilai kinerja model LSTM yang telah dibangun, digunakan beberapa metrik evaluasi, salah satunya adalah akurasi, yang mengukur seberapa sering prediksi model sesuai dengan data yang sebenarnya. Selain itu, digunakan *categorical cross-entropy* sebagai fungsi kerugian (*loss function*), karena sesuai dengan kebutuhan klasifikasi multikelas seperti dalam proyek ini. Fungsi tersebut dioptimalkan menggunakan algoritma Adam, yaitu metode optimasi yang populer karena cepat dan efisien dalam memperbarui bobot selama proses pelatihan. Kombinasi antara fungsi *loss*, algoritma optimasi, dan metrik evaluasi ini membantu model memberikan hasil prediksi yang lebih akurat dan dapat diandalkan dalam mengenali input dari pengguna.

Tabel 4. Akurasi Loss Pelatihan Model LSTM Berdasarkan Jumlah epochs

Epochs	Accuracy (%)	Val accuracy (%)	Loss (%)	Val loss (%)
400	99	89.9	1.3	1.1


Setelah melalui 400 iterasi pelatihan yang dijelaskan dalam Tabel 4, model LSTM berhasil mencapai tingkat akurasi yang tinggi, yaitu 99%, dengan akurasi validasi sebesar 89.9%. Selain itu, model menunjukkan nilai *loss* yang rendah, yaitu sekitar 1.3%, serta validasi *loss* sebesar 1.1%. Dari training model peneliti mendapat *precision* sebesar % dan *recall* sebesar 90%, akurasi dapat dihitung dari *precision* dan *recall* dengan cara sebagai berikut :

$$F1\ score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \tag{1}$$

$$F1\ score = 2 \cdot \frac{0.917 \cdot 0.900}{0.917 + 0.900} = 0.898\ (89.8\%)$$

Untuk memberikan gambaran yang lebih jelas, visualisasi grafik yang menunjukkan analisis akurasi dan *loss* selama proses pelatihan model LSTM dapat dilihat pada Gambar 4. Grafik ini membantu dalam memahami bagaimana model berkembang seiring dengan bertambahnya iterasi.

Gambar 4 menunjukkan bahwa performa model chatbot yang dibangun menggunakan algoritma LSTM tergolong cukup baik. Namun, terdapat tanda-tanda *overfitting* ringan yang terlihat dari selisih antara nilai *loss* pada data pelatihan dan data validasi, di mana *loss* pada data pelatihan lebih rendah dibandingkan dengan data validasi. Perbedaan ini mengindikasikan bahwa model lebih akurat saat memproses data yang sudah dikenalnya dibandingkan saat menghadapi data baru.



Gambar 4. Grafik Analisis Accuracy, Val_accuracy, Loss dan Val_loss Pelatihan Model LSTM

Meskipun demikian, dampak overfitting ini tidak terlalu signifikan terhadap kualitas jawaban yang diberikan chatbot. Model masih mampu memberikan respons yang relevan dan cukup tepat terhadap berbagai pertanyaan pengguna. Overfitting ini kemungkinan terjadi karena model terlalu menyesuaikan diri dengan detail-detail kecil dalam data pelatihan, sehingga kemampuannya untuk memahami konteks baru di luar data latih sedikit menurun. Hal ini tetap penting untuk diperhatikan agar ke depannya model bisa lebih siap dalam menghadapi variasi pertanyaan di situasi nyata.

Evaluasi performa model dilakukan menggunakan data uji (test set) sebesar 15% dari total dataset (sekitar 244 data uji), yang dipisahkan secara acak menggunakan metode stratified split. Model dinilai berdasarkan metrik klasifikasi multikelas, yaitu akurasi, precision, recall, dan F1-score, dengan pendekatan macro averaging. Tabel 5 menunjukkan ringkasan performa model pada data uji setelah pelatihan selama 400 epoch.

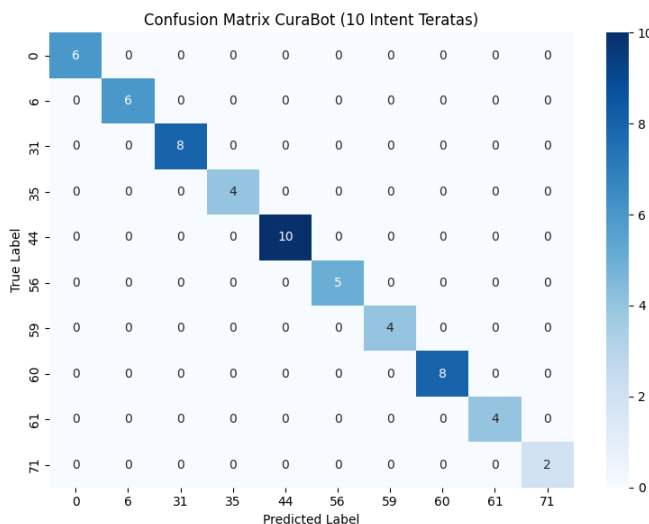
Tabel 5. Metrik Evaluasi Model CuraBot (Data Uji)

Metrik	Nilai (%)
Akurasi	89.9
Precision	90.4
Recall	89.1
F1-Score	89.8

Tabel 6. Evaluasi Per Kelas (Beberapa Intent)

Intent	Precision (%)	Recall (%)	F1-Score (%)
Stres	91.7	88.9	90.3
kecemasan	89.2	86.1	87.6
motivasi	92.5	94.3	93.4
konsultasi	88.1	90.0	89.0

Tabel 6 menyajikan metrik per kelas untuk beberapa intent representatif yang sering muncul dalam interaksi pengguna.



Gambar 5. Confusion Matrix

Visualisasi confusion matrix pada Gambar 5 menunjukkan performa klasifikasi per intent. Mayoritas prediksi berada pada diagonal, menunjukkan bahwa model mampu mengenali intent dengan baik, meskipun beberapa kelas semantik mirip mengalami kesalahan klasifikasi.

3.6 Deployment

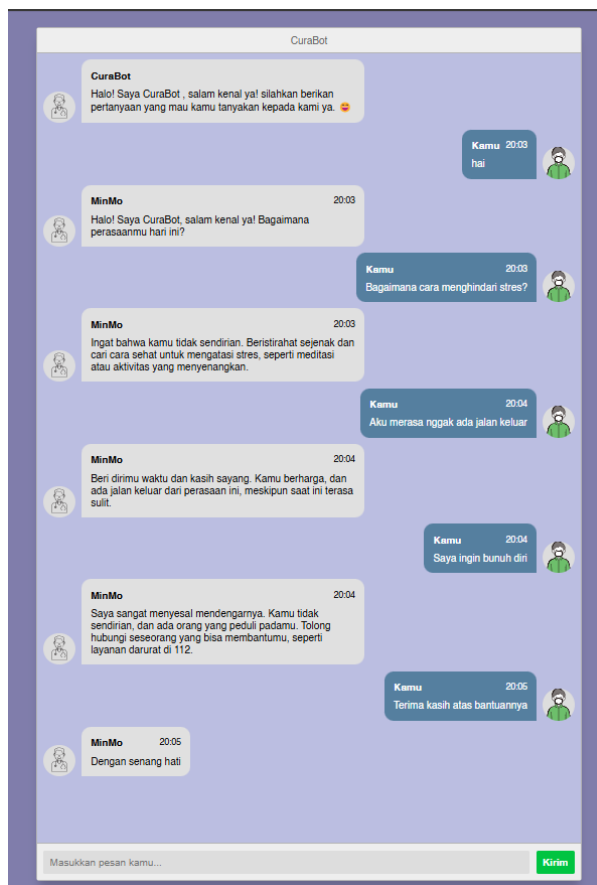
Penelitian ini difokuskan pada bagaimana menyederhanakan penggunaan model chatbot yang telah dikembangkan dengan cara menerapkannya melalui proses deployment. Tahapan ini bertujuan untuk mengintegrasikan model ke dalam sebuah aplikasi berbasis web menggunakan framework Flask. Dalam proses ini, teknologi seperti JavaScript, HTML, dan CSS digunakan untuk membangun tampilan antarmuka pengguna yang menarik, intuitif, dan mudah digunakan. Aplikasi web yang dibuat memiliki halaman utama yang berisi navigasi dan area khusus untuk berinteraksi dengan chatbot, dirancang agar pengguna merasa nyaman dan dapat berkomunikasi dengan chatbot secara responsif.

Fitur chatbot diperkuat dengan empat fungsi utama berbasis JavaScript. Fungsi pertama mengatur bagaimana pesan dari pengguna dikirim dan ditampilkan. Fungsi kedua bertugas menghubungkan pesan tersebut dengan model melalui AJAX dan API, sehingga sistem dapat mengirimkan input dan menerima respons dari chatbot. Fungsi ketiga

menampilkan balasan yang diterima dari model, dan fungsi keempat menambahkan penanda waktu (timestamp) agar percakapan terlihat lebih nyata dan kontekstual.

Setelah itu, dilakukan proses routing untuk mengatur jalur atau alamat URL tertentu agar dapat memanggil fungsi-fungsi tertentu di aplikasi. Sebagai contoh, halaman utama chatbot dapat diakses melalui rute “/”, sedangkan respons API untuk chatbot diakses melalui rute “/get”. Setelah seluruh pengaturan selesai, model chatbot beserta elemen-elemen pendukungnya dimuat ke dalam aplikasi, lalu dijalankan menggunakan layanan Railway sebagai server. Dengan platform ini, aplikasi bisa diakses secara daring maupun melalui jaringan lokal, sehingga pengguna dapat mencoba fitur chatbot kapan saja dan dari mana saja.

Terakhir, Gambar 6 memperlihatkan antarmuka chatbot yang telah siap digunakan, dengan tampilan yang sudah dilengkapi navigasi, area percakapan, dan balasan yang muncul secara real-time. Hal ini menciptakan pengalaman interaktif yang menyenangkan dan memudahkan mahasiswa dalam menggunakan chatbot untuk kebutuhan konsultasi kesehatan mental.



Gambar 6. Tampilan Chatbot pada Website

Gambar 6 menampilkan tampilan antarmuka dari aplikasi chatbot berbasis web. Melalui antarmuka ini, pengguna dapat berinteraksi langsung dengan chatbot menggunakan kolom pesan yang telah disediakan. Saat pengguna mengetikkan pertanyaan atau pernyataan lalu menekan tombol kirim, sistem akan memproses input tersebut dan memberikan respons yang sesuai dan relevan. Jika pengguna ingin mengajukan pertanyaan lanjutan, mereka cukup menulis pesan baru di kolom yang sama dan mengirimkannya kembali. Fitur ini mendukung percakapan yang bersifat terus-menerus, sehingga memungkinkan pengguna untuk berkomunikasi dengan chatbot dalam satu sesi interaksi yang utuh dan nyaman.

3.7 Pembahasan

Hasil evaluasi menunjukkan bahwa model CuraBot mampu melakukan klasifikasi intent dengan akurasi yang tinggi, yaitu sebesar 89.9%, serta F1-score 89.8%. Hasil ini mengindikasikan bahwa model mampu memahami ekspresi pengguna dengan cukup akurat, meskipun jumlah kelas yang diklasifikasikan cukup banyak (77 intent).

Berdasarkan confusion matrix, sebagian besar kelas berhasil diklasifikasikan dengan benar, meskipun terdapat beberapa kebingungan antar kelas yang memiliki ekspresi semantik mirip, seperti antara “stres” dan “kecemasan” atau “butuh bantuan” dan “konsultasi”. Hal ini masih dapat dimaklumi karena overlapping makna dalam dialog sehari-hari. Dari sisi pelatihan, model menunjukkan potensi overfitting ringan karena akurasi pelatihan yang sangat tinggi (99%) dibanding akurasi uji (89.9%). Namun, selisih ini tidak terlalu signifikan dan performa pada data uji tetap stabil, menandakan generalisasi model masih dalam batas wajar.

Secara keseluruhan, model CuraBot layak dijadikan sebagai alat bantu awal dalam sistem konseling, karena mampu memahami dan merespons berbagai kategori intent secara kontekstual dan cepat.

3.8 Batasan Penelitian

Penelitian ini masih terbatas pada tahap pengembangan prototipe chatbot berbasis LSTM untuk layanan kesehatan mental. Sistem telah berhasil diimplementasikan dan diintegrasikan ke dalam platform web, namun belum melalui tahap pengujian langsung oleh pengguna akhir seperti mahasiswa atau konselor. Dengan demikian, efektivitas chatbot dalam konteks penggunaan nyata, termasuk kualitas interaksi, kenyamanan pengguna, dan dampak terhadap pengalaman konseling, belum dapat divalidasi secara menyeluruh. Batasan ini menjadi dasar untuk penelitian lanjutan yang akan berfokus pada tahap uji coba sistem terhadap pengguna aktual guna memperoleh umpan balik dan evaluasi lebih komprehensif.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan chatbot kesehatan mental berbasis web yang diberi nama CuraBot, guna mendukung layanan konseling awal bagi mahasiswa Universitas Dian Nuswantoro. Dengan memanfaatkan algoritma Long Short-Term Memory (LSTM), sistem ini dirancang untuk mengenali berbagai ekspresi emosional pengguna dan memberikan respons yang empatik serta informatif. Pengembangan dilakukan melalui tahapan sistematis yang mencakup preprocessing data, pelatihan model, evaluasi performa, dan deployment ke dalam aplikasi web. Model CuraBot dilatih menggunakan 1.624 data percakapan dan dievaluasi menggunakan test set sebanyak 244 data uji. Hasil evaluasi menunjukkan performa model yang tinggi, dengan akurasi sebesar 89,9%, precision 90,4%, recall 89,1%, dan F1-score sebesar 89,8%. Evaluasi per kelas juga menunjukkan bahwa intent-intent populer seperti “stres”, “motivasi”, dan “konsultasi” dapat dikenali dengan baik, dengan nilai F1-score di atas 89%. Visualisasi confusion matrix menunjukkan kemampuan klasifikasi yang baik meskipun terdapat tumpang tindih pada beberapa kelas yang memiliki ekspresi semantik serupa. CuraBot memberikan kontribusi nyata dalam integrasi teknologi NLP dan deep learning untuk layanan kesehatan mental berbasis web. Sistem ini menawarkan solusi yang praktis, anonim, dan mudah diakses oleh mahasiswa yang membutuhkan dukungan awal tanpa harus bertatap muka langsung dengan tenaga profesional. Selain itu, pendekatan user-centered yang digunakan dalam pembuatan dataset turut meningkatkan relevansi sistem terhadap konteks lokal pengguna. Namun demikian, penelitian ini masih memiliki keterbatasan, terutama karena belum dilakukan pengujian terhadap pengguna akhir (mahasiswa/konselor) secara langsung. Hal ini membuka peluang untuk penelitian selanjutnya, seperti melakukan uji coba sistem secara langsung terhadap pengguna aktual untuk menilai pengalaman interaksi dan kepuasan pengguna. Pengembangan lebih lanjut juga dapat mengintegrasikan model berbasis transformer seperti BERT untuk pemahaman konteks yang lebih dalam, serta menambahkan fitur deteksi emosi real-time yang adaptif terhadap kondisi psikologis pengguna. Dengan langkah-langkah ini, CuraBot dapat dikembangkan menjadi sistem yang lebih komprehensif dalam mendukung layanan kesehatan mental digital di lingkungan pendidikan tinggi.

REFERENCES

- [1] P. Rathnayaka, N. Mills, D. Burnett, D. De Silva, D. Alahakoon, and R. Gray, “A Mental Health Chatbot with Cognitive Skills for Personalised Behavioural Activation and Remote Health Monitoring,” *Sensors*, vol. 22, no. 10, May 2022, doi: 10.3390/s22103653.
- [2] Gangadhar Baredy, Dr. Veparala Lazar, Khushi Mahajan, and Dr Pallerla Srikanth, “Impact of Adverse Childhood Experiences on the Treatment Journey of Women Facing Infertility,” 2024. [Online]. Available: <https://dergipark.org.tr/en/pub/jnbs>
- [3] H. Liang and P. Phokha, “The Development of Music Recreation Therapy for Students’ Stress, using of Music Activity Learning Methods,” *Pak J Life Soc Sci*, vol. 22, no. 2, pp. 6758–6771, 2024, doi: 10.57239/PJLSS-2024-22.2.00511.
- [4] D. L. Tobing and Sari Septiningtyas, “Regulasi Emosi dan Perilaku Cyberbullying pada Remaja,” *Jurnal Keperawatan Widya Gantari Indonesia*, vol. 8, no. 1, Mar. 2024, doi: 10.52020/jkwgi.v8i1.7445.
- [5] N. Agustin and F. Malahati, “Hubungan Resiliensi dan Coping Stres Terhadap Tingkat Stres Mahasiswa yang Mengikuti Program MBKM,” *Journal of Basic Educational Studies*, vol. 4, no. 3, pp. 2077–2085, Nov. 2024, doi: <https://doi.org/10.47467/edu.v4i3.5723>.
- [6] F. N. Nesimnasi, T. M. Tiwa, and M. Naharia, “Stres Akademik Mahasiswa Fakultas Ilmu Pendidikan dan Psikologi Universitas Negeri Manado yang Mengikuti Merdeka Belajar Kampus Merdeka (MBKM) Tahun 2020,” *PSIKOPEDIA*, vol. 5, no. 3, pp. 263–270, Jun. 2024, doi: 10.53682/pj.v5i3.9553.
- [7] A. Rizky Saputra, A. Matulesy, and F. Psikologi, “Stres akademik pada mahasiswa Merdeka Belajar Kampus Merdeka (MBKM): Bagaimana peran dukungan sosial?,” *INNER: Journal of Psychological Research*, vol. 3, no. 4, pp. 564–570, 2024.
- [8] D. Maharani Harahap, H. Ramayana Sidabutar, N. Apriani Lubis, N. Salsabila Pasaribu, and H. Laila Siregar, “Pengaruh Pola Asuh Orang Tua Terhadap Pembentukan Perilaku Disiplin Mahasiswa di Kota Medan,” *JCRD: Journal of Citizen Research and Development*, vol. 2, no. 1, pp. 555–564, 2025, doi: <https://doi.org/10.57235/jcrd.v2i1.4770>.
- [9] M. Efendy, N. Pratitis, M. R. Norhidayah, and E. N. A. Putri, “Coping Religius dan Kesejahteraan Psikologis Mahasiswa Muslim di Indonesia,” *Jurnal Ilmiah Fakultas Psikologi Universitas Yudharta Pasuruan*, vol. 11, Sep. 2024, doi: 10.35891/jip.v11i2.



- [10] R. Gunawan and A. R. Nugroho, “Pengembangan Prototipe Cyber Counseling dalam Setting Pendidikan dan Kesehatan Mental bagi Mahasiswa,” *Jurnal Dinamika Pendidikan*, vol. 16, no. 1, pp. 33–47, Apr. 2023, doi: 10.51212/jdp.v16i1.
- [11] A. Anggraini, C. E. Rahelta, M. A. Simangunsong, T. A. Mediansyah, Z. Harahap, and S. F. Dalimunthe, “Pengaruh Kebiasaan Membaca Buku terhadap Kesehatan Mental Mahasiswa di Fakultas Teknik UNIMED,” *JIIIC : Jurnal Intelek Insan Cendekia*, vol. 1, no. 10, Dec. 2024, [Online]. Available: <https://jicnusantara.com/index.php/jiic>
- [12] A. Fathoni, M. Putra Sahalana, and Z. N. Azizah, “Pengembangan Layanan Konseling Mahasiswa UIN Walisongo Semarang Berbasis Expert System,” *JURNAL FASILKOM*, vol. 14, no. 3, pp. 627–636, Dec. 2024.
- [13] E. Budiyantri and M. J. Wijaya, “Hubungan Konsumsi Kafein dengan Gangguan Tidur pada Mahasiswa Preklinik,” *Damianus Journal of Medicine*, vol. 22, no. 3, pp. 225–231, Dec. 2023, doi: <https://doi.org/10.25170/djm.v22i3.3610>.
- [14] B. Satrio, A. F. Rochim, and D. M. K. Nugraheni, “Mental health consultation information system using natural language processing based on expert system with forward chaining method,” *AIP Conf Proc*, vol. 2865, no. 1, p. 050004, Dec. 2023, doi: 10.1063/5.0183789.
- [15] A. S. Zahira, P. N. Agustina, K. C. Satyafebrianti, R. A. Arbani, and H. Fahma, “Peran AI dalam Pemahaman dan Optimalisasi Kesehatan Mental pada Masyarakat,” *Prosiding Seminar Nasional COSMIC Kedokteran*, vol. 3, pp. 112–118, Jan. 2025, [Online]. Available: <https://prosidingcosmic.fk.uwks.ac.id/index.php/cosmic/article/view/75>
- [16] C. A. Khairan and M. S. Habib, “Chatbot AI dalam Identifikasi Awal Gangguan Kesehatan Mental di Indonesia: Tantangan dan Prospek,” *Jurnal Empati*, vol. 13, no. 6, pp. 498–508, Dec. 2025, doi: 10.14710/empati.2024.47903.
- [17] P. Arjanto and F. F. W. Senduk, “Literature Review on the Double-Edged Sword of AI in Mental Health: A Deep Dive into ChatGPT’s Capabilities and Limitations,” *Journal of Community Mental Health and Public Policy*, vol. 6, no. 2, pp. 67–76, Apr. 2024, doi: 10.51602/cmhp.v6i2.144.
- [18] I. Nurhafiyah and H. Marcos, “Sistem Pakar Diagnosis Kesehatan Mental pada Mahasiswa Universitas AMIKOM Purwokerto,” *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, pp. 49–56, Apr. 2023.
- [19] B. Kelana, A. R. Qodri, and S. Muruliza, “Desain Chatbot Layanan Daring Kesehatan Mental yang Sesuai Persepsi dan Kepuasan Generasi Z,” *Jurnal Sistem Komputer dan Kecerdasan Buatan*, vol. 8, no. 1, pp. 18–26, 2024, doi: <https://doi.org/10.47970/siskom-kb.v7i1.540>.
- [20] R. R. Hidayat, M. Fikry, and Yusra, “Chatbot Deteksi Awal Gangguan Kecemasan Menggunakan Dialogflow,” *Jurnal Teknologi Terpadu*, vol. 11, no. 2, Oct. 2023.
- [21] S. P. Afrisia, F. M. Hana, and W. C. Wahyudin, “Implementasi Metode Long Short Term Memory (LSTM) pada Chatbot Kesehatan Mental Mahasiswa,” *Sainteks*, vol. 21, no. 2, p. 107, Oct. 2024, doi: 10.30595/sainteks.v21i2.23869.
- [22] I. D. Raharjo and E. R. Subhiyanto, “Implementing Long Short Term Memory (LSTM) in Chatbots for Multi Usaha Raya,” *Advance Sustainable Science, Engineering and Technology*, vol. 6, no. 4, Aug. 2024, doi: 10.26877/asset.v6i4.934.
- [23] S. Widodo, D. Setiawan, T. Ridwan, and R. Ambari, “Perancangan Deteksi Emosi Manusia berdasarkan Ekspresi Wajah Menggunakan Algoritma VGG16,” *Syntax : Jurnal Informatika*, vol. 11, pp. 1–12, Mar. 2022, doi: 10.35706/syji.v11i01.6594.