

**IMPLEMENTASI CNN BERBASIS WORD EMBEDDING
UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI
UMSU**

SKRIPSI

DISUSUN OLEH

RAYHAN PRATAMA

NPM. 2209010298



UMSU
Unggul | Cerdas | Terpercaya

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN**

2026

**IMPLEMENTASI CNN BERBASIS WORD EMBEDDING
UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI
UMSU**

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Sistem Informasi
pada Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah
Sumatera Utara

RAYHAN PRATAMA

NPM. 2209010298

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN**

2026

LEMBAR PENGESAHAN

Judul Skripsi : IMPLEMENTASI CNN BERBASIS WORD
EMBEDDING UNTUK KLASIFIKASI PERTANYAAN
CHATBOT FIKTI UMSU

Nama Mahasiswa : RAYHAN PRATAMA
NPM : 2209010298
Program Studi : SISTEM INFORMASI

Menyetujui
Komisi Pembimbing



(Dr. Irvan, M.Si)

NIDN. 0117117301

Ketua Program Studi



(Mahardika Prawira Tanjung, S.Kom., M.Kom.)

NIDN. 0117088902



(Dr. Al Khawarizmi, S.Kom., M.Kom.)

NIDN. 0127099201

PERNYATAAN ORISINALITAS

**IMPLEMENTASI CNN BERBASIS WORD EMBEDDING
UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI
UMSU**

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 2026

Yang membuat pernyataan



Rayhan Pratama

NPM. 2209010298

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama	: Rayhan Pratama
NPM	: 2209010298
Program Studi	: Sistem Informasi
Karya Ilmiah	: Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**IMPLEMENTASI CNN BERBASIS WORD EMBEDDING
UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI
UMSU**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 2026

Yang membuat pernyataan



Rayhan Pratama

NPM. 2209010298

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Rayhan Pratama
Tempat dan Tanggal Lahir : Medan, 20 Agustus 2004
Alamat Rumah : Jln Seto gg Abdulmanaf
Telepon/Faks/HP : 08996054626
E-mail : agarayhan123@gmail.com
Instansi Tempat Kerja :
Alamat Kantor :

DATA PENDIDIKAN

SD	: SD Negeri 060796 Medan	TAMAT: 2016
SMP	: SMP Negeri 4 Medan	TAMAT: 2019
SMA	: SMA Negeri 10 Medan	TAMAT: 2022

KATA PENGANTAR



Puji Syukur dipanjatkan kehadiran Allah SWT berkat Rahmat, hidayah dan karunia-nya sehingga penulis dapat menyelesaikan penulisan skripsi dengan judul **“IMPLEMENTASI CNN BERBASIS WORD EMBEDDING UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI UMSU”**. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer pada Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara. Penulis menyadari bahwa dalam penyusunan skripsi ini terwujud berkat bantuan, arahan, bimbingan, dan doa dari berbagai pihak. Oleh karena itu penulis menyampaikan terimakasih kepada:

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firahmi Rizky, S.Kom., M.Kom. Wakil dekan I Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
4. Bapak Mhd. Basri, S.Si, S.Kom., M.Kom. Wakil dekan III Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
5. Bapak Mahardika Prawira Tanjung, S.Kom., M.Kom. Ketua Program Studi Sistem Informasi. selaku dosen pembahas yang telah memberikan kritikan dan saran yang konstruktif demi kesempurnaan penulisan dan penyusunan proposal hingga skripsi.
6. Bapak Mulkan Azhari, S.Kom., M.Kom. Sekretaris Program Studi Sistem Informasi
7. Bapak Dr. Irvan, M.Si selaku dosen pembimbing skripsi yang dengan penuh kesabaran dan perhatian membimbing penulis hingga sampai pada titik ini.

Terima kasih telah percaya, membantu, membimbing, dan selalu mendorong penulis untuk terus berkembang.

8. Ibu Yoshida Sary, S.E., S.Kom., M.Kom. selaku dosen pembimbing akademik yang telah telah memberikan bimbingan selama penulis menempuh Pendidikan di perguruan tinggi.
9. Dosen beserta Staff Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara yang tidak dapat penulis sebut satu persatu karena telah memberikan banyak ilmu dan masukan kepada penulis.
10. Teristimewa kepada kedua Orang tua tercinta, yang senantiasa memberikan kasih sayang, doa, dukungan, nasihat, serta pengorbanan yang tidak pernah putus kepada penulis. Terima kasih atas segala cinta, perhatian, dan semangat yang telah diberikan sehingga penulis dapat menyelesaikan pendidikan dan penyusunan skripsi ini.
11. Terima kasih kepada Wike Oktaviani, selaku pasangan sekaligus support system penulis, yang senantiasa memberikan doa, dukungan, semangat, dan perhatian selama proses penyusunan skripsi ini. Terima kasih telah selalu hadir, menemani setiap proses, serta menjadi tempat berbagi cerita dan menguatkan penulis di saat lelah dan menghadapi berbagai kesulitan. Kehadiran dan dukungan yang diberikan menjadi salah satu alasan penulis dapat terus bertahan hingga skripsi ini terselesaikan.
12. Penulis mengucapkan terimakasih kepada teman terdekat yaitu Asrul Alafgani, Fadhlur Rahman, M. Ardiansyah Matondang, yang telah menjadi bagian dari perjalanan hidup penulis selama menempuh pendidikan hingga penyusunan skripsi ini. Terima kasih karena selalu hadir dalam setiap proses, bukan hanya di saat penuh tawa dan kebahagiaan, tetapi juga di saat penulis berada di titik paling lelah, bingung, dan hampir menyerah. Kalian adalah orang-orang yang mengetahui setiap perjuangan, setiap air mata, setiap rasa takut, setiap kegagalan, dan setiap langkah kecil yang harus penulis lalui hingga mampu berada di titik ini. Terima kasih karena tidak pernah bosan mendengarkan setiap keluh kesah, selalu memberikan semangat ketika penulis kehilangan harapan, mengingatkan untuk terus

bangkit ketika keadaan terasa begitu berat, serta tetap bertahan menemani di setiap proses tanpa pernah meninggalkan penulis. Kehadiran kalian membuat penulis menyadari bahwa perjuangan ini tidak pernah dijalani sendirian. Setiap tawa yang kita bagi, setiap cerita yang kita simpan, setiap langkah yang kita tempuh bersama akan selalu menjadi kenangan yang sangat berharga dan tidak akan pernah tergantikan.

IMPLEMENTASI CNN BERBASIS WORD EMBEDDING UNTUK KLASIFIKASI PERTANYAAN CHATBOT FIKTI UMSU

ABSTRAK

Perkembangan layanan informasi digital di perguruan tinggi mendorong pemanfaatan chatbot untuk membantu mahasiswa memperoleh informasi secara cepat dan mandiri. Namun, variasi pertanyaan pengguna dapat menyebabkan kesalahan dalam klasifikasi intent sehingga respons yang diberikan menjadi tidak sesuai. Penelitian ini bertujuan untuk mengimplementasikan Convolutional Neural Network (CNN) berbasis Word2Vec untuk klasifikasi pertanyaan pada chatbot FIKTI UMSU. Dataset yang digunakan terdiri dari 619 pertanyaan yang dikelompokkan ke dalam enam intent, yaitu dekan, dosen, fakultas, kaprodi, sapaan, dan UKT. Data diproses melalui tahap case folding, tokenizing, word indexing, dan padding, sedangkan Word2Vec digunakan sebagai representasi kata dan bobot awal pada Embedding Layer yang bersifat trainable. Dataset dibagi menjadi 495 data training dan 124 data testing. Hasil evaluasi model memperoleh accuracy sebesar 99,19%, dengan 123 data berhasil diklasifikasikan dengan benar dan satu data mengalami kesalahan klasifikasi dari intent kaprodi menjadi dekan. Pengujian sistem dilakukan menggunakan 30 pertanyaan dengan berbagai bentuk dan susunan kata.

Kata Kunci: Chatbot, Convolutional Neural Network, Word2Vec, Word Embedding, Klasifikasi Teks, Intent.

IMPLEMENTATION OF CNN BASED ON WORD EMBEDDING FOR QUESTION CLASSIFICATION IN THE FIKTI UMSU CHATBOT

ABSTRACT

The development of digital information services in higher education has encouraged the use of chatbots to help students obtain information quickly and independently. However, variations in user questions can cause errors in intent classification, resulting in inappropriate responses. This study aims to implement a Word2Vec-based Convolutional Neural Network (CNN) for question classification in the FIKTI UMSU chatbot. The dataset consists of 619 questions categorized into six intents: dekan, dosen, fakultas, kaprodi, sapaan, and UKT. The data were processed through case folding, tokenizing, word indexing, and padding, while Word2Vec was used for word representation and as the initial weights of the trainable Embedding Layer. The dataset was divided into 495 training data and 124 testing data. The model achieved an accuracy of 99.19%, with 123 data correctly classified and one misclassification from the kaprodi intent to dekan. System testing was conducted using 30 questions with various forms and word arrangements.

Keywords: Chatbot, Convolutional Neural Network, Word2Vec, Word Embedding, Text Classification, Intent.

DAFTAR ISI

LEMBAR PENGESAHAN.....	i
PERNYATAAN ORISINALITAS	Error! Bookmark not defined.
KATA PENGANTAR.....	v
ABSTRAK	viii
ABSTRACT.....	ix
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR.....	xiv
BAB I	1
PENDAHULUAN	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	8
BAB II.....	9
LANDASAN TEORI.....	9
2.1 Tinjauan Pustaka	9
2.2 Chatbot.....	11
2.3 Pengolahan Bahasa Alami (Natural Language Processing).....	13
2.4 Klasifikasi Teks.....	16
2.5 Representasi Teks (Text Representation)	17
2.5.1 Bag-of-Words.....	17
2.5.2 Term Frequency-Inverse Document Frequency (TF-IDF).....	18
2.5.3 Word Embedding	20
2.6 Convolutional Neural Network (CNN)	21
2.7 Evaluasi Kinerja Model.....	23
2.8 Kerangka Pemikiran.....	26
2.9 Penelitian Terdahulu	28
BAB III	31
ANALISIS DAN PERANCANGAN SISTEM	31
3.1 Analisis Permasalahan.....	31
3.2 Metode Penelitian.....	31
3.3 Pemodelan dan Perancangan Sistem	33
3.4 Text Preprocessing	35
3.5 Word Embedding	36

3.6 Convolutional Neural Network (CNN)	36
3.7 Training dan Evaluasi Model	39
3.7.1 Training Model.....	39
3.7.2 Evaluasi Model.....	40
3.8 Perancangan Sistem	41
3.8.1 Arsitektur Sistem.....	41
3.8.2 Use Case Diagram.....	43
3.8.3 Activity Diagram.....	45
3.8.4 Flowchart Sistem.....	47
3.8.5 Perancangan Basis Data	48
3.8.6 Algoritma Sistem	49
3.9 Perancangan Antarmuka (UI/UX).....	50
3.9.1 Halaman Login.....	51
3.9.2 Halaman Dashboard Pengguna.....	52
3.9.3 Halaman Chatbot.....	53
3.9.4 Halaman Riwayat Percakapan	54
BAB IV	55
HASIL DAN PEMBAHASAN	55
4.1 Hasil Implementasi Sistem.....	55
4.1.1 Tampilan Antarmuka Nova AI	55
4.1.2 Tampilan Interaksi Chatbot	57
4.1.3 Alur Kerja Sistem.....	58
4.2 Hasil Preprocessing dan Pembentukan Representasi Data	59
4.2.1 Case Folding	60
4.2.2 Tokenizing	61
4.2.3 Pembentukan Representasi Word2Vec.....	62
4.2.4 Word Indexing	63
4.2.5 Padding	63
4.2.6 Hasil Akhir Preprocessing.....	65
4.3 Pembentukan dan Pelatihan Model CNN	66
4.3.1 Pembagian Data	66
4.3.2 Pembentukan Label Intent.....	67
4.3.3 Arsitektur Model CNN.....	68
4.3.4 Proses Pelatihan Model	69
4.3.5 Hasil Pelatihan Model	70
4.3.6 Hasil Model CNN.....	70
4.4 Hasil Klasifikasi Intent.....	73
4.4.1 Proses Klasifikasi Intent.....	73

4.4.2 Hasil Klasifikasi Pertanyaan.....	73
4.4.3 Kesesuaian Hasil Prediksi	74
4.4.4 Hasil Klasifikasi sebagai Dasar Pemberian Respons	75
4.5 Hasil Integrasi Knowledge Base dan Respons.....	76
4.5.1 Integrasi Intent dengan Knowledge Base	76
4.5.2 Pengambilan Informasi Berdasarkan Intent.....	78
4.5.3 Hasil Respons Chatbot	79
4.5.4 Alur Pemberian Respons	81
4.6 Pengujian Sistem.....	82
4.6.1 Skenario Pengujian.....	82
4.6.2 Hasil Pengujian Klasifikasi	83
4.6.3 Hasil Pengujian Respons	86
4.6.4 Pengujian Pertanyaan di Luar Knowledge Base	87
4.6.5 Hasil Pengujian Keseluruhan	88
4.6.6 Dokumentasi Pengujian Sistem	88
4.7 Pembahasan.....	91
4.7.1 Pembahasan Hasil Preprocessing	91
4.7.2 Pembahasan Hasil Model CNN	92
4.7.3 Pembahasan Hasil Klasifikasi Intent	93
4.7.4 Pembahasan Integrasi Knowledge Base dan Respons	94
4.7.5 Pembahasan Hasil Pengujian Sistem	96
4.7.6 Pembahasan Sistem Secara Keseluruhan.....	98
BAB V	101
KESIMPULAN DAN SARAN	101
5.1 Kesimpulan	101
5.2 Saran	102
DAFTAR PUSTAKA.....	104

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu.....	29
Tabel 4.2 Hasil Case Folding dan Tokenizing	61
Tabel 4.3 Representasi Kata Menggunakan Word2Vec.....	62
Tabel 4.4 Hasil Word Indexing	63
Tabel 4.5 Hasil Padding	64
Tabel 4.6 Hasil Akhir Preprocessing.....	65
Tabel 4.7 Pembagian Data Training dan Testing	66
Tabel 4.8 Daftar Intent pada Dataset	67
Tabel 4.9 Arsitektur Model CNN	68
Tabel 4.10 Parameter Pelatihan Model CNN	69
Tabel 4.11 Hasil Evaluasi Model CNN.....	71
Tabel 4.12 Confusion Matrix Model CNN	72
Tabel 4.13 Hasil Klasifikasi Intent.....	74
Tabel 4.14 Kesesuaian Hasil Prediksi Intent.....	75
Tabel 4.15 Integrasi Intent dengan Knowledge Base	77
Tabel 4.16 Pengambilan Informasi Berdasarkan Intent	79
Tabel 4.17 Hasil Respons Nova AI	80
Tabel 4.18 Skenario Pengujian Nova AI.....	83
Tabel 4.19 Hasil Pengujian Klasifikasi Intent.....	84
Tabel 4.20 Hasil Pengujian Respons Nova AI	86
Tabel 4.21 Pengujian Pertanyaan di Luar Knowledge Base	87
Tabel 4.22 Rekapitulasi Hasil Pengujian	88

DAFTAR GAMBAR

Gambar 3.1 Flowchart Sistem Klasifikasi Pertanyaan Chatbot Menggunakan CNN	34
Gambar 3.2 Arsitektur Convolutional Neural Network (CNN)	38
Gambar 3.3 Arsitektur Sistem Klasifikasi Pertanyaan Chatbot FIKTI UMSU Menggunakan CNN Berbasis Word Embedding.	43
Gambar 3.4 Use Case Diagram Sistem	44
Gambar 3.5 Activity Diagram User.....	45
Gambar 3.6 Activity Diagram Admin	46
Gambar 3.7 Flowchart Sistem	47
Gambar 3.8 Rancangan Halaman Login.....	51
Gambar 3.9 Rancangan Halaman Dashboard Pengguna	52
Gambar 3.10 Rancangan Halaman Chatbot	53
Gambar 3.11 Rancangan Halaman Riwayat Percakapan	54
Gambar 4.1 Tampilan Antarmuka Nova AI	56
Gambar 4.2 Tampilan Interaksi Pengguna dengan Nova AI.....	57
Gambar 4.3 Alur Kerja Sistem Nova AI	59
Gambar 4.4 Grafik Accuracy dan Loss Selama Proses Pelatihan Model CNN ..	70
Gambar 4.5 Hasil Interaksi Pengguna dengan Nova AI.....	81
Gambar 4.6 Hasil Pengujian Pertanyaan dengan Intent Sesuai.....	89
Gambar 4.7 Hasil Pengujian Pertanyaan dengan Intent Tidak Sesuai	89
Gambar 4.8 Hasil Pengujian Pertanyaan di Luar Knowledge Base	90

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Perkembangan teknologi informasi dalam satu dekade terakhir telah memberikan dampak signifikan terhadap transformasi layanan digital, termasuk pada sektor pendidikan tinggi. Salah satu inovasi yang semakin banyak dimanfaatkan adalah penggunaan chatbot, yaitu sistem berbasis kecerdasan buatan yang dirancang untuk berinteraksi dengan pengguna melalui pesan teks secara otomatis. Chatbot memiliki potensi besar dalam meningkatkan aksesibilitas informasi karena mampu memberikan respons yang cepat, konsisten, dan dapat diakses kapan saja. Sejumlah penelitian menunjukkan bahwa chatbot berkontribusi terhadap peningkatan efisiensi layanan informasi dan pengalaman pengguna di lingkungan akademik. (Adamopoulou & Moussiades, 2020; Smutny & Schreiberova, 2020) Oleh sebab itu, pengembangan chatbot yang lebih cerdas dan responsif menjadi kebutuhan yang relevan di era digital saat ini.

Di lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi pada Universitas Muhammadiyah Sumatera Utara, chatbot digunakan sebagai sarana bagi mahasiswa untuk memperoleh informasi terkait akademik, administrasi, dan layanan umum lainnya. Sistem ini diharapkan dapat membantu mahasiswa mengakses informasi secara mandiri dan cepat. Namun, kenyataannya, chatbot yang tersedia masih menghadapi berbagai kendala, terutama dalam memahami maksud pertanyaan pengguna. Ketidaktepatan dalam memberikan respons umumnya disebabkan oleh kelemahan sistem dalam mengklasifikasikan kategori pertanyaan secara akurat. Sejumlah studi mengemukakan bahwa tantangan utama

dalam pengembangan chatbot adalah kemampuan memahami bahasa manusia yang bersifat kompleks dan bervariasi (Dale, 2021; Huang et al., 2020). Dengan demikian, peningkatan kemampuan pemahaman bahasa menjadi aspek penting dalam penyempurnaan chatbot.

Klasifikasi teks merupakan salah satu komponen inti dalam sistem chatbot karena berfungsi untuk menentukan kategori pertanyaan sebelum chatbot memberikan respons. Tingkat akurasi klasifikasi sangat menentukan relevansi jawaban yang diterima pengguna. Namun dalam praktiknya, variasi bentuk bahasa yang digunakan mahasiswa, seperti penggunaan bahasa informal, singkatan, serta kombinasi istilah populer, menimbulkan kesulitan tersendiri bagi sistem dalam memahami maksud sebenarnya dari sebuah pertanyaan. Hal ini ditegaskan oleh penelitian terbaru yang menyatakan bahwa bahasa alami yang digunakan pengguna sering memiliki struktur yang tidak baku sehingga menyulitkan model klasifikasi tradisional dalam mengenali pola dan konteksnya (Kowsari et al., 2019). Oleh karena itu, dibutuhkan pendekatan yang lebih adaptif untuk memahami teks secara lebih komprehensif.

Pendekatan representasi teks konvensional seperti bag-of-words dan TF-IDF memang kerap digunakan dalam sistem klasifikasi teks, tetapi metode ini memiliki keterbatasan mendasar. Representasi tersebut tidak mampu menangkap hubungan semantik antar kata sehingga kata-kata dianggap berdiri sendiri tanpa mempertimbangkan konteks kalimat. Kondisi ini mengakibatkan informasi penting dalam kalimat sering terabaikan sehingga akurasi klasifikasi cenderung menurun. Sejumlah penelitian terbaru mengonfirmasi bahwa metode representasi tradisional tidak lagi memadai untuk menangani kompleksitas data teks modern (Minaee et al.,

2022). Oleh sebab itu, diperlukan pendekatan representasi yang mampu menggambarkan makna dan hubungan antar kata dengan lebih baik.

Perkembangan dalam bidang pemrosesan bahasa alami kemudian menghadirkan teknik word embedding sebagai solusi atas kelemahan representasi teks sebelumnya. Word embedding memetakan kata ke dalam bentuk vektor numerik yang mencerminkan kedekatan makna antar kata. Metode ini dapat merepresentasikan hubungan semantik dan sintaksis secara lebih kaya sehingga model dapat memahami konteks bahasa secara lebih mendalam. Penelitian yang dilakukan beberapa tahun terakhir menunjukkan bahwa embedding mampu meningkatkan performa model dalam berbagai tugas pengolahan bahasa alami, terutama klasifikasi teks (Devlin et al., 2019; Mikolov et al., 2013). Dengan keunggulan tersebut, word embedding menjadi pendekatan representasi yang sangat relevan dalam meningkatkan kemampuan pemahaman chatbot.

Selain representasi teks, pemilihan algoritma klasifikasi juga sangat menentukan kualitas kinerja sistem. Salah satu metode deep learning yang banyak digunakan dan terbukti efektif adalah Convolutional Neural Network atau CNN. Meskipun awalnya dikembangkan untuk pengolahan citra, CNN telah menunjukkan kemampuan yang sangat baik dalam memproses data teks melalui mekanisme ekstraksi fitur otomatis. Penelitian mutakhir menunjukkan bahwa CNN mampu mengenali pola-pola penting dalam teks dengan tingkat akurasi yang lebih tinggi dibandingkan metode tradisional (Kim, 2014). Dengan demikian, CNN menjadi salah satu model yang tepat untuk tugas klasifikasi teks pada sistem chatbot.

Penggabungan antara word embedding dan CNN menawarkan pendekatan yang lebih kuat dalam memahami dan mengklasifikasikan teks. Word embedding menyediakan representasi kata yang kaya makna, sedangkan CNN berfungsi mengekstraksi fitur penting dari representasi tersebut secara otomatis. Kombinasi keduanya telah terbukti meningkatkan performa model secara signifikan dalam berbagai penelitian klasifikasi teks kontemporer (Wang & Li, 2022). Oleh karena itu, pendekatan ini memiliki potensi besar untuk memperbaiki proses klasifikasi pertanyaan pada chatbot FIKTI UMSU.

Dalam konteks chatbot akademik, penerapan CNN berbasis word embedding diharapkan dapat membantu sistem memahami pertanyaan mahasiswa yang sangat beragam dari segi struktur, gaya bahasa, maupun konteks penggunaan kata. Embedding memungkinkan sistem memahami kedekatan makna antara kata, sementara CNN memungkinkan pengenalan pola frasa atau kombinasi kata tertentu yang menjadi ciri khas kategori pertanyaan tertentu. Penelitian terbaru menunjukkan bahwa pendekatan ini efektif dalam meningkatkan akurasi klasifikasi pada data teks yang tidak baku dan memiliki variasi tinggi (Wang et al., 2020). Berdasarkan temuan tersebut, penerapan model ini dinilai relevan untuk meningkatkan kualitas chatbot FIKTI UMSU.

Rendahnya akurasi klasifikasi pertanyaan pada chatbot FIKTI UMSU menjadi latar belakang utama bagi penelitian ini. Ketidaktepatan dalam memahami maksud pengguna menyebabkan chatbot memberikan respons yang tidak relevan, dan hal ini berdampak pada menurunnya tingkat kepercayaan mahasiswa terhadap sistem yang disediakan. Dengan demikian, diperlukan pendekatan yang lebih modern dan efektif untuk meningkatkan akurasi klasifikasi pertanyaan.

Implementasi CNN berbasis word embedding diharapkan dapat menjadi solusi yang mampu menangani kompleksitas bahasa pengguna serta meningkatkan kualitas respons chatbot secara keseluruhan.

Selain memberikan manfaat teknis, penelitian ini juga berkontribusi dalam peningkatan kualitas layanan akademik berbasis digital. Dengan meningkatnya kemampuan chatbot dalam mengklasifikasikan pertanyaan pengguna secara akurat, mahasiswa dapat memperoleh informasi yang sesuai kebutuhan secara lebih cepat dan efisien. Sejumlah penelitian menunjukkan bahwa peningkatan akurasi chatbot berkorelasi positif dengan kepuasan pengguna dan kualitas layanan institusi (Chaves & Gerosa, 2021). Dengan demikian, penelitian ini memiliki nilai strategis dalam mendukung upaya peningkatan kualitas pelayanan pendidikan.

Berdasarkan keseluruhan uraian tersebut, penelitian ini memfokuskan pada pengembangan model klasifikasi pertanyaan chatbot FIKTI UMSU menggunakan CNN berbasis word embedding sebagai upaya untuk meningkatkan efektivitas sistem dalam memahami dan mengelompokkan pertanyaan pengguna. Pendekatan ini diharapkan mampu memberikan kontribusi nyata dalam pengembangan chatbot akademik yang lebih cerdas, akurat, dan responsif terhadap kebutuhan mahasiswa pada lingkungan kampus.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana proses representasi teks menggunakan word embedding pada data pertanyaan pengguna chatbot FIKTI UMSU?

2. Bagaimana implementasi metode Convolutional Neural Network berbasis word embedding dalam mengklasifikasikan kategori pertanyaan pada chatbot FIKTI UMSU?
3. Bagaimana kinerja model CNN berbasis word embedding dalam proses klasifikasi pertanyaan pengguna yang diukur menggunakan metrik evaluasi seperti accuracy, precision, recall, dan F1-score?
4. Bagaimana efektivitas model CNN berbasis Word2Vec dalam melakukan klasifikasi kategori pertanyaan pada chatbot FIKTI UMSU berdasarkan hasil evaluasi model?

1.3 Batasan Masalah

Agar penelitian ini lebih terarah dan tidak meluas dari tujuan yang telah ditetapkan, maka batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Data yang digunakan dalam penelitian ini berupa kumpulan 619 pertanyaan yang disusun berdasarkan kebutuhan informasi pada chatbot FIKTI Universitas Muhammadiyah Sumatera Utara. Data pertanyaan dikumpulkan dari orang-orang di sekitar peneliti dan kemudian disusun dalam berbagai variasi kalimat yang tetap mewakili maksud informasi yang sama. Selanjutnya, data diseleksi dan dikelompokkan berdasarkan intent yang sesuai dengan kebutuhan sistem.
2. Klasifikasi pertanyaan dibatasi pada beberapa kategori tertentu yang telah ditentukan sebelumnya, seperti kategori akademik, administrasi, dan informasi umum.
3. Representasi teks yang digunakan dalam penelitian ini terbatas pada teknik word embedding, tanpa membahas metode representasi lain secara mendalam.

4. Metode klasifikasi yang digunakan adalah Convolutional Neural Network berbasis word embedding, tanpa membahas atau mengembangkan model deep learning lainnya secara kompleks.
5. Penelitian ini membahas perancangan antarmuka pengguna (UI/UX) sebagai bagian pendukung dalam pengembangan sistem chatbot, sedangkan fokus utama penelitian tetap pada proses klasifikasi pertanyaan menggunakan Convolutional Neural Network (CNN) berbasis Word2Vec.
6. Evaluasi kinerja model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score.
7. Bahasa yang digunakan dalam data penelitian dibatasi pada bahasa Indonesia sesuai dengan konteks pertanyaan pengguna chatbot FIKTI UMSU.
8. Penelitian ini tidak membahas aspek keamanan sistem, integrasi dengan sistem lain, maupun implementasi chatbot secara real-time dalam skala besar.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah ditetapkan, tujuan dari penelitian ini adalah sebagai berikut:

1. Menerapkan teknik word embedding sebagai metode representasi teks pada data pertanyaan pengguna chatbot FIKTI Universitas Muhammadiyah Sumatera Utara untuk memperoleh representasi vektor yang lebih bermakna dan kontekstual.
2. Mengimplementasikan model Convolutional Neural Network berbasis word embedding dalam proses klasifikasi kategori pertanyaan yang diajukan oleh pengguna chatbot FIKTI UMSU.

3. Menganalisis kinerja model CNN berbasis word embedding dalam klasifikasi pertanyaan pengguna dengan menggunakan metrik evaluasi berupa accuracy, precision, recall, dan F1-score.
4. Menganalisis efektivitas model CNN berbasis Word2Vec dalam melakukan klasifikasi kategori pertanyaan berdasarkan hasil evaluasi model pada data pengujian.

1.5 Manfaat Penelitian

1. Bagi FIKTI UMSU

Penelitian ini diharapkan dapat membantu meningkatkan kualitas layanan chatbot dalam memberikan bantuan informasi kepada mahasiswa secara lebih akurat dan efisien.

2. Bagi Pengguna

Penelitian ini diharapkan dapat memberikan kemudahan bagi pengguna dalam memperoleh informasi yang sesuai dengan kebutuhan melalui chatbot.

3. Bagi Peneliti

Penelitian ini dapat menambah wawasan dan pengalaman dalam mengimplementasikan metode Convolutional Neural Network (CNN) pada sistem chatbot.

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Penelitian mengenai pengembangan chatbot dan klasifikasi teks berbasis kecerdasan buatan terus mengalami perkembangan. Berbagai studi sebelumnya telah mengkaji efektivitas penggunaan metode NLP, word embedding, dan algoritma deep learning untuk meningkatkan kemampuan chatbot dalam memahami teks pengguna. Penelitian yang dilakukan oleh Adamopoulou & Moussiades (2020) meninjau perkembangan chatbot modern dan menyimpulkan bahwa efektivitas chatbot sangat bergantung pada kemampuan sistem dalam memahami bahasa alami. Senada dengan itu, Smutny & Schreiberova (2020) menjelaskan bahwa chatbot memiliki potensi besar dalam mendukung aktivitas pendidikan, namun keberhasilannya sangat ditentukan oleh akurasi pemrosesan teks yang dilakukan oleh model klasifikasi.

Penelitian terkait klasifikasi teks juga terus berkembang. Yan et al. (2020) menyatakan bahwa metode representasi teks tradisional seperti bag-of-words dan TF-IDF semakin kurang efektif dalam menangani data teks yang kompleks. Hal ini mendorong peneliti untuk menggunakan metode representasi yang lebih modern. Mikolov et al. (2013) dan Devlin et al. (2019) menunjukkan bahwa word embedding mampu menghasilkan representasi teks yang lebih bermakna dan memiliki kemampuan menangkap hubungan semantik antar kata, sehingga berkontribusi positif pada peningkatan akurasi model NLP.

Dalam konteks klasifikasi teks berbasis deep learning, penelitian oleh Zhang dan LeCun (2016) menunjukkan bahwa Convolutional Neural Network memiliki

performa yang stabil dan kuat dalam ekstraksi fitur tekstual. CNN mampu menangkap pola lokal dalam kalimat melalui proses konvolusi sehingga sering digunakan untuk tugas klasifikasi teks. Hasil penelitian tersebut diperkuat oleh Wang dan Li (2022) yang menemukan bahwa CNN berbasis word embedding dapat menghasilkan tingkat akurasi yang lebih tinggi dibandingkan CNN dengan representasi teks konvensional.

Penelitian lain yang berfokus pada integrasi NLP dengan chatbot dilakukan oleh Dale (2021) yang menegaskan bahwa kesalahan pemahaman bahasa alami pada chatbot sering kali disebabkan oleh keterbatasan teknik klasifikasi teks. Huang et al. (2020) juga menyatakan bahwa kesulitan utama chatbot akademik terletak pada variasi bahasa pengguna yang tidak selalu mengikuti struktur formal. Oleh karena itu, penggunaan metode deep learning yang lebih robust diperlukan untuk mengatasi tantangan tersebut.

Dalam ranah pendidikan, Chaves & Gerosa (2021) menemukan bahwa chatbot yang memiliki ketepatan respons tinggi dapat meningkatkan pengalaman pengguna dan kualitas layanan akademik secara keseluruhan. Namun, mereka juga menyoroti adanya kebutuhan penelitian lebih lanjut terkait metode peningkatan akurasi klasifikasi teks sebagai dasar pemberian respons yang tepat. Penelitian oleh Wang et al. (2020) semakin memperkuat temuan ini dengan menunjukkan bahwa penggunaan embedding dan CNN dapat secara signifikan meningkatkan performa chatbot dalam memahami konteks teks yang tidak baku.

Meskipun berbagai penelitian telah membahas penggunaan NLP, embedding, dan CNN, studi-studi tersebut sebagian besar dilakukan pada konteks umum seperti sentiment analysis, analisis media sosial, atau klasifikasi berita. Penelitian khusus

yang mengkaji penerapan CNN berbasis word embedding dalam meningkatkan akurasi klasifikasi pertanyaan pada chatbot di lingkungan perguruan tinggi masih sangat terbatas. Dengan demikian, terdapat ruang penelitian yang cukup signifikan untuk mengkaji efektivitas kombinasi metode CNN dan word embedding pada chatbot akademik, khususnya di lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.

Berdasarkan hasil kajian tersebut, dapat disimpulkan bahwa penelitian ini memiliki posisi strategis dalam melengkapi kekurangan penelitian terdahulu. Penelitian ini berupaya memberikan kontribusi baru dalam pengembangan chatbot akademik melalui penerapan model CNN berbasis word embedding yang diharapkan dapat meningkatkan efektivitas klasifikasi kategori pertanyaan pengguna. Dengan demikian, penelitian ini berperan dalam mengisi kesenjangan penelitian yang belum banyak dibahas, sekaligus memberikan solusi yang relevan bagi peningkatan sistem layanan informasi digital di lingkungan pendidikan tinggi.

2.2 Chatbot

Chatbot merupakan sistem komputer yang dirancang untuk mensimulasikan percakapan manusia melalui media teks maupun suara, sehingga pengguna dapat berinteraksi secara langsung dengan sistem tanpa melibatkan operator manusia. Dalam beberapa tahun terakhir, chatbot mengalami perkembangan yang signifikan seiring dengan kemajuan teknologi kecerdasan buatan. Adamopoulou dan Moussiades (2020) menyatakan bahwa chatbot telah menjadi bagian penting dalam transformasi layanan digital karena kemampuannya dalam memberikan respons secara cepat, konsisten, dan tersedia sepanjang waktu. Keunggulan tersebut

menjadikan chatbot sebagai solusi yang efektif dalam meningkatkan efisiensi layanan informasi di berbagai sektor.

Secara umum, chatbot dapat diklasifikasikan menjadi dua jenis utama, yaitu chatbot berbasis aturan dan chatbot berbasis kecerdasan buatan. Chatbot berbasis aturan bekerja berdasarkan pola atau skrip yang telah ditentukan sebelumnya, sehingga hanya dapat merespons pertanyaan yang sesuai dengan aturan yang telah diprogram. Sebaliknya, chatbot berbasis kecerdasan buatan menggunakan teknik pengolahan bahasa alami dan pembelajaran mesin untuk memahami maksud pengguna secara lebih fleksibel. Dale (2021) menjelaskan bahwa chatbot berbasis kecerdasan buatan memiliki kemampuan adaptasi yang lebih baik terhadap variasi bahasa pengguna dibandingkan dengan chatbot berbasis aturan.

Dalam konteks pendidikan, chatbot telah banyak dimanfaatkan sebagai media pendukung layanan akademik. Chatbot dapat digunakan untuk memberikan informasi terkait jadwal perkuliahan, proses administrasi, serta layanan konsultasi sederhana bagi mahasiswa. Smutny dan Schreiberova (2020) menunjukkan bahwa penggunaan chatbot dalam lingkungan pendidikan mampu meningkatkan aksesibilitas informasi serta mengurangi beban kerja tenaga administrasi. Selain itu, chatbot juga memungkinkan mahasiswa untuk memperoleh informasi secara mandiri tanpa harus menunggu layanan manual dari pihak kampus.

Pada lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi di Universitas Muhammadiyah Sumatera Utara, chatbot dimanfaatkan sebagai sarana untuk membantu penyampaian informasi kepada mahasiswa. Sistem ini diharapkan mampu memberikan respons yang akurat terhadap berbagai pertanyaan yang berkaitan dengan kegiatan akademik maupun administrasi. Namun dalam

implementasinya, chatbot masih menghadapi kendala dalam memahami maksud pertanyaan pengguna. Hal ini menyebabkan respons yang diberikan sering kali tidak sesuai dengan kebutuhan pengguna.

Salah satu faktor utama yang memengaruhi kualitas chatbot adalah kemampuan sistem dalam mengklasifikasikan kategori pertanyaan pengguna. Proses klasifikasi ini berperan penting dalam menentukan respons yang akan diberikan oleh chatbot. Jika proses klasifikasi tidak dilakukan dengan tepat, maka chatbot akan memberikan jawaban yang tidak relevan. Huang et al. (2020) menyatakan bahwa kesalahan dalam memahami input pengguna sering kali disebabkan oleh keterbatasan model dalam mengenali konteks bahasa alami yang kompleks dan bervariasi.

Selain itu, variasi bahasa yang digunakan oleh mahasiswa juga menjadi tantangan tersendiri dalam pengembangan chatbot. Penggunaan bahasa informal, singkatan, serta struktur kalimat yang tidak baku sering kali menyulitkan sistem dalam memahami maksud pengguna. Oleh karena itu, diperlukan pendekatan yang lebih canggih dalam pengolahan bahasa alami dan klasifikasi teks agar chatbot mampu memahami konteks pertanyaan secara lebih akurat. Dengan demikian, peningkatan kemampuan klasifikasi menjadi langkah penting dalam mengoptimalkan kinerja chatbot, khususnya pada lingkungan akademik.

2.3 Pengolahan Bahasa Alami (Natural Language Processing)

Pengolahan Bahasa Alami atau Natural Language Processing (NLP) merupakan salah satu cabang dari kecerdasan buatan yang berfokus pada interaksi antara komputer dan bahasa manusia. NLP bertujuan untuk memungkinkan komputer memahami, mengolah, dan menghasilkan bahasa manusia dalam bentuk

teks maupun suara. Hirschberg dan Manning (2015) menyatakan bahwa NLP memiliki peran penting dalam membantu sistem komputer membaca, memproses, dan menafsirkan bahasa manusia secara otomatis.

Dalam sistem chatbot, NLP memiliki peran penting dalam memahami maksud dari pertanyaan yang diajukan oleh pengguna. Young et al. (2018) menjelaskan bahwa keberhasilan chatbot dalam memberikan respons yang tepat sangat ditentukan oleh kemampuan sistem dalam melakukan pemrosesan bahasa alami secara akurat. Sebelum data teks diproses oleh model klasifikasi, teks tersebut harus melalui beberapa tahapan pengolahan agar dapat diinterpretasikan oleh sistem secara lebih efektif.

Beberapa tahapan umum dalam NLP antara lain:

1. Tokenizing

Tokenizing merupakan proses pemecahan teks menjadi unit-unit kecil, seperti kata atau kalimat. Proses ini bertujuan untuk mempermudah analisis terhadap setiap bagian teks. Menurut Indurkha dan Damerau (2010), tokenizing adalah langkah fundamental dalam setiap proses NLP karena menentukan struktur dasar yang akan diproses oleh algoritma selanjutnya.

2. Case Folding

Case folding adalah proses mengubah seluruh huruf dalam teks menjadi huruf kecil (lowercase) untuk menghindari perbedaan penulisan yang dapat mempengaruhi hasil analisis. Tahapan ini penting untuk menjaga konsistensi teks sehingga variasi huruf kapital tidak mengganggu proses pemahaman model (Jurafsky dan Martin, 2020).

3. Stopword Removal

Stopword removal merupakan proses penghapusan kata-kata umum yang tidak memiliki makna penting dalam analisis, seperti “dan”, “yang”, “di”, dan sebagainya. Menurut Manning et al. (2008), stopwords harus dihapus karena keberadaannya tidak memberikan kontribusi signifikan terhadap representasi makna teks.

4. Stemming

Stemming adalah proses mengubah kata menjadi bentuk dasarnya. Misalnya, kata “berjalan”, “berjalanlah”, dan “berjalan” akan diubah menjadi kata dasar “jalan”. Porter (2006) menjelaskan bahwa stemming membantu memperkecil jumlah variasi kata yang berbeda namun memiliki akar kata yang sama, sehingga memudahkan sistem dalam mengenali makna.

Setelah melalui tahapan tersebut, data teks akan diubah ke dalam bentuk representasi numerik agar dapat diproses oleh model machine learning, termasuk metode Convolutional Neural Network (CNN). Representasi ini memungkinkan sistem untuk mengenali pola dalam teks dan melakukan proses klasifikasi secara lebih akurat. Mikolov et al. (2013) menegaskan bahwa representasi numerik yang baik sangat memengaruhi tingkat akurasi model klasifikasi berbasis deep learning.

Dengan demikian, NLP menjadi tahap awal yang sangat penting dalam penelitian ini, karena kualitas hasil klasifikasi sangat dipengaruhi oleh proses pengolahan data teks yang dilakukan sebelumnya. Tan et al. (2024) menyatakan bahwa kualitas preprocessing pada NLP memiliki korelasi langsung dengan kinerja model klasifikasi, terutama pada aplikasi chatbot yang bergantung pada pemahaman konteks teks secara tepat.

2.4 Klasifikasi Teks

Klasifikasi teks adalah proses mengelompokkan teks ke dalam kategori tertentu berdasarkan makna dan isi yang terkandung di dalamnya. Teknik ini banyak digunakan dalam berbagai aplikasi seperti deteksi spam, analisis sentimen, rekomendasi konten, dan chatbot. Yogatama et al. (2017) menyatakan bahwa klasifikasi teks menjadi dasar bagi banyak sistem kecerdasan buatan yang bergantung pada pemahaman teks pengguna, termasuk chatbot akademik. Dalam chatbot, akurasi klasifikasi teks menentukan apakah respons yang diberikan relevan dengan pertanyaan pengguna.

Tahapan klasifikasi teks melibatkan proses pengumpulan data, preprocessing, representasi teks, pelatihan model, dan evaluasi. Keragaman bahasa menjadikan proses klasifikasi teks lebih kompleks karena model harus mampu mengenali pola dan konteks dalam kalimat. Kowsari et al. (2019) menegaskan bahwa tantangan utama klasifikasi teks terletak pada variasi struktur dan konteks bahasa yang tidak selalu konsisten. Oleh karena itu, dibutuhkan metode klasifikasi yang dapat mempelajari pola secara mendalam dan adaptif.

Metode klasifikasi tradisional seperti Naive Bayes dan Support Vector Machine sering digunakan karena sederhana dan efisien. Namun metode ini memiliki keterbatasan ketika berhadapan dengan data teks yang kompleks. Perkembangan deep learning memungkinkan model seperti Recurrent Neural Network dan Convolutional Neural Network memiliki kemampuan ekstraksi fitur otomatis. Zhang dan LeCun (2016) menunjukkan bahwa CNN dapat memberikan akurasi lebih tinggi dalam klasifikasi teks karena mampu menangkap pola lokal pada kata dan frasa.

Dalam konteks chatbot akademik seperti pada lingkungan FIKTI UMSU, klasifikasi teks menjadi bagian penting yang menentukan kualitas respons chatbot. Pertanyaan mahasiswa yang beragam, mulai dari akademik hingga administrasi, membutuhkan sistem klasifikasi yang akurat. Jika klasifikasi tidak tepat, maka respons yang diberikan tidak relevan sehingga menurunkan efektivitas sistem. Dengan demikian, penelitian ini memfokuskan pada pemilihan metode klasifikasi teks yang mampu mengatasi kompleksitas data bahasa alami.

2.5 Representasi Teks (Text Representation)

Representasi teks merupakan proses mengubah data teks ke dalam bentuk numerik agar dapat diproses oleh algoritma machine learning maupun deep learning. Representasi teks sangat penting karena komputer tidak dapat memahami teks secara langsung. Menurut Jurafsky dan Martin (2020), kualitas representasi teks sangat mempengaruhi hasil klasifikasi, terutama pada data yang memiliki kompleksitas tinggi seperti bahasa alami pengguna.

2.5.1 Bag-of-Words

Bag-of-Words (BoW) merupakan salah satu metode representasi teks yang paling sederhana dan banyak digunakan dalam pengolahan bahasa alami. Metode ini merepresentasikan teks sebagai kumpulan kata tanpa memperhatikan urutan maupun struktur kalimat. Setiap dokumen diubah menjadi vektor yang berisi frekuensi kemunculan kata-kata yang terdapat dalam dokumen tersebut. Salton dan McGill (1983) menjelaskan bahwa BoW merupakan pendekatan dasar dalam pemrosesan teks yang berfokus pada keberadaan dan jumlah kata dalam suatu dokumen.

Cara kerja Bag-of-Words dimulai dengan membangun kosakata dari seluruh kumpulan dokumen yang digunakan. Setiap kata unik akan menjadi fitur dalam representasi vektor. Selanjutnya, setiap dokumen direpresentasikan dalam bentuk vektor berdasarkan jumlah kemunculan kata tersebut. Proses ini menghasilkan matriks yang dapat digunakan sebagai input bagi algoritma machine learning. Meskipun sederhana, metode ini cukup efektif untuk tugas klasifikasi teks dasar karena mampu menangkap informasi frekuensi kata dalam dokumen.

Namun demikian, Bag-of-Words memiliki beberapa kelemahan. Metode ini tidak mampu menangkap hubungan semantik antar kata karena setiap kata diperlakukan secara independen. Selain itu, BoW juga mengabaikan urutan kata dalam kalimat sehingga informasi konteks menjadi hilang. Yan et al. (2020) menyatakan bahwa metode ini cenderung menghasilkan dimensi fitur yang sangat besar dan kurang efisien dalam menangani teks yang kompleks. Oleh karena itu, metode ini sering dikombinasikan atau digantikan dengan pendekatan yang lebih canggih seperti word embedding dalam penelitian modern.

2.5.2 Term Frequency-Inverse Document Frequency (TF-IDF)

Term Frequency-Inverse Document Frequency (TF-IDF) merupakan salah satu metode representasi teks yang sering digunakan dalam pengolahan bahasa alami karena mampu memberikan bobot yang lebih bermakna pada setiap kata dalam dokumen. Berbeda dengan Bag-of-Words yang hanya menghitung frekuensi kata, TF-IDF mempertimbangkan tingkat kepentingan sebuah kata dalam suatu dokumen dibandingkan dengan keseluruhan korpus. Menurut Manning et al. (2008), metode TF-IDF menekankan kata-kata yang jarang muncul namun

memiliki makna spesifik dalam dokumen, sehingga memberikan representasi yang lebih informatif untuk kebutuhan analisis teks.

Secara umum, TF-IDF terdiri dari dua komponen utama yaitu Term Frequency (TF) dan Inverse Document Frequency (IDF). Term Frequency mengukur seberapa sering kata muncul dalam sebuah dokumen, sedangkan IDF mengukur seberapa jarang kata tersebut muncul dalam keseluruhan kumpulan dokumen. Nilai TF-IDF diperoleh dari hasil perkalian kedua komponen tersebut sehingga kata yang sering muncul dalam dokumen tetapi jarang muncul pada dokumen lain akan mendapatkan nilai bobot yang tinggi. Jurafsky dan Martin (2020) menjelaskan bahwa mekanisme ini membuat TF-IDF lebih efektif dalam memilih kata yang relevan dibandingkan metode representasi teks sederhana.

Meskipun TF-IDF memberikan bobot kata yang lebih akurat dibandingkan Bag-of-Words, metode ini masih memiliki beberapa kelemahan. TF-IDF tetap tidak mampu menangkap hubungan semantik antar kata dan tidak mempertimbangkan urutan kata dalam teks. Selain itu, representasi TF-IDF menghasilkan vektor berdimensi tinggi yang kurang efisien untuk digunakan oleh metode deep learning modern. Kowsari et al. (2019) menyatakan bahwa TF-IDF kurang optimal pada tugas klasifikasi teks berskala besar karena tidak dapat mempelajari makna kata seperti yang dilakukan oleh teknik word embedding. Oleh sebab itu, metode TF-IDF dapat digunakan sebagai salah satu representasi teks pembanding dalam penelitian klasifikasi teks sebelum menggunakan metode word embedding seperti Word2Vec, GloVe, atau FastText.

2.5.3 Word Embedding

Word embedding merupakan metode representasi teks modern yang mengubah kata menjadi vektor berdimensi tertentu sehingga kata-kata yang memiliki makna serupa akan berada dalam ruang vektor yang berdekatan. Mikolov et al. (2013) menjelaskan bahwa embedding mampu menangkap hubungan semantik dan sintaksis antar kata, sehingga jauh lebih efektif dibandingkan metode representasi tradisional.

Konsep dasar embedding adalah memetakan setiap kata menjadi vektor angka yang merepresentasikan makna kata dalam ruang multidimensional. Dengan cara ini, hubungan semantik seperti kesamaan makna, analogi kata, atau asosiasi dapat dipelajari oleh model. Penelitian oleh Pennington et al. (2014) menunjukkan bahwa embedding memberikan representasi yang lebih konsisten pada tugas klasifikasi teks.

Beberapa metode embedding yang umum digunakan meliputi:

a. Word2Vec

Diperkenalkan oleh Mikolov et al. (2013), dan terdiri dari dua pendekatan utama yaitu Continuous Bag-of-Words (CBOW) dan Skip-Gram. Word2Vec efektif dalam mempelajari hubungan antar kata menggunakan neural network sederhana.

b. GloVe (Global Vectors)

Dikembangkan oleh Pennington et al. (2014). GloVe memanfaatkan informasi statistik global dari korpus sehingga menghasilkan vektor kata yang lebih stabil dan konsisten.

c. FastText

Dikembangkan oleh Bojanowski et al. (2017). FastText menggunakan konsep subword sehingga mampu mengenali kata yang belum pernah muncul dalam data (out-of-vocabulary). Ini sangat berguna untuk bahasa yang kaya morfologi atau banyak variasi kata seperti bahasa Indonesia.

Word embedding menjadi pilihan utama dalam penelitian modern karena menghasilkan representasi teks yang lebih bermakna. Dalam penelitian ini, embedding digunakan untuk merepresentasikan pertanyaan pengguna sebelum diproses oleh model CNN, sebagaimana direkomendasikan oleh Wang et al. (2020).

2.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu metode dalam deep learning yang banyak digunakan untuk proses klasifikasi data. Meskipun pada awalnya CNN lebih sering digunakan dalam pengolahan citra, perkembangan penelitian menunjukkan bahwa metode ini juga efektif digunakan dalam klasifikasi teks. LeCun et al. (2015) menjelaskan bahwa CNN memiliki kemampuan yang kuat dalam mengekstraksi pola lokal melalui proses konvolusi, sehingga dapat diterapkan pada berbagai jenis data termasuk teks.

CNN memiliki kemampuan untuk mengekstraksi fitur secara otomatis dari data input tanpa memerlukan proses ekstraksi fitur secara manual. Hal ini menjadikan CNN sebagai salah satu metode yang unggul dalam mengenali pola-pola kompleks pada data, termasuk data berbentuk teks. Kim (2014) menyatakan bahwa CNN dapat mendeteksi pola n-gram secara otomatis yang sangat berguna dalam memahami konteks kalimat pada tugas klasifikasi teks. Keunggulan ini membuat CNN menjadi salah satu model yang populer untuk pemrosesan bahasa alami.

Dalam penerapannya pada klasifikasi teks, data yang telah melalui tahap preprocessing akan diubah ke dalam bentuk representasi numerik, seperti vektor atau embedding, yang kemudian menjadi input bagi model CNN. Selanjutnya, CNN akan melakukan proses pembelajaran untuk mengenali pola-pola tertentu yang dapat digunakan dalam menentukan kategori dari teks tersebut. Goodfellow et al. (2016) menjelaskan bahwa penggunaan embedding sebagai input CNN memungkinkan model untuk mempelajari hubungan semantik antar kata secara lebih efektif.

Secara umum, arsitektur CNN terdiri dari beberapa lapisan utama, yaitu:

1. Convolution Layer

Lapisan ini berfungsi untuk mengekstraksi fitur dari data input dengan menggunakan filter atau kernel. Proses konvolusi akan menghasilkan feature map yang merepresentasikan pola-pola penting dalam data. Menurut Zhang dan LeCun (2016), penggunaan beberapa filter dengan ukuran berbeda dapat membantu CNN menangkap pola teks dengan variasi yang lebih luas.

2. Pooling Layer

Pooling layer digunakan untuk mengurangi dimensi dari feature map yang dihasilkan oleh convolution layer. Hal ini bertujuan untuk mengurangi kompleksitas komputasi serta mempertahankan informasi penting. Max pooling merupakan teknik pooling yang paling umum digunakan karena mampu mempertahankan nilai fitur paling signifikan dalam suatu region (Goodfellow et al., 2016).

3. Fully Connected Layer

Lapisan ini berfungsi untuk menghubungkan seluruh neuron dan menghasilkan output berupa klasifikasi kategori. Pada tahap ini, model akan menentukan kelas dari data berdasarkan fitur yang telah dipelajari sebelumnya. Lapisan ini biasanya menggunakan fungsi aktivasi seperti Softmax untuk menghasilkan probabilitas setiap kelas (Jurafsky & Martin, 2020).

Dalam konteks penelitian ini, CNN digunakan untuk mengklasifikasikan kategori pertanyaan pengguna pada chatbot FIKTI di Universitas Muhammadiyah Sumatera Utara. Dengan kemampuan dalam mengekstraksi fitur secara otomatis, CNN diharapkan mampu memberikan hasil klasifikasi yang baik pada data pertanyaan chatbot FIKTI. Tan et al. (2024) menemukan bahwa kombinasi antara word embedding dan CNN memberikan performa yang sangat baik dalam tugas klasifikasi karena embedding menyediakan konteks semantik, sementara CNN mengekstraksi pola penting secara hierarkis.

Oleh karena itu, penerapan metode CNN menjadi salah satu solusi yang relevan dalam meningkatkan kualitas layanan chatbot, khususnya dalam memahami dan mengelompokkan pertanyaan pengguna secara lebih tepat. Selain itu, CNN juga dinilai lebih robust dalam menghadapi variasi bahasa pengguna seperti singkatan, bahasa informal, serta struktur kalimat yang tidak baku yang sering ditemukan pada pertanyaan mahasiswa (Huang et al., 2020). Dengan demikian, penggunaan CNN sangat sesuai untuk mendukung peningkatan akurasi sistem chatbot yang digunakan dalam lingkungan akademik.

2.7 Evaluasi Kinerja Model

Evaluasi kinerja model merupakan tahap penting dalam proses pembangunan sistem klasifikasi untuk menentukan seberapa baik model mampu melakukan

prediksi terhadap data yang diberikan. Evaluasi ini dilakukan untuk mengukur akurasi, keandalan, dan kemampuan model dalam mengklasifikasikan data secara benar. Menurut Tan et al. (2024), pemilihan metrik evaluasi yang tepat sangat berpengaruh terhadap interpretasi performa model, khususnya pada tugas klasifikasi teks yang melibatkan variasi kelas. Evaluasi model diperlukan agar peneliti dapat mengetahui apakah model yang digunakan sudah optimal atau masih memerlukan perbaikan lebih lanjut.

1. Confusion Matrix

Confusion matrix merupakan representasi tabular yang digunakan untuk memberikan gambaran keseluruhan performa model klasifikasi dengan membandingkan antara prediksi model dan nilai sebenarnya. Confusion matrix terdiri dari empat komponen utama yaitu True Positive, True Negative, False Positive, dan False Negative (Powers, 2011). Matriks ini sangat membantu dalam memahami jenis kesalahan yang dilakukan oleh model, bukan hanya seberapa sering model memprediksi benar atau salah. Dengan melihat confusion matrix, peneliti dapat menganalisis apakah model cenderung melakukan kesalahan pada kelas tertentu atau memiliki bias terhadap kategori tertentu.

2. Accuracy

Accuracy merupakan metrik evaluasi yang menghitung persentase prediksi yang benar dibandingkan seluruh prediksi yang dilakukan oleh model. Accuracy banyak digunakan karena sederhana dan mudah diinterpretasikan. Menurut Jurafsky dan Martin (2020), accuracy adalah metrik dasar yang sesuai digunakan ketika distribusi kelas dalam dataset seimbang. Namun metrik ini

dapat menyesatkan jika digunakan pada data dengan ketidakseimbangan kelas yang tinggi, karena model dapat tampak akurat meskipun sering salah dalam memprediksi kelas minoritas.

3. Precision

Precision adalah metrik yang mengukur seberapa banyak prediksi positif model yang benar-benar relevan. Metrik ini menghitung proporsi True Positive dibandingkan jumlah seluruh prediksi positif ($TP + FP$). Goodfellow et al. (2016) menjelaskan bahwa precision sangat penting dalam kasus ketika kesalahan prediksi positif harus diminimalkan, misalnya ketika model tidak boleh terlalu banyak memberikan hasil positif yang tidak relevan. Precision memberikan indikator apakah model terlalu sering salah dalam menganggap suatu sampel sebagai kelas positif.

4. Recall

Recall adalah metrik yang mengukur kemampuan model dalam menemukan atau mengenali seluruh data yang sebenarnya termasuk ke dalam suatu kelas. Recall menghitung proporsi True Positive dibandingkan dengan jumlah seluruh data positif aktual, yaitu True Positive ditambah False Negative ($TP + FN$). Nilai recall yang tinggi menunjukkan bahwa model mampu mengenali sebagian besar data yang sebenarnya termasuk ke dalam kelas tersebut. Recall penting digunakan untuk mengetahui seberapa banyak data dari suatu kategori yang berhasil ditemukan oleh model tanpa banyak melewatkan data yang seharusnya termasuk dalam kategori tersebut (Powers, 2011).

5. F1-Score

F1-Score adalah metrik evaluasi yang menggabungkan precision dan recall ke

dalam satu nilai dengan menggunakan rata-rata harmonik. Metrik ini memberikan keseimbangan antara precision dan recall, sehingga sangat cocok digunakan ketika dataset memiliki distribusi kelas yang tidak seimbang (Powers, 2011). F1-Score dianggap lebih stabil dibandingkan accuracy dalam kondisi ketika salah satu kelas lebih dominan dibandingkan kelas lainnya. Dalam tugas klasifikasi teks seperti penelitian ini, F1-Score sering menjadi metrik utama karena memberikan gambaran performa model yang lebih komprehensif.

Penggunaan keempat metrik dan confusion matrix tersebut bertujuan untuk memberikan evaluasi yang lebih menyeluruh terhadap performa model CNN dalam melakukan klasifikasi teks. Dengan adanya evaluasi ini, dapat diketahui apakah metode yang digunakan mampu meningkatkan efektivitas sistem chatbot dalam memahami dan mengelompokkan pertanyaan pengguna.

2.8 Kerangka Pemikiran

Kerangka pemikiran dalam penelitian ini disusun untuk memberikan gambaran mengenai alur logis yang digunakan dalam proses penyelesaian permasalahan. Penelitian ini berangkat dari kebutuhan untuk meningkatkan efektivitas dan akurasi chatbot pada lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi di Universitas Muhammadiyah Sumatera Utara dalam memahami pertanyaan mahasiswa. Chatbot yang ada masih sering menghasilkan respons yang tidak relevan akibat proses klasifikasi teks yang kurang optimal. Hal ini disebabkan oleh keterbatasan metode representasi teks dan model klasifikasi yang digunakan, sehingga tidak mampu menangkap konteks dan makna kata secara mendalam.

Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan penggunaan metode representasi teks berbasis word embedding. Word embedding memberikan representasi numerik yang lebih bermakna karena mampu memetakan kata ke dalam ruang vektor yang menggambarkan hubungan semantik antar kata. Dengan demikian, word embedding menyediakan representasi kata yang mempertimbangkan hubungan semantik antar kata, sedangkan Bag-of-Words dan TF-IDF merupakan representasi berbasis karakteristik kemunculan kata. Dalam penelitian ini, word embedding digunakan sebagai representasi teks yang menjadi masukan bagi model klasifikasi.

Setelah teks direpresentasikan menggunakan word embedding, langkah selanjutnya adalah melakukan proses klasifikasi menggunakan Convolutional Neural Network (CNN). CNN dipilih karena memiliki kemampuan dalam mengekstraksi fitur secara otomatis melalui mekanisme konvolusi. Model CNN dapat mengenali pola lokal dalam teks, termasuk kombinasi kata dan frasa yang penting untuk menentukan kategori pertanyaan. Dengan memanfaatkan kemampuan tersebut, CNN diharapkan mampu melakukan klasifikasi pertanyaan mahasiswa dengan baik sesuai dengan pola yang dipelajari dari data training.

Hubungan antar variabel dalam penelitian ini dapat dijelaskan sebagai berikut. Variabel input berupa pertanyaan mahasiswa yang telah melalui tahap preprocessing. Variabel proses meliputi representasi teks menggunakan word embedding dan klasifikasi menggunakan CNN. Variabel output berupa kategori pertanyaan yang berhasil diklasifikasikan oleh model. Kualitas output sangat dipengaruhi oleh kualitas representasi teks dan efektivitas model CNN dalam mengekstraksi pola-pola penting. Dengan demikian, semakin baik metode

representasi dan model klasifikasi yang digunakan, semakin akurat hasil klasifikasi yang diperoleh.

Secara keseluruhan, kerangka pemikiran penelitian ini menunjukkan bahwa peningkatan akurasi chatbot dapat dicapai melalui perbaikan proses pengolahan bahasa alami, khususnya pada tahap representasi teks dan klasifikasi. Melalui integrasi word embedding dan CNN, penelitian ini bertujuan menghasilkan model klasifikasi teks yang lebih efektif untuk menentukan kategori pertanyaan pengguna. Hasil akhir penelitian ini diharapkan mampu meningkatkan kualitas layanan chatbot dalam memberikan respons yang relevan dan akurat kepada mahasiswa.

2.9 Penelitian Terdahulu

Penelitian terdahulu digunakan untuk menunjukkan keterkaitan antara penelitian yang telah dilakukan dengan penelitian yang sedang dilaksanakan. Kajian penelitian terdahulu mencakup persamaan dan perbedaan dengan penelitian ini serta digunakan untuk memperjelas posisi dan permasalahan yang dibahas. Berikut merupakan tabel penelitian terdahulu.

Tabel 2.1 Penelitian Terdahulu

No.	Peneliti & Tahun	Judul Penelitian	Metode	Hasil Penelitian	Relevansi
1	Yogatama dkk. (2017)	<i>Generative and Discriminative Text Classification with Recurrent Neural Networks</i>	RNN	Model deep learning mampu meningkatkan performa klasifikasi teks dibanding metode tradisional.	Menjadi pembanding metode deep learning dalam klasifikasi teks chatbot.
2	Zhang dkk. (2016)	<i>Text Understanding from Scratch</i>	Deep Learning	Model deep learning dapat memahami pola teks tanpa memerlukan ekstraksi fitur manual.	Mendukung penggunaan deep learning dalam klasifikasi pertanyaan chatbot.
3	Pennington dkk. (2014)	<i>GloVe: Global Vectors for Word Representation</i>	Word Embedding (GloVe)	Representasi kata mampu menangkap hubungan semantik antar kata dengan lebih baik.	Menjadi dasar penggunaan Word Embedding pada penelitian.
4	Bojanowski dkk. (2017)	<i>Enriching Word Vectors with Subword Information</i>	FastText Word Embedding	Model FastText meningkatkan kualitas representasi kata terutama pada kata yang jarang digunakan.	Mendukung penerapan Word Embedding dalam pengolahan bahasa alami.

5	Yan, Dongyan, dkk. (2020)	<i>Network-Based Deep Learning for Natural Language Processing</i>	Network- Based Deep Learning	Metode deep learning memberikan peningkatan performa dalam pemrosesan bahasa alami.	Mendukung penggunaan deep learning untuk klasifikasi teks chatbot.
---	---------------------------------	--	------------------------------------	--	---

BAB III

ANALISIS DAN PERANCANGAN SISTEM

3.1 Analisis Permasalahan

Analisis permasalahan dalam penelitian ini berfokus pada rendahnya akurasi chatbot FIKTI UMSU dalam memahami dan mengklasifikasikan pertanyaan pengguna. Hal ini disebabkan oleh variasi bahasa yang digunakan mahasiswa, seperti bahasa informal dan singkatan, sehingga sistem kesulitan memahami maksud pertanyaan.

Selain itu, metode representasi teks yang digunakan sebelumnya, seperti Bag-of-Words dan TF-IDF, masih memiliki keterbatasan karena tidak mampu menangkap hubungan makna antar kata secara baik. Akibatnya, konteks pertanyaan tidak dapat dipahami secara optimal oleh sistem.

Oleh karena itu, diperlukan pendekatan yang lebih efektif dengan menggunakan word embedding sebagai representasi teks dan Convolutional Neural Network (CNN) sebagai metode klasifikasi, yang diharapkan dapat meningkatkan akurasi dan kualitas respons chatbot.

3.2 Metode Penelitian

Metode penelitian yang digunakan dalam penelitian ini adalah metode eksperimen. Metode eksperimen digunakan untuk menguji performa model Convolutional Neural Network (CNN) berbasis word embedding dalam proses klasifikasi pertanyaan pada chatbot FIKTI Universitas Muhammadiyah Sumatera Utara.

Pada penelitian ini, data pertanyaan pengguna chatbot melalui beberapa tahapan pengolahan teks menggunakan Natural Language Processing (NLP), yaitu

case folding dan tokenizing. Setelah proses tersebut, kata-kata yang dihasilkan dipetakan ke dalam indeks berdasarkan vocabulary, kemudian dilakukan padding untuk menyamakan panjang sequence. Representasi kata diperoleh melalui Word2Vec dan digunakan sebagai dasar pembentukan embedding matrix yang kemudian digunakan pada Embedding Layer model CNN. Selanjutnya, data yang telah direpresentasikan akan diproses menggunakan model Convolutional Neural Network (CNN) untuk melakukan klasifikasi kategori pertanyaan. Model akan dilatih menggunakan data training dan diuji menggunakan data testing untuk mengetahui kemampuan model dalam mengenali kategori pertanyaan pengguna chatbot.

Dataset yang digunakan dalam penelitian ini terdiri dari 619 data pertanyaan yang disusun berdasarkan kebutuhan informasi pada chatbot Nova AI. Data pertanyaan dikumpulkan dari orang-orang di sekitar peneliti dan kemudian dikembangkan dalam berbagai variasi kalimat yang tetap mewakili maksud informasi yang sama. Selanjutnya, setiap pertanyaan diseleksi dan diberi label berdasarkan maksud pertanyaan dan informasi yang ingin diperoleh pengguna. Label yang digunakan terdiri dari enam intent, yaitu dekan, dosen, fakultas, kaprodi, sapaan, dan UKT. Berdasarkan hasil pengelompokan data, terdapat 102 data pada intent dekan, 102 data pada intent dosen, 106 data pada intent fakultas, 102 data pada intent kaprodi, 103 data pada intent sapaan, dan 104 data pada intent UKT, sehingga total dataset berjumlah 619 data.

Proses evaluasi model dilakukan menggunakan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Hasil evaluasi tersebut digunakan


untuk mengetahui kinerja model CNN berbasis Word2Vec dalam melakukan klasifikasi pertanyaan pada chatbot FIKTI UMSU.

3.3 Pemodelan dan Perancangan Sistem

Algoritma sistem dalam penelitian ini menjelaskan alur proses klasifikasi pertanyaan pada chatbot FIKTI UMSU menggunakan metode Convolutional Neural Network (CNN) berbasis word embedding. Proses diawali dari input berupa teks pertanyaan pengguna yang kemudian diproses melalui beberapa tahapan.

Tahap pertama adalah preprocessing teks menggunakan teknik Natural Language Processing (NLP), yang meliputi case folding dan tokenizing. Setelah itu, token yang dihasilkan dipetakan ke dalam word index dan sequence diseragamkan melalui proses padding. Selanjutnya, representasi kata diperoleh menggunakan Word2Vec dan embedding matrix yang dihasilkan digunakan sebagai bobot awal pada Embedding Layer dalam model CNN.

Setelah tahap preprocessing, teks yang telah diproses kemudian direpresentasikan ke dalam bentuk vektor numerik menggunakan metode word embedding. Representasi ini memungkinkan sistem untuk menangkap hubungan semantik antar kata dalam teks. Selanjutnya, vektor hasil word embedding dimasukkan ke dalam model Convolutional Neural Network (CNN). Pada tahap ini, CNN melakukan proses ekstraksi fitur melalui lapisan konvolusi dan pooling untuk mengenali pola dari data teks. Hasil dari proses tersebut kemudian masuk ke lapisan klasifikasi untuk menentukan kategori pertanyaan pengguna. Output sistem berupa label atau kelas pertanyaan yang akan digunakan oleh chatbot untuk memberikan respons yang sesuai.



Gambar 3.1 Flowchart Sistem Klasifikasi Pertanyaan Chatbot Menggunakan CNN

3.4 Text Preprocessing

Text preprocessing merupakan tahap awal dalam pengolahan data teks yang bertujuan untuk membersihkan dan menyiapkan data agar dapat digunakan pada proses klasifikasi. Pada penelitian ini, preprocessing dilakukan terhadap data pertanyaan pengguna chatbot FIKTI UMSU menggunakan teknik Natural Language Processing (NLP).

Text preprocessing merupakan tahap awal dalam pengolahan data teks yang bertujuan untuk menyiapkan data agar dapat digunakan pada proses klasifikasi. Pada penelitian ini, preprocessing dilakukan melalui dua tahapan utama, yaitu case folding dan tokenizing. Case folding digunakan untuk menyeragamkan penulisan huruf menjadi huruf kecil, sedangkan tokenizing digunakan untuk memisahkan teks menjadi token berupa kata. Setelah tokenisasi, setiap token dipetakan ke dalam word index berdasarkan vocabulary yang telah dibentuk. Sequence hasil indexing kemudian dilakukan padding dengan panjang maksimum 10 agar seluruh data memiliki panjang yang seragam dan dapat digunakan sebagai input model.

Case folding dilakukan dengan mengubah seluruh huruf menjadi huruf kecil agar tidak terjadi perbedaan akibat penggunaan huruf kapital. Setelah itu, tokenizing digunakan untuk memecah teks menjadi potongan kata (token) sehingga dapat diproses secara lebih terstruktur.

Hasil dari proses ini adalah data teks yang lebih bersih dan terstruktur, sehingga lebih siap untuk diproses ke tahap representasi menggunakan word embedding.

3.5 Word Embedding

Word embedding merupakan teknik untuk mengubah kata menjadi representasi angka dalam bentuk vektor. Tujuannya adalah agar komputer dapat memahami hubungan antar kata berdasarkan konteks penggunaannya dalam data teks.

Berbeda dengan metode seperti Bag-of-Words dan TF-IDF yang hanya melihat frekuensi kemunculan kata, word embedding mampu menangkap hubungan makna antar kata. Dengan cara ini, kata yang memiliki arti atau konteks yang mirip akan memiliki representasi vektor yang juga berdekatan.

Dalam penelitian ini digunakan metode Word2Vec sebagai teknik word embedding. Word2Vec mempelajari representasi kata berdasarkan pola kemunculan kata dalam suatu teks. Dari dua pendekatan yang ada, yaitu CBOW dan Skip-gram, penelitian ini menggunakan CBOW karena lebih sederhana dan cocok untuk data dengan ukuran tidak terlalu besar.

Hasil dari Word2Vec ini kemudian digunakan sebagai input pada model Convolutional Neural Network (CNN) untuk proses klasifikasi pertanyaan chatbot FIKTI UMSU.

3.6 Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) merupakan salah satu metode dalam deep learning yang pada awalnya banyak digunakan untuk pengolahan data citra, namun juga dapat diterapkan pada data teks. Dalam penelitian ini, CNN digunakan untuk melakukan klasifikasi pertanyaan pada chatbot FIKTI UMSU berdasarkan fitur yang diperoleh dari hasil word embedding.

CNN bekerja dengan cara mengekstraksi fitur dari data input menggunakan operasi konvolusi. Dalam konteks teks, CNN mampu mengenali pola hubungan antar kata yang terdapat dalam kalimat, sehingga dapat membantu proses klasifikasi menjadi lebih akurat.

Pada penelitian ini, input yang digunakan pada model CNN berasal dari hasil representasi word embedding. Data yang sudah berbentuk vektor kemudian dimasukkan ke dalam beberapa lapisan CNN, yang terdiri dari convolution layer, pooling layer, dan fully connected layer.

Convolution layer berfungsi untuk mengekstraksi fitur dari input dengan menggunakan filter. Selanjutnya, pooling layer digunakan untuk mereduksi dimensi fitur agar lebih efisien tanpa menghilangkan informasi penting. Hasil dari proses ini kemudian diteruskan ke fully connected layer untuk melakukan proses klasifikasi.

Pada bagian akhir, digunakan fungsi aktivasi softmax untuk menghasilkan probabilitas dari setiap kelas kategori pertanyaan. Kelas dengan nilai probabilitas tertinggi akan menjadi output dari sistem, yang kemudian digunakan sebagai hasil klasifikasi chatbot.



Gambar 3.2 Arsitektur Convolutional Neural Network (CNN)

Gambar di atas menunjukkan arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini. Model dimulai dari input berupa representasi teks hasil word embedding, kemudian diproses melalui beberapa lapisan, yaitu convolution layer, pooling layer, hingga fully connected layer.

Convolution layer berfungsi untuk mengekstraksi fitur penting dari data teks, sedangkan pooling layer digunakan untuk mereduksi dimensi fitur agar lebih efisien. Hasil ekstraksi fitur kemudian diproses pada fully connected layer untuk

menentukan kategori pertanyaan. Pada tahap akhir, digunakan fungsi aktivasi softmax untuk menghasilkan probabilitas dari setiap kelas.

3.7 Training dan Evaluasi Model

Pada penelitian ini, model Convolutional Neural Network (CNN) akan melalui tahap training dan evaluasi untuk mengetahui kemampuan sistem dalam mengklasifikasikan pertanyaan chatbot FIKTI UMSU. Proses training dilakukan menggunakan data yang telah melalui tahap preprocessing dan word embedding menggunakan Word2Vec. Setelah proses training selesai, model kemudian dievaluasi menggunakan beberapa metrik untuk mengetahui tingkat performa sistem dalam melakukan klasifikasi pertanyaan.

3.7.1 Training Model

Pada tahap training, model Convolutional Neural Network (CNN) dilatih menggunakan data pertanyaan chatbot yang telah melalui proses preprocessing dan word embedding menggunakan Word2Vec. Data kemudian dibagi menjadi data training dan data testing untuk proses pelatihan dan pengujian model.

Data training digunakan agar model dapat mempelajari pola hubungan antar kata dan kategori pertanyaan. Proses pelatihan dilakukan dengan beberapa parameter, yaitu epoch, batch size, optimizer, learning rate, dan loss function. Epoch digunakan untuk menentukan jumlah pengulangan proses pelatihan terhadap seluruh data training, sedangkan batch size menentukan jumlah data yang diproses dalam satu kali iterasi. Optimizer yang digunakan adalah Adam dengan learning rate sebesar 0,001, sedangkan fungsi loss yang digunakan adalah Sparse Categorical Crossentropy. Nilai parameter pelatihan yang digunakan pada penelitian ini disajikan pada Tabel 3.1.

Epoch digunakan untuk menentukan jumlah pengulangan pelatihan terhadap seluruh data training, sedangkan batch size menentukan jumlah data yang diproses dalam satu kali iterasi pelatihan. Pada penelitian ini, optimizer Adam digunakan karena memiliki performa yang baik dan mampu mempercepat proses pelatihan model.

Tabel 3.1 Parameter Training Model

Parameter	Nilai
Model	CNN
Word Embedding	Word2Vec
Epoch	20
Batch Size	32
Optimizer	Adam
Learning Rate	0,001
Loss Function	Sparse Categorical Crossentropy
Metrics	Accuracy

3.7.2 Evaluasi Model

Setelah proses training selesai dilakukan, tahap berikutnya adalah evaluasi model untuk mengetahui performa sistem dalam mengklasifikasikan pertanyaan chatbot. Evaluasi dilakukan menggunakan data testing yang sebelumnya tidak digunakan pada proses pelatihan model.

Pada penelitian ini, evaluasi model dilakukan menggunakan beberapa metrik, yaitu accuracy, precision, recall, dan F1-score. Accuracy digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi secara keseluruhan.

Precision digunakan untuk mengukur ketepatan hasil prediksi pada setiap kategori pertanyaan, sedangkan recall digunakan untuk melihat kemampuan model dalam menemukan data yang sesuai dengan kategori sebenarnya. Selain itu, F1-score digunakan untuk menyeimbangkan nilai precision dan recall sehingga hasil evaluasi dapat memberikan gambaran performa model secara lebih baik. Hasil evaluasi tersebut digunakan untuk mengetahui kinerja model CNN berbasis Word2Vec dalam melakukan klasifikasi pertanyaan pada chatbot FIKTI UMSU.

3.8 Perancangan Sistem


Perancangan sistem merupakan tahapan yang dilakukan untuk menggambarkan rancangan sistem yang akan dibangun berdasarkan kebutuhan penelitian. Pada penelitian ini, perancangan sistem bertujuan untuk memberikan gambaran mengenai alur kerja sistem klasifikasi pertanyaan Chatbot FIKTI UMSU menggunakan metode Convolutional Neural Network (CNN) berbasis Word Embedding. Perancangan sistem meliputi arsitektur sistem, use case diagram, activity diagram, flowchart sistem, serta perancangan basis data yang digunakan sebagai acuan dalam proses implementasi sistem.

3.8.1 Arsitektur Sistem

Perancangan sistem merupakan tahap yang dilakukan untuk menggambarkan bagaimana proses kerja sistem klasifikasi pertanyaan mulai dari pengguna memasukkan pertanyaan hingga sistem menghasilkan kategori pertanyaan berdasarkan model Convolutional Neural Network (CNN) berbasis Word Embedding. Perancangan ini bertujuan agar proses pengembangan sistem dapat dilakukan secara terstruktur dan memudahkan implementasi pada tahap selanjutnya.

Sistem terdiri dari dua aktor utama, yaitu pengguna (user) dan admin. Pengguna berinteraksi dengan sistem untuk melakukan klasifikasi pertanyaan, sedangkan admin bertugas mengelola dataset, melakukan pelatihan model, serta mengevaluasi performa model CNN.

Sistem akan menerima masukan berupa teks pertanyaan dari pengguna. Selanjutnya teks akan melalui proses preprocessing menggunakan teknik Natural Language Processing (NLP), kemudian diubah menjadi representasi numerik menggunakan Word2Vec. Data hasil word embedding diproses oleh model CNN sehingga menghasilkan kategori pertanyaan yang paling sesuai. Hasil klasifikasi kemudian ditampilkan kepada pengguna dan disimpan ke dalam basis data sebagai riwayat klasifikasi.



Gambar 3.3 Arsitektur Sistem Klasifikasi Pertanyaan Chatbot FIKTI UMSU Menggunakan CNN Berbasis Word Embedding.

3.8.2 Use Case Diagram

Use Case Diagram digunakan untuk menggambarkan interaksi antara aktor dengan sistem. Diagram ini menunjukkan fungsi-fungsi utama yang dapat dilakukan oleh pengguna maupun admin selama menggunakan sistem.


Pada sistem yang dirancang terdapat dua aktor, yaitu:

1. Pengguna (User)

- Login
- Menginput pertanyaan
- Melihat hasil klasifikasi
- Melihat riwayat klasifikasi

2. Admin

- Login
- Mengelola dataset
- Melakukan preprocessing dataset
- Melakukan pelatihan model CNN
- Melakukan evaluasi model
- Mengelola data pengguna (opsional)




Gambar 3.4 Use Case Diagram Sistem

3.8.3 Activity Diagram

Activity Diagram digunakan untuk menggambarkan alur aktivitas yang dilakukan pengguna maupun admin saat menggunakan sistem.

a. Activity Diagram User


Alur aktivitas pengguna dimulai dari proses login ke dalam sistem. Setelah berhasil masuk, pengguna dapat memasukkan pertanyaan yang ingin diklasifikasikan. Sistem akan melakukan preprocessing, mengubah teks menggunakan Word2Vec, kemudian memprosesnya menggunakan CNN sehingga menghasilkan kategori pertanyaan. Hasil klasifikasi ditampilkan kepada pengguna dan disimpan sebagai riwayat klasifikasi.



Gambar 3.5 Activity Diagram User

b. Activity Diagram Admin

Admin melakukan login ke dalam sistem kemudian mengelola dataset yang digunakan sebagai data pelatihan model. Setelah dataset diperbarui, sistem melakukan preprocessing data kemudian melatih model CNN. Setelah proses pelatihan selesai, sistem melakukan evaluasi model menggunakan data uji sehingga diperoleh nilai akurasi model yang akan digunakan dalam proses klasifikasi pertanyaan.




Gambar 3.6 Activity Diagram Admin

3.8.4 Flowchart Sistem

Flowchart digunakan untuk menggambarkan urutan proses klasifikasi pertanyaan yang dilakukan oleh sistem mulai dari pengguna memasukkan pertanyaan hingga sistem menghasilkan kategori pertanyaan.

Tahapan proses meliputi:

1. Pengguna memasukkan pertanyaan.
2. Sistem melakukan preprocessing teks.
3. Sistem melakukan proses Word Embedding menggunakan Word2Vec.
4. Model CNN melakukan proses klasifikasi.
5. Sistem menentukan kategori pertanyaan.
6. Hasil klasifikasi ditampilkan kepada pengguna.
7. Riwayat klasifikasi disimpan ke dalam basis data.



Gambar 3.7 Flowchart Sistem

3.8.5 Perancangan Basis Data

Perancangan basis data dilakukan untuk mengelola seluruh data yang digunakan oleh sistem. Database dirancang agar mampu menyimpan data pengguna, dataset pelatihan, hasil klasifikasi, serta riwayat penggunaan sistem.

Beberapa entitas utama yang digunakan dalam sistem antara lain:

Tabel User

- id_user
- nama
- email
- password
- role

Tabel Dataset

- id_dataset
- pertanyaan
- kategori

Tabel Hasil Klasifikasi

- id_hasil
- id_user
- pertanyaan
- kategori_prediksi
- tanggal

Tabel Model

- id_model
- akurasi

- precision
- recall
- f1_score
- tanggal_training

3.8.6 Algoritma Sistem

Algoritma sistem menjelaskan tahapan proses klasifikasi pertanyaan menggunakan metode Convolutional Neural Network (CNN) berbasis Word Embedding.

Tahapan proses dimulai ketika pengguna memasukkan pertanyaan melalui antarmuka sistem. Selanjutnya, sistem melakukan preprocessing teks yang meliputi case folding dan tokenizing. Token yang dihasilkan kemudian dipetakan ke dalam word index berdasarkan vocabulary dan dilakukan padding untuk menyamakan panjang sequence. Data tersebut kemudian direpresentasikan menggunakan Word2Vec melalui embedding matrix yang digunakan sebagai bobot awal pada Embedding Layer dalam model CNN. Embedding Layer tetap bersifat trainable, sehingga bobot awal dari Word2Vec masih dapat diperbarui selama proses pelatihan CNN. Selanjutnya, keluaran dari Embedding Layer diproses melalui convolution layer, pooling layer, fully connected layer, dan softmax layer untuk menghasilkan klasifikasi intent pertanyaan pengguna.

Model CNN akan melakukan proses klasifikasi sehingga menghasilkan kategori pertanyaan yang memiliki probabilitas tertinggi beserta nilai confidence. Nilai confidence tersebut kemudian digunakan sebagai dasar untuk menentukan apakah hasil klasifikasi dapat digunakan oleh sistem. Apabila nilai confidence lebih besar atau sama dengan 0,70, maka kategori hasil prediksi CNN digunakan sebagai

intent pertanyaan. Sebaliknya, apabila nilai confidence kurang dari 0,70, maka sistem mengubah hasil prediksi menjadi label “unknown”. Hasil klasifikasi tersebut kemudian digunakan dalam proses pemberian respons kepada pengguna.

3.9 Perancangan Antarmuka (UI/UX)


Perancangan antarmuka (User Interface/User Experience) merupakan tahap perancangan tampilan sistem yang bertujuan untuk memberikan gambaran mengenai bentuk dan alur interaksi pengguna dengan sistem klasifikasi pertanyaan Chatbot FIKTI UMSU. Perancangan ini dilakukan sebelum tahap implementasi sebagai acuan dalam proses pengembangan sistem.

Rancangan antarmuka dibuat dengan memperhatikan kemudahan penggunaan (*usability*), kesederhanaan tampilan, serta kemudahan pengguna dalam mengakses setiap fitur yang tersedia. Antarmuka sistem dirancang menggunakan aplikasi Figma dalam bentuk *wireframe* atau rancangan awal, sehingga dapat menggambarkan struktur dan fungsi setiap halaman tanpa menampilkan implementasi aplikasi secara lengkap.

Pada penelitian ini, rancangan antarmuka meliputi halaman login, dashboard pengguna, halaman input pertanyaan, halaman hasil klasifikasi, halaman riwayat klasifikasi, dashboard admin, halaman pengelolaan dataset, serta halaman pelatihan model CNN.

3.9.1 Halaman Login

Halaman login merupakan halaman awal yang digunakan oleh pengguna dan admin untuk mengakses sistem klasifikasi pertanyaan Chatbot FIKTI UMSU. Pada halaman ini, pengguna diminta memasukkan alamat email dan kata sandi sebagai proses autentikasi. Setelah data yang dimasukkan berhasil diverifikasi, sistem akan mengarahkan pengguna ke halaman utama sesuai dengan hak akses masing-masing.

The image shows a login page for UMSU. At the top center is the UMSU logo, which is a circular emblem with a sun in the center and the text 'UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA' around it. Below the logo is the text 'UMSU' in a bold, blue font, followed by the tagline 'Unggul | Cerdas | Terpercaya' in a smaller font. Below this, there are two input fields. The first is labeled 'EMAIL' and the second is labeled 'PASSWORD'. Both fields are represented by gray rectangular boxes. At the bottom center of the form is a white, rounded rectangular button with the text 'LOGIN' in a bold, black font.

Gambar 3.8 Rancangan Halaman Login

3.9.2 Halaman Dashboard Pengguna


Halaman dashboard pengguna merupakan halaman utama yang ditampilkan setelah proses login berhasil. Halaman ini berfungsi sebagai pusat navigasi bagi pengguna untuk mengakses fitur-fitur yang tersedia pada sistem. Pada dashboard tersedia menu Chatbot untuk melakukan konsultasi atau mengajukan pertanyaan, serta menu Riwayat Percakapan untuk melihat kembali percakapan yang pernah dilakukan.



Gambar 3.9 Rancangan Halaman Dashboard Pengguna

3.9.3 Halaman Chatbot


Halaman chatbot merupakan halaman utama yang digunakan pengguna untuk berinteraksi dengan sistem. Pada halaman ini, pengguna dapat memasukkan pertanyaan melalui kolom percakapan yang telah disediakan. Pertanyaan yang dikirimkan akan diproses oleh sistem menggunakan tahapan *preprocessing*, *word embedding* (Word2Vec), dan metode *Convolutional Neural Network* (CNN) untuk mengklasifikasikan kategori pertanyaan sebelum sistem memberikan respons kepada pengguna.



Gambar 3.10 Rancangan Halaman Chatbot

3.9.4 Halaman Riwayat Percakapan

Halaman riwayat percakapan digunakan untuk menampilkan daftar percakapan yang pernah dilakukan oleh pengguna dengan chatbot. Fitur ini memudahkan pengguna untuk melihat kembali pertanyaan yang pernah diajukan beserta respons yang diberikan oleh sistem tanpa harus mengulangi percakapan dari awal.



Gambar 3.11 Rancangan Halaman Riwayat Percakapan

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Implementasi Sistem

Pada penelitian ini telah berhasil dikembangkan sebuah chatbot berbasis Convolutional Neural Network (CNN) yang diberi nama Nova AI. Sistem dikembangkan sebagai asisten virtual yang digunakan untuk memberikan informasi kepada pengguna berdasarkan data dan *knowledge base* yang telah disiapkan.


Nova AI diimplementasikan dalam bentuk aplikasi berbasis antarmuka web menggunakan Streamlit. Antarmuka tersebut menyediakan ruang percakapan yang memungkinkan pengguna memasukkan pertanyaan dan menerima respons dari sistem. Selain ruang percakapan, sistem juga menyediakan bagian *sidebar* yang memuat informasi pendukung mengenai aplikasi.

Pada penggunaannya, pertanyaan yang diberikan oleh pengguna akan diproses oleh sistem sebelum menghasilkan respons. Pertanyaan tersebut melalui tahapan pengolahan data dan kemudian digunakan oleh model CNN untuk menentukan *intent*. Hasil klasifikasi *intent* selanjutnya digunakan untuk menentukan respons yang sesuai berdasarkan *knowledge base*. Alur tersebut menunjukkan bahwa komponen antarmuka, proses klasifikasi, dan penyediaan respons telah diintegrasikan dalam satu aplikasi.

4.1.1 Tampilan Antarmuka Nova AI

Tampilan antarmuka merupakan bagian yang digunakan pengguna untuk berinteraksi dengan Nova AI. Aplikasi dibuat menggunakan Streamlit sehingga chatbot dapat dijalankan melalui halaman web.

Pada halaman utama terdapat identitas Nova AI dan bagian percakapan yang menjadi tempat pengguna memasukkan pertanyaan serta melihat respons yang diberikan oleh sistem.




Gambar 4.1 Tampilan Antarmuka Nova AI

Gambar 4.1 menunjukkan tampilan antarmuka Nova AI yang digunakan sebagai media interaksi antara pengguna dengan sistem. Pada bagian kiri terdapat sidebar yang memuat identitas aplikasi Nova AI, tombol Percakapan Baru, tombol Riwayat Percakapan, serta informasi mengenai model, versi aplikasi, dan pengembang. Tombol Percakapan Baru digunakan untuk memulai percakapan baru, sedangkan tombol Riwayat Percakapan digunakan untuk melihat percakapan yang telah dilakukan sebelumnya. Pada bagian utama terdapat logo dan nama Nova AI, keterangan sebagai Asisten Virtual FIKTI UMSU, area percakapan yang menampilkan pesan dari sistem, serta kolom masukan yang digunakan pengguna untuk memasukkan pertanyaan.

Tampilan tersebut menjadi bagian utama dari sistem karena seluruh proses interaksi pengguna dengan chatbot dilakukan melalui halaman ini.

4.1.2 Tampilan Interaksi Chatbot

Interaksi antara pengguna dan Nova AI dilakukan melalui halaman percakapan. Pengguna memasukkan pertanyaan pada bagian input yang tersedia, kemudian sistem memproses pertanyaan tersebut untuk menentukan kategori pertanyaan dan menghasilkan respons.



Gambar 4.2 Tampilan Interaksi Pengguna dengan Nova AI

Pada tahap interaksi, pengguna dapat menyampaikan pertanyaan melalui kolom masukan yang tersedia pada aplikasi. Pertanyaan yang diberikan kemudian diproses oleh sistem untuk menentukan *intent* dan menghasilkan respons yang sesuai. Gambar 4.2 menunjukkan contoh interaksi antara pengguna dengan Nova AI, mulai dari pertanyaan yang diberikan hingga respons yang ditampilkan oleh sistem.


Nova AI dapat menerima pertanyaan yang diberikan oleh pengguna dan menampilkan respons melalui halaman percakapan. Proses tersebut menunjukkan bahwa aplikasi telah menghubungkan bagian input pengguna dengan proses klasifikasi dan pemberian respons.

Respons yang diberikan oleh chatbot ditentukan berdasarkan *intent* yang diperoleh dari proses klasifikasi. Hasil *intent* tersebut kemudian digunakan untuk menentukan informasi yang sesuai dari *knowledge base*.

4.1.3 Alur Kerja Sistem

Proses kerja sistem dimulai ketika pengguna memberikan pertanyaan melalui aplikasi. Pertanyaan tersebut kemudian masuk ke tahap *preprocessing* untuk mempersiapkan data sebelum digunakan dalam proses klasifikasi. Setelah data diproses, sistem menggunakan Word2Vec untuk membentuk representasi kata dalam bentuk numerik. Data tersebut kemudian disiapkan melalui proses *word indexing* dan *padding* sebelum digunakan sebagai masukan pada model CNN.

Model CNN selanjutnya melakukan proses klasifikasi untuk menentukan *intent* dari pertanyaan pengguna. Hasil klasifikasi tersebut digunakan oleh sistem untuk menentukan informasi yang sesuai pada *knowledge base*. Setelah informasi ditemukan, sistem menampilkan respons kepada pengguna melalui halaman percakapan.



Gambar 4.3 Alur Kerja Sistem Nova AI

4.2 Hasil Preprocessing dan Pembentukan Representasi Data

Tahap preprocessing dilakukan untuk mengubah pertanyaan pengguna yang masih berupa teks menjadi data yang dapat diproses oleh model. Pada Nova AI, proses pengolahan data dilakukan melalui tahapan case folding, tokenizing, word indexing, dan padding. Hasil tersebut kemudian digunakan sebagai input pada Embedding Layer yang menggunakan embedding matrix Word2Vec sebagai bobot awal sebelum diproses oleh model CNN.

Setiap tahapan memiliki fungsi yang berbeda. Case folding digunakan untuk menyeragamkan penulisan huruf, tokenizing memisahkan kalimat menjadi token, Word2Vec mengubah kata menjadi representasi numerik, word indexing memberikan indeks pada token, sedangkan padding digunakan untuk menyamakan panjang data sebelum digunakan sebagai input model CNN.

4.2.1 Case Folding

Case folding merupakan tahap untuk mengubah seluruh huruf pada pertanyaan menjadi huruf kecil. Proses ini dilakukan agar penulisan kata menjadi seragam sehingga perbedaan antara huruf kapital dan huruf kecil tidak menyebabkan kata dianggap berbeda.

Sebagai contoh, pertanyaan yang ditulis menggunakan huruf kapital akan diubah menjadi bentuk huruf kecil. Hasil dari proses ini kemudian digunakan pada tahap *tokenizing*.

Tabel 4.1 Hasil Case Folding

Pertanyaan Pengguna	Case Folding
Siapa Dekan FIKTI?	siapa dekan fiksi?
Apa saja Program Studi FIKTI?	apa saja program studi fiksi?
Siapa Dekan FIKTI sekarang?	siapa dekan fiksi sekarang?

Berdasarkan Tabel 4.1, pertanyaan yang sebelumnya menggunakan huruf kapital telah diubah menjadi huruf kecil. Proses ini dilakukan untuk menyeragamkan bentuk penulisan kata sebelum masuk ke tahap *tokenizing*.

4.2.2 Tokenizing

Setelah proses *case folding*, tahap berikutnya adalah *tokenizing*. *Tokenizing* merupakan proses memecah teks menjadi bagian-bagian yang lebih kecil berupa token, yang dalam penelitian ini berupa kata.

Sebagai contoh, pertanyaan:

“Siapa Dekan FIKTI UMSU?”

setelah melalui *case folding* menjadi:

“siapa dekan fiksi umsu?”

Kemudian hasil tersebut dipisahkan menjadi:

[“siapa”, “dekan”, “fiksi”, “umsu”]

Proses *tokenizing* menghasilkan beberapa token dari setiap pertanyaan. Setiap token tersebut kemudian digunakan pada tahap pembentukan representasi kata menggunakan Word2Vec.

Tabel 4.2 Hasil Case Folding dan Tokenizing

No.	Pertanyaan Pengguna	Case Folding	Hasil Tokenizing
1.	Siapa Dekan FIKTI?	siapa dekan fiksi?	`siapa`, `dekan`, `fiksi`
2.	Siapa Dekan FIKTI sekarang?	siapa dekan fiksi sekarang?	`siapa`, `dekan`, `fiksi`, `sekarang`
3.	Apa saja Program Studi FIKTI?	apa saja program studi fiksi?	`apa`, `saja`, `program`, `studi`, `fiksi`

4.2.3 Pembentukan Representasi Word2Vec

Word2Vec digunakan untuk membentuk representasi vektor kata yang selanjutnya disusun menjadi embedding matrix. Embedding matrix tersebut digunakan sebagai bobot awal pada Embedding Layer model CNN. Dengan demikian, Word2Vec berfungsi menyediakan representasi awal kata berdasarkan hasil pembelajaran pada data teks, sedangkan proses pembentukan input model dilakukan melalui word indexing dan padding sebelum data masuk ke Embedding Layer.

Tabel 4.3 Representasi Kata Menggunakan Word2Vec

Kata	Dimensi Vector	Representasi Vektor
siapa	100	[-0.06479381, 0.22993141, -0.18413816, ..., 0.02616134]
kaprodi	100	[-7.36599118e-02, 1.39800906e-01, -1.67710632e-01, ..., -4.90554534e-02]
di	100	[-1.48884624e-01, 2.73775488e-01, -1.30448908e-01, ..., -8.92671719e-02]
fikti	100	[-2.42849320e-01, 3.92991990e-01, -1.27479851e-01, ..., -1.64035678e-01]

Berdasarkan Tabel 4.3, setiap token hasil tokenizing direpresentasikan dalam bentuk vektor numerik menggunakan model Word2Vec. Model menghasilkan vektor dengan 100 dimensi untuk setiap kata. Sebagai contoh, token *siapa*, *kaprodi*, *di*, dan *fikti* masing-masing memiliki nilai vektor yang berbeda. Representasi tersebut digunakan untuk mengubah kata dalam bentuk teks menjadi representasi numerik yang dapat digunakan pada tahap pemrosesan selanjutnya.

4.2.4 Word Indexing

Setelah representasi kata terbentuk, data perlu diubah menjadi bentuk indeks numerik berdasarkan vocabulary yang digunakan.

Pada tahap ini, setiap kata memiliki indeks tertentu. Indeks tersebut digunakan untuk merepresentasikan token dalam bentuk angka sehingga dapat diproses lebih lanjut.

Tabel 4.4 Hasil Word Indexing

Token	Indeks
Siapa	1
Kaprodi	7
Di	17
fikti	2

Setelah setiap kata direpresentasikan dalam bentuk numerik, proses selanjutnya adalah melakukan *word indexing*. Pada tahap ini, setiap token dipetakan ke dalam nilai indeks berdasarkan *word index* yang telah tersedia pada sistem. Berdasarkan hasil proses pada data pengujian, token *siapa*, *kaprodi*, *di*, dan *fikti* masing-masing memperoleh indeks 1, 7, 17, dan 2. Hasil pemetaan tersebut membentuk *sequence* [1, 7, 17, 2] yang selanjutnya digunakan pada proses *padding*.

4.2.5 Padding

Setelah word indexing, setiap pertanyaan masih dapat memiliki jumlah token yang berbeda. Contohnya, satu pertanyaan dapat memiliki empat token, sedangkan pertanyaan lainnya dapat memiliki enam token. Kondisi tersebut membuat panjang setiap urutan indeks berbeda.

Oleh karena itu dilakukan padding. Padding digunakan untuk menambahkan nilai tertentu pada urutan yang lebih pendek sehingga seluruh data memiliki panjang yang sama.

Sebagai contoh:

[12, 8, 24]

dapat diseragamkan menjadi:

[12, 8, 24, 0, 0]

Sedangkan data yang telah memiliki panjang lima elemen tidak memerlukan tambahan nilai:

[5, 17, 43, 29, 24]

Tabel 4.5 Hasil Padding

Sebelum Padding	Panjang Maksimum	Setelah Padding
[1, 7, 17, 2]	10	[1, 7, 17, 2, 0, 0, 0, 0, 0, 0]

Setelah proses *word indexing*, setiap *sequence* diseragamkan panjangnya melalui proses *padding*. Berdasarkan implementasi sistem, panjang maksimum *sequence* ditetapkan sebanyak 10 dan metode yang digunakan adalah *post-padding*, yaitu penambahan nilai nol dilakukan pada bagian akhir *sequence* sampai mencapai panjang yang telah ditentukan. Pada data pengujian, *sequence* [1, 7, 17, 2] memiliki empat elemen sehingga ditambahkan enam nilai nol dan menghasilkan [1, 7, 17, 2, 0, 0, 0, 0, 0, 0]. Hasil *padding* tersebut kemudian digunakan sebagai masukan untuk proses klasifikasi menggunakan CNN.

4.2.6 Hasil Akhir Preprocessing

Setelah seluruh tahapan dilakukan, pertanyaan pengguna yang awalnya berupa teks telah melalui beberapa proses sehingga menjadi data numerik dengan panjang yang seragam. Secara keseluruhan, proses pengolahan data dapat dirangkum sebagai berikut:

Urutannya adalah:

Case Folding → Tokenizing → Word Indexing → Padding → Embedding

Layer dengan bobot awal Word2Vec → CNN

Hasil dari proses padding kemudian digunakan sebagai input pada Embedding Layer yang telah menggunakan embedding matrix Word2Vec sebagai bobot awal. Keluaran dari Embedding Layer selanjutnya digunakan sebagai masukan pada model CNN. Dengan demikian, preprocessing menjadi tahap yang menghubungkan data pertanyaan pengguna dengan proses klasifikasi menggunakan CNN.

Setelah proses *case folding* dan *tokenizing* dilakukan, hasil tokenisasi digunakan sebagai data masukan pada tahap pembentukan representasi kata menggunakan Word2Vec. Word2Vec digunakan untuk mengubah kata dalam bentuk teks menjadi representasi numerik berupa vektor yang dapat diproses oleh model CNN.

Tabel 4.6 Hasil Akhir Preprocessing

Pertanyaan Pengguna	Hasil Tokenizing	Hasil Word Indexing	Hasil padding
siapa kaprodi di fiksi	['siapa', 'kaprodi', 'di', 'fiksi']	[1, 7, 17, 2]	[1, 7, 17, 2, 0, 0, 0, 0, 0, 0]

4.3 Pembentukan dan Pelatihan Model CNN

Setelah data melalui tahap preprocessing dan diperoleh data dalam bentuk numerik dengan panjang yang seragam, tahap berikutnya adalah pembentukan dan pelatihan model *Convolutional Neural Network* (CNN). Model CNN digunakan untuk melakukan klasifikasi terhadap pertanyaan pengguna berdasarkan *intent* yang telah ditentukan.

Pada tahap ini, data hasil preprocessing digunakan sebagai masukan model. Proses pelatihan dilakukan menggunakan data yang telah disiapkan sehingga model dapat mempelajari pola dari setiap *intent*. Setelah proses pelatihan selesai, model yang diperoleh digunakan pada tahap klasifikasi pertanyaan pengguna.

4.3.1 Pembagian Data

Sebelum model CNN dilatih, dataset yang telah dipersiapkan dibagi menjadi bagian yang digunakan untuk proses pelatihan dan bagian yang digunakan untuk melakukan pengujian atau evaluasi model.

Data pelatihan digunakan oleh model untuk mempelajari pola hubungan antara pertanyaan dengan *intent*. Sementara itu, data pengujian digunakan untuk mengetahui kemampuan model dalam melakukan klasifikasi terhadap data yang tidak digunakan pada proses pelatihan.

Tabel 4.7 Pembagian Data Training dan Testing

Data	Jumlah Data	Persentase
Data Training	495	79,97%
Data Testing	124	20,03%
Total	619	100%

Data yang telah melalui tahap preprocessing selanjutnya dibagi menjadi data training dan data testing. Dari total 619 data, sebanyak 495 data digunakan sebagai data training dengan persentase 79,97%, sedangkan 124 data digunakan sebagai data testing dengan persentase 20,03%. Pembagian tersebut digunakan untuk proses pelatihan dan pengujian model CNN.

4.3.2 Pembentukan Label Intent

Setelah data dibagi, setiap pertanyaan memiliki label *intent* yang menunjukkan kategori dari pertanyaan tersebut. Label tersebut digunakan sebagai target yang harus dipelajari oleh model CNN.

Pada proses pelatihan, model mempelajari hubungan antara data pertanyaan yang telah melalui preprocessing dengan label *intent*. Dengan demikian, ketika terdapat pertanyaan baru, model dapat menentukan *intent* yang paling sesuai berdasarkan pola yang telah dipelajari selama proses training.

Tabel 4.8 Daftar Intent pada Dataset

No.	Intent	Keterangan	Jumlah Data
1.	dekan	Pertanyaan yang berkaitan dengan dekan atau pimpinan fakultas.	102
2.	fakultas	Pertanyaan mengenai informasi umum tentang fakultas.	106
3.	kaprodi	Pertanyaan yang berkaitan dengan ketua program studi.	102
4.	ukt	Pertanyaan yang berkaitan dengan Uang Kuliah Tunggal (UKT)	104
5.	sapaan	Pertanyaan atau masukan berupa sapaan kepada chatbot.	103
6.	dosen	Pertanyaan yang berkaitan dengan Dosen	102
Total			619

Berdasarkan Tabel 4.8, dataset penelitian terdiri dari 619 pertanyaan yang terbagi ke dalam enam intent. Jumlah data pada setiap intent relatif seimbang, dengan jumlah terbanyak terdapat pada intent fakultas sebanyak 106 data, sedangkan intent dekan, dosen, dan kaprodi masing-masing terdiri dari 102 data. Distribusi tersebut digunakan sebagai dataset untuk proses pelatihan dan pengujian model CNN.

4.3.3 Arsitektur Model CNN

Model CNN dibangun untuk melakukan klasifikasi terhadap data pertanyaan yang telah diproses. Data hasil preprocessing digunakan sebagai masukan model, kemudian diproses melalui beberapa lapisan sampai menghasilkan prediksi *intent*.

Arsitektur model CNN yang digunakan dalam penelitian ini terdiri dari beberapa lapisan yang saling berhubungan. Setiap lapisan memiliki fungsi dalam mengolah data sebelum menghasilkan keluaran berupa klasifikasi *intent*.

Tabel 4.9 Arsitektur Model CNN

No.	Layer	Konfigurasi	Output Shape	Jumlah Parameter
1.	Embedding	Input dimension: 233 Output dimension: 100 Trainable: True	(None, 10, 100)	23,300
2.	Conv1D	Filters: 64 Kernel size: 3 Activation: ReLU Padding: Valid	(None, 8, 64)	19,264
3.	GlobalMaxPooling1D	Global Max Pooling	(None, 64)	0
4.	Dense	Units: 64 Activation: ReLU	(None, 64)	4,160
5.	Dense Output	Units: 6 Activation: Softmax	(None, 6)	390

Data hasil preprocessing kemudian dikonversi menjadi representasi vektor menggunakan metode Word2Vec. Vektor kata yang dihasilkan selanjutnya disusun menjadi embedding matrix berdasarkan word index. Embedding matrix tersebut digunakan sebagai bobot awal pada Embedding Layer dalam model CNN. Embedding Layer yang telah menggunakan bobot awal dari Word2Vec kemudian diproses melalui convolution layer, pooling layer, fully connected layer, dan softmax layer untuk menghasilkan klasifikasi intent pertanyaan pengguna.

4.3.4 Proses Pelatihan Model

Setelah arsitektur model CNN dibentuk, tahap selanjutnya adalah proses pelatihan. Pada tahap ini, data training digunakan sebagai masukan model dan label *intent* digunakan sebagai target.

Selama proses pelatihan, model melakukan penyesuaian terhadap parameter internal berdasarkan kesalahan prediksi yang diperoleh. Proses tersebut dilakukan secara berulang sesuai dengan jumlah *epoch* yang ditentukan.

Pada setiap proses pelatihan, nilai *loss* dan *accuracy* digunakan untuk melihat perkembangan kemampuan model dalam mempelajari data.


Tabel 4.10 Parameter Pelatihan Model CNN

Parameter Pelatihan	Nilai
Optimizer	Adam
Learning Rate	0,001
Loss Function	Sparse Categorical Crossentropy
Metrics	Accuracy
Batch Size	32
Epoch	20

4.3.5 Hasil Pelatihan Model

Setelah proses training dilakukan, hasil pelatihan digunakan untuk melihat perkembangan kemampuan model selama proses pembelajaran.

Nilai *accuracy* menunjukkan tingkat ketepatan model dalam melakukan klasifikasi, sedangkan *loss* menunjukkan tingkat kesalahan model selama proses pelatihan. Perubahan kedua nilai tersebut dapat digunakan untuk melihat perkembangan model dari awal hingga akhir proses training.



Gambar 4.4 Grafik Accuracy dan Loss Selama Proses Pelatihan Model CNN

Berdasarkan Gambar 4.4, hasil pelatihan menunjukkan perubahan nilai *accuracy* dan *loss* selama proses training. Grafik tersebut digunakan untuk melihat perkembangan model dalam mempelajari data training dan mengevaluasi hasil pembelajaran model.

4.3.6 Hasil Model CNN

Setelah proses pelatihan selesai, model CNN yang telah dilatih digunakan sebagai model klasifikasi pada Nova AI. Model tersebut menerima data pertanyaan yang telah melalui tahapan preprocessing dan mengolahnya untuk menentukan *intent* dari pertanyaan pengguna.

Hasil klasifikasi dari model kemudian digunakan pada tahap berikutnya untuk menentukan respons yang sesuai. Dengan demikian, model CNN menjadi bagian yang menghubungkan data hasil preprocessing dengan proses penentuan *intent* pada chatbot.

Hasil evaluasi model CNN berdasarkan nilai precision, recall, F1-score, dan support untuk setiap kategori intent. Evaluasi dilakukan untuk mengetahui kemampuan model dalam mengklasifikasikan data pengujian ke dalam masing-masing kategori intent.

Tabel 4.11 Hasil Evaluasi Model CNN

Kelas	Precision	Recall	F1-Score	Support
Dekan	0.95	1.0	0.98	20
Dosen	1.0	1.0	1.0	20
Fakultas	1.0	1.0	1.0	21
Kaprodi	1.0	0.95	0.98	21
Sapaan	1.0	1.0	1.0	21
UKT	1.0	1.0	1.0	21
Accuracy			0.99	124
Macro Avg	0.99	0.99	0.99	124
Weighted Avg	0.99	0.99	0.99	124

Hasil evaluasi menunjukkan kemampuan model CNN dalam mengklasifikasikan setiap kategori intent berdasarkan nilai precision, recall, dan F1-score. Nilai support menunjukkan jumlah data pengujian pada masing-masing kategori.

Berdasarkan Tabel 4.11, model CNN memperoleh accuracy sebesar 0,99 pada data pengujian. Nilai tersebut menunjukkan bahwa sebagian besar data pengujian berhasil diklasifikasikan sesuai dengan intent sebenarnya. Pada masing-masing kategori, sebagian besar nilai precision, recall, dan F1-score berada pada angka

1,00. Namun, kategori dekan memiliki precision sebesar 0,95, sedangkan kategori kaprodi memiliki recall sebesar 0,95. Perbedaan tersebut menunjukkan adanya satu kesalahan klasifikasi pada data pengujian, yaitu satu data dengan intent aktual kaprodi yang diprediksi sebagai dekan. Meskipun terdapat satu kesalahan klasifikasi, hasil evaluasi menunjukkan bahwa model CNN memiliki kemampuan yang tinggi dalam mengenali intent pada data pengujian. Selain menggunakan precision, recall, dan F1-score, evaluasi model juga dilakukan menggunakan confusion matrix untuk melihat kesesuaian antara kelas aktual dan kelas hasil prediksi model.

Tabel 4.12 Confusion Matrix Model CNN

Aktual/ Prediksi	Dekan	Dosen	Fakultas	Kaprodi	Sapaan	UKT
Dekan	20	0	0	0	0	0
Dosen	0	20	0	0	0	0
Fakultas	0	0	21	0	0	0
Kaprodi	1	0	0	20	0	0
Sapaan	0	0	0	0	21	0
UKT	0	0	0	0	0	21

Berdasarkan Tabel 4.12, sebagian besar data pengujian berada pada diagonal utama yang menunjukkan bahwa model mampu mengklasifikasikan data sesuai dengan kelas sebenarnya. Namun, terdapat satu data dengan kelas aktual kaprodi yang diprediksi sebagai dekan. Dengan demikian, dari total 124 data pengujian, sebanyak 123 data berhasil diklasifikasikan dengan benar dan satu data mengalami kesalahan klasifikasi. Hasil tersebut menghasilkan accuracy sebesar 0,99, yang

menunjukkan bahwa model CNN memiliki kemampuan klasifikasi yang tinggi pada data pengujian.

4.4 Hasil Klasifikasi Intent

Setelah model CNN selesai dilatih, model digunakan untuk melakukan klasifikasi terhadap pertanyaan yang diberikan oleh pengguna. Pertanyaan yang telah melalui tahapan preprocessing kemudian digunakan sebagai masukan model untuk menentukan *intent* yang sesuai.

Intent merupakan kategori yang digunakan untuk menunjukkan maksud dari pertanyaan pengguna. Hasil klasifikasi ini menjadi dasar bagi sistem untuk menentukan informasi yang akan diberikan kepada pengguna melalui *knowledge base*.

4.4.1 Proses Klasifikasi Intent

Pada tahap klasifikasi, pertanyaan pengguna yang telah melalui proses preprocessing diberikan kepada model CNN. Model kemudian menghasilkan prediksi *intent* berdasarkan pola yang telah dipelajari selama proses training.

Secara umum, proses klasifikasi pada Nova AI berlangsung dari data pertanyaan yang telah diproses, kemudian masuk ke model CNN, dan menghasilkan satu *intent* sebagai hasil prediksi.

4.4.2 Hasil Klasifikasi Pertanyaan

Hasil klasifikasi dapat dilihat dari *intent* yang dihasilkan oleh model terhadap pertanyaan pengguna. Pada tahap ini, beberapa pertanyaan digunakan untuk melihat apakah model dapat memberikan kategori *intent* yang sesuai.

Tabel 4.13 Hasil Klasifikasi Intent

No.	Pertanyaan Pengguna	Intent Aktual	Hasil Prediksi CNN	Keterangan
1.	Assalamu'alaikum nova	sapaan	sapaan	Sesuai
2.	Kaprodi FIKTI siapa	kaprodi	dekan	Tidak sesuai
3.	Siapa Pemimpin FIKTI	dekan	dekan	Sesuai
4.	Jadwal bayar uang kuliah	ukt	ukt	Sesuai
5.	Berapa Prodi yang ada di FIKTI	fakultas	fakultas	Sesuai

Hasil pengujian menunjukkan bahwa model CNN dapat mengklasifikasikan sebagian besar pertanyaan sesuai dengan intent aktualnya. Hal tersebut ditunjukkan oleh beberapa data pengujian yang memiliki hasil prediksi sama dengan intent aktual. Namun, terdapat pula data pengujian yang menghasilkan prediksi berbeda dari intent aktual. Perbedaan tersebut menunjukkan bahwa model masih memiliki kesalahan dalam mengenali beberapa pertanyaan dengan pola kata yang memiliki kemiripan antarintent.

Hasil klasifikasi pada Tabel 4.13 merupakan contoh pengujian terhadap pertanyaan pengguna, sedangkan performa model secara keseluruhan dievaluasi menggunakan classification report dan confusion matrix pada tahap evaluasi model CNN. Dengan demikian, hasil pada tabel digunakan untuk menunjukkan contoh penerapan klasifikasi intent secara langsung pada pertanyaan pengguna.

4.4.3 Kesesuaian Hasil Prediksi

Untuk mengetahui kesesuaian hasil klasifikasi, hasil prediksi CNN dibandingkan dengan *intent* yang seharusnya dimiliki oleh pertanyaan tersebut.

Prediksi yang sama dengan *intent* aktual menunjukkan bahwa model berhasil mengklasifikasikan pertanyaan dengan benar.

Sebaliknya, apabila hasil prediksi berbeda dengan *intent* aktual, maka pertanyaan tersebut dikategorikan sebagai hasil klasifikasi yang tidak sesuai.

Tabel 4.14 Kesesuaian Hasil Prediksi Intent

No.	Intent Aktual	Prediksi CNN	Keterangan
1.	Sapaan	Sapaan	Sesuai
2.	Kaprodi	Dekan	Tidak Sesuai
3.	Dekan	Dekan	Sesuai
4.	Ukt	Ukt	Sesuai
5.	Fakultas	Fakultas	Sesuai

Berdasarkan Tabel 4.14, kesesuaian hasil prediksi ditentukan dengan membandingkan intent aktual dengan intent yang dihasilkan oleh model CNN. Hasil prediksi dikategorikan “Sesuai” apabila intent aktual dan hasil prediksi CNN memiliki kategori yang sama, sedangkan kategori “Tidak Sesuai” diberikan apabila keduanya berbeda. Berdasarkan hasil pengujian, terdapat prediksi yang sesuai dengan intent aktual dan terdapat pula prediksi yang tidak sesuai. Perbedaan hasil prediksi menunjukkan adanya beberapa pertanyaan yang belum dapat diklasifikasikan secara tepat oleh model CNN.

4.4.4 Hasil Klasifikasi sebagai Dasar Pemberian Respons

Hasil klasifikasi *intent* tidak berhenti pada proses prediksi. *Intent* yang diperoleh dari model CNN digunakan sebagai acuan untuk menentukan informasi yang sesuai pada *knowledge base*.

Dengan demikian, hasil klasifikasi menjadi penghubung antara model CNN dengan proses pemberian respons. Setelah *intent* diperoleh, sistem mencari

informasi yang sesuai berdasarkan kategori tersebut dan kemudian menampilkan respons kepada pengguna.

4.5 Hasil Integrasi Knowledge Base dan Respons

Setelah proses klasifikasi menghasilkan *intent*, hasil tersebut digunakan oleh sistem untuk menentukan informasi yang sesuai dari *knowledge base*. *Knowledge base* berisi informasi yang telah disiapkan untuk mendukung pemberian respons berdasarkan kategori pertanyaan pengguna.

Integrasi antara hasil klasifikasi dan *knowledge base* memungkinkan Nova AI memberikan respons yang disesuaikan dengan maksud pertanyaan. Dengan demikian, model CNN berfungsi menentukan *intent*, sedangkan *knowledge base* digunakan sebagai sumber informasi untuk menghasilkan respons yang akan ditampilkan kepada pengguna.

4.5.1 Integrasi Intent dengan Knowledge Base

Pada tahap ini, *intent* yang dihasilkan oleh model CNN digunakan sebagai acuan untuk menentukan bagian informasi yang sesuai pada *knowledge base*. Setiap *intent* memiliki informasi atau respons yang berkaitan dengan kategori pertanyaan tertentu.

Proses tersebut membuat hasil klasifikasi dari model dapat diteruskan ke bagian penyediaan informasi. Dengan adanya hubungan antara *intent* dan *knowledge base*, sistem dapat menentukan respons berdasarkan kategori pertanyaan yang telah diperoleh dari proses klasifikasi.

Tabel 4.15 Integrasi Intent dengan Knowledge Base

No.	Intent	Informasi pada Knowledge Base	Respons
1.	dekan	Informasi Dekan	Menyediakan informasi mengenai Dekan FIKTI UMSU.
2.	dosen	Informasi Dosen	Menyediakan informasi mengenai dosen FIKTI UMSU dan mengarahkan pengguna ke daftar dosen pada website resmi FIKTI UMSU.
3.	fakultas	Informasi Fakultas	Menyediakan informasi mengenai Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU serta akses menuju informasi program studi dan website FIKTI.
4.	kaprodi	Informasi Ketua Program Studi (Kaprodi)	Menyediakan informasi mengenai Ketua Program Studi (Kaprodi) serta akses informasi Kaprodi untuk program studi yang tersedia.
5.	sapaan	Halo	Menyediakan beberapa respons sapaan untuk menyambut pengguna dan menawarkan bantuan sebagai asisten virtual FIKTI UMSU.
6.	ukt	Informasi Biaya Kuliah	Menyediakan informasi mengenai biaya kuliah serta pilihan informasi terkait cara pembayaran UKT, jadwal pembayaran UKT, dan website biaya kuliah.

Berdasarkan Tabel 4.15, setiap intent hasil klasifikasi CNN telah diintegrasikan dengan knowledge base yang sesuai. Knowledge base digunakan sebagai sumber informasi yang akan diberikan kepada pengguna berdasarkan intent yang teridentifikasi. Pada intent *dekan*, sistem menyediakan informasi mengenai Dekan FIKTI UMSU. Pada intent *dosen*, sistem menyediakan informasi mengenai dosen serta akses menuju daftar dosen pada website resmi FIKTI UMSU.

Selanjutnya, intent *fakultas* menyediakan informasi mengenai FIKTI UMSU beserta akses menuju informasi program studi dan website fakultas. Pada intent *kaprodi*, knowledge base menyediakan informasi mengenai Ketua Program Studi

(Kaprodi) serta akses menuju informasi Kaprodi pada program studi yang tersedia. Sementara itu, intent *sapaan* digunakan untuk memberikan respons awal ketika pengguna memberikan sapaan kepada sistem. Pada intent *ukt*, knowledge base menyediakan informasi mengenai biaya kuliah serta pilihan informasi terkait cara pembayaran UKT, jadwal pembayaran UKT, dan website biaya kuliah.

Integrasi tersebut menunjukkan bahwa hasil klasifikasi intent tidak berhenti pada proses pengenalan kategori pertanyaan, tetapi digunakan sebagai dasar untuk menentukan informasi yang relevan dari knowledge base. Dengan demikian, hasil prediksi CNN menjadi penghubung antara pertanyaan pengguna dan informasi yang diberikan oleh sistem.

4.5.2 Pengambilan Informasi Berdasarkan Intent

Setelah *intent* diperoleh, sistem menggunakan hasil tersebut untuk menentukan informasi yang sesuai dari *knowledge base*. Informasi yang dipilih kemudian digunakan sebagai dasar dalam menyusun respons kepada pengguna.

Sebagai bagian dari proses ini, sistem tidak memberikan respons secara acak, tetapi menggunakan kategori pertanyaan yang telah ditentukan oleh model CNN. Dengan demikian, respons yang diberikan disesuaikan dengan *intent* hasil klasifikasi.

Tabel 4.16 Pengambilan Informasi Berdasarkan Intent

No.	Pertanyaan Pengguna	Intent	Informasi yang Dipilih
1.	Siapa Pemimpin FIKTI	dekan	Informasi Dekan
2.	Siapa saja Dosen di FIKTI	dosen	Informasi Dosen
3.	Apa saja Program Studi di FIKTI	fakultas	Informasi Fakultas
4.	Siapa Pemimpin setiap Prodi	kaprodi	Informasi Ketua Program Studi
5.	Bagaimana cara bayar uang kuliah	ukt	Informasi Biaya kuliah

Informasi yang dipilih oleh sistem disesuaikan dengan intent yang dihasilkan dari proses klasifikasi. Setiap pertanyaan pengguna diarahkan kepada informasi pada knowledge base yang sesuai dengan kategori pertanyaannya. Dengan demikian, hasil klasifikasi intent digunakan sebagai acuan dalam menentukan informasi yang akan diberikan kepada pengguna sebelum sistem menghasilkan respons.

4.5.3 Hasil Respons Chatbot


Setelah informasi yang sesuai diperoleh dari *knowledge base*, sistem menampilkan respons kepada pengguna melalui antarmuka Nova AI. Respons yang ditampilkan merupakan hasil akhir dari proses klasifikasi dan pengambilan informasi.

Pada tahap ini, keberhasilan sistem dapat dilihat dari kesesuaian antara pertanyaan pengguna dengan respons yang diberikan oleh chatbot.

Tabel 4.17 Hasil Respons Nova AI

No.	Pertanyaan Pengguna	Intent	Respons Nova AI
1.	Siapa Pemimpin FIKTI	dekan	Memberikan informasi tentang Dekan FIKTI UMSU.
2.	Siapa saja Dosen di FIKTI	dosen	Memberikan informasi tentang Dosen FIKTI dan akses daftar Dosen.
3.	Apa saja Program Studi di FIKTI	fakultas	Memberikan informasi tentang fakultas FIKTI UMSU dan Program Studi yang tersedia.
4.	Siapa Pemimpin setiap Prodi	kaprodi	Memberikan informasi tentang Ketua Program Studi dan pilihan Program Studi.
5.	Bagaimana cara bayar uang kuliah	ukt	Memberikan informasi tentang Biaya Kuliah.

Respons Nova AI diberikan berdasarkan *intent* yang diperoleh dari proses klasifikasi. Respons tersebut diambil dari informasi yang telah disediakan dalam *knowledge base* sehingga jawaban yang diberikan berkaitan dengan pertanyaan pengguna.



Gambar 4.5 Hasil Interaksi Pengguna dengan Nova AI

Gambar 4.5 menunjukkan hasil interaksi pengguna dengan Nova AI. Pengguna memberikan pertanyaan melalui antarmuka chatbot, kemudian sistem melakukan proses klasifikasi intent dan mengambil informasi yang sesuai dari knowledge base. Hasil pengambilan informasi tersebut selanjutnya ditampilkan sebagai respons kepada pengguna.

4.5.4 Alur Pemberian Respons

Proses pemberian respons pada Nova AI merupakan tahap lanjutan setelah klasifikasi *intent*. Hasil prediksi dari model CNN digunakan untuk menentukan kategori pertanyaan, kemudian sistem mencari informasi yang sesuai pada *knowledge base*. Informasi tersebut selanjutnya digunakan untuk memberikan respons kepada pengguna.

Proses pemberian respons dimulai dari pertanyaan pengguna dan dilanjutkan dengan klasifikasi *intent*. Hasil klasifikasi kemudian digunakan untuk menentukan informasi yang sesuai pada *knowledge base*. Setelah informasi ditemukan, sistem memberikan respons melalui antarmuka chatbot.

Dengan integrasi tersebut, Nova AI dapat menghubungkan proses klasifikasi menggunakan CNN dengan penyediaan informasi yang terdapat pada *knowledge base*. Hasil akhirnya berupa respons yang diberikan kepada pengguna berdasarkan kategori pertanyaan yang telah ditentukan.

4.6 Pengujian Sistem

Pengujian sistem dilakukan untuk mengetahui kemampuan Nova AI dalam menerima pertanyaan pengguna, melakukan klasifikasi *intent*, dan memberikan respons yang sesuai. Pengujian dilakukan dengan memberikan beberapa pertanyaan kepada chatbot, kemudian mengamati hasil klasifikasi dan respons yang diberikan oleh sistem.

Pengujian ini dilakukan untuk melihat apakah proses yang telah dijelaskan pada subbab sebelumnya dapat berjalan dengan baik ketika sistem digunakan secara langsung.

4.6.1 Skenario Pengujian

Pengujian dilakukan dengan memberikan pertanyaan yang berkaitan dengan informasi yang tersedia pada *knowledge base*. Setiap pertanyaan digunakan untuk melihat hasil klasifikasi *intent* dan respons yang diberikan oleh Nova AI.

Skenario pengujian disusun berdasarkan beberapa kategori *intent* yang terdapat pada sistem.

Tabel 4.18 Skenario Pengujian Nova AI

No.	Skenario Pengujian	Input Pengguna	Hasil yang Diharapkan
1.	Pertanyaan Informasi Dekan	Siapa Dekan FIKTI sekarang?	Sistem mengklasifikasikan pertanyaan ke intent dekan dan memberikan informasi mengenai Dekan FIKTI UMSU.
2.	Pertanyaan Informasi Kaprodi	Siapa Ketua Program Studi?	Sistem mengklasifikasikan pertanyaan ke intent kaprodi dan memberikan informasi mengenai kaprodi.
3.	Pertanyaan Informasi Fakultas	Apa saja Program Studi di FIKTI?	Sistem mengklasifikasikan pertanyaan ke intent fakultas dan memberikan informasi mengenai fakultas serta pilihan program studi yang ada.

Setiap skenario pengujian menggunakan pertanyaan yang diberikan melalui antarmuka Nova AI. Hasil yang diharapkan digunakan sebagai pembanding terhadap hasil yang diberikan oleh sistem.

4.6.2 Hasil Pengujian Klasifikasi

Setelah skenario pengujian ditentukan, pertanyaan diberikan kepada Nova AI untuk mengetahui intent yang dihasilkan oleh model CNN. Pengujian dilakukan menggunakan 30 pertanyaan dengan berbagai variasi susunan kata, penambahan kata, penggunaan istilah yang berbeda, dan bentuk pertanyaan. Variasi tersebut digunakan untuk mengetahui kemampuan model dalam mengenali pertanyaan yang memiliki intent yang sama meskipun disampaikan dengan bentuk bahasa yang berbeda.

Hasil klasifikasi kemudian dibandingkan dengan *intent* yang seharusnya sesuai dengan pertanyaan. Perbandingan tersebut digunakan untuk mengetahui apakah model dapat menentukan kategori pertanyaan dengan benar.

Tabel 4.19 Hasil Pengujian Klasifikasi Intent

No.	Pertanyaan Pengguna	Intent yang Diharapkan	Intent Hasil Prediksi	Confidence	Hasil
1	Siapa Dekan FIKTI?	dekan	dekan	99,94%	Sesuai
2	Siapa Dekan FIKTI UMSU?	dekan	dekan	88,46%	Sesuai
3	Siapa saja dosen FIKTI?	dosen	dosen	98,55%	Sesuai
4	Bagaimana melihat daftar dosen FIKTI?	dosen	dosen	99,96%	Sesuai
5	Apa saja program studi di FIKTI?	fakultas	fakultas	99,86%	Sesuai
6	FIKTI memiliki program studi apa saja?	fakultas	fakultas	99,56%	Sesuai
7	Siapa Ketua Program Studi?	kaprodi	kaprodi	99,90%	Sesuai
8	Siapa Kaprodi di FIKTI?	kaprodi	kaprodi	94,70%	Sesuai
9	Halo Nova	sapaan	sapaan	99,99%	Sesuai
10	Hai, Nova	sapaan	sapaan	99,99%	Sesuai
11	Bagaimana cara membayar UKT?	ukt	ukt	99,86%	Sesuai
12	Informasi biaya kuliah FIKTI apa?	ukt	unknown	37,70%	Tidak Sesuai
13	Dekan FIKTI siapa?	dekan	dekan	99,45%	Sesuai
14	FIKTI siapa Dekannya?	dekan	dekan	85,17%	Sesuai
15	Program studi FIKTI apa saja?	fakultas	fakultas	99,98%	Sesuai
16	FIKTI punya prodi apa?	fakultas	fakultas	98,73%	Sesuai
17	Kaprodi FIKTI siapa?	kaprodi	kaprodi	91,94%	Sesuai
18	UKT FIKTI bagaimana cara bayarnya?	ukt	unknown	40,04%	Tidak Sesuai
19	Siapa Dekan FIKTI sekarang?	dekan	dekan	99,90%	Sesuai
20	Siapa Dekan FIKTI saat ini?	dekan	dekan	99,79%	Sesuai
21	Siapa Ketua Program Studi di FIKTI UMSU?	kaprodi	fakultas	99,65%	Tidak Sesuai
22	Bagaimana cara membayar UKT FIKTI?	ukt	ukt	99,02%	Sesuai
23	dosen basis data siapa?	dosen	dosen	99,91%	Sesuai
24	kontak dosen	dosen	dosen	99,86%	Sesuai
25	daftar nama dosen	dosen	dosen	99,97%	Sesuai
26	Apa saja Jurusan di FIKTI?	fakultas	fakultas	99,75%	Sesuai

27	Siapa pemimpin FIKTI?	dekan	dekan	96,66%	Sesuai
28	Siapa pimpinan program studi di FIKTI?	kaprodi	fakultas	79,11%	Tidak Sesuai
29	Informasi dosen yang memimpin program studi	kaprodi	dosen	99,68%	Tidak Sesuai
30	siapa pimpinan tertinggi fakultas?	dekan	dekan	99,50%	Sesuai

Berdasarkan hasil pengujian pada Tabel 4.19, dari 30 pertanyaan yang diuji, terdapat 25 pertanyaan yang berhasil diklasifikasikan sesuai dengan intent yang diharapkan, sedangkan 5 pertanyaan menghasilkan prediksi yang tidak sesuai. Dengan demikian, tingkat keberhasilan klasifikasi sistem adalah sebesar 83,33%.

Hasil tersebut menunjukkan bahwa model CNN mampu mengenali sebagian besar pertanyaan yang diberikan dengan berbagai variasi susunan kata dan bentuk pertanyaan. Namun, masih terdapat beberapa pertanyaan yang menghasilkan prediksi tidak sesuai atau unknown. Hal tersebut menunjukkan bahwa model masih memiliki keterbatasan dalam mengenali beberapa bentuk pertanyaan tertentu.

Pada sistem ini, label “unknown” tidak termasuk ke dalam enam intent yang dipelajari oleh model CNN. Label tersebut ditentukan setelah proses prediksi berdasarkan nilai confidence yang dihasilkan model. Sistem menggunakan confidence threshold sebesar 0,70. Apabila nilai confidence kurang dari 0,70, maka hasil prediksi diubah menjadi “unknown”, sedangkan apabila nilai confidence lebih besar atau sama dengan 0,70, hasil prediksi CNN tetap digunakan sebagai intent.

Hasil pengujian digunakan untuk melihat kesesuaian antara *intent* yang diharapkan dengan *intent* hasil prediksi model CNN. Hasil tersebut menjadi salah satu dasar dalam menilai kemampuan model dalam melakukan klasifikasi pertanyaan pengguna.

4.6.3 Hasil Pengujian Respons

Selain melihat hasil klasifikasi, pengujian juga dilakukan terhadap respons yang diberikan oleh Nova AI. Pengujian ini bertujuan untuk mengetahui apakah respons yang ditampilkan sesuai dengan pertanyaan pengguna dan informasi yang terdapat pada *knowledge base*.

Tabel 4.20 Hasil Pengujian Respons Nova AI

No.	Pertanyaan Pengguna	Intent	Kesesuaian Respons	Keterangan
1.	Siapa Dekan FIKTI?	dekan	Sesuai	Respons menjawab pertanyaan dan sesuai knowledge base.
2.	Apa saja program studi di FIKTI?	fakultas	Sesuai	Respons memberikan informasi program studi yang relevan.
3.	Siapa Ketua Program Studi di FIKTI?	unknown	Tidak sesuai	Respons tidak memberikan informasi Kaprodi yang sesuai.

Berdasarkan Tabel 4.20, hasil pengujian menunjukkan bahwa respons Nova AI pada sebagian pertanyaan telah sesuai dengan pertanyaan pengguna dan informasi yang terdapat pada *knowledge base*. Pada pertanyaan mengenai Dekan dan program studi di FIKTI, respons yang diberikan dinilai sesuai karena informasi yang ditampilkan berkaitan dengan pertanyaan yang diberikan. Sementara itu, pada pertanyaan mengenai Ketua Program Studi, sistem menghasilkan intent unknown, sehingga respons yang diberikan belum sesuai dengan informasi yang diharapkan.

Hasil tersebut menunjukkan bahwa kesesuaian respons Nova AI dipengaruhi oleh hasil klasifikasi intent. Ketika intent berhasil dikenali dengan tepat, sistem dapat menentukan informasi yang sesuai dari *knowledge base*. Sebaliknya, ketika

pertanyaan menghasilkan intent unknown, sistem belum dapat memberikan informasi yang sesuai dengan pertanyaan pengguna.

4.6.4 Pengujian Pertanyaan di Luar Knowledge Base

Selain pertanyaan yang sesuai dengan *knowledge base*, pengujian juga dilakukan menggunakan pertanyaan yang tidak berkaitan dengan informasi yang tersedia pada sistem.

Pengujian ini dilakukan untuk mengetahui bagaimana Nova AI memberikan respons ketika menerima pertanyaan yang tidak termasuk dalam informasi yang telah disediakan.

Tabel 4.21 Pengujian Pertanyaan di Luar Knowledge Base

No.	Pertanyaan Pengguna	Intent Hasil Prediksi	Respons Nova AI	Keterangan
1.	Siapa Rektor Umsu saat ini?	unknown	Maaf nova belum memahami pertanyaan tersebut.	Di luar Knowledge Base
2.	Siapa Presiden Republik Indonesia	unknown	Maaf nova belum memahami pertanyaan tersebut.	Di luar Knowledge Base
3.	Kenapa Bumi bulat?	unknown	Maaf nova belum memahami pertanyaan tersebut.	Di luar Knowledge Base

Pengujian terhadap pertanyaan di luar *knowledge base* digunakan untuk melihat kemampuan sistem dalam menangani pertanyaan yang tidak termasuk dalam informasi yang telah disediakan. Hasil pengujian tersebut dapat menunjukkan bagaimana sistem memberikan respons ketika pertanyaan yang diterima tidak sesuai dengan informasi yang tersedia.

4.6.5 Hasil Pengujian Keseluruhan

Setelah seluruh skenario pengujian dilakukan, hasil pengujian dirangkum untuk mengetahui jumlah pengujian yang menghasilkan klasifikasi benar dan klasifikasi yang tidak sesuai.


Tabel 4.22 Rekapitulasi Hasil Pengujian

Keterangan	Jumlah
Jumlah Pengujian	30
Prediksi Benar	25
Prediksi Salah	5
Persentase Keberhasilan	83,33%

Pengujian sistem dilakukan menggunakan 30 pertanyaan yang telah disiapkan untuk menguji kemampuan Nova AI dalam mengenali intent dengan berbagai variasi bentuk pertanyaan. Variasi tersebut digunakan untuk melihat kemampuan sistem dalam menangani perubahan susunan kata dan bentuk penyampaian pertanyaan pengguna.


4.6.6 Dokumentasi Pengujian Sistem

Sebagai dokumentasi, hasil interaksi pengguna dengan Nova AI dapat ditampilkan dalam bentuk tangkapan layar. Dokumentasi ini menunjukkan kondisi aplikasi ketika menerima pertanyaan dan memberikan respons.




Gambar 4.6 Hasil Pengujian Pertanyaan dengan Intent Sesuai

Hasil pengujian Nova AI pada pertanyaan mengenai Dekan FIKTI. Berdasarkan hasil pengujian, sistem berhasil mengenali pertanyaan pengguna dan memberikan respons yang sesuai dengan informasi yang tersedia pada knowledge base.



Gambar 4.7 Hasil Pengujian Pertanyaan dengan Intent Tidak Sesuai

Hasil pengujian Nova AI pada pertanyaan mengenai Dekan FIKTI. Pada pengujian tersebut, sistem belum mampu memahami pertanyaan yang diberikan sehingga tidak memberikan informasi yang diharapkan. Hasil ini menunjukkan bahwa masih terdapat kondisi tertentu ketika sistem belum dapat mengenali intent pertanyaan meskipun informasi yang ditanyakan tersedia pada knowledge base.



Gambar 4.8 Hasil Pengujian Pertanyaan di Luar Knowledge Base

Hasil pengujian Nova AI terhadap pertanyaan yang berada di luar cakupan knowledge base, yaitu pertanyaan mengenai bentuk bumi. Sistem memberikan respons bahwa pertanyaan belum dapat dipahami. Hasil tersebut menunjukkan bahwa sistem tidak memberikan informasi di luar cakupan pengetahuan yang telah ditentukan.

Berdasarkan dokumentasi pengujian tersebut, Nova AI mampu memberikan respons yang sesuai pada pertanyaan tertentu, tetapi masih terdapat kondisi ketika sistem belum dapat mengenali intent pertanyaan dengan tepat. Selain itu, pada pertanyaan yang berada di luar knowledge base, sistem tidak memberikan informasi yang tidak tersedia dalam sumber pengetahuan yang digunakan.

4.7 Pembahasan

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan, Nova AI merupakan chatbot berbasis *Convolutional Neural Network* (CNN) yang digunakan untuk membantu pengguna memperoleh informasi melalui interaksi berbasis teks. Sistem menggabungkan proses pengolahan pertanyaan, klasifikasi *intent*, dan pengambilan informasi dari *knowledge base* dalam satu aplikasi.

Tahapan pengolahan data dimulai dari pertanyaan pengguna yang kemudian melalui proses *preprocessing*. Tahapan tersebut meliputi *case folding* dan *tokenizing*, kemudian dilanjutkan dengan pembentukan representasi menggunakan Word2Vec, *word indexing*, dan *padding*. Hasil akhir dari tahapan tersebut digunakan sebagai masukan bagi model CNN.

4.7.1 Pembahasan Hasil Preprocessing

Berdasarkan hasil implementasi, tahapan preprocessing pada Nova AI telah menghasilkan data pertanyaan dalam bentuk yang sesuai untuk digunakan oleh model CNN. Proses *case folding* dan *tokenizing* membantu menyeragamkan serta memisahkan pertanyaan menjadi token, sedangkan Word2Vec mengubah kata menjadi representasi numerik. Selanjutnya, *word indexing* dan *padding* menghasilkan input dengan bentuk yang seragam sehingga dapat diproses oleh model CNN.

Hasil tersebut menunjukkan bahwa preprocessing menjadi tahap penting sebelum klasifikasi *intent* dilakukan. Pertanyaan pengguna yang awalnya berupa teks harus diubah menjadi representasi numerik agar dapat diproses oleh model. Dengan tahapan tersebut, data masukan menjadi lebih terstruktur dan siap digunakan pada proses klasifikasi *intent*.

4.7.2 Pembahasan Hasil Model CNN

Berdasarkan Tabel 4.11, model CNN memperoleh accuracy sebesar 0,99 pada data pengujian. Nilai tersebut menunjukkan bahwa sebagian besar data pengujian berhasil diklasifikasikan sesuai dengan intent sebenarnya. Pada masing-masing kategori, sebagian besar nilai precision, recall, dan F1-score berada pada angka 1,00. Namun, kategori dekan memiliki precision sebesar 0,95, sedangkan kategori kaprodi memiliki recall sebesar 0,95. Perbedaan tersebut menunjukkan adanya satu kesalahan klasifikasi pada data pengujian, yaitu satu data dengan intent aktual kaprodi yang diprediksi sebagai dekan.

Nilai accuracy sebesar 0,99 tersebut diperoleh dari 123 data yang berhasil diklasifikasikan dengan benar dari total 124 data pengujian, sehingga tingkat ketepatan model secara perhitungan mencapai 99,19%. Hasil tersebut menunjukkan bahwa model CNN mampu mengenali sebagian besar pola pertanyaan pada enam intent yang digunakan dalam penelitian. Hasil evaluasi pada Tabel 4.11 juga menunjukkan bahwa sebagian besar kategori memperoleh nilai precision, recall, dan F1-score sebesar 1,00. Meskipun demikian, nilai accuracy yang tinggi tidak menunjukkan bahwa seluruh pertanyaan dapat diklasifikasikan dengan sempurna karena masih terdapat satu data yang mengalami kesalahan klasifikasi.

Kesalahan klasifikasi tersebut ditunjukkan pada Tabel 4.12, yaitu data dengan intent aktual kaprodi yang diprediksi sebagai dekan. Contoh pertanyaan dengan hasil klasifikasi tersebut dapat dilihat pada Tabel 4.13, yaitu pertanyaan “Kaprodi FIKTI siapa” yang memiliki intent aktual kaprodi tetapi diprediksi sebagai dekan. Pertanyaan tersebut memiliki susunan yang singkat dan hanya memuat beberapa kata utama yang berkaitan dengan kaprodi dan FIKTI. Kondisi tersebut dapat

membuat pola pertanyaan menjadi lebih sulit dibedakan dari pertanyaan yang berkaitan dengan pimpinan atau pihak tertentu di lingkungan FIKTI. Hasil ini menunjukkan bahwa model masih memiliki keterbatasan dalam membedakan intent yang memiliki kemiripan konteks, terutama pada pertanyaan yang singkat dan memiliki informasi pendukung yang terbatas.

Hasil evaluasi tersebut menunjukkan bahwa model CNN yang telah dilatih mampu mengenali pola pertanyaan berdasarkan intent yang tersedia pada dataset pengujian. Model selanjutnya digunakan dalam aplikasi Nova AI untuk melakukan klasifikasi terhadap pertanyaan pengguna secara langsung sebelum sistem menentukan informasi yang sesuai dari knowledge base.

Tingginya hasil klasifikasi model CNN dapat dipengaruhi oleh beberapa faktor. Salah satunya adalah distribusi dataset yang relatif seimbang pada enam intent, dengan jumlah data pada setiap intent berada pada rentang 102 hingga 106 data. Kondisi tersebut memberikan jumlah contoh yang relatif sebanding bagi model dalam mempelajari karakteristik masing-masing intent. Selain itu, penggunaan Word2Vec sebagai representasi kata dan bobot awal pada Embedding Layer memberikan representasi numerik yang digunakan oleh CNN dalam proses ekstraksi fitur. Kombinasi representasi tersebut dengan proses konvolusi memungkinkan model mempelajari pola kata yang berkaitan dengan masing-masing intent pada data training.

4.7.3 Pembahasan Hasil Klasifikasi Intent

Berdasarkan hasil evaluasi pada Tabel 4.11, model CNN mampu melakukan klasifikasi terhadap enam kategori intent, yaitu dekan, dosen, fakultas, kaprodi, sapaan, dan UKT. Evaluasi dilakukan menggunakan metrik precision, recall, dan

F1-score untuk mengetahui kemampuan model dalam mengenali masing-masing kategori intent.

Hasil evaluasi menunjukkan bahwa sebagian besar kategori intent memperoleh nilai precision, recall, dan F1-score sebesar 1,00. Pada kategori dekan, diperoleh precision sebesar 0,95, recall sebesar 1,00, dan F1-score sebesar 0,98. Sementara itu, kategori kaprodi memperoleh precision sebesar 1,00, recall sebesar 0,95, dan F1-score sebesar 0,98. Perbedaan nilai tersebut menunjukkan bahwa masih terdapat sebagian kecil data pada kedua kategori yang belum diklasifikasikan secara sempurna.

Secara keseluruhan, model memperoleh nilai accuracy sebesar 0,99 dengan jumlah data pengujian sebanyak 124 data. Nilai macro average dan weighted average yang juga mencapai 0,99 menunjukkan bahwa kinerja model relatif konsisten pada seluruh kategori intent. Hasil tersebut menunjukkan bahwa model CNN telah mampu mengenali intent pertanyaan pengguna dengan tingkat ketepatan yang tinggi.

Hasil klasifikasi intent tersebut selanjutnya digunakan sebagai dasar dalam menentukan informasi yang perlu diambil dari knowledge base. Dengan demikian, kemampuan model dalam mengenali intent menjadi salah satu faktor yang memengaruhi kesesuaian informasi dan respons yang diberikan oleh Nova AI.

4.7.4 Pembahasan Integrasi Knowledge Base dan Respons

Integrasi knowledge base dengan model klasifikasi CNN menjadi bagian penting dalam proses kerja Nova AI. Hasil klasifikasi intent digunakan oleh sistem sebagai dasar untuk menentukan informasi yang perlu diambil dari knowledge base. Dengan demikian, pertanyaan pengguna tidak hanya diklasifikasikan berdasarkan

kategori intent, tetapi juga diteruskan ke proses pengambilan informasi yang sesuai dengan kategori tersebut.

Berdasarkan hasil pengujian, ketika intent berhasil dikenali dengan tepat, Nova AI dapat mengambil informasi yang relevan dari knowledge base dan menggunakannya sebagai dasar dalam memberikan respons kepada pengguna. Hal ini menunjukkan bahwa integrasi antara model CNN dan knowledge base dapat menghubungkan proses klasifikasi pertanyaan dengan penyediaan informasi yang dibutuhkan pengguna.

Namun, hasil pengujian juga menunjukkan bahwa kesalahan klasifikasi intent dapat memengaruhi respons akhir sistem. Ketika pertanyaan menghasilkan intent yang tidak sesuai atau unknown, sistem dapat mengalami kesulitan dalam menentukan informasi yang tepat dari knowledge base. Label “unknown” pada sistem diperoleh ketika nilai confidence hasil prediksi CNN berada di bawah confidence threshold sebesar 0,70, sehingga sistem tidak menggunakan intent tersebut untuk mengambil informasi dari knowledge base. Oleh karena itu, kualitas respons Nova AI tidak hanya bergantung pada kelengkapan knowledge base, tetapi juga pada ketepatan model CNN dalam menentukan intent dari pertanyaan pengguna.

Secara keseluruhan, integrasi model CNN dengan knowledge base telah memungkinkan Nova AI menjalankan alur dari pertanyaan pengguna, klasifikasi intent, pengambilan informasi, hingga pemberian respons. Integrasi tersebut menjadi dasar bagi sistem dalam memberikan jawaban yang sesuai dengan informasi yang telah tersedia pada knowledge base.

4.7.5 Pembahasan Hasil Pengujian Sistem

Berdasarkan hasil pengujian pada Tabel 4.19, Tabel 4.20, Tabel 4.21, dan Tabel 4.22, pengujian sistem dilakukan untuk mengetahui kemampuan Nova AI dalam melakukan klasifikasi intent, memberikan respons berdasarkan informasi yang tersedia pada knowledge base, serta menangani pertanyaan yang berada di luar cakupan knowledge base.

Berdasarkan rekapitulasi hasil pengujian pada Tabel 4.22, dari 30 pertanyaan yang diuji terdapat 25 pertanyaan yang menghasilkan prediksi sesuai dengan intent yang diharapkan, sedangkan 5 pertanyaan menghasilkan prediksi yang tidak sesuai. Dengan demikian, persentase keberhasilan pengujian sistem adalah sebesar 83,33%. Hasil tersebut menunjukkan bahwa sebagian besar pertanyaan yang diberikan melalui sistem dapat diproses sesuai dengan intent yang diharapkan.

Kesesuaian hasil pengujian menunjukkan bahwa ketika intent berhasil dikenali dengan tepat, sistem dapat menggunakan intent tersebut untuk menentukan informasi yang relevan dari knowledge base dan menghasilkan respons yang berkaitan dengan pertanyaan pengguna.

Hal ini menunjukkan bahwa integrasi antara model CNN dan knowledge base dapat berjalan dengan baik pada sebagian besar pertanyaan yang diuji. Persentase keberhasilan sebesar 83,33% pada pengujian sistem tidak dapat disamakan dengan accuracy model CNN sebesar 0,99. Accuracy sebesar 0,99 diperoleh dari evaluasi classifier menggunakan 124 data testing dan menunjukkan kemampuan model dalam mengklasifikasikan intent pada data pengujian. Sementara itu, persentase keberhasilan sebesar 83,33% diperoleh dari pengujian sistem secara langsung menggunakan 30 pertanyaan. Pengujian tersebut digunakan untuk melihat

kesesuaian hasil klasifikasi intent terhadap intent yang diharapkan pada pertanyaan pengguna. Dengan demikian, kedua nilai tersebut digunakan untuk mengukur aspek yang berbeda, yaitu performa model klasifikasi dan keberhasilan sistem secara keseluruhan.

Sementara itu, ketidaksesuaian pada beberapa pengujian menunjukkan bahwa model masih mengalami kesulitan dalam mengenali variasi bentuk pertanyaan tertentu. Salah satu kesalahan ditemukan pada pertanyaan “Siapa Ketua Program Studi di FIKTI UMSU?” yang memiliki intent yang diharapkan berupa kaprodi, tetapi diprediksi sebagai fakultas dengan confidence sebesar 99,65%. Kesalahan lainnya terdapat pada pertanyaan “Siapa pimpinan program studi di FIKTI?” yang diprediksi sebagai fakultas, serta pertanyaan “Informasi dosen yang memimpin program studi” yang diprediksi sebagai dosen. Hasil tersebut menunjukkan bahwa model masih mengalami kesulitan ketika menghadapi variasi pertanyaan mengenai pimpinan program studi yang menggunakan susunan kata atau istilah yang berbeda.

Dengan demikian, penyebab ketidaksesuaian pada pengujian tidak hanya berkaitan dengan informasi yang tersedia pada knowledge base, tetapi juga dengan kemampuan model dalam mengenali variasi bahasa pengguna. Penambahan variasi pertanyaan pada dataset pelatihan, termasuk penggunaan kata atau frasa yang memiliki makna serupa, dapat menjadi salah satu upaya untuk meningkatkan kemampuan model dalam mengenali intent pada pertanyaan yang lebih beragam. Selain kemampuan model dalam mengenali variasi bahasa, keterbatasan dataset juga menjadi salah satu faktor yang dapat memengaruhi hasil pengujian sistem.

Dataset penelitian terdiri dari 619 pertanyaan yang terbagi ke dalam enam intent, sehingga variasi bahasa yang terdapat dalam dataset belum tentu mencakup

seluruh bentuk pertanyaan yang mungkin digunakan oleh pengguna. Kondisi tersebut dapat menyebabkan model mengalami kesulitan ketika menerima pertanyaan dengan susunan kata atau istilah yang belum cukup terwakili dalam dataset. Oleh karena itu, penambahan jumlah dan variasi data pada setiap intent dapat dilakukan untuk memperluas pola bahasa yang dipelajari oleh model dan meningkatkan kemampuan generalisasi sistem.

Secara keseluruhan, hasil pengujian menunjukkan bahwa Nova AI telah mampu menjalankan proses klasifikasi intent, pengambilan informasi dari knowledge base, dan pemberian respons pada sebagian besar pertanyaan yang diuji. Persentase keberhasilan sebesar 83,33% menunjukkan bahwa sistem telah berfungsi sesuai dengan alur yang dirancang, tetapi masih terdapat keterbatasan dalam menghadapi variasi bentuk pertanyaan pengguna.

4.7.6 Pembahasan Sistem Secara Keseluruhan

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan, Nova AI telah mampu mengintegrasikan tahapan preprocessing, klasifikasi intent menggunakan model CNN, pengambilan informasi dari knowledge base, dan pemberian respons dalam satu sistem chatbot. Setiap tahapan memiliki peran yang saling berkaitan dalam menghasilkan respons terhadap pertanyaan pengguna.

Pada tahap preprocessing, pertanyaan pengguna diubah menjadi bentuk yang dapat diproses oleh model melalui proses tokenisasi, word indexing, dan padding. Data tersebut kemudian digunakan oleh model CNN untuk menentukan intent pertanyaan. Hasil evaluasi model menunjukkan bahwa model mampu melakukan klasifikasi intent dengan tingkat ketepatan yang tinggi pada data pengujian.

Hasil klasifikasi selanjutnya digunakan untuk menentukan informasi yang relevan pada knowledge base. Informasi tersebut menjadi dasar bagi Nova AI dalam memberikan respons kepada pengguna. Hasil pengujian sistem menunjukkan bahwa dari 30 pertanyaan yang diuji, sebanyak 25 pertanyaan menghasilkan klasifikasi yang sesuai dengan intent yang diharapkan, sedangkan 5 pertanyaan tidak sesuai. Dengan demikian, diperoleh tingkat keberhasilan pengujian sistem sebesar 83,33%.

Hasil tersebut menunjukkan bahwa Nova AI telah mampu menjalankan alur utama sistem sesuai dengan rancangan. Namun, pengujian juga menunjukkan bahwa sistem masih memiliki keterbatasan dalam mengenali variasi bentuk pertanyaan pengguna. Pertanyaan dengan intent yang sama dapat menghasilkan prediksi berbeda ketika terdapat perubahan atau penambahan kata tertentu. Oleh karena itu, pengembangan variasi data pelatihan dan peningkatan kemampuan model dalam mengenali variasi bahasa dapat dilakukan untuk meningkatkan kinerja Nova AI pada penggunaan selanjutnya.

Secara keseluruhan, hasil penelitian menunjukkan bahwa keberhasilan Nova AI tidak hanya dipengaruhi oleh performa model CNN, tetapi juga oleh representasi data, distribusi dataset, dan integrasi model dengan knowledge base. Accuracy model sebesar 0,99 menunjukkan kemampuan klasifikasi yang tinggi pada data testing, sedangkan tingkat keberhasilan sistem sebesar 83,33% menunjukkan bahwa masih terdapat kesalahan ketika model diterapkan pada pertanyaan pengguna dengan berbagai variasi bahasa. Perbedaan tersebut menunjukkan bahwa performa model pada data testing belum sepenuhnya menggambarkan kemampuan sistem dalam menghadapi seluruh variasi pertanyaan pengguna. Oleh karena itu,

peningkatan variasi dataset dan pengembangan data pengujian yang lebih beragam diperlukan untuk meningkatkan kemampuan generalisasi Nova AI.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai penerapan Convolutional Neural Network (CNN) pada Nova AI sebagai chatbot layanan informasi akademik FIKTI UMSU, maka dapat diambil beberapa kesimpulan sebagai berikut:

1. Penerapan Convolutional Neural Network (CNN) pada Nova AI dapat digunakan untuk melakukan klasifikasi intent berdasarkan pertanyaan yang diberikan oleh pengguna. Pada penelitian ini, intent yang digunakan terdiri dari enam kategori, yaitu dekan, dosen, fakultas, kaprodi, sapaan, dan UKT.
2. Berdasarkan hasil evaluasi model pada 124 data pengujian, model CNN memperoleh nilai accuracy sebesar 0,99. Hasil confusion matrix menunjukkan bahwa terdapat 123 data yang berhasil diklasifikasikan dengan benar dan satu data mengalami kesalahan klasifikasi, yaitu data dengan intent aktual kaprodi yang diprediksi sebagai dekan. Hasil tersebut menunjukkan bahwa model CNN memiliki kemampuan yang baik dalam melakukan klasifikasi intent pada data yang digunakan dalam penelitian.
3. Integrasi antara hasil klasifikasi intent dengan knowledge base dapat digunakan untuk menentukan informasi yang sesuai dengan kebutuhan pengguna. Intent yang diperoleh dari proses klasifikasi digunakan sebagai dasar dalam menentukan informasi pada knowledge base yang kemudian menjadi sumber dalam pemberian respons oleh Nova AI.

4. Berdasarkan pengujian sistem menggunakan 30 pertanyaan, diperoleh 25 pengujian yang sesuai dan 5 pengujian yang tidak sesuai, sehingga tingkat keberhasilan pengujian sistem mencapai 83,33%. Nilai tersebut merupakan hasil pengujian sistem secara langsung dan berbeda dengan accuracy model CNN sebesar 0,99 yang diperoleh dari evaluasi classifier pada 124 data testing. Hasil pengujian menunjukkan bahwa Nova AI telah dapat melakukan proses klasifikasi intent, mengambil informasi dari knowledge base, dan memberikan respons kepada pengguna. Namun, hasil pengujian juga menunjukkan bahwa perubahan bentuk, susunan, atau penambahan kata pada pertanyaan tertentu masih dapat memengaruhi hasil klasifikasi.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat digunakan untuk pengembangan Nova AI pada penelitian selanjutnya, yaitu:

1. Dataset dapat dikembangkan dengan menambahkan lebih banyak variasi pertanyaan pada setiap kategori intent. Penambahan variasi tersebut diharapkan dapat membantu model mengenali pertanyaan dengan susunan kata yang berbeda, sehingga hasil klasifikasi dapat lebih konsisten.
2. Knowledge base dapat dikembangkan dengan menambahkan dan memperbarui informasi akademik yang dibutuhkan oleh pengguna. Dengan knowledge base yang lebih lengkap dan diperbarui secara berkala, Nova AI dapat memberikan informasi yang lebih sesuai dengan kebutuhan pengguna.
3. Pengujian sistem dapat dilakukan dengan jumlah pertanyaan yang lebih banyak dan variasi pertanyaan yang lebih beragam. Hal ini diperlukan untuk

mengetahui kemampuan sistem dalam menghadapi berbagai bentuk pertanyaan pengguna dan memperoleh gambaran kinerja sistem yang lebih menyeluruh.

4. Penelitian selanjutnya dapat mempertimbangkan pengembangan model atau metode klasifikasi yang lebih mampu menangani variasi bahasa pada pertanyaan pengguna, khususnya ketika terdapat perubahan atau penambahan kata yang dapat memengaruhi hasil klasifikasi intent.

DAFTAR PUSTAKA

- Adamopoulou, E., & Moussiades, L. (2020). Chatbots: History, technology, and applications. *Machine Learning with Applications*, 2, 100006. <https://doi.org/10.1016/j.mlwa.2020.100006>
- Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T. (2017). Enriching Word Vectors with Subword Information. *Transactions of the Association for Computational Linguistics*, 5, 135–146. https://doi.org/10.1162/tacl_a_00051
- Chaves, A. P., & Gerosa, M. A. (2021). How Should My Chatbot Interact? A Survey on Social Characteristics in Human–Chatbot Interaction Design. *International Journal of Human–Computer Interaction*, 37(8), 729–758. <https://doi.org/10.1080/10447318.2020.1841438>
- Dale, R. (2021). GPT-3: What’s it good for? *Natural Language Engineering*, 27(1), 113–118. <https://doi.org/10.1017/S1351324920000601>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of the 2019 Conference of the North*, 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org/>
- Hirschberg, J., & Manning, C. D. (2015). *Advances in natural language processing*. <http://science.sciencemag.org/>
- Huang, M., Zhu, X., & Gao, J. (2020). Challenges in Building Intelligent Open-domain Dialog Systems. *ACM Transactions on Information Systems*, 38(3), 1–32. <https://doi.org/10.1145/3383123>
- Indurkha, N., & Damerau, F. J. (Eds.). (2010). *Handbook of Natural Language Processing*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781420085938>
- Jurafsky, D., & Martin, J. H. (2020). *Speech and Language Processing*. Stanford University.
- Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- Kowsari, K., Jafari Meimandi, K., Heidarysafa, M., Mendu, S., Barnes, L., & Brown, D. (2019). Text Classification Algorithms: A Survey. *Information*, 10(4), 150. <https://doi.org/10.3390/info10040150>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to Information Retrieval*. Cambridge University Press. <https://nlp.stanford.edu/IR-book/information-retrieval-book.html>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). *Efficient Estimation of Word Representations in Vector Space*.
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2022). Deep Learning--based Text Classification. *ACM Computing Surveys*, 54(3), 1–40. <https://doi.org/10.1145/3439726>

- Pennington, J., Socher, R., & Manning, C. (2014). Glove: Global Vectors for Word Representation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1532–1543. <https://doi.org/10.3115/v1/D14-1162>
- Porter, M. (2006). *The Porter Stemming Algorithm*. <https://tartarus.org/martin/PorterStemmer/>
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Salton, G., & McGill, M. J. (1983). *Introduction to Modern Information Retrieval*. McGraw-Hill. <https://www.semanticscholar.org/paper/Introduction-to-Modern-Information-Retrieval-Salton-McGill/49af3e80343eb80c61e727ae0c27541628c7c5e2>
- Smutny, P., & Schreiberova, P. (2020). Chatbots for learning: A review of educational chatbots for the Facebook Messenger. *Computers & Education*, 151, 103862. <https://doi.org/10.1016/j.compedu.2020.103862>
- Tan, L., Yi, J., & Yang, F. (2024). Improving Performance of Massive Text Real-Time Classification for Document Confidentiality Management. *Applied Sciences (Switzerland)*, 14(4). <https://doi.org/10.3390/app14041565>
- Wang, H., & Li, X. (2022). Chinese News Text Classification Based on Convolutional Neural Network. *Journal on Big Data*, 4(1), 41–60. <https://doi.org/10.32604/jbd.2022.027717>
- Wang, H., Tian, K., Wu, Z., & Wang, L. (2020). A Short Text Classification Method Based on Convolutional Neural Network and Semantic Extension. *International Journal of Computational Intelligence Systems*, 14(1), 367. <https://doi.org/10.2991/ijcis.d.201207.001>
- Yan, D., Li, K., Gu, S., & Yang, L. (2020). Network-Based Bag-of-Words Model for Text Classification. *IEEE Access*, 8, 82641–82652. <https://doi.org/10.1109/ACCESS.2020.2991074>
- Yogatama, D., Dyer, C., Ling, W., & Blunsom, P. (2017). Generative and Discriminative Text Classification with Recurrent Neural Networks. *ArXiv Preprint ArXiv:1703.01898*, 1–11.
- Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent Trends in Deep Learning Based Natural Language Processing. *IEEE Computational Intelligence Magazine*, 13(3), 55–75. <http://arxiv.org/abs/1708.02709>
- Zhang, X., & LeCun, Y. (2016). Text Understanding from Scratch. *Advances in Neural Information Processing Systems*. <http://arxiv.org/abs/1502.01710>

**UMSU**

Unggul | Cerdas | Terpercaya

Bila menjawab surat ini agar disebutkan nomor dan tanggalnya

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI**

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/BAN-PT/Akred/PT/III/2019

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

<https://fikti.umsu.ac.id>fikti@umsu.ac.id[f umsumedan](https://www.facebook.com/umsu.medan)[i umsumedan](https://www.instagram.com/umsu.medan)[t umsumedan](https://www.twitter.com/umsu.medan)[y umsumedan](https://www.youtube.com/umsu.medan)**Berita Acara Pembimbingan Skripsi**

Nama Mahasiswa : Rayhan Pratama
 Program Studi : Sistem Informasi
 NPM : 2209010298
 Judul Penelitian : Implementasi CNN Berbasis Word Embedding untuk Klasifikasi
 Pertanyaan Chatbot FIKTI UMSU
 Nama Dosen Pembimbing : Dr. Irvan, M.Si

Tanggal Bimbingan	Hasil Evaluasi	Paraf Dosen
1/8 2026	pengulas implementasi,	
3/8 2026	sumakan seluruh parameter	
7/8 2026	kejelasan sumber proses pembelajaran & data dan distribusi	
15/8 2026	tentang nama variabel dan argumen.	
16/8 2026	perkembangan uji coba sistem	
18/8 2026	perubahan mekanisme sistem	
19/8 2026	perbaikan dan hasil teori dan hasil diuji - coba	
31/8 2026	Ace sidang.	

Medan, Agustus 2026

Diketahui oleh :

Ketua Program Studi

(Mahardika Prawira Tanjung, S.Kom., M.Kom)

Disetujui oleh :

Dosen Pembimbing

(Dr. Irvan, M.Si)



UMSU
Unggul | Cerdas | Terpercaya

Bila mendapat surat ini agar disebarkan
nomor dan tanggalnya

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi Unggul Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 174/SK/BAN-PT/Ak.Ppj/PT/III/2024

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

<http://fiks@umsu.ac.id>

fiks@umsu.ac.id

[umsu.medan](https://www.facebook.com/umsu.medan)

[umsu.medan](https://www.instagram.com/umsu.medan)

[umsu.medan](https://www.tiktok.com/@umsu.medan)

[umsu.medan](https://www.youtube.com/channel/UC...)

FORMULIR PERBAIKAN UJIAN SKRIPSI

Pada hari ini, Selasa 1 September 2026 telah dilaksanakan Ujian Skripsi bagi mahasiswa
Fakultas Ilmu Komputer Dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.
Sbb:

Nama Mahasiswa : Rayhan Pratama
NPM : 2209010298
Program Studi : Sistem Informasi
Judul Proposal : Implementasi Cnn Berbasis Word Embedding Untuk Klasifikasi
Pertanyaan Chatbot Fikti Umsu
Materi/Point yang Diperbaiki :

		Paraf
Dr. Irvan, M.Si	perbaiki sesuai arahan dari penguji	
Mahardika Prawira Tanjung, S.Kom., M.Kom.	Tambahkan knowledge CNN pada chatbot itu sendiri. Intuit dan knowledge chat botnya masih minim	
Asrar Aspia Manurung, S.Pd., M.Pd.	1. Bab ini dilakukannya uji coba 2. Simpulan belum terjawab	

Berita acara ini **ditandatangani** setelah skripsi diperbaiki sesuai petunjuk/arahan dari
Pembimbing dan Penguji/Pembahas.

The Last of Skripsi Rayhan ++.docx

ORIGINALITY REPORT

26%

SIMILARITY INDEX

PRIMARY SOURCES

1	repository.umsu.ac.id Internet	635 words — 3%
2	etheses.uin-malang.ac.id Internet	271 words — 1%
3	repository.ar-raniry.ac.id Internet	160 words — 1%
4	kc.umn.ac.id Internet	157 words — 1%
5	proceeding.unpkediri.ac.id Internet	146 words — 1%
6	repository.itpln.ac.id Internet	136 words — 1%
7	repository.uin-suska.ac.id Internet	123 words — 1%
8	fikti.umsu.ac.id Internet	86 words — < 1%
9	123dok.com Internet	75 words — < 1%
10	eprints2.undip.ac.id Internet	75 words — < 1%
11	dspace.uui.ac.id Internet	63 words — < 1%
12	lab.tik.pnj.ac.id Internet	63 words — < 1%