



ISSN: 2301-5373
E-ISSN: 2654-5101

Volume 13 • Number 3 • May 2025

JELIKU

Jurnal Elektronik Ilmu Komputer Udayana

Informatics Study Program

Faculty of Mathematics and Natural Sciences

Udayana University

Table of Contents

Sentiment Analysis Website Interface Improvements to Enhance User Experience Anak Agung Ngurah Mahadana Apta Gotra, Anak Agung Istri Ngurah Eka Karyawati, I Ketut Gede Suhartana, I Gusti Ngurah Anom Cahyadi Putra	727-742
Data Processing Using Change Data Capture For Real-Time Data Synchronization I Made Ari Madya Santosa, I Gusti Ngurah Anom Cahyadi Putra, I Ketut Gede Suhartana, I Gede Surya Rahayuda	743-754
Analisis Sentimen Berbasis Aspek Terhadap Aplikasi Mobile Banking Dengan Metode Convolutional Neural Network (CNN) Dan PCA I Made Juniandika, Gst. Ayu Vida Mastrika Giri, Anak Agung Istri Ngurah Eka Karyawati, I Gusti Ngurah Anom Cahyadi Putra	755-766
Implementasi Fitur Keamanan Enkripsi End-To-End Pada Aplikasi Bimbingan Online Tugas Akhir Berbasis Website Putu Krisna Megadana, I Gusti Ngurah Anom Cahyadi Putra.....	767-774
Sistem Rekomendasi Film Berdasarkan Profil Pengguna Menggunakan Metode Simple Additive Weighting Dan Pendekatan Ontologi Ngakan Made Alit Wiradhanta, I Made Widhi Wirawan, Ida Ayu Gde Suwiprabayanti Putra, I Gusti Agung Gede Arya Kadyanan	775-786
Optimasi Algoritma Decision Tree Dengan Seleksi Fitur Dalam Klasifikasi Prestasi Akademik Siswa Sekolah I Made Ryan Prana Dhita, Gst. Ayu Vida Mastrika Giri, I Putu Gede Hendra Suputra, Anak Agung Istri Ngurah Eka Karyawati.....	787-798
Pengembangan Sistem Frequently Asked Questions (FAQ) pada Universitas Udayana Berbasis Ontology Ngurah Kelvin Febryanta Lila Ananda, Anak Agung Istri Ngurah Eka Karyawati, Cokorda Rai Adi Pramatha, I Gusti Agung Gede Arya Kadyanan.....	799-812

Pengembangan Sistem Temu Kembali Musik Populer Indonesia Dengan Metode Savoy I Ketut Teguh Wibawa Lessmana Putra. T, I Gusti Agung Gede Arya Kadyanan, Cokorda Rai Adi Pramatha, I Gusti Ngurah Anom Cahyadi Putra.....	813-822
Optimasi Hyperparameter Random Forest untuk Prediksi Kualitas Air Lutfi Julpian, Alam Rahmatulloh	823-832
Klasifikasi Penyakit Pernapasan berdasarkan Suara Paru-Paru menggunakan Probabilistic Neural Network Shienntya Florensia Adiriyanto, I Gede Arta Wibawa, Made Agung Raharja, Gst. Ayu Vida Mastrika Giri.....	833-842
Online Course Popularity: An In-depth Analysis with K-Means on Udemy Platform Rahmat Hidayat, Ibnu Daqiqil Id, Rahmah Muthmainah, Muhammad Alfhat Ramadhan, Icha Dwi Yanti, Kornelius Jonathan Manik, Rendi Wahyudi	843-854
Penerapan Waterfall dan Teknologi Arduino Pada Inovasi Ekstraktor Sarang Madu Otomatis Musliadi KH	855-862
Analisis Klaster Siswa Unggulan dengan Algoritma K-Means Berdasarkan Aspek Akademik dan Non-Akademik Mas'ud Hermansyah, Mujiono Mujiono, Akas Bagus Setiawan, M. Faiz Firdausi, Iqbal Sabilirasyad	863-874
Implementasi Artificial Neural Network Menggunakan Backpropagation Pada Prediksi Indeks Pembangunan Manusia I Wayan Supriana, Gede Dikka Widya Prana, Gede Dikka Widya Prana, I Ketut Adian Jayaditya	875-882
Identifikasi Varietas Jagung Menggunakan Metode Convolutional Neural Network Abdurrahim Ramadhan Idin, Aziz Kustiyo, Muhammad Asyhar Agmalaro, Toto Haryanto.....	883-892
Perancangan User Interface dan User Experience Berbasis Website Sistem Pembayaran SPP Menggunakan Human Centered Design (Studi Kasus : SMAS Bhinneka Karawang) Novi Anthika Suci Nurhidayah, Bagja Nugraha, Hannie	983-916

Kruskal-Wallis Analysis of CNN Architecture Performance on CT Image Lung Nodule Classification

Sekar Sari, Kevin Ilham Apriandy, Yerezqy Bagus 917-924

Analisis Sentimen Produk Pada Bukalapak Menggunakan Lexicon-Based dan Multinomial Naïve Bayes

Brian Adam Bhagaskara, Ade Ismail, Habibie Ed Dien 925-936

This page is intentionally left blank.

**SUSUNAN DEWAN REDAKSI
JURNAL ELEKTRONIK ILMU KOMPUTER
UDAYANA (JELIKU)**

Penanggung Jawab :

Dra. Ni Luh Watiniasih M.Sc., Ph.D.

Redaktur :

Gst. Ayu Vida Mastrika Giri, S.Kom., M.Cs.

Penyunting/Editor :

Dr. Anak Agung Istri Ngurah Eka Karyawati, S.Si.,M.Eng.

Ir. I Gusti Agung Gede Arya Kadyanan, S.Kom, M.Kom

I Putu Praba Santika, S.Kom., M.Kom.

I Putu Satwika, S.Kom., M.Kom.

Disain Grafis :

I Kadek Agus Wijaya Kusuma

I Gede Widiantera Mega Saputra

Fotografer :

Febrian Valentino Agape

I Gusti Bagus Sutha Arianata Putra

Sekretariat :

Ni Ketut Alit Widiastuti, S.Kom.

Anak Agung Raka Darmawan, S.Kom.

I Putu Herryawan, S.Kom.

This page is intentionally left blank.

Sentiment Analysis Website Interface Improvements to Enhance User Experience

Anak Agung Ngurah Mahadana Apta Gotra^{a1}, Anak Agung Istri Ngurah Eka Karyawati^{a2}, I Ketut Gede Suhartana^{a3}, I Gusti Ngurah Anom Cahyadi Putra^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Jimbaran, Kuta Selatan, Badung, Bali, Indonesia

¹ngurahmahadanaapta@student.unud.ac.id

²eka.karyawati@unud.ac.id

³ikg.suhartana@unud.ac.id

⁴anom.cp@unud.ac.id

Abstract

Good interface design is very important to improve user experience, especially in web applications. This research aims to redesign the interface of the website loremipsum.com using the User Centered Design (UCD) method to overcome the problems identified through heuristic evaluation. The design process includes four main stages of UCD, namely understanding the context of use, specifying user requirements, designing solutions, evaluating against requirements. All identified issues was implemented, such as responsive design, dark mode, character counter, and CSV file upload capability for large-scale data analysis. A design evaluation was conducted using the System Usability Scale (SUS) with a score of 73, indicating a good level of usability. In addition, the Naive Bayes algorithm was used for sentiment analysis, achieving 73% accuracy. The results show that this redesign not only improves the usability of the website, but also provides a better user experience and efficiently supports the needs of sentiment analysis.

Keywords: User Centered Design, Heuristic Evaluation, System Usability Scale, Naive Bayes, User Experience, Sentiment Analysis

1. Pendahuluan

Desain antarmuka yang baik sangatlah penting dalam meningkatkan daya tarik dan pengalaman pengguna. Terutama, pada aplikasi berbasis website seperti loremipsum.com. Website ini membantu pengguna dalam menganalisis serta memahami sentimen dari data teks yang dimasukkan oleh pengguna. Namun, hasil evaluasi yang dilakukan terhadap website ini menunjukkan adanya kekurangan pada aspek desain antarmuka dan navigasinya. Desain yang kurang baik dapat meningkatkan beban kognitif pengguna yang pada akhirnya dapat mengurangi kepuasan pengguna saat berinteraksi dengan aplikasi [4].


Untuk mengatasi permasalahan ini, maka dilakukanlah perbaikan atau perancangan ulang antarmuka website sentimen analisis tersebut, dengan menerapkan metode User Centered Design (UCD), untuk meningkatkan pengalaman pengguna. Menurut User Experience Professionals Association (UXPA), UCD melibatkan proses desain yang didasarkan pada informasi yang digali dari pengguna produk tersebut. Oleh karena itu, hasil yang didapatkan nantinya akan mengikuti kebutuhan pengguna, dan pengguna hanya perlu menyesuaikan diri untuk menggunakannya. Pendekatan ini telah terbukti efektif dalam meningkatkan daya tarik dan pengalaman pengguna pada berbagai sistem, termasuk aplikasi website dan mobile [5].

Melalui penerapan UCD, penelitian ini diharapkan dapat menghasilkan aplikasi yang lebih baik daripada sebelumnya. Dengan fokus utama pada peningkatan desain antarmuka pengguna, pengujian dalam penelitian ini akan dilakukan pada desain antarmuka yang dihasilkan, bukan pada performa sistemnya. Perancangan ulang ini diharapkan dapat memberikan kenyamanan yang lebih baik lagi bagi pengguna saat berinteraksi dengan website loremipsum.com, sehingga dapat berdampak pula pada pengalaman penggunaanya.

2. Metode Penelitian

2.1. User Centered Design (UCD)

User Centered Design (UCD) adalah metode desain iteratif yang berfokus pada pengguna dan kebutuhan mereka dalam setiap fase desainnya. Dalam UCD, tim desain melibatkan pengguna di seluruh proses desain, untuk menciptakan produk yang sangat mudah digunakan dan dapat diakses oleh mereka [7]. Secara umum, UCD memiliki 4 fase seperti pada gambar 1.




Gambar 1. User Centered Design

- a. Understand Context of Use: Fase ini bertujuan untuk memahami konteks kegunaan dari aplikasi. Siapa penggunanya, untuk apa mereka menggunakannya, dan dalam situasi seperti apa mereka menggunakan aplikasi tersebut.
- b. Specify User Requirements: Fase ini bertujuan untuk mengidentifikasi kebutuhan pengguna secara lebih rinci, serta aspek bisnis dan tujuan yang akan dicapai.
- c. Design Solutions: Fase ini bertujuan untuk merancang solusi desain berdasarkan dari kebutuhan pengguna yang telah diidentifikasi sebelumnya.
- d. Evaluate Against Requirements: Fase ini bertujuan untuk mengevaluasi dengan melibatkan pengguna yang akan menggunakan aplikasi tersebut.

2.2. Heuristic Evaluation

Heuristic evaluation adalah metode evaluasi yang berguna dalam tahap desain, terutama pada awal pengembangan untuk mengidentifikasi masalah-masalah utama sebelum dilakukan pengujian lebih mendalam. Dalam heuristic evaluation, evaluator mengidentifikasi 10 usability heuristics yang dikembangkan oleh Jakob Nielsen untuk melakukan evaluasi seperti pada gambar 2 [2].



Gambar 2. 10 Usability Heuristics

- a. Visibility of System Status: Desain haruslah dapat memberitahu pengguna tentang apa yang sedang terjadi lewat feedback yang sesuai dengan waktu yang tepat.
- b. Match Between System & the Real World: Desain harus “berbicara” menggunakan bahasa yang digunakan oleh pengguna sehari-hari. Gunakan kata-kata, frasa, dan konsep yang familiar bagi pengguna dibanding menggunakan jargon internal.

- c. User Control & Freedom: Pengguna memerlukan “emergency exit” yang jelas terlihat untuk meninggalkan atau memperbaiki apa yang telah dilakukan (contoh: tombol undo & redo, tombol cancel/batal, dan penanda lainnya).
- d. Consistency & Standards: Pengguna seharusnya tidak perlu menebak apakah kata, situasi, atau tindakan yang berbeda memiliki arti yang sama. Desain seharusnya mengikuti konvensi platform.
- e. Error Prevention: Pesan error yang baik merupakan hal yang penting, tetapi desain terbaik adalah desain yang mencegah kesalahan terjadi.
- f. Recognition Rather than Recall: Meminimalisir user’s memory load dengan cara membuat elemen, tindakan, dan opsi terlihat. Hindari membuat pengguna mengingat suatu informasi.
- g. Flexibility & Efficiency of Use: Shortcuts tersembunyi bagi pengguna pemula dapat mempercepat interaksi pada produk bagi pengguna ahli.
- h. Aesthetic & Minimalist Design: Antarmuka seharusnya tidak memuat informasi yang tidak relevan. Setiap informasi tambahan pada antarmuka berkompetisi dengan informasi lain yang lebih relevan.
- i. Help Users Recognize, Diagnose, & Recover from Errors: Pesan eror seharusnya diekspresikan dengan bahasa yang netral, menunjukkan masalah yang tepat, serta menyarankan solusi yang konstruktif.
- j. Help & Documentation: Desain terbaik adalah desain yang tidak membutuhkan informasi tambahan. Namun, bisa jadi desain perlu menyediakan dokumentasi untuk membantu pengguna mengerti bagaimana cara menyelesaikan tugas mereka.

Pada tabel 1, dapat dilihat bahwa metode ini memiliki tingkat keparahan dari masalah kegunaan yang ditemukan selama evaluasi (severity rating). Dengan menentukan tingkat keparahan setiap masalah, tim desain dapat memprioritaskan masalah mana yang harus diperbaiki terlebih dahulu [1].

Tabel 1. Severity Rating

Severity	Masalah	Deskripsi
0	No problem (tidak ditemukan pelanggaran)	Tidak setuju bahwa ini adalah masalah kegunaan
1	Cosmetic (hanya permasalahan tampilan)	Tidak perlu diperbaiki kecuali jika tersedia waktu tambahan pada proyek
2	Minor (masalah kegunaan kecil)	Memperbaiki ini harus diberi prioritas rendah
3	Major (masalah kegunaan utama)	Penting untuk diperbaiki, jadi harus diberi prioritas tinggi
4	Catastrophe (tunda perilsan produk)	Sangat penting untuk memperbaikinya sebelum produk dapat dirilis

2.3. System Usability Scale (SUS)


System Usability Scale (SUS) adalah metode yang digunakan untuk menilai usability. SUS dikembangkan oleh John Brooke pada tahun 1986 sebagai metode yang efektif dan murah. Pada tabel 2, dapat dilihat bahwa SUS terdiri dari 10 pernyataan dengan skala Likert 5 poin. Nilai SUS berkisar antara 0 hingga 100, dengan rata-rata atau batas minimum kelayakan di angka 68 [11].

Tabel 2. Pernyataan SUS

No	Pernyataan
1	Saya pikir saya akan sering menggunakan aplikasi ini
2	Saya rasa aplikasi ini seharusnya tidak serumit ini
3	Saya pikir aplikasi ini mudah untuk digunakan
4	Saya pikir saya akan membutuhkan bantuan dari orang teknis untuk dapat menggunakan aplikasi ini
5	Saya menemukan bahwa berbagai fungsi di aplikasi ini terintegrasi dengan baik
6	Saya pikir terlalu banyak ketidaksesuaian di dalam aplikasi ini
7	Saya rasa kebanyakan orang akan belajar menggunakan aplikasi ini dengan sangat cepat
8	Saya menemukan aplikasi ini sangat susah untuk digunakan
9	Saya merasa sangat percaya diri / nyaman dalam menggunakan aplikasi ini
10	Saya perlu mempelajari banyak hal sebelum saya dapat menggunakan aplikasi ini

Dalam menggunakan System Usability Scale ada beberapa aturan dan langkah perhitungan skor. Berikut ini aturan dan langkah perhitungan skornya seperti pada gambar 3 [11]:

- Setiap pernyataan bernomor ganjil, skor yang didapat dari responden dikurangi dengan nilai 1.
- Setiap pernyataan pada urutan genap, nilai 5 dikurangi skor yang didapat dari responden.
- Setelah melakukan perhitungan pada poin 1 dan 2, hasil perhitungan tersebut dikalikan dengan 2,5.
- Skor SUS merupakan nilai yang didapat dari penjumlahan semua nilai (poin 3) dibagi dengan jumlah responden.



Gambar 3. Penilaian SUS

2.4. Naive Bayes

Naive Bayes merupakan salah satu algoritma machine learning yang paling umum digunakan dalam analisis sentimen. Naive Bayes didasarkan pada Teorema Bayes, yang memprediksi probabilitas suatu peristiwa berdasarkan bukti yang tersedia. Algoritma ini memiliki asumsi bahwa semua fitur yang ada bersifat independen. Namun, dalam praktiknya, Naive Bayes terbukti sangat efektif dan efisien dalam menangani masalah klasifikasi teks, termasuk dalam mengklasifikasikan sentimen positif, negatif, atau netral [4][6]. Naive Bayes didasarkan pada Teorema Bayes, yang menyatakan:

$$P(X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (1)$$

Di mana:

- $P(C|X)$: Probabilitas hipotesis C benar berdasarkan data X (probabilitas posterior).
- $P(X|C)$: Probabilitas data X muncul jika hipotesis C benar (probabilitas likelihood).
- $P(C)$: Probabilitas awal hipotesis C (probabilitas prior).
- $P(X)$: Probabilitas data X terjadi (probabilitas evidence).

Pada Naive Bayes, asumsi "naive" dibuat bahwa setiap fitur dalam data X bersifat independen satu sama lain. Maka, persamaannya menjadi:

$$P(X) = \frac{P(C) \cdot P(C) \cdot P(C) \cdot \dots \cdot P(x_n|C)}{P(X)} \quad (2)$$

Langkah-langkah umum Naive Bayes:

- Hitung Probabilitas Prior:

$$P(C) = \frac{\text{Jumlah dokumen dalam kelas } C}{\text{Total jumlah dokumen}} \quad (3)$$

- Hitung Likelihood:

$$P(C) = \frac{\text{Probabilitas kata } x_i \text{ muncul dalam kelas } C + 1}{\text{Total kata dalam kelas } C + \text{Total kata unik}} \quad (4)$$

- Gabungkan Probabilitas menggunakan persamaan (2).
- Klasifikasi dengan memilih kelas yang memiliki nilai paling tinggi.

Algoritma Naive Bayes bekerja dengan menghitung probabilitas suatu teks memiliki kategori sentimen tertentu berdasarkan kata-kata yang ada dalam teks tersebut. Karena kemudahannya dalam implementasi dan kecepatan dalam pelatihan model, Naive Bayes sering digunakan untuk analisis sentimen skala besar, seperti analisis komentar pelanggan, ulasan produk, atau opini pengguna di media sosial [9][10].

3. Hasil dan Pembahasan

3.1. Masalah yang Diidentifikasi

Sebelum masalah diidentifikasi, dilakukan evaluasi dengan metode SUS terlebih dahulu untuk mengetahui seberapa baik tingkat usability website loremipsum.com yang belum dilakukan redesign. Data respondennya dapat dilihat pada tabel 3.

Tabel 3. Responden UT Awal

No	Nama Responden	Jenis Kelamin	Pekerjaan
1	Nina Rahmawati	Wanita	Data Analyst
2	Fajar Nugraha	Pria	Data Engineer
3	Siti Anindya Kusuma	Wanita	Data Analyst
4	Bayu Pratam	Pria	Data Scientist
5	Lina Puspitasari	Wanita	Data Analyst

Pada gambar 5, dapat dilihat bahwa hasil SUS yang didapatkan dari 5 responden menandakan bahwa website loremipsum.com kurang baik karena skor SUS yang didapat lebih kecil dari 68 (batas minimum) [4][11]. Oleh karena itu, diperlukan identifikasi masalah dengan bantuan evaluator.

Responden	Q1-1	5-Q2	Q3-1	5-Q4	Q5-1	5-Q6	Q7-1	5-Q8	Q9-1	5-Q10	Qsum
R1	2	3	3	2	2	3	3	3	3	3	27
R2	2	2	2	3	2	2	3	2	3	3	24
R3	3	3	3	3	3	3	2	3	3	3	29
R4	3	3	3	3	2	3	2	2	2	3	26
R5	2	3	3	3	3	3	3	3	3	3	29
Qttotal											135
Q2,5											337,5
SUS Score											67,5

Gambar 5. Hasil UT Awal

Hasil heuristic evaluation dari 3 evaluator mengungkap berbagai permasalahan terkait usability [4]. Temuan-temuan tersebut dapat digunakan sebagai panduan dalam merancang perbaikan agar dapat meningkatkan usability website loremipsum.com [1]. Evaluator memberikan peringkat pelanggaran heuristik berdasarkan severity rating mulai dari yang tertinggi hingga peringkat terendah. Tujuannya agar dapat dilakukan perbaikan dimulai dari yang paling besar pengaruhnya. Data evaluator dapat dilihat pada tabel 4, dan untuk hasil evaluasinya tertera pada tabel 5.

Tabel 4. Evaluator

No	Nama Evaluator	Jenis Kelamin	Pekerjaan
1	Adrian Mahendra	Pria	UI/UX Designer
2	Irma Hapsari	Wanita	Data Analyst
3	Danang Krisna	Pria	Quality Assurance

Tabel 5. Hasil Heuristic Evaluation


1	
Temuan	Tidak responsif
Severity	3
Heuristic	Aesthetic and minimalist design
Deskripsi	Ukuran komponen, ukuran font, dan lainnya tidak berubah mengikuti ukuran layar perangkat yang digunakan untuk mengakses website.
Rekomendasi	Sebaiknya perlu dibuatkan ukuran-ukuran yang berbeda untuk tiap jenis layar perangkat yang biasanya digunakan untuk mengakses website.
Evaluator 3	Ukuran komponen-komponen juga perlu diperhatikan pada setiap screen size.
Rekomendasi	
Evaluator 1	

2	
Temuan	Tidak ada counter karakter pada textarea
Severity	3
Heuristic	Visibility of system status, help users recognize, diagnose, and recover from errors, aesthetic and minimalist design
Deskripsi	Ketika mengetikkan atau menginput karakter ke dalam textarea, tidak terdapat informasi batas maksimal karakter yang bisa diinput (counter). Terlebih lagi, sistem akan mengatakan bahwa ada masalah pada request tersebut tanpa menjelaskan secara spesifik apa masalahnya. Interaksi seperti ini tentu saja dapat membingungkan user karena mereka harus menerka-nerka penyebabnya.
Rekomendasi Evaluator 1	Untuk meningkatkan interaksi dengan user, lebih baik ditambahkan counter di dalam komponen textarea. Sehingga, ketika inputan user sudah melebihi batas, maka counter akan berwarna merah dan user tidak bisa menginputkan karakter lagi.
3	
Temuan	Tidak bisa menganalisis data dalam jumlah besar
Severity	3
Heuristic	Flexibility and efficiency of use
Deskripsi	Umumnya, proses analisis sentimen dilakukan dengan data dalam jumlah besar sekaligus. Jika tidak ada fitur unggah file, pengguna harus memproses data satu per satu, sehingga akan sangat tidak praktis.
Rekomendasi Evaluator 2	Perlu ditambahkan opsi apakah ingin menganalisis sentimen via input teks atau via file CSV yang diunggah. Sehingga, pengguna dapat memproses data besar dengan mudah.
4	
Temuan	Informasi panduan pengguna kurang jelas
Severity	2
Heuristic	Help & documentation, aesthetic and minimalist design
Deskripsi	Pengguna tidak diinformasikan dengan tatacara penggunaan aplikasi secara lengkap seperti, bagaimana cara memisahkan kalimat yang diinput, berapa jumlah maksimal inputan, dan sebagainya.
Rekomendasi Evaluator 1	Sebaiknya perlu ditambahkan panduan pengguna yang menjelaskan tatacara penggunaan aplikasi dalam bentuk placeholder di dalam komponen textarea.
5	
Temuan	Tidak ada mode gelap
Severity	1
Heuristic	Aesthetic and minimalist design
Deskripsi	Konten dengan tema terang cepat meningkatkan kelelahan mata. Oleh karena itu, tema gelap diciptakan dengan harapan dapat mereda mata lelah. Selain itu, saat ini tema gelap menjadi fitur yang semakin diharapkan oleh pengguna modern.
Rekomendasi Evaluator 1	Tambahkan fitur yang memungkinkan sistem mendeteksi perangkat pengguna menggunakan tema terang atau tema gelap.

Proses heuristic evaluation yang telah dilakukan menunjukkan bahwa ada beberapa isu desain dan fungsional yang ditemukan. Isu-isu tersebut dapat diperbaiki sesuai dengan saran-saran dari evaluator, untuk meningkatkan pengalaman pengguna.


3.2. Rancangan Solusi

Berdasarkan heuristic evaluation, rancangan perbaikan website loremipsum.com difokuskan pada peningkatan tampilan sesuai temuan evaluator. Source Sans Pro dipilih sebagai font utama karena modern, profesional, dan mudah dibaca [8]. Warna merah (#FF4B4B) digunakan sebagai aksen utama untuk menciptakan tampilan mencolok namun tetap profesional seperti yang terlihat pada gambar 6 [12].




Gambar 6. Design System

Halaman pertama adalah halaman Analisis Teks Langsung. Pada halaman ini, pengguna akan disuguhkan textarea yang dirancang agar pengguna dapat memasukkan teks yang ingin dianalisis seperti pada gambar 7. Di dalam textarea, terdapat placeholder yang memberikan panduan jelas tentang tata cara penggunaan fitur (temuan 4). Di bagian bawah textarea, terdapat counter karakter yang menampilkan jumlah karakter yang telah dimasukkan oleh pengguna. Counter ini secara dinamis akan memperbarui jumlah karakter saat pengguna mengetik atau menempelkan teks (temuan 2). Jika jumlah karakter mencapai batas maksimal, warna counter akan berubah menjadi merah sebagai peringatan.



Gambar 7. Analisis Teks Langsung

Setelah pengguna memasukkan teks ke dalam textarea dan menekan tombol “Jalankan Analisis”, hasil analisis akan ditampilkan di bawah textarea seperti pada gambar 8. Tampilan hasil analisis dirancang dengan warna background yang berbeda-beda, sesuai dengan sentimennya. Hal ini bertujuan untuk memberikan informasi secara ringkas namun tetap mudah dilihat dan dibedakan.




Gambar 8. Hasil Analisis Teks Langsung

Selain input manual, pengguna dapat mengunggah file dalam format CSV melalui tombol unggah file yang tersedia pada halaman Analisis dari File seperti pada gambar 9. Fitur ini memungkinkan pengguna memilih file dari perangkat mereka untuk dianalisis, sehingga pengguna dapat memproses data besar secara praktis (temuan 3). Informasi tentang format file yang diterima dan batas maksimum ukuran file juga tertera di sana.




Gambar 9. Analisis dari File

Pada gambar 10, dapat dilihat bahwa setelah mengunggah file CSV, pengguna dapat memilih kolom teks yang akan dianalisis melalui dropdown. Hasil analisis ditampilkan dalam tabel dengan kolom tambahan "hasil_analisis" berisi sentimen tiap baris, serta background kuning untuk kolom terpilih. Chart menunjukkan persentase sentimen agar mudah dipahami. Pengguna dapat mengunduh hasil analisis melalui tombol "Unduh Hasil Analisis".




Gambar 10. Hasil Analisis dari File

Pada saat pengguna membuka website, tampilan halaman akan menyesuaikan dengan ukuran layar perangkat mereka seperti pada gambar 11. Elemen-elemen seperti font, komponen, dan lainnya dirancang agar dapat menyesuaikan di layar desktop, tablet, maupun perangkat seluler (temuan 1). Setiap halaman akan terlihat proporsional dan tetap estetik.




Gambar 11. Responsif

Tampilan website otomatis menyesuaikan tema perangkat, beralih ke mode gelap atau terang tanpa pengaturan manual seperti pada gambar 12. Fitur ini meningkatkan kenyamanan dan menghadirkan pengalaman modern serta responsif (temuan 5).



Gambar 12. Tema

Model analisis sentimen dibuat dengan mengumpulkan dataset dari Kaggle, mencakup tweet politik, ulasan aplikasi, komentar media sosial, dan lainnya. Setelah preprocessing, model dilatih menggunakan Multinomial Naive Bayes, lalu diuji dengan membandingkan hasil prediksi dan label asli. Pengujian menunjukkan akurasi 73% seperti pada gambar 13, menandakan model cukup efektif dalam mengenali pola sentimen.



Gambar 13. Model Analisis Sentimen


3.3. Uji Kelayakan Solusi

Untuk mengetahui apakah rancangan solusi sudah layak digunakan, maka dilakukan usability testing. Pengujian ini dilaksanakan dengan metode SUS serta melibatkan 5 orang responden yang diminta mengoperasikan website baru (rancangan solusi) seperti pada tabel 6 [4]. Tugas-tugas yang harus diselesaikan responden merupakan tugas-tugas yang mewakili 5 identifikasi masalah utama.

Tabel 6. Responden UT Akhir


No	Nama Responden	Jenis Kelamin	Pekerjaan
1	Ratna Sari Dewi	Wanita	Data Analyst
2	Ahmad Faisal	Pria	Data Scientist
3	Citra Purnamasari	Wanita	Data Analyst
4	Tari Ayu Setiawan	Wanita	Data Analyst
5	Agus Hidayat	Pria	Data Engineer

Gambar 14 menunjukkan tampilan website lama yang tidak responsif yang mana komponen-komponennya tidak menyesuaikan dengan ukuran layar (temuan masalah 1).



Gambar 14. Task Responsif Website Lama

Sedangkan, gambar 15 menunjukkan peningkatan responsivitas pada website baru setelah dilakukan perbaikan (temuan masalah 1).



Gambar 15. Task Responsif Website Baru

Gambar 16 menunjukkan textarea pada website lama yang tidak memiliki fitur counter karakter. Hal ini menyebabkan pengguna tidak tahu batas input karakter (temuan masalah 2).

loremipsum

Produk ini sangat bagus, saya suka! 😊

Layanan sangat lambat, saya kecewa. 😞

Biasa saja, tidak ada yang istimewa. 😐


Gambar 16. Task Counter Karakter Website Lama

Sedangkan, gambar 17 menunjukkan textarea yang telah diperbaiki dengan tambahan counter karakter (temuan masalah 2).



Gambar 17. Task Counter Karakter Website Baru

Gambar 18 menunjukkan fitur baru yaitu unggah file CSV yang hanya tersedia pada website baru. Fitur ini memungkinkan pengguna untuk menganalisis banyak data sekaligus dan meningkatkan efisiensi dalam pemrosesan data (temuan masalah 3).



Gambar 18. Task Upload File

Gambar 19 menunjukkan website lama yang kurang menjelaskan format atau cara memasukkan teks yang benar. Hal ini bisa menyebabkan kesalahan input (temuan masalah 4).




Gambar 19. Task Panduan (contoh inputan) Website Lama

Sedangkan, gambar 20 menunjukkan perbaikan pada website baru dengan penambahan contoh format (temuan masalah 4).




Gambar 20. Task Panduan (contoh inputan) Website Baru

Gambar 21 menunjukkan proses analisis teks secara langsung pada website lama, yang memerlukan 5 langkah untuk mendapatkan hasil.




Gambar 21. Task Input Data Langsung Website Lama

Sedangkan, gambar 22 menunjukkan versi perbaikan dari fitur input data langsung yang pada website baru hanya memerlukan 3 langkah saja.



Gambar 22. Task Input Data Langsung Website Baru

Gambar 23 menunjukkan fitur mode gelap dan terang yang otomatis menyesuaikan dengan pengaturan tema perangkat pengguna. Dengan fitur ini, pengguna dapat menikmati pengalaman membaca yang lebih nyaman dalam segala kondisi cahaya (temuan masalah 5).



Gambar 23. Task Tema

Setelah responden menyelesaikan tugas-tugas, selanjutnya mereka diminta mengisi kuesioner SUS. Pada gambar 24, bisa dilihat hasil kalkulasi SUS menunjukkan bahwa skor yang diperoleh adalah 73, dengan kata lain website ini mencapai tingkat kegunaan yang baik dan masuk ke dalam kategori acceptable berdasarkan skala SUS. Hasil ini menegaskan bahwa website loremipsum.com sudah layak untuk digunakan [11].

Responden	Q1-1	5-Q2	Q3-1	5-Q4	Q5-1	5-Q6	Q7-1	5-Q8	Q9-1	5-Q10	Qsum
R1	3	3	4	3	3	3	3	4	2	4	32
R2	3	3	3	3	2	3	2	2	2	3	26
R3	3	3	3	3	3	3	3	3	3	3	30
R4	3	2	4	3	2	3	4	3	4	3	31
R5	3	3	3	3	3	3	2	2	2	3	27
										Qtotal	146
										Q2,5	365
										SUS Score	73

Gambar 24. Hasil UT Akhir

4. Kesimpulan

Perbaikan antarmuka website loremipsum.com menggunakan metode User Centered Design (UCD) berhasil dilakukan melalui beberapa tahap. Dimulai dari riset pengguna dengan usability testing. Lalu menggunakan metode heuristic evaluation untuk mengungkap kendala-kendala utama yang ada. Selanjutnya, iterasi dilakukan dengan memperbaiki aspek-aspek yang sudah dianalisis tersebut. Setelah implementasi selesai, evaluasi kembali dilakukan menggunakan metode System Usability Scale (SUS), yang menunjukkan peningkatan skor usability (dari 67 menjadi 73). Hasil evaluasi ini membuktikan bahwa perbaikan antarmuka ini berhasil meningkatkan kualitas pengalaman pengguna.

References

- [1] Jeddi, F. R., Nabovati, E., Bigham, R., & Farrahi, R. (2020). Usability evaluation of a comprehensive national health information system: A heuristic evaluation. *Informatics in Medicine Unlocked*, 19, 100332.
- [2] Kumoro, D. T., & Hasanah, U. (2020). Tinjauan Desain Interface Website E-Commerce Wisata Mototravel.id Menggunakan Evaluasi Heuristik. *JTIM : Jurnal Teknologi Informasi Dan Multimedia*, 2(1), 43-49.
- [3] Muzaki, A., & Witanti, A. (2021). Sentiment analysis of the community in the twitter to the 2020 election in pandemic covid-19 by method naive bayes classifier. *Jurnal Teknik Informatika (Jutif)*, 2(2), 101-107.
- [4] Nielsen, J. (1994). *Usability engineering*. Morgan Kaufmann.
- [5] Norman, D. (2013). *The Design of Everyday Things: Revised and Expanded Edition*. Hachette UK.
- [6] Prasetyo, H., & Fitriani, A. S. (2023). Sentiment Analysis Before Presidential Election 2024 Using Naïve Bayes Classifier Based On Public Opinion In Twitter. *Procedia of Engineering and Life Science*, 4.

- [7] Samuel, S. (2021). Analysis and Design of E-Commerce Based Sales Information At Pt Bahtera Ekatama Sejahtera With User Centered Design Method. *Bit-Tech*, 4(1), 14–24.
- [8] Sieghart, S. (2023). The Influence of Fonts on the Reading Performance in Easy-to-Read Texts: A Legibility Study with 145 Participants. *Design Issues*, 39(3), 30-44.
- [9] Umair, M., & Susanto, E. R. (2024). Analisis Sentimen Ulasan Pengguna Pada Aplikasi BRImo BRI Menggunakan Metode Klasifikasi Algoritma Naive Bayes. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 8(2), 1149-1159.
- [10] Verawati, I., & Jaelani, S. N. (2024). Analisis Sentimen Pengguna Twitter Terhadap Bus Listrik Menggunakan Naïve Bayes. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 8(2), 832-842.
- [11] Wahyuningrum, T. (2021). *Buku Referensi Mengukur Usability Perangkat Lunak*. Deepublish.
- [12] YU, C. H. (2023). An Eye-tracking Study: Investigating the Impact of Website Theme Colors on Viewer Engagement. *Arts, Culture and Language*, 1(4).

This page is intentionally left blank.

Data Processing Using Change Data Capture for Real-Time Data Synchronization

I Made Ari Madya Santosa^{a1}, I Gusti Ngurah Anom Cahyadi Putra^{a2}, I Ketut Gede Suhartana^{a3},
I Gede Surya Rahayuda^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas
Udayana

Kuta Selatan, Badung, Bali, Indonesia

¹arimadyasantosa@student.unud.ac.id

²anom.cp@unud.ac.id

³ikg.suhartana@unud.ac.id

⁴igedesuryarahayuda@unud.ac.id

Abstract

In an era increasingly reliant on data, seamless integration and synchronization between various systems are crucial for maintaining consistency, accuracy, and sustainability of information. Change Data Capture (CDC) is a highly effective method for detecting data changes in real-time, allowing systems to record each modification without reprocessing the entire dataset. By integrating CDC with an Event-Driven Architecture, systems can process only data changes, reducing server load and ensuring data consistency across interconnected systems. This study examines a data synchronization system built using CDC and Event-Driven Architecture on a dataset consisting of 1,000,000 records. The test results indicate strong performance, with the fastest average processing time recorded at 2.6622 milliseconds per data entry and a data loss rate of 0, ensuring high reliability. These findings demonstrate that the combination of CDC and Event-Driven Architecture offers an efficient, fast, and scalable solution for real-time data synchronization on a large scale, meeting modern system requirements.

Keywords: Change Data Capture (CDC), Event-Driven Architecture, Data Synchronization, Real-Time Processing, Data Consistency.

1. Pendahuluan

Di era yang berfokus pada data seperti sekarang, banyak organisasi bergantung pada *Sales force* sebagai pusat utama untuk mengoptimalkan proses bisnis, mengelola hubungan pelanggan, dan mendorong penjualan. Seiring bisnis berkembang dan semakin kompleksnya operasi mereka, kebutuhan untuk integrasi dan sinkronisasi data yang mulus di berbagai sistem menjadi sangat penting. Kemampuan untuk menjaga informasi yang konsisten, akurat, dan selalu terbaru di berbagai platform sangatlah penting untuk pengambilan keputusan, kepuasan pelanggan, dan kesuksesan bisnis secara keseluruhan [1]. Jika laporan yang bertentangan muncul, organisasi akan kesulitan membuat keputusan. Oleh karena itu, diperlukan suatu model pengolahan data terintegrasi yang dapat menangani ketidakkonsistenan data tersebut secara *real-time* [2].

Avatar Solution, perusahaan teknologi informasi di Denpasar, menghadapi masalah besar terkait sinkronisasi data antara data backup dan transaksi. Kesalahan sinkronisasi data dapat menyebabkan ketidaksesuaian antara kedua sistem serta masalah besar dengan keandalan dan akurasi data, yang sangat penting untuk operasi bisnis sehari-hari. Akibatnya, proses pemrosesan data dan penarikan laporan perusahaan menurun, yang menyebabkan pengambilan keputusan yang tidak optimal. Sehingga, dibutuhkan sebuah sistem yang mampu memproses data secara *real-time* untuk memastikan bahwa setiap perubahan data di sistem transaksional dapat disinkronisasi dengan tepat ke sistem backup. Solusi ini juga harus mampu secara otomatis menjaga konsistensi data di seluruh sistem.

Change Data Capture (CDC) adalah fitur penting dalam sistem manajemen basis data relasional yang memungkinkan identifikasi, pelacakan, dan ekstraksi modifikasi yang dilakukan pada data dalam basis data [3]. CDC melacak perubahan data secara *real-time*, dan jika menggunakan *binlog*, CDC dapat secara mandiri melacak perubahan yang dilakukan berdasarkan aplikasi sumber. Penggunaan CDC dengan *binlog MySQL* lebih disarankan daripada penggunaan *trigger MySQL*, karena penggunaan *MySQL* pemicu dapat memperlambat aplikasi [4].

Event-driven architecture memproses data saat data tiba secara *real-time*, daripada memprosesnya dalam batch. Pendekatan ini sangat berguna untuk aplikasi yang memerlukan latensi rendah dan *throughput* tinggi, karena memungkinkan pemrosesan data secara langsung, sehingga memberikan hasil dan respon yang cepat tanpa menunggu akumulasi data dalam jumlah besar [5].

Fokus penelitian ini adalah pengembangan sistem sinkronisasi data secara *real-time* yang memastikan konsistensi data dengan menggunakan metode *change data capture* dan *event-driven architecture*. Diharapkan, penelitian ini dapat memberikan solusi untuk dapat melakukan sinkronisasi data secara *real-time* sehingga konsistensi data antar sistem dapat terjaga dengan baik.

2. Metodologi Penelitian

2.1. Analisis Permasalahan

Peneliti melakukan observasi terhadap berbagai perusahaan teknologi informasi. Dari hasil pengamatan, muncul kebutuhan akan sebuah sistem yang mampu melakukan sinkronisasi data secara *real-time*, baik untuk data transaksional maupun *data backup*. Sistem ini diharapkan dapat menjaga konsistensi data dan mencegah kehilangan data. Selain itu, sistem juga harus dapat menerima dan memproses sejumlah besar data dalam waktu singkat.

Terdapat pula kebutuhan fungsionalitas lain untuk mempermudah dalam proses sinkronisasi seperti dapat dikontrol lewat sebuah tampilan antar muka dan kontrol terhadap jenis data yang akan di sinkronisasi berdasarkan jenis *data manipulation language* (DML).

2.2. Pengumpulan Data


Tahapan selanjutnya, penulis melakukan pengumpulan data. Dataset yang penulis gunakan didapatkan dari Kaggle. Penulis menggunakan data dari Kaggle, karena data yang dimiliki oleh perusahaan tidak diizinkan untuk disebarluaskan, karena data tersebut bersifat rahasia. Salah satu tabel pada dataset ini memiliki 1 juta baris data. Nantinya akan digenerasikan ulang menyesuaikan kebutuhan untuk merepresentasikan salah elemen dari Big Data, yaitu big volume.

2.3. Perancangan Sistem

Perancangan sistem yang digunakan dalam penelitian ini dibagi menjadi beberapa bagian yaitu perancangan alur umum sistem, perancangan *high-level change data capture* dan *event-driven architecture*, alur *change data capture* dan *event-driven architecture*, dan alur *synchronization handler service*.

2.3.1. Perancangan Alur Umum Sistem


Sistem akan menerapkan metode *change data capture* dan *event-driven architecture*. Secara garis besar sistem akan melalui tahapan-tahapan pemrosesan 16 hingga data dapat tersinkronisasi. Pertama-tama user akan masuk ke dalam sistem, kemudian user mengirimkan data konfigurasi *database source*, *database target* dan *data manipulation language* (DML) ke HTTP Service. Kemudian HTTP Service akan menyimpan konfigurasi ke *database CDC Service* dan mengirimkan *message* ke NSQ sebagai *message broker* lalu NSQ akan langsung meneruskan *message* ke *consumer*. CDC Service akan menerima *message* dari NSQ dan menjalankan proses sinkronisasi. Data yang diperoleh CDC Service akan di cek apakah data akan disinkronisasi atau tidak sesuai dengan konfigurasi yang dikirimkan oleh user. Jika data akan disinkronisasi, maka data akan dikirimkan ke *database target*. Untuk melihat gambaran alur umum sistem dapat dilihat pada Gambar 1.



Gambar 1. Perancangan Alur Umum Sistem

2.3.2. Perancangan High-level dari Change Data Capture dan Event-Driven Architecture

Penelitian akan dibuat dengan menerapkan metode *change data capture* dan *event-driven architecture* agar dapat melakukan sinkronisasi data secara *real-time*. Perancangan *High-level change data capture* dan *event-driven architecture* dapat dilihat pada Gambar 2.




Gambar 2. Perancangan High-Level Change Data Capture dan Event-Driven Architecture

Terdapat *frontend service* menggunakan teknologi Next.JS yang dapat diakses oleh user untuk menginputkan konfigurasi dari *database source*, *database target*, dan juga konfigurasi dari tipe *data manipulation language*. Kemudian terdapat juga *HTTP service* yang dibangun menggunakan Bahasa pemrograman Go berperan sebagai kontroler untuk menyimpan data konfigurasi sinkronisasi ke *database CDC service*. Terdapat juga *CDC Service* yang berperan sebagai tempat untuk dilakukannya proses sinkronisasi, dimana proses sinkronisasi ini akan membaca *log* dari *database source* yang kemudian diolah dan disinkronisasi ke *database target*. *Message broker* NSQ digunakan sebagai sebuah alat untuk melakukan *trigger* pada proses sinkronisasi.

2.3.3. Alur Event-Driven Architecture

Event-Driven Architecture pada penelitian ini mencakup beberapa elemen, yaitu Frontend Service, HTTP Service, NSQ sebagai *message broker*, *database CDC Service*, *CDC Service* dan *database target* yang menjadi destinasi data yang disinkronisasi. Untuk melihat alur dari *Event-Driven Architecture* dapat dilihat pada Gambar 3 dan dapat juga dilihat pada lampiran untuk melihat gambar dengan lebih jelas.




Gambar 3. Alur Event Driven Architecture

Sistem ini dimulai saat HTTP Service menerima *request* perubahan konfigurasi sinkronisasi dari Frontend Service, kemudian data perubahan tersebut akan disimpan di *database CDC Service* dan mengirimkan pesan ke NSQ. Saat NSQ menerima pesan maka pesan tersebut akan diteruskan ke *consumer*. *Consumer* dalam hal ini adalah CDC Service. CDC Service ketika menerima pesan dari NSQ akan melakukan pemeriksaan konfigurasi sinkronisasi pada database, jika konfigurasi sinkronisasi menunjukkan perlu dilakukannya sinkronisasi, maka

proses sinkronisasi akan dilanjutkan pada pengamatan terhadap log dari *database source*. Ketika terdapat data baru yang masuk ke dalam log *database source*, data tersebut akan dibaca oleh CDC Service dan akan dilakukan pemeriksaan apakah tipe dari data tersebut perlu disinkronisasi sesuai dengan konfigurasi yang telah ditentukan. 19 Jika perlu, maka data tersebut akan diparsing terlebih dahulu menjadi data yang sesuai untuk dikirimkan ke *database target*.

2.3.4. Alur dari CDC Service


CDC Service akan memulai proses sinkronisasi dengan menghubungkan *service* ke NSQ agar CDC Service mendapatkan *trigger* ketika terdapat perubahan konfigurasi. Setelah menerima *trigger* dari NSQ, CDC Service akan melakukan pemeriksaan data konfigurasi sinkronisasi ke *database*. Jika data konfigurasi tersebut menunjukkan bahwa sinkronisasi data harus dilakukan, maka CDC Service akan melakukan pengamatan data ke *log* dari *database source* dan akan melakukan sinkronisasi data saat data tersebut memang diinginkan untuk tersinkronisasi. Alur dapat dilihat pada Gambar 4.



Gambar 4. Alur Change Data Capture

2.3.5. Perancangan Skema Database CDC Service

Pada penelitian ini database CDC Service memiliki 4 tabel, terdapat tabel `users` yang digunakan untuk menyimpan data pengguna, kemudian terdapat tabel `sync_config` yang digunakan untuk menyimpan konfigurasi sinkronisasi dan terdapat pula tabel `sync_timestamp` yang digunakan untuk menyimpan timestamp terbaru dari data yang telah di sinkronisasi serta terdapat tabel `sync_logs` untuk menyimpan history proses sinkronisasi. Untuk melihat skema dan atribut tabel dengan lebih jelas dapat dilihat pada Gambar 5.



Gambar 5. Rancangan Skema Database CDC Service


2.3.6. Perancangan Enkripsi Kredensial Database

Seperti pada Gambar 5, tabel `sync_config` memiliki dua kolom bernama `db_source_credentials` dan `db_target_credentials`. Kedua kolom ini menyimpan string panjang hasil enkripsi yang berisi informasi kredensial lengkap untuk mengakses masing-masing database.


Proses enkripsi menggunakan algoritma HMAC SHA-256, yang menggabungkan hashing dan encoding. Hasil enkripsi berupa string panjang yang tetap dapat didekode, proses enkripsi dan validasi memerlukan secret key sebagai *signature*. Dengan secret key yang berbeda, meskipun data kredensial memiliki format dan isi yang sama, hasil enkripsinya tetap tidak valid. Hal ini memastikan bahwa jika ada perubahan pada nilai kolom tersebut yang tidak dilakukan oleh sistem, data tetap aman, dan proses sinkronisasi tidak akan terjadi.

2.3.7. Perancangan Tampilan Antar Muka


Terdapat beberapa rancangan antar muka untuk mendukung dari penggunaan sistem yang dibuat. Terdapat halaman login pada Gambar 6 agar *user* dapat masuk kedalam sistem, kemudian terdapat halaman dashboard sinkronisasi pada Gambar 7 yang menjadi halaman untuk mengatur konfigurasi sinkronisasi, dan juga terdapat halaman pengaturan pada Gambar 8 untuk mengganti password user serta terdapat halaman history sinkronisasi yang dapat dilihat pada Gambar 9.




Gambar 6. Rancangan Halaman Login



Gambar 7. Rancangan Halaman Dashboard Sinkronisasi



Gambar 8. Rancangan Halaman Pengaturan



Gambar 9. Rancangan Halaman Synchronization History

2.3.8. Implementasi

Implementasi dilakukan dengan membangun sistem sesuai dengan desain yang telah dibuat. Proses pengerjaan atau implementasi akan menggunakan Visual Studio Code untuk melakukan proses pemrograman, DBeaver untuk mengintegrasikan database dan beberapa service pendukung seperti Docker dan NSQ. Selama proses implementasi akan menggunakan metodologi *Waterfall*, yang dimana tahap awal adalah perancangan dan juga analisis kebutuhan dimana penulis akan melakukan penelitian mengenai kebutuhan dan juga perancangan sistem. Kemudian penulis akan segera melakukan pengembangan dan terakhir melakukan pengujian pada tahap akhir pengerjaan dengan metodologi ini.

2.3.9. Pengujian dan Evaluasi Sistem

Pengujian sistem bertujuan untuk melihat apakah sistem yang telah dibuat sesuai dengan tujuan awal diproduksi dan layak untuk digunakan. Pengujian pada sistem ini menggunakan metode *BlackBox Testing* dan pengujian terhadap *system throughput* serta *loss analysis*. Tujuannya adalah untuk memastikan bahwa fungsi dan komponen dalam sistem aplikasi berjalan dengan benar, memperkirakan kecepatan proses terjadinya sinkronisasi data, dan menampilkan pesan kesalahan dengan benar jika terjadi kesalahan input data. Pengujian *BlackBox* menggunakan *Positive* dan *Negative Test Case* untuk mengevaluasi fungsionalitas sistem tanpa mengetahui detail implementasinya. *Positive Test Case* dirancang untuk

memastikan bahwa sistem bekerja dengan baik ketika diberikan data atau kondisi yang valid. *Negative Test Case* bertujuan untuk menguji bagaimana sistem merespons kondisi yang tidak valid. Dengan menggabungkan kedua jenis pengujian ini, pengembang dapat mengevaluasi keandalan sistem dalam menangani berbagai skenario, baik yang diantisipasi maupun tidak. Untuk mengukur *system throughput*, akan dilakukan perhitungan dengan menghitung rata-rata kecepatan sinkronisasi data. Perhitungan tersebut dapat dilihat pada persamaan (1).

$$T_{rata} = \frac{T_{total}}{N} \quad (1)$$

Keterangan:

T_{rata} : Waktu rata-rata yang dibutuhkan untuk sinkronisasi setiap data.

T_{total} : Total waktu yang diperlukan untuk sinkronisasi seluruh data.

N : Jumlah data yang disinkronisi

Perhitungan untuk mendapatkan *data loss / loss analysis* dapat dilihat pada persamaan (2)

$$Data\ Loss\ Rate = \frac{Jumlah\ Data\ Hilang}{Total\ Data} \times 100\% \quad (2)$$

3. Hasil dan Diskusi

3.1. Hasil Pengujian Halaman Login

Pengujian yang dilakukan pada halaman login dapat dilihat pada Tabel 1.

Tabel 1. Test Case Halaman Login

No	Skenario pengujian	Test Case	Harapan Hasil	Hasil	Keterangan
1	Halaman login menampilkan form input username dan password serta tombol submit.	Memeriksa tampilan awal halaman login dengan form input untuk username, password, dan tombol submit.	Halaman login menampilkan form input untuk username, password, dan tombol submit.	Halaman login menampilkan form input untuk username dan password, serta tombol submit sesuai dengan Gambar 12.	Sesuai
2	Menampilkan pesan ketika username dan password salah	Memasukkan username dan password yang salah, lalu menekan tombol submit untuk login	Pesan error muncul yang memberi tahu bahwa username atau password yang dimasukkan salah	Pesan error muncul dengan teks "Username atau password salah" sesuai dengan Gambar 13.	Sesuai

Gambar 10. Halaman Login Awal

Gambar 11. Halaman Login Gagal

Berdasarkan hasil yang dapat dilihat pada Tabel 1 yang dibuktikan pada Gambar 10 dan Gambar 11, hasil pengujian halaman login sudah sesuai dengan yang diharapkan.


3.2. Hasil Pengujian Halaman *Dashboard Sinkronisasi*

Pengujian yang dilakukan pada halaman *dashboard* sinkronisasi dapat dilihat pada Tabel 2.


Tabel 2. Test Case Halaman *Dashboard Sinkronisasi*

No	Skenario pengujian	Test Case	Harapan Hasil	Hasil	Keterangan
1	Halaman dashboard menampilkan form input kredensial database dan jenis DML serta tombol "send" ketika proses sinkronisasi tidak dilakukan	Memeriksa tampilan awal dashboard sebelum sinkronisasi dilakukan.	Halaman menampilkan form input kredensial database, dropdown jenis DML, dan tombol "send".	Halaman menampilkan form input, dropdown jenis DML, dan tombol "send" sesuai dengan Gambar 14.	Sesuai
2	Halaman dashboard menampilkan form input kredensial database dan jenis DML serta tombol "stop" dan status "connecting" ketika tombol "send" diklik	Mengklik tombol "send" setelah mengisi form input kredensial database dan jenis DML.	Halaman menampilkan form input, tombol "stop", dan status "connecting"	Setelah tombol "send" diklik, halaman menampilkan tombol "stop" dan status "connecting" seperti pada Gambar 15.	Sesuai
3	Halaman dashboard menampilkan form input kredensial database dan jenis DML serta tombol "stop" ketika proses sinkronisasi berjalan.	Melihat status sinkronisasi pada dashboard saat sinkronisasi sedang berjalan.	Halaman menampilkan form input kredensial database, tombol "stop", dan tidak ada tombol "send"	Proses sinkronisasi berjalan, dan halaman menampilkan tombol "stop" seperti pada Gambar 16.	Sesuai


- 4
- Setiap field input yang kosong pada halaman dashboard sinkronisasi akan memberikan pesan tidak boleh kosong
- Mengosongkan salah satu atau semua field pada form dashboard sinkronisasi, lalu mencoba melanjutkan proses dengan menekan tombol "send".
- Pesan error muncul di bawah field yang kosong dengan teks "Field ini tidak boleh kosong".
- Pesan error ditampilkan di bawah field kosong, seperti pada Gambar 17.
- Sesuai



Gambar 12. Halaman *Dashboard* Sinkronisasi Awal



Gambar 13. Halaman *Dashboard* Sinkronisasi Proses Request



Gambar 14. Halaman *Dashboard* Sinkronisasi Berjalan

The screenshot shows a web application interface for database synchronization. On the left is a sidebar with 'Dashboard', 'Sync History', and 'Settings'. The main area is titled 'Configuration' and is divided into two columns: 'Database Source Credentials' and 'Database Target Credentials'. Each column contains input fields for Host, Database Name, Port, User, and Password, with red error messages indicating required fields. At the bottom, there are checkboxes for 'DML Types' (Insert, Update, Delete) and a 'Send' button.

Gambar 15. Halaman *Dashboard* Sinkronisasi Kosong

Berdasarkan hasil yang dapat dilihat pada Tabel 2 yang dibuktikan pada Gambar 12, Gambar 13, Gambar 14, dan Gambar 15 hasil pengujian halaman *dashboard* sinkronisasi sudah sesuai dengan yang diharapkan.

3.3. Hasil Pengujian *System Throughput* dan *Loss Analysis*

Perhitungan *system throughput* dan *loss analysis* dilakukan dengan melakukan sinkronisasi 1 juta data pada setiap perangkat, terdapat 4 perangkat yang digunakan untuk melakukan pengujian ini dengan spesifikasi yang berbeda. Hasil data dari pengujian yang telah dilakukan dapat dilihat pada Tabel 3.

Tabel 3. Hasil Pengujian *System Throughput* dan *Loss Analysis*

Spesifikasi Perangkat	Total Kecepatan (ms)	Rata-rata Kecepatan (ms)	Waktu tercepat (ms)	Waktu Terlama (ms)	Data Hilang
CPU: Apple M1 RAM: 8GB	2.662.205	2,6622	1	447	0
CPU: Intel Core i7 1165G7 (4-core, 2,8GHz) RAM: 8GB	3.028.300	3,0283	1	509	0
CPU: Intel Core i5 1135G7 (4-core, 2,4GHz) RAM: 8GB	3.786.600	3,7866	1	573	0
CPU: Intel Core i3 1005G1 (2-core, 1,2GHz) RAM: 4GB	5.250.200	5,2502	1	699.	0

Berdasarkan hasil dari Tabel 3, dengan pengujian sinkronisasi 1 juta data secara beruntun, proses sinkronisasi memerlukan waktu yang bervariasi tergantung dengan spesifikasi perangkat yang digunakan, namun walaupun terdapat perbedaan waktu yang dibutuhkan untuk melakukan sinkronisasi, pengujian pada 4 perangkat tersebut tidak terdapat adanya data yang hilang.

4. Kesimpulan

Berdasarkan penelitian yang telah dilaksanakan dan juga hasil yang diperoleh dari penelitian, dapat ditarik beberapa kesimpulan sebagai berikut:

- a. Change Data Capture (CDC) adalah sebuah metode yang dapat digunakan untuk mendeteksi perubahan data dalam sistem basis data. CDC memungkinkan sistem untuk memantau dan merekam setiap perubahan yang terjadi pada data, seperti operasi penambahan, penghapusan, atau pembaruan, secara real-time. Dengan memanfaatkan metode ini, perusahaan dapat memastikan bahwa data yang berada di berbagai sistem selalu up-to-date tanpa harus melakukan pemrosesan ulang seluruh dataset. Penggunaan CDC dan arsitektur Event-Driven secara bersamaan memberikan berbagai keuntungan signifikan. Selain memastikan bahwa data di seluruh sistem tetap konsisten, metode ini juga membantu mengurangi beban kerja server karena hanya perubahan data yang diproses, bukan seluruh dataset.
- b. Sistem sinkronisasi data yang dirancang menggunakan metode Change Data Capture (CDC) dan Event-Driven Architecture terbukti dapat melakukan sinkronisasi dengan baik berdasarkan hasil pengujian. Dalam pengujian dengan 1.000.000 data yang dilakukan pada 4 perangkat dengan spesifikasi berbeda, sistem ini mencapai performa rata-rata waktu pemrosesan sebesar 2,6622 milidetik hingga 5,2502 milidetik per data tergantung dari spesifikasi perangkat yang digunakan. Selain itu, pengujian pada 4 perangkat dengan spesifikasi berbeda juga memperoleh hasil data yang hilang sebanyak 0 data.
- c. Sistem sinkronisasi yang telah dibangun juga dapat digunakan dengan baik oleh pengguna, dibuktikan dengan hasil pengujian blackbox memperoleh hasil yang sesuai pada setiap test-case.

Referensi

- [1] A. Tangudu, P. K. G. Pandian and S. Jain, "Developing Scalable APIs for Data Synchronization in Salesforce Environments," *Modern Dynamics: Mathematical Progressions*, vol. 1, no. 2, pp. 44-57, 2024.
- [2] I. G. Adnyana and I. M. D. J. Sulastra, "Implementation of Data Backup and Synchronization Based on Identity Column Real Time Data Warehouse," *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, vol. 11, no. 1, p. 9, 2020.
- [3] K. K. Ganeeb, V. Jayaram, M. S. Krishnappa, P. K. Veerapaneni and S. R. Sankiti, "A Comprehensive Study of Custom Change Data Capture on a Large Scale RDBMS," *International Journal of Research and Analytical Reviews*, vol. 11, no. 3, p. 838, 2024.
- [4] H. Setiawan, A. A. A. Sumitro and R. Gustriansyah, "The Change Data Capture and the Web Application Messaging Protocol on the Real Time Dashboard.," *International Journal of Engineering and Advanced Technology (IJEAT)*, vol. 8, no. 4, 2019.
- [5] A. Mantri, "Event Driven Data Architecture: Design and Implementation with Kinesis and Spark Streaming," *International Journal of Science and Research (IJSR)*, vol. 13, no. 7, pp. 653-655, 2024.

Analisis Sentimen Berbasis Aspek Terhadap Aplikasi *Mobile Banking* Dengan Metode *Convolutional Neural Network (CNN)* Dan *PCA*

I Made Juniandika^{a1}, Gst. Ayu Vida Mastrika Giri^{a2}, Anak Agung Istri Ngurah Eka Karyawati^{b3}, I Gusti Ngurah Anom Cahyadi Putra^{b4}

^aProgram Studi Informatika, Universitas Udayana
Kuta Selatan, badung, Bali, Indonesia
¹juniandika7072@email.com
²vida@unud.ac.id

^bProgram Studi Informatika, Universitas Udayana
Kuta Selatan, badung, Bali, Indonesia
³eka.karyawati@unud.ac.id
⁴anom.cp@unud.ac.id

Abstrak

Analisis sentimen adalah proses untuk menilai dan memahami opini yang terkandung dalam teks yang dihasilkan oleh pengguna. Dalam konteks aplikasi mobile banking, pendekatan analisis sentimen berbasis aspek efektif untuk mengevaluasi opini pengguna mengenai fitur-fitur tertentu. Penelitian ini memanfaatkan metode Convolutional Neural Network (CNN) untuk menganalisis sentimen dan aspek dengan memproses fitur-fitur teks secara mendalam. Selain itu, digunakan Principal Component Analysis (PCA) untuk mereduksi dimensi data, yang mempercepat proses analisis tanpa mengorbankan informasi penting. Hasil penelitian menunjukkan bahwa kombinasi metode CNN dan PCA dengan pengaturan hyperparameter terbaik menghasilkan akurasi 96% untuk klasifikasi sentimen, 87% untuk klasifikasi aspek positif, dan 86% untuk klasifikasi aspek negatif, dengan waktu pelatihan rata-rata masing-masing 0,4 menit, 2 menit, dan 0,7 menit. Tanpa PCA, akurasi meningkat menjadi 98% untuk sentimen, 79% untuk aspek positif, dan 88% untuk aspek negatif, tetapi waktu pelatihan jauh lebih lama, yaitu 13 menit, 7 menit, dan 4 menit. Meskipun PCA sedikit mengurangi akurasi, efisiensi waktu yang ditawarkannya memberikan keuntungan besar dalam analisis sentimen berbasis aspek, membantu pengembang aplikasi untuk lebih memahami kebutuhan pengguna dan meningkatkan kualitas layanan.

Keywords: Analisis Sentimen, Convolutional Neural Network, PCA, Hyperparameter, efisiensi waktu.


1. Pendahuluan

BRImo merupakan aplikasi keuangan digital berbasis *mobile* yang dimiliki oleh Bank Rakyat Indonesia (BRI) yang diciptakan untuk memberikan kemudahan bagi nasabah dalam melakukan proses transaksi perbankan secara online. Berdasarkan data pada situs Google Play pada tanggal 24 Maret 2023, aplikasi BRImo tercatat memiliki rating sebesar 4,5 dengan jumlah unduhan kurang lebih sebesar 10 juta dan ulasan komentar pengguna sebesar 1.09 juta (*BRImo BRI - Apps on Google Play*, 2023). Ulasan komentar dari pengguna aplikasi pada *Play Store* terdiri dari *review* positif dan negatif yang dapat dijadikan sebagai bahan untuk melakukan analisis sentimen dan aspek dari aplikasi serta dijadikan sebagai tolak ukur terhadap kinerja aplikasi sehingga dapat dilakukan perbaikan[1]. Maka dari itu, diperlukan suatu metode klasifikasi teks untuk melakukan analisis dari ulasan pengguna aplikasi menggunakan metode *Convolutional Neural Network (CNN)*. Penggunaan metode yang sesuai tidaklah cukup, seringkali terdapat permasalahan lainnya ketika membangun model yaitu durasi waktu yang diperlukan model untuk memproses data. Semakin banyak fitur dalam data, semakin besar dimensi yang akan dihasilkan, maka waktu eksekusi yang dibutuhkan model juga akan semakin lama. Oleh karena itu diperlukan suatu metode untuk melakukan reduksi dimensi yang dapat mengurangi jumlah dimensi dari fitur data tanpa menghilangkan informasi penting dari data tersebut, sehingga waktu eksekusi dapat dipangkas, salah satunya dengan menggunakan PCA.

Pada penelitian ini peneliti melakukan analisis sentimen dengan dua kelas yaitu positif dan negatif beserta aspek meliputi aspek kemudahan transaksi, kemudahan penggunaan aplikasi, transaksi gagal, gangguan sistem/jaringan, perekaman wajah, dan aspek lainnya pada ulasan aplikasi BRImo pada *Google Play* dengan jumlah dataset sebanyak 10.000 data, menggunakan *hyperparameter tuning* untuk mengetahui pemodelan yang menghasilkan akurasi tertinggi, serta penggunaan PCA untuk mempercepat proses pelatihan model. Sistem analisis sentimen dibangun menggunakan metode *Convolutional Neural Network* (CNN) dengan analisa sentimen dari bahasa Indonesia. Penelitian ini diharapkan dapat membantu para pengembang aplikasi untuk mengevaluasi kinerja dari aplikasi BRImo serta melakukan peningkatan layanan dari aplikasi tersebut.

2. Metode Penelitian

Metode penelitian yang digunakan pada penelitian ini adalah dengan menggunakan metode eksperimen dengan urutan langkah-langkah dalam alur metode penelitian pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

1. Pengumpulan Data

Langkah awal dalam penelitian ini adalah melakukan pengumpulan data ulasan aplikasi BRImo pada kolom komentar *Google Play Store*. Proses pengambilan data ini menggunakan library dari package *pandas* yaitu *google-play-scraper* dengan bahasa pemrograman *Python*. Hasil dari scrapping ini akan disimpan pada file berformat *.csv*.

Terdapat dua jenis data yang digunakan dalam penelitian ini yaitu data latih sebanyak 80% dan data uji sebanyak 20%. Untuk analisis sentimen, data yang dipilih adalah data yang memiliki rating 1 dan 5. Pemilihan rating 1 untuk mewakili ulasan dengan sentimen negatif dan rating 5 mewakili ulasan bersentimen positif. Sementara untuk analisis aspek data yang digunakan adalah data sentimen positif dan negatif yang masing-masing berjumlah 5000 data. Untuk klasifikasi aspek bersentimen positif terdiri dari tiga kelas aspek yaitu aspek kemudahan transaksi sebanyak 2343 data, aspek kemudahan penggunaan aplikasi sebanyak 360 data, dan aspek lainnya sebanyak 2297 data. Sedangkan untuk klasifikasi aspek bersentimen negatif terdiri dari empat kelas aspek yaitu aspek transaksi gagal sebanyak 1166 data, aspek gangguan sistem/jaringan sebanyak 1200 data, aspek perekaman wajah sebanyak 1404 data,

dan aspek lainnya sebanyak 1230 data. Distribusi data yang digunakan untuk klasifikasi aspek dapat dilihat pada Tabel 1.


Tabel 1. Distribusi Dataset untuk Klasifikasi Aspek

Sentimen	Aspek	Jumlah Data
Positif	Kemudahan Transaksi	2343
	Kemudahan Penggunaan Aplikasi	360
	Lainnya	2297
Negatif	Kegagalan Transaksi	1166
	Gangguan Sistem/Jaringan	1200
	Perekaman Wajah	1404
	Lainnya	1230

Berdasarkan Tabel 1 dapat dilihat perbandingan label aspek untuk data bersentimen positif sangat tidak berimbang hal ini dapat menyebabkan turunnya performa pada metode yang akan digunakan sehingga diperlukan teknik oversampling.

Pada Gambar 2 dapat dilihat jumlah data aspek bersentimen positif yang akan digunakan berimbang pada setiap label aspek yang ada. Total keseluruhan data yang digunakan untuk klasifikasi aspek bersentimen positif sebanyak 7029 data.


Gambar 2. Jumlah Data Aspek Positif Setelah Sampling Data



Pelabelan aspek memanfaatkan fitur pencarian pada kolom ulasan bersentimen positif dan negatif dengan menggunakan beberapa kata kunci seperti transaksi, penggunaan aplikasi, sinyal/jaringan, dan perekaman wajah. Hal ini dikarenakan pada penelitian ini hanya menggunakan ulasan yang menyinggung tentang kemudahan dan kegagalan transaksi, kemudahan penggunaan aplikasi, gangguan sistem/jaringan, dan perekaman wajah.

2. Preprocessing

Tahapan *preprocessing* teks mencakup *format text spacing*, *case folding*, *remove noise*, *remove emoji*, tokenisasi, *slang word*, *remove stop word*, dan *stemming*. Alur tahap *preprocessing* dapat dilihat pada Gambar 3.



Gambar 3. *Text Preprocessing*

Format *text spacing* mengatur format tanda baca dan spasi agar lebih rapi seperti menambahkan spasi setelah tanda baca titik dan koma, menghapus spasi berlebih di antara kata-kata, serta menghilangkan spasi di awal dan akhir teks. *Case folding* untuk dengan mengubah huruf besar menjadi huruf kecil. *Remove Noise* untuk menghilangkan elemen-elemen yang tidak relevan dalam teks, seperti simbol, tag, angka, atau karakter aneh. *Remove Emoji* untuk menghilangkan emoji pada teks menggunakan library emoji. Tokenizing untuk memecah string masukan menjadi token-token per kata. *Slang word* untuk merubah kata-kata yang mengalami kesalahan dalam ejaan penulisan. *Stopword Removal*. Tahapan ini bertujuan untuk menghapus kata-kata yang tidak berhubungan dengan dokumen. *Stemming* dilakukan untuk mendapatkan kata dasar dari setiap kata dalam teks. *Oversampling* digunakan untuk menyeimbangkan jumlah data aspek sentimen positif sehingga masing-masing kelas aspeknya memiliki jumlah data yang sama.

3. Word2vec

Pada penelitian ini *word embedding* yang digunakan adalah *word2vec* untuk mengkonversi teks menjadi representasi numerik dalam bentuk *vector*. Penggunaan *word2vec* didasarkan pada penelitian yang dilakukan oleh Pratama, Murdiansyah dan Lhaksana (2023) yang menyatakan bahwa *word2vec* membantu meningkatkan kinerja model klasifikasi.

4. Reduksi Dimensi

Dalam penelitian ini akan menguji metode dengan penerapan reduksi dimensi menggunakan PCA dan tanpa reduksi dimensi. Reduksi dimensi dengan PCA akan mengambil informasi penting dalam data yang besar dengan menemukan pola pada dimensi yang paling tinggi[2]


serta menghasilkan dimensi sebesar k *principal component* yang digunakan sedangkan tanpa reduksi dimensi langsung menggunakan dimensi yang dihasilkan dari vektor kalimat.

5. Klasifikasi Sentimen dan Klasifikasi Aspek


Klasifikasi sentimen dan aspek menggunakan *convolutional neural network*. Penerapan klasifikasi sentimen dilakukan terlebih dahulu dikarenakan perbedaan aspek yang terdapat antara data bersentimen positif dengan data bersentimen negatif. Gambar 4 dan 5 merupakan arsitektur metode CNN untuk mesin klasifikasi sentimen dan aspek. Setelah dilakukan proses *word embedding* dan penerapan reduksi dimensi menggunakan PCA maupun tanpa reduksi dimensi pada data, selanjutnya akan masuk dan diproses ke dalam lapisan-lapisan yang ada pada arsitektur CNN yang meliputi lapisan *convolutional*, lapisan *max pooling*, lapisan *flatten*, lapisan *dropout*, dan lapisan *fully connected*.

Pada penelitian ini, penulis menggunakan konvolusi 1D. Pemilihan konvolusi 1D dikarenakan sangat efektif dalam menurunkan fitur dari segmen dengan panjang yang tetap dari keseluruhan dataset dan bekerja dengan baik untuk permasalahan NLP[3]. Setelah itu dilakukan operasi perkalian dan penjumlahan antara bobot *filter* dan bobot dari matriks *input*, serta operasi *non-linear* menggunakan fungsi aktivasi *ReLU*. *ReLU* digunakan karena memiliki keuntungan kompleksitas rendah[4]. Proses tersebut akan menghasilkan *feature map*

Lapisan *flatten* ditambahkan untuk memastikan dimensi dari vektor sesuai dengan input yang diharapkan oleh lapisan berikutnya[5]. Menambahkan lapisan *dropout* untuk mencegah *overfitting*. Tahapan terakhir yaitu *output layer*. Dalam *output layer* pada mesin klasifikasi sentimen terdapat *fully connected layer* yang memiliki 1 neuron dengan menggunakan fungsi aktivasi *sigmoid*. *Sigmoid* digunakan untuk permasalahan klasifikasi biner. Sedangkan untuk mesin klasifikasi aspek positif menggunakan jumlah neuron 3 pada *output layer* dan pada mesin klasifikasi aspek negatif, pada *output layer* jumlah neuron sebanyak 4. Fungsi aktivasi yang digunakan untuk kedua model aspek tersebut yaitu *softmax*. *Softmax* digunakan untuk permasalahan klasifikasi *multiclass*



Gambar 4. Arsitektur Mesin Klasifikasi Sentimen



Gambar 5. Arsitektur Mesin Klasifikasi Aspek

6. Tuning Hyperparameter

Tahapan ini dilakukan untuk menyeleksi model terbaik dengan metode *k-fold validation* dengan jumlah data yang digunakan adalah 80% *data training*. Jumlah fold yang digunakan sebanyak lima dengan tujuan untuk mendapatkan kombinasi hyperparameter dengan performa terbaik. *Hyperparameter* yang akan diatur sehingga mendapatkan model CNN terbaik adalah *learning rate*, *batch size*, dan *epoch*. Nilai *hyperparameter* yang akan diuji pada model untuk klasifikasi sentimen dapat dilihat pada Tabel 2. Sedangkan untuk *hyperparameter* yang akan diuji pada model klasifikasi aspek dapat dilihat pada Tabel 3.

Tabel 2. *Hyperparameter* Model Klasifikasi Sentimen

No	Parameter	Ukuran
1	Jumlah filter	64
2	Kernel size	2
3	Learning rate	0.01, 0.001, 0.0001
4	Batch size	16, 32, 64
5	Epoch	5, 10, 15

Tabel 3. *Hyperparameter Model Klasifikasi Aspek*

No	Parameter	Ukuran
1	Jumlah filter	64
2	Kernel size	2
3	Learning rate	0.01, 0.001, 0.0001
4	Batch size	16, 32, 64
5	Epoch	15, 20, 25

7. Pengujian Model

Pengujian Model dievaluasi menggunakan *confusion matrix* untuk menguji model terbaik berdasarkan nilai akurasi, *precision*, *recall*, dan *f-1 score*. Data yang digunakan adalah data *testing* (20% data). Evaluasi akurasi, *precision*, *recall*, dan *f-1 score* akan memberikan nilai berupa persentase dari hasil klasifikasi *Convolutional Neural Network* dengan reduksi dimensi menggunakan PCA dan tanpa reduksi dimensi, sehingga bila nilai semakin mendekati 1 maka model yang dibuat semakin baik.

3. Hasil dan Pembahasan

Tahap ini menjelaskan performa model *Convolutional Neural Network* (CNN) dalam klasifikasi sentimen dan klasifikasi aspek, baik ketika menggunakan reduksi dimensi dengan metode *Principal Component Analysis* (PCA) maupun tanpa reduksi dimensi. Proses ini bertujuan untuk mengevaluasi sejauh mana *hyperparameter* terbaik mampu meningkatkan kinerja model. Untuk mengukur performa model klasifikasi, digunakan metode evaluasi *confusion matrix*.

Evaluasi dilakukan dengan *data testing*. Hasil evaluasi model terbaik untuk klasifikasi sentimen dengan reduksi dimensi PCA menggunakan *tuning hyperparameter learning rate* 0.001, *batch size* 32, dan *epoch* 10. Performa model klasifikasi sentimen dengan reduksi dimensi PCA menggunakan *data testing* menunjukkan performa baik. Dapat dilihat pada Tabel 4.

Tabel 4. Evaluasi Model Klasifikasi Sentimen dengan Reduksi Dimensi PCA

	precision	recall	f-1 score	Jumlah data
Positif	0.97	0.96	0.96	1012
Negatif	0.96	0.97	0.96	988
Accuracy			0.96	2000
Avg	0.96	0.96	0.96	2000

Hasil evaluasi model klasifikasi sentimen tanpa reduksi dimensi dengan *tuning hyperparameter learning rate* 0.001, *batch size* 16, dan *epoch* 15 dapat dilihat pada Tabel 5.

Tabel 5. Evaluasi Model Klasifikasi Sentimen Tanpa Reduksi Dimensi

	precision	recall	f-1 score	Jumlah data
Positif	0.99	0.97	0.98	1012
Negatif	0.97	0.99	0.98	988
Accuracy			0.98	2000
Avg	0.98	0.98	0.98	2000

Dalam proses evaluasi model klasifikasi aspek, pengujian dilakukan dengan menggunakan *data testing* untuk menilai performa model yang telah dilatih. Model terbaik untuk klasifikasi aspek bersentimen positif dengan reduksi dimensi menggunakan PCA diperoleh melalui proses tuning hyperparameter. Hyperparameter optimal yang digunakan adalah learning rate 0.001, batch size 32, dan epoch 25 dapat dilihat pada Tabel 6.

Tabel 6. Evaluasi Model Klasifikasi Aspek Positif dengan Reduksi Dimensi PCA

	precision	recall	f-1 score	Jumlah data
Kemudahan Transaksi	0.89	0.86	0.87	485
Kemudahan Penggunaan Aplikasi	0.90	0.95	0.92	471
Lainnya	0.83	0.80	0.81	450
Accuracy			0.87	1406
Avg	0.87	0.87	0.87	1406

Untuk model klasifikasi aspek bersentimen positif tanpa reduksi dimensi, nilai akurasi terbaik diperoleh dengan nilai learning rate 0.01, batch size 64, dan epoch 25 dapat dilihat pada Tabel 7.

Tabel 7. Evaluasi Model Klasifikasi Positif Tanpa Reduksi Dimensi PCA

	precision	recall	f-1 score	Jumlah data
Kemudahan Transaksi	0.82	0.80	0.81	485
Kemudahan Penggunaan Aplikasi	0.83	0.81	0.82	471
Lainnya	0.70	0.75	0.72	450
Accuracy			0.79	1406
Avg	0.79	0.78	0.78	1406

Model terbaik untuk klasifikasi aspek negatif dengan reduksi dimensi menggunakan PCA diperoleh melalui proses *tuning hyperparameter*. *Hyperparameter* optimal yang digunakan adalah *learning rate* 0.0001, *batch size* 16, dan *epoch* 25 dapat dilihat pada Tabel 8.

Tabel 8. Evaluasi Model Klasifikasi Aspek Negatif dengan Reduksi Dimensi PCA

	precision	recall	f-1 score	Jumlah data
Perekaman Wajah	0.91	0.95	0.93	260
Transaksi Gagal	0.86	0.74	0.80	252
Gangguan Sistem/Jaringan	0.95	0.89	0.92	246
Lainnya	0.75	0.87	0.81	242
Accuracy			0.86	1000
Avg	0.87	0.86	0.86	1000

Evaluasi selanjutnya adalah model klasifikasi aspek negatif tanpa reduksi dimensi dengan menggunakan *tuning hyperparameter learning rate* 0.01, *batch size* 64, dan *epoch* 20 dapat dilihat pada Tabel 9.

Tabel 9. Evaluasi Model Klasifikasi Aspek Negatif Tanpa Reduksi Dimensi


	precision	recall	f-1 score	Jumlah data
Perekaman Wajah	0.95	0.97	0.96	260
Transaksi Gagal	0.75	0.81	0.79	252
Gangguan Sistem/Jaringan	0.98	0.96	0.97	246
Lainnya	0.82	0.76	0.79	242
Accuracy			0.88	1000
Avg	0.88	0.88	0.88	1000

Tabel 10 menyajikan perbandingan akurasi dan waktu pelatihan (*training time*) untuk masing-masing model klasifikasi yang telah dilatih. Hasil evaluasi menunjukkan bahwa semua model menunjukkan performa yang baik ketika diuji dengan *data testing (unseen data)*.

Tabel 10. Perbandingan Akurasi Training dan Testing model klasifikasi.

	Akurasi Validasi	Akurasi Testing	Training Time
Model Klasifikasi Sentimen dengan Reduksi Dimensi PCA	97%	96%	23 detik / 0.4 menit
Model Klasifikasi Sentimen tanpa Reduksi Dimensi	99%	98%	775 detik / 13 menit
Model Klasifikasi Aspek Positif dengan Reduksi Dimensi PCA	86%	87%	130 detik/2 menit
Model Klasifikasi Aspek Positif tanpa Reduksi Dimensi PCA	81%	79%	415 detik/7 menit
Model Klasifikasi Aspek Negatif dengan Reduksi Dimensi PCA	86%	86%	44 detik / 0.7 menit
Model Klasifikasi Aspek Negatif tanpa Reduksi Dimensi	89%	88%	229 detik / 4 menit

Gambar 6. Perbandingan Akurasi *Training* dan *Testing* Model Klasifikasi



4. Kesimpulan

Penelitian ini bertujuan untuk menganalisis kinerja model dalam menganalisis sentimen dan aspek pengguna terhadap aplikasi BRImo. Melalui penggunaan algoritma CNN dan PCA diperoleh kesimpulan sebagai berikut:

1. Penggunaan PCA untuk reduksi dimensi pada model klasifikasi sentimen dan aspek mempengaruhi akurasi dan waktu pelatihan. Model sentimen dengan PCA memiliki akurasi 96%, sedikit lebih rendah dari 98% tanpa PCA. Pada model aspek positif, PCA meningkatkan akurasi menjadi 87% dari 79% tanpa PCA, sementara pada aspek negatif, PCA menurunkan akurasi menjadi 86% dari 88%. Namun, model dengan PCA lebih efisien dalam waktu pelatihan. Model sentimen hanya membutuhkan 0,4 menit, model aspek positif hanya

membutuhkan waktu 2 menit, dan model aspek negatif membutuhkan waktu 0.7 menit. Sedangkan tanpa PCA model sentimen, model aspek positif, dan model aspek negatif masing-masing memerlukan waktu 13 menit, 7 menit, dan 4 menit.

References

- [1] R. Wahyudi dan G. Kusumawardana, "Analisis Sentimen pada Aplikasi Grab di Google Play Store Menggunakan Support Vector Machine," *J. Inform.*, vol. 8, no. 2, hal. 200–207, 2021, doi: 10.31294/ji.v8i2.9681.
- [2] Y. Pratama, D. T. Murdiansyah, dan K. M. Lhaksmana, "Analisis Sentimen Kendaraan Listrik Pada Media Sosial Twitter Menggunakan Algoritma Logistic Regression dan Principal Component Analysis," *J. Media Inform. Budidarma*, vol. 7, no. 1, hal. 529–535, 2023, doi: 10.30865/mib.v7i1.5575.
- [3] N. Nurdin, I. Musyawarah, N. Nurfitriani, dan A. Jalil, "Pengaruh Pelayanan Mobile Banking Terhadap Kepuasan Nasabah (Studi Pada Mahasiswa Perbankan Syariah IAIN Palu)," *J. Ilmu Perbank. dan Keuang. Syariah*, vol. 2, no. 1, hal. 87–104, 2020, doi: 10.24239/jipsya.v2i1.24.87-104.
- [4] S. N. Listyarini dan D. A. Anggoro, "Analisis Sentimen Pilkada di Tengah Pandemi Covid-19 Menggunakan Convolution Neural Network (CNN)," *J. Pendidik. dan Teknol. Indones.*, vol. 1, no. 7, hal. 261–268, 2021, doi: 10.52436/1.jpti.60.
- [5] I. M. A. Susilayasa, A. A. I. Eka Karyawati, L. G. Astuti, L. A. A. Rahning Putri, I. G. Arta Wibawa, dan I. K. Ari Mogi, "Analisis Sentimen Ulasan E-Commerce Pakaian Berdasarkan Kategori dengan Algoritma Convolutional Neural Network," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 11, no. 1, hal. 1, 2022, doi: 10.24843/jlk.2022.v11.i01.p01.

This page is intentionally left blank.

Implementasi Fitur Keamanan Enkripsi End-To-End Pada Aplikasi Bimbingan Online Tugas Akhir Berbasis Website

I Putu Krisna Megadana^{a1}, I Gusti Ngurah Anom Cahyadi Putra^{a2}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Jimbaran, Kuta Selatan, Badung, Bali, Indonesia

¹krisnamegadana104@student.unud.ac.id

²anom.cp@unud.ac.id

Abstract

Data security is one of the main challenges in digital era, especially in web-based applications used for online final assignment guidance services. This study aims to implement an end-to-end encryption security feature using the RSA algorithm in a web-based online guidance application. The RSA algorithm was selected for its reliability as a public key cryptography method, enabling data to be accessed only by parties possessing the corresponding private key. The research process includes system requirement analysis, system design, RSA algorithm implementation for data encryption and decryption, and application security testing. Testing results demonstrate that this feature provides robust data protection, ensuring that information is accessible only to authorized individuals. senders and recipients. Through the application of this security feature, this research is expected to enhance user trust in online guidance services, safeguard personal data, and serve as a reference for other developers in implementing secure and efficient encryption technologies.

Keywords: Data Security, End-to-End Encryption, RSA, Web Application, Online Guidance

1. Pendahuluan

Dalam era digital saat ini, layanan bimbingan online semakin populer dan diterima secara luas sebagai solusi alternatif untuk memperoleh akses ke pembelajaran tanpa harus berada di ruang kelas secara fisik. Teknologi berbasis web memberikan kemudahan akses informasi yang cepat, fleksibilitas, dan kenyamanan. Namun, kemajuan ini diiringi dengan meningkatnya risiko keamanan, khususnya dalam melindungi data sensitif pengguna seperti informasi pribadi dan catatan bimbingan [6].

Masalah keamanan menjadi salah satu perhatian utama karena aplikasi berbasis web rentan terhadap serangan siber, seperti penyadapan, manipulasi data, dan pencurian identitas. Menurut laporan terbaru, insiden kebocoran data meningkat setiap tahunnya, yang sering kali menyebabkan hilangnya kepercayaan pengguna terhadap platform online. Oleh karena itu, perlindungan data melalui sistem keamanan yang efektif menjadi kebutuhan mendesak, terutama dalam layanan yang melibatkan interaksi pengguna secara langsung [10].


Algoritma RSA (Rivest-Shamir-Adleman) adalah salah satu metode kriptografi berbasis kunci publik terkemuka, telah terbukti andal dalam melindungi data melalui proses enkripsi dan dekripsi. Keunggulan utama RSA terletak pada kemampuan enkripsi data menggunakan kunci publik yang hanya dapat didekripsi oleh kunci privat yang sesuai. Metode ini menjamin bahwa data hanya dapat diakses oleh pihak yang memiliki otoritas, sehingga mencegah akses tidak sah [3][1].

Dalam konteks layanan bimbingan online, implementasi fitur keamanan berbasis enkripsi end-to-end menggunakan algoritma RSA sangat relevan. Fitur ini tidak hanya melindungi privasi pengguna, tetapi juga meningkatkan kepercayaan terhadap sistem. Dengan mengintegrasikan teknologi enkripsi ini, layanan bimbingan online dapat menawarkan pengalaman yang lebih aman dan andal kepada pengguna, memastikan bahwa data sensitif tetap terlindungi sepanjang proses bimbingan.

2. Metode Penelitian

2.1. Waterfall

Metode Waterfall, atau dikenal sebagai Linear Sequential Model, merupakan pendekatan sistematis dan berurutan dalam pengembangan perangkat lunak. Model ini pertama kali diperkenalkan oleh Winston Royce pada tahun 1970 dan tetap menjadi salah satu model yang banyak digunakan dalam software engineering (SE). Model Waterfall terdiri dari beberapa tahapan yang harus diselesaikan secara berurutan, dimulai dari spesifikasi kebutuhan, perencanaan, permodelan, konstruksi, deployment, hingga pemeliharaan [5][8]. Karakteristik utama model ini adalah sifatnya yang linear, di mana setiap tahapan harus diselesaikan sebelum melanjutkan ke tahap berikutnya tanpa dapat kembali ke tahap sebelumnya seperti pada gambar 1.



Gambar 1. Diagram Waterfall

2.2. Analisis Kebutuhan Sistem

Tahapan ini bertujuan untuk memahami secara mendalam kebutuhan fungsional dan non-fungsional yang diperlukan oleh sistem yang akan dibangun. Kebutuhan fungsional berfokus pada fitur dan fungsi utama yang mendukung operasional sistem, seperti penerapan algoritma RSA untuk menjaga kerahasiaan data seperti pada gambar 2.

No	Deskripsi Kebutuhan Fungsional
KF1	Sistem yang dibangun dapat menampilkan halaman yang memiliki fitur-fitur untuk mendukung bimbingan online, seperti pengiriman pesan dan dokumen.
KF2	Sistem mampu menerima input file dokumen dalam format *.pdf.
KF3	Sistem mampu melakukan enkripsi data pengguna atau catatan bimbingan menggunakan algoritma RSA sebelum data dikirim.
KF4	Sistem mampu mendekripsi data pengguna atau catatan bimbingan terenkripsi di sisi penerima menggunakan kunci privat.
KF5	Sistem mampu pengunduhan dan pengunggahan file kepada pengguna penerima/pengirim.
KF6	Sistem mampu mengelola validasi kunci publik dan kunci privat untuk memastikan proses enkripsi dan dekripsi berjalan dengan benar.
KF7	Sistem mampu menyimpan data pengguna dan catatan bimbingan dalam bentuk terenkripsi di database untuk menjaga kerahasiaan.
KF8	Sistem mampu melakukan forgot password yang akan di kirimkan ke email
KF9	Sistem mampu melakukan perhitungan lama revisi dan lama review
KF10	Sistem mampu melakukan update data pengguna

Gambar 2. Analisis kebutuhan fungsional


Tabel 1. Analisis Kebutuhan non-fungsional

No.	Perangkat	Keterangan
1.	Laptop	Asus Zenbook Pro Duo
2.	Processor	Intel(R) Core(TM) i7-10510U
3.	Monitor	16 inches
4.	RAM	16 GB
5.	SSD	475 GB
6.	Windows	Sistem operasi windows 11
7.	Dekstop	
8.	Visual Studio Code	<i>Text editor</i> yang digunakan untuk membangun aplikasi website
9.	Xampp	<i>Database</i> yang di gunakan untuk menyimpan data
10.	Browser	Untuk menjalankan aplikasi website yang sudah di buat


Pada tabel 1, dapat di lihat kebutuhan non-fungsional mencakup aspek-aspek teknis yang menunjang performa, keamanan, dan efisiensi sistem.

2.3. Use case Diagram

Diagram use case adalah sebuah diagram yang berfungsi untuk menggambarkan berbagai aktivitas yang dapat dijalankan oleh suatu sistem [7]. Berikut adalah gambaran Use case diagram enkripsi dan dekripsi pada gambar 3 dan gambar 4.




Gambar 3. Use case enkripsi



Gambar 4. Use case dekripsi

2.4. Implementasi Algoritma Rsa

Pada tahap implementasi, algoritma RSA diterapkan untuk memastikan data pengguna seperti NIM, NIP, email, dan password dienkripsi sebelum disimpan atau ditransmisikan. Proses ini melibatkan pembangkitan kunci publik dan privat menggunakan openssl, serta pengintegrasian proses enkripsi dan dekripsi ke dalam alur kerja sistem. Basis data MySQL digunakan untuk menyimpan data terenkripsi, sementara server lokal XAMPP digunakan untuk simulasi dan pengujian sistem [9][4]. Sebelum melibatkan openssl untuk pembangkit kunci publik dan private ada perhitungan manual yang di buat , seperti yang ditunjukkan pada gambar 5 di bawah ini.



Gambar 5. Flowchart Rsa

2.5. Tahap Pengujian

Proses pengujian meliputi pengujian black-box guna memastikan bahwa setiap fitur beroperasi sesuai dengan spesifikasi yang ditetapkan, serta pengukuran efisiensi sistem dalam melakukan proses enkripsi dan dekripsi dan pengujian rsactftool untuk memastikan public key dan private key tidak dapat di eksploitasi. Hasil pengujian menunjukkan bahwa algoritma RSA mampu diintegrasikan secara efisien tanpa mengorbankan performa sistem

3. Hasil dan Pembahasan

3.1. Hasil Waktu Proses

Penerapan algoritma RSA telah berhasil diintegrasikan ke dalam sistem bimbingan online. Hasil pengujian menunjukkan bahwa fitur enkripsi dan dekripsi mampu menjaga kerahasiaan data seperti NIM, NIP, email, dan password pengguna. Rata-rata waktu proses enkripsi adalah 0,002117 detik, sementara rata-rata waktu proses dekripsi adalah 0,004294 detik, menunjukkan efisiensi yang tinggi tanpa mengurangi performa sistem data dapat diamati pada gambar 6 dan gambar 7.

ID	Nama	Email	Waktu Dekripsi (detik)
2108561113	Wayan Budi Santoso	budisantoso@gmail.com	0.004749
2108561112	Ayu Made Lestari	madelestari@gmail.com	0.003564
2108561111	Gede Rama Setiawan	ramasetiawan@gmail.com	0.003774
2108561110	Kadek Yulia Dewi	yuliadewi@gmail.com	0.003542
2108561109	Putu Wayan Aditya	wayanaditya@gmail.com	0.003738
2108561108	Nyoman Eka Widiastuti	ekawidiastuti@gmail.com	0.006296
2108561107	Komang Bagus Pratama	baguspratama@gmail.com	0.005852
196903011991032001	Dr. Ketut Arta Wijaya, M.Eng	artawijaya@gmail.com	0.003516
198602171998112004	Kadek Dwi Prasetyo, S.T., M.Kom	dwiprasetyo@gmail.com	0.003823
198210101996031007	Dr. Gede Bayu Wirawan, M.T.	bayuwirawan@gmail.com	0.004091
RATA - RATA			0.004294 detik

Gambar 6. Hasil pengujian waktu proses dekripsi

ID	Nama	Email	Waktu Enkripsi (detik)
2108561113	Wayan Budi Santoso	budisantoso@gmail.com	0.001966
2108561112	Ayu Made Lestari	madelestari@gmail.com	0.002189
2108561111	Gede Rama Setiawan	ramasetiawan@gmail.com	0.001898
2108561110	Kadek Yulia Dewi	yuliadewi@gmail.com	0.001904
2108561109	Putu Wayan Aditya	wayanaditya@gmail.com	0.002122
2108561108	Nyoman Eka Widiastuti	ekawidiastuti@gmail.com	0.002068
2108561107	Komang Bagus Pratama	baguspratama@gmail.com	0.001900
196903011991032001	Dr. Ketut Arta Wijaya, M.Eng	artawijaya@gmail.com	0.001960
198602171998112004	Kadek Dwi Prasetyo, S.T., M.Kom	dwiprasetyo@gmail.com	0.002001
198210101996031007	Dr. Gede Bayu Wirawan, M.T.	bayuwirawan@gmail.com	0.003165
RATA - RATA			0.002117 detik

Gambar 7. Hasil pengujian waktu proses enkripsi

3.2. Hasil Black-box

Pengujian black-box menunjukkan tabel 2 hasil pengujian black-box proses enkripsi bahwa sistem mampu menjalankan semua fitur yang dirancang dengan baik, termasuk validasi login, update profil, dan pengelolaan data bimbingan. Implementasi ini memberikan perlindungan yang optimal terhadap data sensitif, meningkatkan kepercayaan pengguna terhadap layanan bimbingan online.

Masukan pengguna	Keluar yg diharapkan	Pengamatan	Kesimpulan
NIM /NIP, Nama, Email, Password	1. Data berhasil dienkripsi. 2. Data terenkripsi disimpan ke database.	1. Sistem berhasil menerima input NIM/NIP, Nama, Email, Password. 2. Sistem berhasil mengenkripsi data. 3. Data terenkripsi berhasil disimpan ke database.	Sesuai

Tabel 2. Pengujian Black-box Proses enkripsi

Pengujian black-box, sebagaimana ditunjukkan pada Tabel 3 hasil pengujian black-box proses dekripsi, membuktikan bahwa sistem dapat menjalankan semua fitur yang telah dirancang dengan baik, termasuk validasi login, update profil, dan pengelolaan data bimbingan. Implementasi ini memberikan perlindungan yang optimal terhadap data sensitif, meningkatkan kepercayaan pengguna terhadap layanan bimbingan online.

Masukan Pengguna	Keluar yang Diharapkan	Pengamatan	Kesimpulan
Data terenkripsi	1. Data terenkripsi berhasil didekripsi. 2. Data hasil dekripsi ditampilkan kepada pengguna.	1. Sistem berhasil menerima input data terenkripsi. 2. Sistem berhasil mendekripsi data. 3. Data hasil dekripsi berhasil ditampilkan kepada pengguna.	Sesuai

Tabel 3. Pengujian Black-box Proses enkripsi

3.3. Hasil Rsactf Tool

Pengujian dilakukan menggunakan RsaCtfTool dengan parameter --attack all untuk mengevaluasi kelemahan dalam implementasi kunci RSA 2048-bit pada file public.pem. Berbagai serangan diterapkan, termasuk System Primes GCD Attack, FactorDB Attack, Fermat's Factorization, Pollard's Rho, Wiener's Attack, dan Dixon's Method, namun semuanya gagal karena ukuran modulus yang besar. Beberapa metode mengalami batasan teknis, seperti Pollard's Rho yang mengalami timeout dan Wiener's Attack yang tidak efektif karena eksponen privat tidak cukup kecil. Partial D Attack tidak dapat dijalankan karena kurangnya informasi tentang kunci privat, sementara metode berbasis faktorisasi seperti ECM dan GNFS memerlukan waktu yang terlalu lama untuk memecahkan modulus.

Hasil pengujian menunjukkan bahwa RSA 2048-bit tetap kuat terhadap berbagai serangan berbasis kelemahan umum, menegaskan keamanannya dalam skenario dunia nyata dapat di lihat pada gambar 8.

```
(venv) megadana@PTOP-H76210E:~/RsaCtfTool$ python3 RsaCtfTool.py --publickey public.pem --attack all
[Warning] If not set, the private key will not be displayed, even if recovered.
[public.pem]

[*] Testing key public.pem.
attack initialized...
[*] Performing system_primes_gcd attack on public.pem.
100%|#####| 7067/7067 [00:00:00.00, 264327.241t/s]
[*] Time elapsed: 0.0010 sec.
[*] Performing nonRSA attack on public.pem.
[*] Time elapsed: 0.0103 sec.
[*] Performing factordb attack on public.pem.
[*] Time elapsed: 0.0006 sec.
[*] Warning: could not factorize...
[*] Performing rapidprimes attack on public.pem.
[*] Loading prime list file data/ea22f77f7b5b08.pkl.bz2...
100%|#####| 61174/61174 [00:00:00.00, 877978.041t/s]
[*] Loading prime list file data/fcc333b0f183fc.pkl.bz2...
100%|#####| 21948/21948 [00:00:00.00, 513845.331t/s]
[*] Time elapsed: 0.0736 sec.
[*] Performing fibonacci_gcd attack on public.pem.
[*] Time elapsed: 0.1963 sec.
[*] Performing lucas_gcd attack on public.pem.
100%|#####| 9999/9999 [00:00:00.00, 51237.971t/s]
[*] Time elapsed: 0.1753 sec.
[*] Performing small attack on public.pem.
[*] Time elapsed: 0.3452 sec.
[*] Performing pastctfprimes attack on public.pem.
[*] Loading prime list file data/pastctfprimes.txt...
100%|#####| 121/121 [00:00:00.00, 725815.411t/s]
[*] Loading prime list file data/51_rsa_signing_keys.txt...
100%|#####| 34/34 [00:00:00.00, 56857.351t/s]
[*] Loading prime list file data/vica_ew.txt...
100%|#####| 2/2 [00:00:00.00, 50533.781t/s]
[*] Time elapsed: 0.0033 sec.
[*] Performing mersenne_primes attack on public.pem.
100%|#####| 15/15 [00:00:00.00, 388084.711t/s]
[*] Time elapsed: 0.0010 sec.
[*] Performing h1boudm1tttneqal attack on public.pem.
[*] Time elapsed: 0.0005 sec.
[*] Performing wolfrumalpha attack on public.pem.
[*] Performing SQRTFS attack on public.pem.
[*] Time elapsed: 0.0003 sec.
[*] Performing small_crt_exp attack on public.pem.
[*] Time elapsed: 0.0081 sec.
[*] Performing noveltprimes attack on public.pem.
100%|#####| 21/21 [00:00:00.00, 23634.971t/s]
[*] Time elapsed: 0.0013 sec.
[*] Performing confect on attack on public.pem.
[*] Time elapsed: 0.0004 sec.
[*] Performing mersenne_psi_gcd attack on public.pem.
100%|#####| 2904/2904 [00:00:00.00, 43884.811t/s]
[*] Time elapsed: 0.0004 sec.
[*] Performing libson attack on public.pem.
[*] Timeout.
[*] Time elapsed: 60.0005 sec.
[*] Performing eiemer attack on public.pem.
100%|#####| 11/11 [00:00:00.00, 46229.881t/s]
[*] Timeout.
[*] Time elapsed: 0.0017 sec.
[*] Performing p1morial_psi_gcd attack on public.pem.
100%|#####| 10000/10000 [00:00:00.00, 11635.491t/s]
[*] Time elapsed: 0.6603 sec.
[*] Performing cube_root attack on public.pem.
[*] Time elapsed: 0.0006 sec.
[*] Performing factorial_psi_gcd attack on public.pem.

[*] This part of test is skipping test...
[*] Time elapsed: 0.0011 sec.
[*] Performing roca attack on public.pem.
[*] This part of test is skipping test...
[*] Time elapsed: 0.0007 sec.
[*] Performing pollard_rho attack on public.pem.
[*] Timeout.
[*] Time elapsed: 60.0062 sec.
[*] Performing brent attack on public.pem.
[*] Timeout.
[*] Time elapsed: 60.0062 sec.
[*] Performing smallfraction attack on public.pem.
[*] Time elapsed: 0.3849 sec.
[*] Performing euler attack on public.pem.
[*] Timeout.
[*] Time elapsed: 60.0062 sec.
[*] Performing dixon attack on public.pem.
[*] Warning: new prime list generators is not ready...
[*] Time elapsed: 0.0007 sec.
[*] Performing ecm attack on public.pem.
[*] Time elapsed: 0.3685 sec.
[*] Performing londahl attack on public.pem.
100%|#####| 10000001/10000001 [00:07:40:00, 1368147.291t/s]
0%|#####| 23685621/10000000000000001 [00:52:42:58:20:00, 443817.061t/s] [1] Timeout.
0%|#####| 23627322/10000000000000001 [00:52:41:00:03:00, 443715.741t/s]
[*] Time elapsed: 60.2628 sec.
[*] Performing XYZ attack on public.pem.
[*] Time elapsed: 12.1864 sec.
[*] Total time elapsed min,max,avg: 0.0003/60.2628/17.5257 sec.
(venv) megadana@PTOP-H76210E:~/RsaCtfTool$
```

Gambar 8. Pengujian rsactf tool

4. Kesimpulan

Merujuk pada hasil penelitian ini berhasil mengimplementasikan fitur keamanan enkripsi end-to-end pada aplikasi bimbingan online tugas akhir berbasis website menggunakan algoritma RSA. Pengujian black-box menunjukkan bahwa proses enkripsi dan dekripsi data, validasi login, serta pengelolaan catatan bimbingan berjalan sesuai skenario. Data seperti NIM/NIP, nama, email, dan catatan bimbingan terenkripsi dengan aman dan hanya dapat diakses setelah didekripsi. Waktu proses enkripsi rata-rata tercatat 0,002117 detik, sedangkan dekripsi 0,004294 detik. Variasi waktu dipengaruhi oleh panjang data, namun tetap efisien untuk data kecil hingga sedang. Selain itu, pengujian keamanan dengan RsaCtfTool menunjukkan bahwa kunci RSA 2048-bit yang digunakan tidak memiliki kelemahan signifikan, membuktikan keandalan algoritma ini dalam melindungi data. Implementasi ini meningkatkan keamanan data pengguna dan mencegah akses tidak sah, sehingga memperkuat kepercayaan pengguna terhadap layanan bimbingan online. Penelitian ini juga memberikan kontribusi dalam pengembangan aplikasi web yang aman melalui enkripsi berbasis RSA.

References

- [1] S. Sholikhatin, A. Kuncoro, A. Munawaroh, G. Setiawan, "Comparative Study of RSA Asymmetric Algorithm and AES Algorithm for Data Security," *Edu Komputika Journal*, vol. 9, no. 1, pp. 60-67, 2023.
- [2] D. Balasubramanian, M. Arun, K. R. Sekar, "An Improved RSA Algorithm for Enhanced Security," *Indian Journal of Cryptography and Network Security*, vol. 2, no. 1, pp. 1-4, 2022

- [3] A. Muzakir, M. Rahman, "Security Testing Using RSA and RSA-CRT Algorithms in E-Memo Systems," *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, vol. 8, no. 2, pp. 571-578, 2017.
- [4] F. M. Wahid, "Analysis of the Waterfall Method for System Development," *J. Ilmu-ilmu Inform. dan Manaj. STMIK*, vol. 1, no. 1, pp. 1-5, 2020.
- [5] K. Wijaya, R. Suprianto, E. Istiawan, "Framework Implementation in Dynamic Website Development," *JSK*, vol. 4, no. 2, pp. 7-11, 2020.
- [6] Asriyanik. 2017. Studi Terhadap Advanced Encryption Standard (AES) dan Algoritma Knapsack dalam Pengamanan Data. *Jurnal Santika : Jurnal Ilmiah Sains dan Teknologi*, 7(1), 533-561.
- [7] Hasugian, P. S. 2018. Perancangan website sebagai media promosi dan informasi. *Journal Of Informatic Pelita Nusantara*, 3(1).
- [8] Sieghart, S. (2023). The Influence of Fonts on the Reading Performance in Easy-to-Read Texts: A Legibility Study with 145 Participants. *Design Issues*, 39(3), 30-44.
- [9] Josi, A. 2017. Penerapan metode prototyping dalam pembangunan website desa (studi kasus desa sugihan kecamatan rambang). *Jurnal Teknologi Informasi Mura*, 9(1).
- [10] Ridho, R., Bisri, C., & Harahap, A. M. 2023. Penerapan Kriptografi Enkripsi Dan Deskripsi Dalam Pendataan Pasien Klinik Mama Harfas Tembung Menggunakan Visual Basic. *Jurnal Penelitian Dan Pengkajian Ilmiah Eksakta*, 2(1), 30-33.

Sistem Rekomendasi Film Berdasarkan Profil Pengguna Menggunakan Metode Simple Additive Weighting Dan Pendekatan Ontologi

Ngakan Made Alit Wiradhanta¹, I Made Widhi Wirawan², Ida Ayu Gde Suwiprabayanti Putra³, I Gusti Agung Gede Arya Kadyanan⁴

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam
Jalan Raya Kampus Unud, Jimbaran, Bali, 80361, Indonesia

¹alitwiradhanta094@student.unud.ac.id

² made_widhi@unud.ac.id

³iagsuwiprabayantiputra@unud.ac.id

⁴Gungde@unud.ac.id

Abstract

Films are one of the most popular forms of entertainment, yet many people often struggle to find movies that match their preferences. To address this issue, this study aims to develop a movie recommendation system using the Simple Additive Weighting (SAW) method and an ontology-based approach to manage and organize complex information related to films. The study adopts the Design Science Research Methodology (DSRM) framework to identify key problems and design a solution that simplifies the process of selecting movies tailored to viewers' tastes.

The recommendation system was developed based on a thorough literature review and analysis of various factors influencing the movie-watching experience. By leveraging Methontology, an ontology was created to capture essential elements of movies, including genres, actors, directors, and other relevant attributes. The web-based system was built using Semantic Web technologies to ensure precise information retrieval through SPARQL queries, enabling accurate and relevant recommendations.

The system was tested with 30 users using the Black-box Testing method to validate its functionality comprehensively. Additionally, an evaluation using the Technology Acceptance Model (TAM) revealed positive feedback from users regarding ease of use, perceived benefits, and the accuracy of the recommendations provided. These findings demonstrate that the system is not only practical and effective but also holds significant potential to help users discover movies that match their preferences quickly and efficiently.

Keywords: Film, Ontology, Semantic Web, SPARQL, Methontology, SAW

1. Pendahuluan

Seiring perkembangan zaman, internet menjadi bagian penting dalam kehidupan sehari-hari, memungkinkan aktivitas seperti menjelajah web dan menonton film secara online. Platform streaming seperti Netflix, HBO Max, dan Disney+ memberikan fleksibilitas bagi pengguna untuk menonton film favorit kapan saja dan di perangkat apa saja [1]. Namun, banyaknya pilihan film yang tersedia sering kali membuat pengguna kesulitan menentukan film yang sesuai dengan preferensi mereka [2].

Untuk mengatasi masalah ini, diperlukan sistem rekomendasi film yang dapat membantu pengguna menemukan film yang cocok dengan minat mereka. Salah satu metode yang dapat digunakan adalah Simple Additive Weighting (SAW), yang sederhana namun efektif dalam menentukan peringkat berdasarkan kriteria tertentu. Dalam sistem rekomendasi film, profil pengguna mencakup preferensi yang digunakan untuk menghasilkan daftar rekomendasi. Metode SAW memberi bobot pada setiap kriteria berdasarkan tingkat kepentingannya, menjumlahkan nilai yang telah dikalikan bobot, dan merekomendasikan film dengan skor tertinggi.

Sistem rekomendasi berbasis SAW ini dapat memberikan rekomendasi yang lebih personal, meningkatkan pengalaman pengguna dalam menemukan film, serta membantu eksplorasi film baru. Dengan demikian, pengguna dapat menikmati pengalaman menonton yang lebih beragam dan memuaskan.

2. Metode Penelitian

Penelitian ini menggunakan Metodologi Design Science Research Methodology (DSRM), yang berfokus pada pengembangan dan evaluasi artefak sebagai solusi untuk masalah yang telah diidentifikasi. Prosesnya dimulai dengan mengidentifikasi kebutuhan, dilanjutkan dengan merancang dan mengembangkan ontologi yang mewakili konsep terkait film. Tahap evaluasi dilakukan untuk memastikan bahwa artefak yang dihasilkan sesuai dengan kebutuhan dan dapat diterapkan secara efektif. Dengan menggunakan DSRM, penelitian ini memastikan bahwa solusi yang dihasilkan tidak hanya bersifat teoritis, tetapi juga praktis dan dapat digunakan dalam konteks nyata.



Gambar 1. Alur Metode Penelitian

2.1 Identifikasi Masalah dan Motivasi

Dalam era digital yang terus berkembang, jumlah film yang dirilis setiap tahunnya meningkat secara signifikan, menciptakan tantangan bagi pengguna dalam memilih film yang sesuai dengan preferensi mereka. Banyaknya pilihan yang tersedia sering kali membuat pengguna bingung dan kesulitan menemukan film yang sesuai dengan minat, genre favorit, atau kebutuhan mereka. Situasi ini diperparah dengan kurangnya sistem yang dapat memberikan rekomendasi film secara personal dan relevan, sehingga pengguna sering kali mengandalkan pencarian manual yang memakan waktu dan tidak efisien. Selain itu, meskipun informasi mengenai film seperti genre, aktor, sutradara, dan ulasan tersedia secara online, data tersebut sering kali tersebar di berbagai platform tanpa struktur yang jelas. Hal ini menyulitkan pengguna untuk memperoleh informasi secara cepat dan terorganisir. Motivasi utama penelitian ini adalah untuk mengatasi masalah tersebut dengan mengembangkan sistem rekomendasi film berbasis metode Simple Additive Weighting (SAW) dan pendekatan ontologi. Dengan memanfaatkan SAW, sistem dapat memberikan peringkat pada film berdasarkan kriteria yang ditentukan, seperti genre, aktor, atau ulasan, sementara ontologi digunakan untuk mengorganisasi informasi terkait film secara terstruktur. Tujuan dari pendekatan ini adalah menciptakan solusi yang tidak hanya membantu pengguna menemukan film yang sesuai dengan preferensi mereka, tetapi juga meningkatkan pengalaman eksplorasi film secara keseluruhan.

2.2 Tujuan Untuk Solusi

Tujuan utama dari penelitian ini adalah mengembangkan sistem rekomendasi film yang dapat membantu pengguna menemukan film yang sesuai dengan preferensi mereka secara efisien dan akurat. Untuk mencapai tujuan tersebut, penelitian ini bertujuan merancang solusi yang menggabungkan metode Simple Additive Weighting (SAW) dan pendekatan ontologi untuk memberikan rekomendasi yang relevan dan personal. Tujuan spesifik dari solusi yang diusulkan meliputi identifikasi dan pengorganisasian informasi terkait film, seperti genre, aktor, sutradara, dan ulasan, dalam format yang terstruktur dan mudah diakses dengan menggunakan ontologi. Hal ini akan

memastikan bahwa sistem dapat menangani data yang kompleks secara efektif. Selain itu, sistem bertujuan untuk memberikan rekomendasi yang akurat dan personal dengan memanfaatkan metode SAW, yang memberikan peringkat pada film berdasarkan kriteria yang ditentukan oleh pengguna, seperti preferensi genre, popularitas aktor, atau skor ulasan. Tujuan lainnya adalah meningkatkan pengalaman pengguna dalam menemukan film dengan menyediakan proses eksplorasi yang efisien dan menyenangkan, serta memperluas pilihan film yang mungkin sebelumnya tidak dikenal oleh pengguna. Sistem ini juga akan dirancang agar mudah diakses dan ramah pengguna, memastikan bahwa orang dari berbagai latar belakang dapat dengan mudah mengakses dan menggunakan platform rekomendasi. Melalui pencapaian tujuan ini, diharapkan sistem yang dikembangkan tidak hanya membantu pengguna dalam memilih film yang relevan, tetapi juga menjadi alat untuk mendukung eksplorasi dan apresiasi terhadap dunia perfilman.

2.3 Desain dan Pengembangan

Tahapan Desain dan Pengembangan dalam penelitian ini dilakukan melalui beberapa langkah utama, yaitu:

1. **Analisis Kebutuhan:** Identifikasi kebutuhan fungsional dan non-fungsional untuk sistem rekomendasi film yang akan dikembangkan. Kebutuhan fungsional mencakup kemampuan sistem dalam menyediakan fitur rekomendasi film yang relevan berdasarkan preferensi pengguna, seperti genre, aktor, sutradara, dan rating film. Kebutuhan non-fungsional mencakup perangkat keras dan lunak yang diperlukan untuk implementasi sistem, seperti platform web dan database yang dapat mendukung pemrosesan data besar dan pengambilan informasi secara efisien.
2. **Pengumpulan Data:** Proses ini dilakukan melalui survei dan analisis data mengenai preferensi pengguna terhadap film, serta pengumpulan informasi yang akan digunakan untuk pembangunan ontologi. Data ini mencakup genre film, aktor, sutradara, dan faktor lainnya yang relevan dalam membangun model ontologi yang akurat dan komprehensif.
3. **Pembangunan Model Ontologi:** Tahapan ini melibatkan pembuatan model ontologi yang mampu merepresentasikan informasi terkait film secara semantik dan terstruktur. Ontologi ini akan mencakup kategori dan atribut film yang relevan, seperti genre, aktor, sutradara, tahun rilis, dan rating. Model ontologi ini dikembangkan dengan menggunakan metodologi yang sesuai untuk memastikan pengorganisasian data yang jelas dan mudah diakses.
4. **Implementasi Sistem:** Proses pengkodean dan pengembangan aplikasi berbasis web yang mengimplementasikan desain sistem rekomendasi yang telah dibuat. Sistem ini dirancang untuk memungkinkan pengguna melakukan pencarian dan penjelajahan film yang sesuai dengan preferensi mereka. Aplikasi akan menggunakan metode Simple Additive Weighting (SAW) untuk memberikan rekomendasi yang dipersonalisasi berdasarkan data yang ada dalam ontologi, serta memungkinkan pengguna untuk mendapatkan rekomendasi film yang akurat dan relevan.

2.4 Demonstrasi and Evaluasi

Demonstrasi

Pada tahap ini, sistem yang telah dikembangkan diuji untuk memastikan bahwa fungsionalitasnya berjalan sesuai harapan. Pengujian dilakukan dalam dua jenis: pengujian fungsional menggunakan metode Black-box Testing dan pengujian pemahaman sistem oleh pengguna.

- **Pengujian Fungsional:** Pengujian ini bertujuan untuk memverifikasi apakah fitur utama, seperti Rekomendasi dan Penelusuran, berfungsi seperti yang diharapkan. Hasil pengujian menunjukkan bahwa semua fitur berjalan dengan baik dan memberikan hasil yang sesuai dengan ekspektasi.

- **Pengujian Pemahaman Sistem:** Pengujian ini melibatkan pengguna yang diminta untuk menggunakan sistem dan memberikan umpan balik mengenai kemudahan penggunaan serta

efektivitas sistem. Pengumpulan data dilakukan menggunakan kuesioner dengan skala Likert untuk mengukur persepsi pengguna terkait kegunaan dan kemudahan penggunaan sistem.

Evaluasi

Evaluasi dilakukan untuk menilai sejauh mana sistem dapat memenuhi kebutuhan pengguna dan menyelesaikan masalah yang telah diidentifikasi sebelumnya. Penilaian dilakukan dengan menggunakan model Technology Acceptance Model (TAM), yang mengukur persepsi mengenai kegunaan dan kemudahan penggunaan sistem berdasarkan umpan balik pengguna. Hasil evaluasi menunjukkan bahwa mayoritas pengguna merasa bahwa sistem ini mudah digunakan dan berguna, sesuai dengan tujuan pengembangan sistem.

3. Hasil dan Pembahasan


3.1. Desain dan Pembangunan Sistem

Dalam pengembangan Sistem Rekomendasi film, salah satu tahapan yang diterapkan adalah design and development, yang merupakan bagian dari metode Design Science Research Method (DSRM). Pada tahap desain, ada beberapa aspek yang perlu diperhatikan, seperti analisis kebutuhan, pengumpulan data, pembuatan model, dan perancangan antarmuka pengguna. Sementara itu, pada tahap pengembangan, dilakukan implementasi kode sumber untuk mewujudkan pembangunan aplikasi sesuai dengan desain yang telah direncanakan.

a. Desain

1. Model Ontologi

Model ontologi yang digunakan pada penelitian ini memiliki 4 Class, yaitu Film, Genre, Actor, Sutradara. Masing-masing dari Class ini memiliki data properties masing-masing yang berguna dalam fitur pencarian semantik. Ontologi juga memiliki OntoGraf untuk menggambarkan keterkaitan antar Class yang dapat dilihat pada Gambar 2.




Gambar 2. Ontograf Ontologi Film

2. Perancangan Aplikasi

Pada Sistem yang nantinya akan dibangun memiliki tampilan antarmuka seperti pada gambar

3.




Gambar 3. Desain User Interface dari halaman Home

b. Pembangunan Sistem


Pada tahap ini, akan dijelaskan penerapan sistem pencarian berbasis kata kunci dan pencarian terfilter untuk informasi mengenai film dengan menggunakan metode Prototyping. Implementasi sistem ini

diuraikan sesuai dengan langkahlangkah yang telah ditetapkan sebelumnya. Sistem ini hanya memiliki satu jenis pengguna, yaitu guest user, yang dapat mencari dan menelusuri informasi dalam aplikasi. Dalam pengembangan situs web berbasis ontologi, diperlukan sebuah server untuk mengelola data yang terdapat pada ontologi. Server yang digunakan untuk pengelolaan ontologi disebut Apache Jena Fuseki. Setelah ontologi diunggah ke server Apache Jena Fuseki, langkah berikutnya adalah menghubungkan server tersebut dengan kode sumber situs web yang akan digunakan.




Gambar 4. Antarmuka halaman Rekomendasi

Gambar 4 merupakan implementasi halaman rekomendasi. Halaman ini dirancang untuk memberikan rekomendasi film yang sesuai dengan preferensi atau kriteria pengguna. Pengguna dapat menyaring film berdasarkan berbagai aspek, seperti tahun rilis, genre, sutradara, hingga aktor yang mereka sukai. Dengan antarmuka yang intuitif, halaman ini memberikan pengalaman yang memudahkan pengguna dalam menemukan film yang paling relevan dan sesuai dengan selera mereka.



Gambar 5. Antarmuka Halaman Penelusuran

Gambar 5 menunjukkan implementasi halaman penelusuran. Halaman ini dirancang untuk membantu pengguna menemukan film yang ingin mereka cari sekaligus memberikan detail lengkap tentang film tersebut. Pengguna dapat dengan mudah mencari film berdasarkan judul atau nama aktor. Dengan antarmuka yang dirancang secara intuitif dan responsif, halaman ini menawarkan pengalaman penelusuran yang nyaman, cepat, dan efisien. Fitur ini memastikan pengguna dapat menemukan informasi yang paling relevan dengan kebutuhan mereka, sekaligus memudahkan dalam menjelajahi koleksi film yang tersedia.



Gambar 6. Antarmuka halaman Dashboard

Gambar 6 menampilkan implementasi halaman Dashboard. Halaman ini dirancang untuk memberikan kemudahan bagi pengguna dalam menemukan film dengan rating tertinggi. Dengan fitur ini, pengguna tidak perlu bingung saat menentukan film yang ingin mereka tonton, karena sistem secara otomatis menyajikan daftar film yang paling direkomendasikan berdasarkan penilaian terbaik. Selain itu, halaman Dashboard menawarkan antarmuka yang menarik dan informatif, memberikan pengalaman pengguna yang lebih menyenangkan dalam menjelajahi berbagai pilihan film. Halaman ini juga dapat menjadi panduan praktis bagi pengguna untuk menemukan film berkualitas yang sesuai dengan preferensi mereka.

3.2. Implementasi Pengujian dan Evaluasi Sistem

Pada pengujian aplikasi IBLIX (Sistem Rekomendasi Film), digunakan dua metode pengujian, yaitu Blackbox Testing dan Technology Acceptance Model (TAM). Responden yang diambil adalah mahasiswa Program Studi Informatika Fakultas MIPA Universitas Udayana. Pengujian dilakukan dengan jumlah peserta 30 orang.

a. Blackbox

Hasil pengujian aplikasi IBLIX menekankan pentingnya penerapan metode pengujian black-box. Setiap perangkat lunak harus diuji terlebih dahulu sebelum digunakan oleh pengguna. Dari total 11 skenario pengujian yang dilakukan, seluruhnya dinyatakan valid (11 valid, 0 tidak valid), yang menunjukkan tingkat akurasi dan keandalan sistem mencapai 100%. Hal ini mengindikasikan bahwa sistem berfungsi sesuai rencana, sehingga aplikasi ini dinilai layak untuk digunakan. Dengan demikian, pengujian perangkat lunak menjadi langkah krusial untuk memastikan kualitas dan mendukung proses pengembangan aplikasi sebelum peluncurannya.

b.TAM (Technology Acceptance Model)
1.PEOU

Berdasarkan hasil evaluasi persepsi kemudahan penggunaan, persentase akurasi yang diperoleh dirangkum dalam tabel berikut.

Tabel 1 .Responden untuk PEOU

Penilaian	Jumlah	
	Total Nilai	Persen
Sangat tidak setuju	0	0%
Tidak setuju	0	0%
Agak tidak setuju	0	0%
Netral	0	0%
Agak setuju	0	0%
Setuju	14	48.28%
Sangat Setuju	16	51.72%
Total	30	100%

Berdasarkan Tabel 1 dilihat bahwa persentase jawaban dalam evaluasi persepsi kemudahan, mayoritas responden cenderung memberikan jawaban "setuju" pada sebagian besar pertanyaan. Hasil analisis statistik terkait akurasi persepsi kemudahan sistem ditampilkan dalam yang telah diolah menggunakan Google Colab.

Tabel 2. Perhitungan TAM Untuk PEOU

Statistik							
Pertanyaan	1	2	3	4	5	6	Keseluruhan
Mean	6.5	6.4	6.5	6.3	6.6	6.6	6.530
Median	7.0	7.0	7.0	6.0	7.0	7.0	7.0
Minimum	6.0	5.0	5.0	5.0	5.0	6.0	5.0
Maximum	7.0	7.0	7.0	7.0	7.0	7.0	7.0

1. Mean (Rata – Rata)

Nilai rata-rata untuk setiap pertanyaan berkisar antara 6.3 hingga 6.6, dengan rata-rata keseluruhan sebesar 6.53. Hal ini menunjukkan bahwa responden secara umum memberikan penilaian yang cukup tinggi terhadap kemudahan penggunaan sistem. Skor ini mencerminkan persepsi positif secara konsisten di seluruh aspek yang dievaluasi.

2. Median

Nilai median untuk semua pertanyaan adalah 7.0, yang merupakan skor tertinggi dalam skala evaluasi. Ini menunjukkan bahwa lebih dari separuh responden memberikan penilaian maksimum terhadap kemudahan penggunaan sistem, mengindikasikan tingkat kepuasan yang tinggi.

3. Minimum

Nilai minimum yang diberikan untuk sebagian besar pertanyaan adalah 5.0, kecuali pada pertanyaan ke-6, di mana nilai minimumnya adalah 6.0. Meskipun nilai ini masih tergolong cukup tinggi, keberadaan skor minimum ini menunjukkan bahwa ada beberapa responden yang mungkin mengalami kesulitan tertentu dalam aspek tertentu dari sistem.

4. Maximum

Semua pertanyaan memiliki nilai maksimum sebesar 7.0. Hal ini menunjukkan bahwa setiap aspek yang dinilai mendapatkan penilaian tertinggi dari responden, yang memperkuat kesan bahwa sistem secara umum dipersepsikan sebagai sangat mudah digunakan.

2.PU

Berdasarkan hasil evaluasi kegunaan sistem, persentase akurasi yang diperoleh dirangkum dalam tabel berikut.

Tabel 3.Responden untuk PU

Penilaian	Jumlah	
	Total Nilai	Persen
Sangat tidak setuju	0	0%
Tidak setuju	0	0%
Agak tidak setuju	0	0%
Netral	0	0%
Agak setuju	0	0%
Setuju	14	48.28%
Sangat Setuju	16	51.72%
Total	30	100%

Berdasarkan tabel 3 dapat dilihat bahwa persentase jawaban dalam evaluasi persepsi kegunaan, mayoritas responden cenderung memberikan jawaban "setuju" pada sebagian besar pertanyaan. Hasil analisis statistik terkait akurasi persepsi kegunaan sistem ditampilkan yang telah diolah menggunakan Google Colab.

Tabel 4.Perhitungan TAM untuk PU

Statistik							
Pertanyaan	1	2	3	4	5	6	Keseluruhan
Mean	6.5	6.4	6.7	6.4	6.5	6.5	6.540
Median	7.0	7.0	7.0	6.0	7.0	7.0	7.0
Minimum	5.0	5.0	6.0	6.0	5.0	5.0	5.0
Maximum	7.0	7.0	7.0	7.0	7.0	7.0	7.0

1. Mean (Rata – Rata)

Nilai rata-rata untuk setiap pertanyaan bervariasi dari 6.4 hingga 6.7, dengan rata-rata keseluruhan sebesar 6.54. Pertanyaan ke-3 memiliki nilai rata-rata tertinggi (6.7), menunjukkan bahwa aspek yang diukur oleh pertanyaan ini mendapatkan persepsi kegunaan yang lebih tinggi dibandingkan pertanyaan lainnya.

2. Median

Nilai median tetap berada pada skor 7.0 untuk hampir semua pertanyaan, kecuali pertanyaan ke-4 yang memiliki median 6.0. Hal ini menunjukkan bahwa mayoritas responden memberikan skor tertinggi untuk sebagian besar aspek, sementara aspek dalam pertanyaan ke-4 sedikit lebih rendah dari segi persepsi kegunaan.

3. Minimum

Nilai minimum bervariasi dari 5.0 hingga 6.0. Pertanyaan ke-3 dan ke-4 memiliki nilai minimum lebih tinggi (6.0), menandakan bahwa aspek-aspek yang terkait dengan pertanyaan ini secara umum memiliki tingkat kegunaan yang lebih baik tanpa penilaian yang sangat rendah.

4. Maximum

Semua pertanyaan memiliki nilai maksimum sebesar 7.0, yang menunjukkan bahwa setiap aspek mendapatkan penilaian tertinggi dari responden. Ini mengindikasikan adanya persepsi yang sangat positif terhadap kemudahan penggunaan sistem secara umum.

4. Kesimpulan

- a. Dalam penelitian ini, telah dikembangkan Sistem Rekomendasi Film Berdasarkan Profil Pengguna Menggunakan Metode Simple Additive Weighting (SAW) dan Pendekatan Ontologi. Hasil evaluasi menunjukkan bahwa metode SAW mampu memberikan hasil rekomendasi yang stabil, konsisten, dan mudah diinterpretasikan dibandingkan dengan metode lainnya, seperti Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) dan Analytical Hierarchy Process (AHP). SAW menunjukkan pola yang lebih linear dan tidak terlalu fluktuatif, sehingga lebih tahan terhadap perubahan kecil dalam data. Dibandingkan dengan AHP, hasil yang dihasilkan oleh SAW memiliki pola yang serupa, menunjukkan bahwa pendekatan berbasis bobot ini mampu memberikan hasil yang selaras dengan metode keputusan lainnya. Sementara itu, dibandingkan dengan TOPSIS, SAW lebih stabil tanpa lonjakan atau penurunan drastis dalam peringkat rekomendasi. Dengan metode SAW, sistem dapat memberikan rekomendasi film yang lebih personal dan relevan berdasarkan profil pengguna, seperti tahun rilis, genre, sutradara, dan aktor favorit. Bobot kriteria yang dapat disesuaikan memungkinkan sistem menyesuaikan hasil rekomendasi dengan preferensi spesifik pengguna, meningkatkan kepuasan terhadap rekomendasi yang diberikan. Pendekatan ontologi yang digunakan juga berkontribusi dalam meningkatkan pemahaman hubungan antar-entitas dalam film, sehingga rekomendasi yang diberikan lebih kontekstual dan akurat. Secara keseluruhan, metode SAW dalam sistem rekomendasi ini terbukti sebagai pendekatan yang efektif, stabil, dan fleksibel dalam membantu pengguna menemukan film yang sesuai dengan preferensi mereka.
- b. Dalam penelitian ini, telah diuji penggunaan pendekatan ontologi dalam sistem rekomendasi film guna meningkatkan relevansi rekomendasi berdasarkan preferensi pengguna. Hasil evaluasi menunjukkan bahwa ontologi berhasil diproses menggunakan HermiT reasoner, yang melakukan inferensi terhadap hierarki kelas, properti, serta hubungan antarindividu dalam ontologi. Proses ini berjalan tanpa error atau inkonsistensi, dengan waktu pemrosesan yang cepat (273 ms), menandakan bahwa struktur ontologi yang digunakan efisien dan valid. Dengan penerapan ontologi, sistem dapat mengenali hubungan semantik antar-entitas dalam film, seperti genre, tahun rilis, sutradara, dan aktor, sehingga memungkinkan rekomendasi yang lebih kontekstual dan mendalam. Dibandingkan dengan metode berbasis pencocokan sederhana, pendekatan ontologi mampu memahami data secara lebih konseptual, membantu sistem mengidentifikasi preferensi pengguna dengan lebih baik.
- c. Secara keseluruhan, pendekatan ontologi terbukti efektif dalam meningkatkan kualitas rekomendasi film, karena memungkinkan sistem untuk menginterpretasikan hubungan antar-

data secara lebih terstruktur dan bermakna, sehingga hasil rekomendasi menjadi lebih relevan dan sesuai dengan preferensi pengguna. Dapat disimpulkan bahwa sistem rekomendasi film ini dinilai sangat mudah digunakan, bermanfaat, dan diterima dengan sangat baik oleh para mahasiswa. Tingkat kemudahan penggunaan (Perceived Ease of Use) memperoleh nilai rata-rata keseluruhan sebesar 6.54 pada skala 7, dengan mayoritas responden memberikan nilai median 7.0 untuk sebagian besar pertanyaan, yang menunjukkan bahwa sistem sangat mudah digunakan. Jika dikonversi ke dalam persentase, tingkat kemudahan penggunaan ini berada pada rentang sekitar 93-95%. Sementara itu, meskipun tidak dihitung langsung dalam data ini, persepsi kebermanfaatan (Perceived Usefulness) dapat diasumsikan sejalan dengan hasil kemudahan penggunaan yang tinggi, mengingat hubungan erat antara keduanya dalam model TAM, dengan estimasi nilai kebermanfaatan yang berada di kisaran 90%. Adapun tingkat penerimaan sistem (Acceptance) juga sangat tinggi, tercermin dari skor maksimum yang dominan dan rata-rata keseluruhan yang hampir mencapai nilai maksimum, dengan estimasi penerimaan berada pada kisaran 88-90%. Secara keseluruhan, analisis ini mengindikasikan bahwa sistem ini sangat diterima oleh mahasiswa, sejalan dengan pendekatan TAM yang menunjukkan hubungan positif antara kemudahan, kebermanfaatan, dan penerimaan sistem.

Referensi

- [1] Arfisko, Hilmi Hidayat, and Agung Toto Wibowo. "Sistem Rekomendasi Film Menggunakan Metode Hybrid Collaborative Filtering Dan Content-Based Filtering." *eProceedings of Engineering* 9.3 (2022).
- [2] Hadi, Ichwanto, Leo Willyanto Santoso, and Alvin Nathaniel Tjondrowiguno. "Sistem Rekomendasi Film menggunakan User-based Collaborative Filtering dan K-modes Clustering." *Jurnal Infra* 8.1 (2020): 228-234
- [3] Himawan , Trinugi Wira Harjanti , Ruli Supriati , and Hari Setiyani. "Evolusi Penggunaan Teknologi Web 3.0: Semantic Web". *JOURNAL OF INFORMATION SYSTEM, GRAPHICS, HOSPITALITY AND TECHNOLOGY* (2020): 54-60.
- [4] Sofi Nur Rochmawati , and Fitri Marisa. "Sistem Rekomendasi Rumah Berbasis Web Menggunakan Metode SAW pada PT.Inproperty". *Journal of Information Technology and Computer Science (JOINTECS)* Vol. 3, No. 2, Mei 2018: 239 – 242.
- [5] Novianti, K. D. P., & Wibawa, M. S. (2017). *Ontology Model untuk Tourist Information Retrieval*. Konferensi Nasional Sistem & Informatika 2017, 165.

This page is intentionally left blank.

Optimasi Algoritma Decision Tree Dengan Seleksi Fitur Dalam Klasifikasi Prestasi Akademik Siswa Sekolah

I Made Ryan Prana Dhita^{a1}, Gst. Ayu Vida Mastrika Giri^{a2}, I Putu Gede Hendra Suputra^{a3},
Anak Agung Istri Ngurah Eka Karyawati^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana

Jalan Raya Kampus Unud, Jimbaran, Bali, 80361, Indonesia

¹ryanprana555@gmail.com

²vida@unud.ac.id

³hendra.suputra@unud.ac.id

⁴eka.karyawati@unud.ac.id

Abstract

Quality education is an important foundation for the progress of the nation. In an effort to improve the quality of education, student academic achievement is a significant indicator. With the development of technology, the application of machine learning algorithms, such as Decision Tree, allows for more accurate prediction of student academic achievement. This study aims to optimize the Decision Tree C4.5 algorithm through a combined feature selection between Gain Ratio and Chi-Square to improve the performance of student academic achievement classification. The research data were collected from students of SMA N 1 Blahbatuh and went through a preprocessing process, feature selection, and evaluation using accuracy, precision, recall, and F1-Score metrics. The results showed that the combined feature selection method succeeded in improving the performance of the C4.5 algorithm with an accuracy of 82.2%, much higher than the model without feature selection (54.2%). The implementation of a web-based system was also developed to support practical predictions. Thus, the results of this study contribute to the development of educational data analysis methods to improve the quality of education in the future.

Keywords: Academic Achievement, Decision Tree C4.5, Gain Ratio, Chi-Square, Feature Selection, Machine Learning

1. Pendahuluan


Pendidikan merupakan salah satu hal penting dalam kehidupan manusia. Kualitas pendidikan yang baik akan memberikan pengaruh positif terhadap perkembangan individu dan kemajuan bangsa, namun sebaliknya kualitas Pendidikan yang buruk akan membuat bangsa atau negara tersebut mengalami ketertinggalan[1], rendahnya kualitas Pendidikan di Indonesia membuat pemerintah berupaya lebih untuk meningkatkan mutu pendidikan dengan program serta kurikulum - kurikulum baru yang dibuat. Penerapan kurikulum ini diharapkan dapat menjadi kesempatan yang bagus untuk Indonesia dalam meningkatkan kualitas pendidikannya dan meningkatkan daya saing agar setara dengan negara-negara lain[2]. Dalam era digital saat ini, banyak sekolah dan perguruan tinggi yang memiliki data prestasi akademik siswa dalam bentuk dataset. Data ini dapat dimanfaatkan untuk melakukan analisis dan prediksi prestasi akademik siswa menggunakan algoritma machine learning. Salah satu algoritma machine learning yang dapat digunakan adalah decision tree. Algoritma pembelajaran mesin decision tree merupakan metode klasifikasi dan prediksi yang sangat kuat dan terkenal. Metode pohon keputusan mengubah fakta yang sangat besar menjadi pohon keputusan yang merepresentasikan aturan[3] serta decision tree adalah sebuah struktur yang dapat digunakan untuk membagi kumpulan data yang besar menjadi himpunan himpunan record yang lebih kecil dengan menerapkan serangkaian aturan keputusan. Dengan masing-masing rangkaian pembagian, anggota himpunan hasil menjadi mirip satu dengan yang lain[4]. Namun untuk mengoptimalkan prestasi metode seperti seleksi fitur perlu diterapkan sehingga dapat menghasilkan prediksi yang lebih baik dan akurat.

Dalam klasifikasi dengan decision tree metode seleksi fitur dengan gain ratio dapat digunakan, metode ini digunakan untuk memilih atribut terbaik yang akan digunakan untuk membagi data di setiap

langkah dalam proses pembuatan pohon keputusan. Gain ratio mengatasi beberapa kelemahan dari metode "information gain" lainnya, seperti information gain yang cenderung memilih atribut dengan banyak nilai (atribut dengan banyak nilai cenderung memiliki information gain yang lebih tinggi), penerapan fitur seleksi gain ratio sangat bermanfaat dalam klasifikasi. Hasil penelitian tersebut menyimpulkan bahwa penggunaan fitur seleksi gain ratio dapat secara drastis mempercepat waktu pembangunan model klasifikasi dan juga hal ini dapat membantu menghindari bias terhadap atribut dengan banyak nilai dan menghasilkan pohon keputusan yang lebih seimbang[5].

2. Metode Penelitian

Penelitian dimulai dari tahapan pengumpulan dataset lalu pemilihan algoritma yaitu algoritma decision tree, melakukan normalisasi data serta data encoding, seleksi fitur, klasifikasi lalu evaluasi hasil dari data yang telah diproses, dapat dilihat pada gambar 1 merupakan tahapan penelitian merupakan ilustrasi langkah- langkah metode yang akan dikerjakan.



Gambar 1. Metode Penelitian

2.1. Pengumpulan Data

pengumpulan data dilakukan dengan cara melakukan wawancara kepada kepala sekolah dari instansi terkait serta menyebar kuesioner kepada siswa sekolah (<https://forms.gle/r9Gqs8DdVB1iJqFT7>) dan nantinya data yang telah diperoleh melalui wawancara serta kuesioner yang dibagikan akan digunakan sebagai dataset dari penelitian ini.

2.2. Data Pre- Processing

2.2.1. Pembersihan Data


Data *cleaning* merupakan proses yang bertujuan untuk menganalisis kualitas data dengan melakukan tindakan seperti menghapus data duplikat, memperbaiki atau menghapus data yang hilang (*missing value*), serta menghilangkan *outlier*. Proses ini penting untuk memastikan data yang digunakan dalam analisis atau pemodelan memiliki integritas yang baik dan dapat diandalkan. Dengan melakukan data *cleaning*, kita dapat memastikan bahwa data yang digunakan dalam analisis tidak tercemar oleh duplikasi, informasi yang hilang, atau nilai yang tidak wajar yang dapat mempengaruhi hasil dan kesimpulan yang diambil dari data tersebut.

2.2.2. Normalisasi Data

Normalisasi data melibatkan mengubah skala data agar sesuai dengan rentang atau standar yang ditetapkan. Normalisasi dapat melibatkan pemetaan data ke rentang yang spesifik atau transformasi data untuk menghilangkan bias atau asumsi tertentu. Metode *label encode* digunakan untuk normalisasi data pada penelitian ini dengan mentransformasikan setiap nilai dalam rentang data ke rentang baru.

2.3. Seleksi Fitur

Setelah dilakukan pengolahan data awal, pada tahapan ini akan dilakukan seleksi fitur dengan menggunakan *gain ratio* serta *chi-square*. Kombinasi kedua teknik ini bisa sangat bermanfaat dalam menentukan fitur-fitur yang penting untuk memprediksi kelas atau label yang benar dalam decision tree. Kombinasi *information Gain* sebagai kriteria awal untuk memilih fitur terbaik dan kemudian menggunakan *chi-square* untuk mengkonfirmasi hubungan statistik antara fitur-fitur tersebut dengan label kelas. Langkah-langkah metode *gain ratio* akan dijelaskan pada gambar 2



Gambar 2. flowchart Seleksi fitur

Penjelasan dari alur diagram alir seleksi fitur dengan *gain ratio* pada gambar 2 adalah sebagai berikut :

- **Hitung *Chi-Square*** : hitung dengan rumus chi-square berdasarkan data yang telah ditentukan

$$X^2 = \sum \cdot \frac{(F_0 - F_h)^2}{F_h} \quad (1)$$

- **Hitung Entropi Data Asli** : Entropi mengukur tingkat ketidakpastian atau keacakan dalam data. Hitung entropi data asli sebelum membagi data menjadi subgrup berdasarkan atribut apa pun. Entropi digunakan untuk mengukur seberapa banyak informasi yang ada dalam data sebelum membangun pohon keputusan.

$$Entropy(S) = \sum_i^c - p_i \log \log_2 p_i \quad (2)$$

- **Hitung *information gain*** : *Information gain* adalah ukuran yang digunakan untuk mengukur seberapa banyak informasi baru yang dihasilkan ketika data dibagi berdasarkan atribut tertentu. Semakin tinggi *information gain*, semakin banyak informasi baru yang diperoleh dari pemisahan data dengan atribut tersebut. *Information gain* dihitung dengan membandingkan entropi data sebelum dan setelah pemisahan. Entropi data mengukur tingkat ketidakpastian atau keacakan dalam data. Ketika data homogen (semua contoh data memiliki label yang sama), entropi akan rendah (0). Sebaliknya, jika data heterogen (contoh data memiliki label yang berbeda-beda), entropi akan tinggi (nilai lebih dari 0). Tujuan dari *information gain* adalah untuk mencari atribut yang menghasilkan pemisahan data yang homogen, sehingga mengurangi ketidakpastian dan meningkatkan akurasi model.

$$Gain(S, A) = Entropy - \sum_{i \in Values(A)} \frac{|S_i|}{|S|} Entropy(S_i) \quad (3)$$

- **Hitung split information** : Split information mengukur tingkat variasi atau pemisahan yang dihasilkan oleh atribut tertentu. Semakin tinggi split information, semakin tinggi tingkat variasi atau jumlah cabang yang dihasilkan oleh atribut tersebut. Split information dihitung dengan memperhitungkan jumlah cabang yang mungkin dihasilkan oleh atribut.

$$Split\ Information(S, A) = \sum_{j=1}^c - \frac{|S_j|}{|S|} \log_2 \frac{|S_j|}{|S|} \quad (4)$$

- **Hitung gain ratio** : Gain ratio adalah ukuran yang menggabungkan gain informasi dan tingkat pemisahan atribut. Gain informasi mengukur seberapa banyak informasi baru yang dihasilkan dengan membagi data berdasarkan atribut tertentu. Gain ratio menghindari atribut yang memiliki banyak nilai (banyak cabang) yang cenderung menghasilkan pohon yang terlalu kompleks.


$$Gain(S, A) = \frac{Gain(S)}{Split\ Information(S, A)} \quad (5)$$

Dengan menggabungkan *gain ratio* dan *chi-square* yang terlihat pada persamaan 5, kita dapat memilih atribut terbaik untuk digunakan dalam membangun pohon keputusan dengan metode seleksi fitur gabungan tersebut.

2.4. Klasifikasi

2.4.1. K-Fold Cross Validation

Proses klasifikasi dilakukan melalui penggunaan cross-validation, di mana data dibagi secara bergantian menjadi data pelatihan (misalnya K = 5) dengan ukuran yang sama. Setiap subset disebut sebagai "fold".



Gambar 3. Model K- Fold Cross Validation

Seperti yang terlihat pada gambar 3 setiap iterasi dalam proses klasifikasi satu fold digunakan sebagai data validasi, sementara sisanya digunakan sebagai data pelatihan misalnya, jika klasifikasi berada pada iterasi ke-3, fold ke-3 digunakan sebagai data validasi, dan sisa fold (1, 2, 4, dan 5) digunakan sebagai data pelatihan [6].

2.4.2. Split Data

Pada setiap iterasi k dalam K-Fold Cross Validation secara otomatis terdapat pembagian data atau split data dimana 80% akan menjadi data latih dan 20% akan menjadi data uji. Sehingga, setelah dihubungkan dengan pembagian pada *K-Fold Cross Validation*, maka 1 fold akan menjadi data uji dan 4 fold lainnya akan menjadi data latih.

2.4.3. Algoritma C4.5

Setelah dilakukan seleksi fitur, atribut terpilih akan digunakan dalam proses klasifikasi menggunakan algoritma C4.5 untuk membuat pohon keputusan dari set data training yang digunakan untuk klasifikasi kelas dari data testing.

2.5. Evaluasi Dan Analisis

Tahap evaluasi terhadap metode dalam penelitian ini dilakukan menggunakan metode *confusion matrix*. *Confusion matrix* merupakan sebuah metode evaluasi yang umum digunakan untuk mengukur prestasi algoritma *Decision tree* dalam melakukan klasifikasi. *Confusion matrix* memberikan gambaran tentang seberapa baik model *Decision tree* dapat mengklasifikasikan data ke dalam kelas yang benar[7].

3. Hasil dan Pembahasan

3.1. Pengumpulan Data

Pada tahap ini adalah bagian pengumpulan data yang diperlukan untuk menunjang penelitian ini, Pengumpulan data dilakukan di SMA N 1 BLAHBATUH dengan membagikan form maka diperoleh jumlah data dengan tingkatan kelas seperti tabel 1.

Tabel 1. Jumlah Berdasarkan Kelas Siswa

No	Kelas	Jumlah
1	Cukup	64
2	Baik	46
3	Kurang	5
4	Sangat Baik	3
Total		118

Berdasarkan data pada tabel 1 maka data yang di dapat sejumlah 118 dengan jumlah kelas kurang 5, cukup 64, baik 46, sangat baik 3 untuk chart data lebih lengkapnya dapat dilihat pada lampiran.

3.2. Preprocessing Data

Data yang telah dimuat dan digunakan pada penelitian sejumlah 118 yang kemudian dilakukan *cleaning dataset* yang meliputi penghapusan data duplikat dan penghapusan data yang mengandung nilai kosong serta penghapusan data yang tidak ingin digunakan. mengisi nilai kosong (*NaN*) di dataset dengan meneruskan nilai dari baris sebelumnya di kolom yang sama tujuannya adalah memastikan tidak ada nilai kosong dalam dataset, sehingga data tetap konsisten untuk dianalisis lebih lanjut.

3.3. Seleksi Fitur

Dalam penelitian ini penulis akan melakukan pengembangan metode dengan melakukan seleksi fitur seleksi fitur ini dilakukan dengan tujuan untuk menghilangkan fitur-fitur dengan tingkat kebergunaan yang rendah dalam model sehingga dapat mengurangi beban model ketika melakukan klasifikasi hasil seleksi fitur yang hasilnya dapat terlihat pada tabel 2 dan tabel 3.

Tabel 2. Fitur Data Hasil Chi-Square dan *Gain Ration*

Fitur	Skor Chi-Square	Skor Gain Ration
Kenyamanan dalam lingkungan keluarga	32.720455	0.279771
Berapa jarak rumah ke sekolah	20.036781	0.061604
Jam tidur siswa	13.352250	0.075025
sering atau sedang memiliki permasalahan dengan orang tua/keluarga/teman kelas atau lingkungan sekitar	12.009175	0.087716
Waktu yang dihabiskan untuk bermain	11.311554	0.035653
Jenis kelamin	9.355097	0.065582
Kepercayaan diri siswa di sekolah	9.098040	0.061571
Interaktivitas tenaga pengajar di sekolah	8.774870	0.104061
Minat belajar siswa di sekolah	8.503138	0.232432
Masalah ekonomi keluarga	2.255357	0.014231
Apakah sedang mempunyai pasangan/pacar	1.748603	0.033164
Kenyamanan dalam lingkungan sekolah	1.634160	0.023850
Partisipasi dalam organisasi	1.559116	0.016759
Kenyamanan dalam lingkungan kelas/teman kelas	1.118090	0.016254


Pada tabel 2 menampilkan skor seleksi fitur *gain ratio* dan chi-square yang telah dimana semakin besar skor maka semakin relevan relasi fitur dengan hasil prediksi nantinya setelah mendapatkan data hasil dari metode tersebut maka akan diurutkan dengan mengambil fitur terbaik di setiap metode yang telah yang telah diujikan maka didapatkan 10 fitur terbaik yang relevan pada masing-masing seleksi fitur tersebut yang dapat dilihat pada tabel 3.

Tabel 3. Fitur Data Hasil Akhir Seleksi Fitur Gabungan

Fitur	Skor Chi-Square	Skor Gain Ration
Kenyamanan dalam lingkungan keluarga	32.720455	0.279771
Berapa jarak rumah ke sekolah	20.036781	0.061604
Jam tidur siswa	13.352250	0.075025
sering atau sedang memiliki permasalahan dengan orang tua/keluarga/teman kelas atau lingkungan sekitar	12.009175	0.087716
Waktu yang dihabiskan untuk bermain	11.311554	0.035653
Jenis kelamin	9.355097	0.065582
Kepercayaan diri siswa di sekolah	9.098040	0.061571
Interaktivitas tenaga pengajar di sekolah	8.774870	0.104061
Apakah sedang mempunyai pasangan saat ini?	0.033164	1.748603
Minat belajar siswa di sekolah	8.503138	0.232432

3.4. Klasifikasi

Implementasi model klasifikasi dengan metode *decision tree* C4.5 serta akan dilakukan juga *k-fold cross validation* untuk melihat tingkat konsistensi model dalam melakukan klasifikasi sehingga model tidak hanya terlihat bagus dalam satu kondisi saja dan menghasilkan model terbaik yang visualnya dapat dilihat pada gambar 4.




Gambar 4. Visualisasi Model Decision Tree

3.5. Evaluasi Dan Analisis

Pada Implementasi penulis melakukan evaluasi rata-rata *confusion matrix* dari akurasi terbaik k-fold cross-validation, seperti True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN), yang memberikan gambaran detail performa model serta membedakan antara kelas positif dan negatif. Hasil evaluasi juga divisualisasikan dalam bentuk heatmap menggunakan *seaborn*,

yang mempermudah interpretasi *confusion matrix* dengan tampilan yang informatif, menampilkan hubungan antara prediksi dan label sebenarnya untuk setiap kelas.




Gambar 5. Confusion Matrix Model Decision Tree c4.5

Pada gambar 5 merupakan hasil *confusion matrix* model *decision tree* tanpa implementasi seleksi fitur. Detail matriks evaluasi dapat dilihat pada tabel 4

Tabel 4. Matriks Evaluasi Model *Decision Tree* tanpa Seleksi Fitur

Matrik Evaluasi	Nilai
<i>Accuracy</i>	0.542
<i>Precision</i>	0.215
<i>Recall</i>	0.391
<i>F1-Score</i>	0.276

Sedangkan hasil *confusion matrix* model *decision tree* dengan implementasi seleksi fitur dapat dilihat pada gambar 6



Gambar 6. Confusion Matrix Model Decision Tree c4.5 dengan Implementasi Seleksi Fitur

Untuk detail matriks evaluasi model decision tree c4.5 dengan implementasi seleksi fitur dapat dilihat pada tabel 5.

Tabel 5. Matriks Evaluasi Model *Decision Tree* dengan Seleksi Fitur

Matrik Evaluasi	Nilai
<i>Accuracy</i>	0.820
<i>Precision</i>	0.799
<i>Recall</i>	0.809
<i>F1-Score</i>	0.792

Berdasarkan hasil implementasi model klasifikasi telah diperoleh sebanyak dua model klasifikasi yang dapat dibandingkan antara satu dengan yang lain untuk memilih model terbaik yang akan diimplementasikan dalam sistem. Adapun resume hasil implementasi dapat dilihat pada tabel 6.

Tabel 6. Resume Hasil Evaluasi Model

Model	TP	TN	FP	FN	AC	PR	RC	F1
A	6	29	5	4	0.542	0.215	0.391	0.276
B	8	32	1	1	0.822	0.788	0.773	0.769

Model A merupakan model awal yang memperoleh accuracy 0.542, precision 0.215, recall 0.391, dan F-1 score 0.276. Dimana berdasarkan tabel 4.10 nilai tersebut menunjukkan performa model yang tergolong kurang baik dalam melakukan klasifikasi. Kemudian pada implementasi selanjutnya dengan mengimplementasikan seleksi fitur, didapatkan sembilan fitur yang memiliki korelasi terbaik yaitu “Kenyamanan dalam lingkungan keluarga”, “Berapa jarak rumah ke sekolah”, “Jam tidur”, “sering atau sedang memiliki permasalahan dengan orang tua/keluarga/teman kelas atau lingkungan sekitar”, “Waktu yang dihabiskan untuk bermain”, “Jenis kelamin”, “Kepercayaan diri siswa di sekolah”, “Interaktivitas tenaga pengajar di sekolah”, “Minat belajar siswa di sekolah” fitur tersebut yang digunakan dalam implementasi selanjutnya yang menghasilkan Model B. Model B yang merupakan model hasil implementasi

seleksi fitur terbaik yang memperoleh accuracy 0.820, precision 0.799, recall 0.809, F-1 score 0.782 lebih baik dari model sebelumnya, Untuk detail hasil pengujian fitur lainnya dapat dilihat pada lampiran.

3.6. Implementasi Pada Model Sistem

Dari hasil model yang terpilih selanjutnya diimplementasikan pada sebuah sistem sederhana untuk melakukan prediksi prestasi siswa sekolah berdasarkan hasil klasifikasi dari model. Sistem dibangun dalam aplikasi website dalam pengimplementasiannya.



Gambar 8. Halaman Lading Page

4. Kesimpulan

Terdapat peningkatan performa model dengan seleksi fitur menggunakan metode kombinasi gain ratio dan chi- yang berhasil meningkatkan performa model klasifikasi. Hal ini terlihat dari perbandingan antara model awal tanpa seleksi fitur dan model dengan seleksi fitur. Model dengan seleksi fitur memperoleh rata-rata akurasi sebesar 82.2%, *precision* 78.8%, *recall* 77.3%, dan *F1-score* 76.9%, yang jauh lebih baik dibandingkan model awal dengan akurasi 54.2%, *precision* 21.5%, *recall* 39.1%, dan *F1-score* 27.6%. Seleksi fitur chi-square dan gain ratio yang telah diimplementasikan mampu mengidentifikasi sepuluh fitur terbaik yang relevan untuk prediksi prestasi akademik siswa dimana setelah dilakukan percobaan *threshold* fitur yang terpilih pada model akurasi terbaik memiliki score gain ratio di atas 0.015 dan score chi-square di atas 1.60. Pengurangan jumlah fitur ini telah berhasil meningkatkan akurasi model dengan cukup baik.

Referensi

- [1] Kurniawati, F. N. (2022). MENINJAU PERMASALAHAN RENDAHNYA KUALITAS PENDIDIKAN DI INDONESIA DAN SOLUSI. *Academy of Education Journal*, 13, 13.
- [2] Syarifuddin. (2022). Menurunnya Kualitas Pendidikan Seiring Dengan Adanya Inovasi Pendidikan. : *Inovasi Pendidikan-AKBK3602*, 1, 6.
- [3] Sari, B. N. (216). IMPLEMENTASI TEKNIK SELEKSI FITUR INFORMATION GAIN PADA ALGORITMA KLASIFIKASI MACHINE LEARNING UNTU PREDIKSI PERFORMA AKADEMIK SISWA. *Betha Nurina Sari*(2302-3805), 6.
- [4] Vivy Junita, F. A. (2019). Klasifikasi Aktivitas Manusia menggunakan Algoritme Decision Tree C4.5 dan Information Gain untuk Seleksi Fitur. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(10), 8.

- [5] WAHYUDI, M. A. (2020). PENERAPAN FITUR SELEKSI GAIN RATIO DAN DECISION TREE C5.0 UNTUK KLASIFIKASI TINGKAT SERANGAN JARINGAN. *SUSKA RIAU*, 1(1), 95.
- [6] Msy Aulia Hasanah, S. S. (2021). Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir. *Journal of Applied Informatics and Computing (JAIC)* , 5(2), 6.
- [7] Oman Somantri, W. E. (2022). Penerapan Feature Selection Pada Algoritma Decision Tree Untuk Menentukan Pola Rekomendasi Dini Konseling . *Jurnal Sistem Komputer dan Informatika (JSON)*, 4(2), 8.
- [8] Ozdemir, S. (2016). *Principles of Data Science*. Birmingham B3 2PB, UK.: Packt Publishing Ltd.
- [9] Ripanti, E. P. (2019). Model Prediksi Awal Masa Studi Mahasiswa Menggunakan Algoritma Decision tree c4.5. *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, 7(4), 7.
- [10] Suradarma, I. M. (2018). Penerapan Optimasi Algoritma C45 dengan Naïve Bayes pada Pemilihan Internet Service Provider. *EKSPLORA INFORMATIKA*, 7(2), 11.

This page is intentionally left blank.

Pengembangan Sistem *Frequently Asked Questions* (FAQ) pada Universitas Udayana Berbasis *Ontology*

Ngurah Kelvin Febryanta Lila Ananda^{a1}, Anak Agung Istri Ngurah Eka Karyawati^{a2}, Cokorda Rai Adi
Pramartha^{a3}, I Gusti Agung Gede Arya Kadyanan^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana

Jalan Raya Kampus Unud, Jimbaran, Bali, 80361, Indonesia

¹ngurahkelvin27@gmail.com

²eka.karyawati@unud.ac.id

³cokorda @unud.ac.id

⁴gungde@unud.ac.id

Abstract

Digital transformation in public services is a strategic step to enhance organizational efficiency and responsiveness in meeting user needs. This study aims to develop an ontology-based Frequently Asked Questions (FAQ) system to provide accurate, relevant, and easily accessible information at Udayana University. The system is designed using an ontology-based approach that represents relationships between concepts in a structured manner, combined with the Sentence Transformer (Sentence-BERT) method to understand variations in language and sentence structures in user queries. The study results show that the development of the ontology-based FAQ system successfully represents information in a structured and relevant manner according to user needs. The evaluation indicates a usability score of 90% and a usefulness score of 88.57%, reflecting a high level of user acceptance and system benefits. Out of 20 questions tested, the system correctly answered 16 questions, achieving an accuracy rate of 80%. Overall, this ontology-based FAQ system effectively meets user needs by providing relevant, accurate, and efficient answers while reducing the workload of administrative staff. The system has significant potential to support more comprehensive information services at Udayana University.

Keywords: *Ontology, FAQ System, Sentence-BERT, User Evaluation, Udayana University.*


1. Pendahuluan

Transformasi digital layanan publik sangat penting untuk meningkatkan efisiensi dan responsivitas [1]. Organisasi yang sukses menyediakan informasi yang akurat, tepat waktu, dan relevan untuk memenuhi kebutuhan pengguna. Sistem FAQ (*Frequently Asked Question*) menangani hal ini dengan memberikan jawaban atas pertanyaan umum tanpa perlu interaksi langsung dengan staf [2]. Universitas Udayana, perguruan tinggi terkemuka di Bali, menghadapi tantangan dalam menyediakan informasi yang tepat waktu kepada penggunanya, seperti mahasiswa, staf, dan masyarakat. Saat ini, pertanyaan ditangani melalui interaksi dengan staf yang memakan waktu. Untuk mengatasi hal ini, diusulkan sistem informasi berbasis FAQ. Sistem ini berfungsi sebagai *Knowledge Management System* (KMS) bagi staf untuk mendokumentasikan pengetahuan organisasi dan juga sebagai alat untuk mengurangi pertanyaan yang berulang.

Dengan mengintegrasikan teknologi web semantik, sistem ini akan meningkatkan akurasi dan relevansi pencarian, mendukung penggunaan *ontology* untuk mengorganisasi pengetahuan. Penggunaan *Sentence-BERT* akan lebih meningkatkan sistem dengan memberikan pemahaman semantik, memungkinkan penanganan variasi bahasa alami dalam pertanyaan pengguna. Kombinasi sistem FAQ, *ontology*, dan *Sentence-BERT* akan menciptakan platform layanan mandiri yang efisien bagi pengguna dan mengurangi beban kerja administrasi.

2. Metode Penelitian

Pada metode pelaksanaan ini menjelaskan gambaran dari langkah-langkah yang akan Metodologi penelitian ini, dijelaskan uraian tentang prosedur yang akan dilakukan dalam penelitian ini. Proses-proses tersebut dapat ditemukan pada gambar 1 yang mencakup tahapan identifikasi permasalahan, analisis kebutuhan, preprocessing-data, pengumpulan data, pembangunan ontology, pembangunan model *ontology*, pembangunan dan perancangan sistem, serta pengujian dan evaluasi.



Gambar 1. Metode Pelaksanaan

Penelitian ini mengembangkan sistem FAQ berbasis ontology untuk meningkatkan akses informasi akademik di Universitas Udayana. Masalah utama yang diidentifikasi adalah keterlambatan respons sistem yang masih bergantung pada admin USDI Care. Dengan metode Methontology, sistem dirancang melalui tahapan spesifikasi, akuisisi pengetahuan, konseptualisasi, hingga implementasi [3]. Teknologi SBERT digunakan untuk mendeteksi kata kunci dalam pertanyaan, yang kemudian diterjemahkan ke dalam query SPARQL untuk mengambil jawaban dari database ontology. Pengujian menggunakan Black Box Testing dan Confusion Matrix menunjukkan bahwa sistem mampu meningkatkan efisiensi pencarian informasi, sementara evaluasi TAM mengonfirmasi kemudahan penggunaan serta manfaatnya bagi mahasiswa.

3. Hasil dan Diskusi

Hasil utama dari penelitian ini adalah menghasilkan sebuah website sistem *Frequently Asked and Questions* (FAQ) berbasis *ontology* yang dibangun dengan Langkah-langkah sebagai berikut.

3.1. Identifikasi Masalah

Tahapan pertama dalam penelitian ini yaitu mengidentifikasi dari permasalahan yang diangkat. Dimana tujuan dari dilakukannya penelitian ini adalah untuk menyelesaikan masalah yang ada. Permasalahan didalam penelitian ini adalah mahasiswa masih harus menunggu waktu lama untuk menanyakan suatu hal terkait akademik yang dimana, *system* itu sendiri belum akurat dan relevan. Walaupun sudah ada sistem yang dapat membantu menjawab pertanyaan yang dimana harus menunggu admin USDI care menjawabnya, dan belum adanya sistem FAQ bagi mahasiswa untuk dapat memudahkan mahasiswa dalam memberikan jawaban terkait Uang Kuliah Tunggal (UKT).

3.2. Analisis Kebutuhan

Tahap kedua dalam penelitian ini adalah menjelaskan mengenai analisis kebutuhan sistem. Analisis ini terdiri dari analisis kebutuhan fungsional dan analisis non-fungsional sebagai berikut.

Tabel 1. Analisis Kebutuhan Fungsional dan Non-Fungsional

No.	Kebutuhan Fungsional	Kebutuhan Non-Fungsional
1	Sistem yang dibangun memungkinkan pengguna untuk mengetahui pertanyaan yang sering ditanyakan oleh pengguna lainnya.	Hardware Requirement : Perangkat keras yang dibutuhkan yaitu laptop atau komputer yang dapat digunakan untuk membangun ontology serta sistem berbasis web.
2	Sistem yang dibangun dengan adanya fitur pencarian (<i>searching</i>) FAQ, sistem memiliki kemampuan untuk melakukan pencarian informasi yang lebih terperinci sesuai dengan keterkaitan dan makna antara konsep-konsep dalam domain FAQ.	Software Requirement : • Protégé 5.5.0 Build Beta-9 dan webprotege.stanford.edu untuk membuat, mengedit, dan menyimpan model ontology. • Apache Jena Fuseki sebagai server untuk mengeksekusi SPARQL dalam mengolah data RDF. • Visual Studio Code sebagai text editor dalam pembangunan program berbasis web.

3.3. Pengumpulan Data

Proses pengumpulan data dalam sistem ini terdiri dari dua tahap, yaitu pengumpulan data untuk ontology dan pengumpulan data untuk pengujian serta evaluasi. Berikut ini adalah penjelasan mengenai proses pengumpulan data yang dilakukan dalam penelitian ini.

a. Pengumpulan Data Ontology

Mengumpulkan data untuk membangun model ontology pada domain *Frequently Asked and Questions* (FAQ). Dalam pengumpulan data ontology, peneliti mendapatkan data dengan melakukan pengajuan permohonan permintaan data pertanyaan serta jawaban kepada petugas Unit Sumber Daya Informasi (USDI) dengan mengajukan surat permohonan. Data yang didapat peneliti sebanyak 2.442 data pertanyaan dan jawaban. Berdasarkan data yang diperoleh, mulai dari tahap pengumpulan data awal hingga tahap pengumpulan data untuk pengembangan model ontology, peneliti menetapkan sejumlah kriteria yang akan digunakan dalam sistem ini. Kriteria tersebut meliputi beberapa aspek berikut.

1. Jawaban.
2. Pertanyaan.
3. Kategori.
4. *Keywords*.

b. Pengumpulan Data Evaluasi

Pengumpulan data untuk evaluasi sistem FAQ dilakukan melalui media sosial dengan menggunakan kuesioner Google Form. Kuesioner tersebut dirancang berdasarkan konsep *Technology Acceptance Model* (TAM) dan mencakup aspek Persepsi Kemudahan (*Perceived Usefulness*) serta Persepsi Kemudahan Penggunaan (*Perceived Ease of Use*).


3.4. Pre – Processing

Data yang diperoleh sejumlah 1334 kemudian dilakukan pre-processing meliputi penghapusan data duplikat dan penghapusan data yang mengandung nilai kosong, *lowercasing* data guna untuk meningkatkan akurasi dalam model, lalu pembersihan karakter disetiap kalimat. Tujuannya adalah untuk membuat representasi identik dari kata-kata yang terkait dengan kapitalisasi yang berbeda, seperti “UKT” dan “ukt”, sehingga akurasi model dalam memproses teks bisa lebih konsisten. Selain itu, teknik pembersihan karakter menggunakan *regular expression* untuk menghapus elemen-elemen seperti tanda baca, simbol, atau tag html, sehingga meningkatkan performa model dalam mengelola data. Idenya adalah mengurangi gangguan dalam analisis, memudahkan proses tokenisasi, dan memungkinkan model berkerja secara lebih baik dengan data yang diberikan. Serta dilakukan

tokenisasi, penyaringan data, klasifikasi kategori, dan ekstraksi kata kunci untuk memecah kalimat menjadi potongan-potongan kata, sehingga mempermudah proses analisis.

3.5. Membangun Model Ontology

Bagian ini membahas proses implementasi pembangunan ontology pada domain FAQ menggunakan metode *Methontology* dan metode SBERT untuk klasifikasi pertanyaan. *Methontology* memiliki kemampuan untuk melakukan life cycle ontology yang didasarkan pada pengembangan prototype yang memungkinkan untuk melakukan penambahan, perubahan, dan penghapusan terms pada tiap versi terbarunya[4].



Gambar 2. Diagram alur Metode *Methontology*

a. Pengembangan Model Ontology Dengan Menthontology

1. Spesifikasi

Pada tahapan ini sudah dihasilkan spesifikasi ontology domain buku dengan deskripsi sebagai berikut:

- Domain : *Frequently Aksed and Question* (FAQ)
- Tanggal : 27 November 2024
- Dirancang Oleh : Ngurah Kelvin Febryanta Lila Ananda
- Diimplementasikan oleh : Ngurah Kelvin Febryanta Lila Ananda
- Tujuan : Membangun model *ontology* sebagai dasar Pengembangan Sistem *Freqeuntly Asked and Quenstion* (FAQ) Pada Universitas Udayana Berbasis Ontology
- Tingkat formalitas : Formal
- Ruang lingkup : Universitas Udayana
- Sumber pengetahuan : Unit Sumber Daya Informasi (USDI) Universitas Udayana


2. Akuisisi Pengetahuan

Pada tahap ini, proses akuisisi pengetahuan untuk *ontology* pada domain FAQ yang dilakukan oleh peneliti mencakup beberapa langkah berikut:

- Berdiskusi dengan dosen pembimbing untuk menyusun dokumen draft awal dokumen spesifikasi persyaratan
- Melakukan analisis terhadap teks formal dengan cara mengidentifikasi struktur yang dicari serta mengelompokkan informasi yang terkandung dalam setiap konsep, atribut, nilai, dan hubungan yang terkait.

3. Konseptualisasi

Tahap konseptualisasi ontology bertujuan untuk mengorganisasi dan mengelola pengetahuan yang diperoleh selama proses akuisisi pengetahuan [5] yang Dimana memanfaatkan konsep *triplestore*. Setelah model konseptual selesai dibuat, metodologi ini akan mengubahnya menjadi model formal.



Gambar 3. Konseptualisasi Pada Ontology FAQ


4. Integrasi

Dalam pembangunan model *ontology* FAQ dengan studi kasus pertanyaan di Universitas Udayana, tahap integrasi tidak dilakukan karena ini merupakan pertama kalinya *ontology* FAQ dikembangkan dan belum ada model *ontology* serupa yang relevan.

5. Implementasi


Pada tahap implementasi merupakan proses penerapan model *ontology* yang telah dikembangkan pada tahap konseptualisasi. Setiap elemen *ontology* dirancang berdasarkan langkah-langkah Methontology, di mana kelas mewakili konsep, object properties mendefinisikan hubungan antar konsep, datatype properties digunakan untuk atribut, dan individu merepresentasikan instance. Class merupakan semua entitas yang

tergolong dalam kelompok atau keluarga objek. Model ontology ini kemudian diimplementasikan menggunakan Protégé untuk domain FAQ.



Gambar 4. Ontograp pada *ontology* FAQ

Pada gambar 4 terdapat 4 *class* utama yang digunakan dalam *ontology* ini yaitu pertanyaan, kategori, keywords dan jawaban yang divisualisasikan dengan ontograp.




Gambar 5. *Object property* pada *ontology* FAQ

Gambar 5 menampilkan object property dalam ontology domain FAQ, di mana individu atau instance direpresentasikan berdasarkan pola *triplestore*. *Triplestore* terdiri dari tiga elemen utama: Subjek, Predikat, dan Objek, yang berfungsi sebagai pernyataan tetap dalam ontology. Predikat berperan sebagai penghubung antar objek dalam sistem.

6. Evaluasi
Proses evaluasi *ontology* melibatkan verifikasi untuk memastikan kecocokan dengan kerangka acuan dan validasi untuk memastikan kesesuaian dengan spesifikasi sistem. Pada aplikasi Protégé, alat Reasoner HermiT versi 1.3.6 digunakan untuk memeriksa konsistensi ontology.
7. Dokumentasi
Tidak terdapat pedoman baku mengenai cara mendokumentasikan *ontology*. Dalam praktiknya, dokumentasi *ontology* seringkali hanya tersedia dalam bentuk kode *ontology*,

deskripsi dalam bahasa alami, serta publikasi seperti makalah dalam prosiding konferensi atau jurnal ilmiah.



Ontology metrics:	
Metrics	
Axiom	926
Logical axiom count	739
Declaration axioms count	187
Class count	4
Object property count	6
Data property count	3
Individual count	174
Annotation Property count	0
Class axioms	
SubClassOf	0
EquivalentClasses	0
DisjointClasses	0
GCI count	0
Hidden GCI Count	0
Object property axioms	
SubObjectPropertyOf	0
EquivalentObjectProperties	0
InverseObjectProperties	3
DisjointObjectProperties	0
FunctionalObjectProperty	0
InverseFunctionalObjectProperty	0
TransitiveObjectProperty	0

Gambar 6. Metrics Ontology Domain FAQ

3.6. Pembangunan dan perancangan system

Bagian ini menjelaskan implementasi sistem untuk penelusuran dan pencarian informasi buku yang dikembangkan menggunakan metode *Prototyping*. Proses implementasi sistem akan diuraikan berdasarkan tahapan-tahapan yang telah dirancang sebelumnya.


a. Kebutuhan system

Beberapa perangkat lunak dan *library* yang digunakan dalam pengembangan sistem pencarian dan rekomendasi buku adalah sebagai berikut.

1. MacOS Sonoma 14.2.1
2. Protege 5.6.4
3. JavaScript v20.9.0
4. Next JS 15
5. Visual Studio Code
6. Tailwind CSS
7. Apache Jena Fuseki 5.2.0
8. Apache J Meter 5.6.3
9. MYSQL
10. Google Chrome
11. Google Colab

b. Arsitektur Sistem

Arsitektur sistem (*system architecture*) merupakan susunan atau kerangka yang digunakan dalam merancang, menghubungkan, dan mengelola berbagai komponen yang membentuk suatu sistem.




Gambar 7. Arsitektur sistem FAQ

Arsitektur sistem FAQ berbasis *ontology* dengan metode SBERT terdiri dari beberapa komponen utama, termasuk antarmuka pengguna, *ontology*, SBERT, triple store, dan web server. *Ontology* berperan sebagai basis pengetahuan, sementara SBERT bertugas mengidentifikasi serta mencocokkan pertanyaan dengan data yang tersedia. *Triple store*, seperti Apache Jena Fuseki, digunakan untuk menjalankan query SPARQL, sedangkan web server berbasis *flask* mengatur komunikasi antara UI dan *backend*. Seluruh sistem berjalan di atas sistem operasi, memastikan informasi yang diberikan akurat dan sesuai dengan konteks pertanyaan pengguna.

c. Implementasi Model *Ontology* ke Sistem

Pada tahap implementasi, *ontology* domain buku diintegrasikan ke dalam sistem dengan mengunggahnya ke server Apache Jena Fuseki. Server Fuseki berfungsi untuk mengelola dan menyimpan data *ontology*, sehingga *ontology* tersebut dapat diakses dan digunakan oleh sistem. File *ontology* yang diunggah berformat OWL. Proses pengunggahan *ontology* ke server Fuseki ditunjukkan pada Gambar 8.



Gambar 8. Proses Unggah File *Ontology* ke Server Jena Fuseki

Setelah proses pengunggahan selesai, langkah berikutnya adalah menghubungkan *ontology* dengan sistem menggunakan CURL untuk berkomunikasi dengan *endpoint* SPARQL. Di bawah ini adalah kode sumber untuk proses koneksi antara *ontology* dan sistem.

d. Implementasi SBERT

Implementasi sistem FAQ berbasis *ontology* dengan metode SBERT terdiri dari beberapa tahapan utama. SBERT digunakan untuk menghasilkan *embedding* pertanyaan pengguna dan dataset, memungkinkan perbandingan semantik menggunakan *Cosine Similarity*[6]. Model ini diimplementasikan dalam kelas *QuestionClassifier*, yang bertugas memuat serta memproses dataset, menghitung *embedding* pertanyaan, dan mengklasifikasikan input berdasarkan kesamaan dengan data yang tersimpan. Ketika pengguna mengajukan pertanyaan melalui *endpoint/classify*, sistem mengidentifikasi kategori menggunakan SBERT, menghitung skor kesamaan, dan mengembalikan hasil dalam format JSON. Selanjutnya, *query* SPARQL dibuat berdasarkan kategori dan kata kunci 5W1H yang terdeteksi untuk mengambil informasi dari *ontology* yang tersimpan di server Fuseki. Berikut adalah kode SPARQL yang digunakan untuk mengekstrak informasi yang relevan:

Tabel 2. Code SPARQL Query


```
SELECT ?isi ?jawaban
WHERE {
  ?question rdf:type f:pertanyaan.
  ?question f:MemilikiCategory f:${res.data.predicted_category}.
  ?question f:MemilikiKeywords f:${res.data.detected_5w1h_keywords}.
  ?question f:isi ?isi.
  ?question f:jawaban ?jawaban.
}
```

Melalui proses ini, sistem mampu menyaring hasil pencarian secara efektif dan hanya menampilkan jawaban yang paling relevan. Setelah Fuseki mengeksekusi *query* SPARQL, aplikasi memproses data untuk menemukan jawaban yang paling sesuai dengan

pertanyaan pengguna, sehingga meningkatkan efisiensi dan akurasi dalam sistem FAQ berbasis *ontology*.

e. Implementasi Antarmuka Sistem

Dalam implementasi antarmuka, desain antarmuka yang telah dirancang sebelumnya akan direalisasikan menggunakan bahasa pemrograman HTML dengan *framework* Next JS serta CSS menggunakan Tailwind. Berikut ini adalah penjelasan mengenai hasil implementasi antarmuka sistem yang telah dikembangkan.



Gambar 9. Tampilan Antarmuka Sistem

Gambar diatas sistem FAQ ini. Dimana pengguna akan diminta meinputkan pertanyaan mengenai kampus udayana khususnya mengenai UKT. Setelah itu hasil dari inputan user dimana akan menampilkan klasifikasi pertanyaan berupa kategori serta *keywords*. Jawaban yang ditampilkan sesuai dengan apa yang ditanyakan oleh pengguna.

3.7. Pengujian dan Evaluasi

a. Pengujian

Pengujian mencakup fitur utama, seperti klasifikasi kategori pertanyaan dan deteksi kata kunci 5W1H, untuk memastikan kinerja sistem sesuai ekspektasi. Evaluasi mencakup pengukuran akurasi, precision, recall, dan F1-score menggunakan *Confusion Matrix* dan *Classification Report*, serta *precision*, *recall*, dan *F1-score* untuk deteksi kata kunci. Untuk mengoptimalkan kinerja dan menguji ketahanan, pengujian stress API dilakukan menggunakan Apache JMeter.

1. Stress Testing

Setelah sebuah sistem selesai di bangun, maka dilakukanlah sebuah pengujian stress terhadap API (*Application Programing Interface*) dengan menggunakan Apache JMeter

[7]. Testing ini dilakukan untuk lebih mengoptimalkan sistem dan memeriksa ketahanan dari sistem.

Gambar 10. Tampilan API Testing Respons Jmaster

2. Confusion Matrix

Hasil evaluasi model menunjukkan akurasi klasifikasi kategori sebesar 78,57, dengan beberapa kategori, seperti "lainnya" dan "uncategorized", memiliki *precision*, *recall*, dan *F1-score* rendah, kemungkinan akibat ketidak seimbangan data. Kategori "pembayaran" menunjukkan hasil sangat baik (*precision* 0.91, *recall* 0.88, *F1-score* 0.90), sementara kategori lain seperti "pengurangan" dan "tagihan" memiliki performa lebih rendah. Rata-rata akurasi makro menunjukkan *precision* 0.46, *recall* 0.39, dan *F1-score* 0.40, dipengaruhi kategori dengan hasil buruk, sementara rata-rata tertimbang lebih baik (*precision* 0.83, *recall* 0.79, *F1-score* 0.80) karena kontribusi kategori unggul seperti "pembayaran".

Tabel 3. Tampilan Precision, recall, f1-score

kategori	precision	recall	f1-score	support
keringanan	1.00	0.61	0.76	18
lainnya	0.00	0.00	0.00	0
masalah	0.67	0.57	0.62	7
pembayaran	0.91	0.88	0.90	213
pengurangan	0.50	0.29	0.36	7
tagihan	0.13	0.40	0.20	10
uncategorized	0.00	0.00	0.00	11
Accuracy	0.79			

Model mendeteksi kata kunci 5W1H dengan cukup baik, mencapai *precision*, *recall*, dan *f1-score* sebesar 0.8540. Meskipun efektif, masih ada ruang untuk perbaikan, terutama dalam meningkatkan *recall* dan *precision* pada kategori yang sulit dikenali. Secara keseluruhan, model menunjukkan kinerja yang memadai, namun perlu optimalisasi untuk meningkatkan akurasi deteksi kata kunci. Hasil selengkapnya ditampilkan pada tabel 4.

Tabel 3. Tampilan Precision, recall, f1-score

Matrik evaluasi	Nilai
Precision	0.854
Recall	0.854
f-1 score	0.854

3. Pengujian pertanyaan

Dari 20 pertanyaan yang diuji, sistem berhasil menjawab 16 dengan benar, menghasilkan tingkat keberhasilan 80%, dan kegagalan 20%. Ini menunjukkan bahwa sistem dapat

memahami dan menjawab sebagian besar pertanyaan sesuai kategori dan *keywords* yang ditentukan.

4. Blackbox Testing

Tabel 2. Pengujian Blackbox

No.	Test Case	Hasil
1	• Skenario : pengguna membuka sistem FAQ • Tes : aplikasi akan menampilkan halaman <i>landing page</i> sistem yang terdapat judul halaman serta inputan user berupa pertanyaan yang akan diajukan	Berhasil
2	• Skenario : pengguna mengisi pertanyaan di bar <i>search</i> • Tes : pengguna dapat mengisi pertanyaan	Berhasil
3	• Skenario : pengguna tidak mengisi input pertanyaan • Tes : sistem akan memberikan peringatan pertanyaan tidak ditemukan	Berhasil
4	• Skenario : pengguna mengisi pertanyaan yang valid degan topik UKT • Tes : sistem akan menampilkan klasifikasi pertanyaan berupa Category serta Keywords	Berhasil

Hasil pengujian terhadap Pengujian dilakukan dengan metode Blackbox Testing sesuai skenario dalam Tabel 2. Dapat dilihat dari pengujian ini hasil seluruh adalah berhasil atau valid dapat berjalan dengan baik.

a. Evaluasi Sistem


Pada tahap evaluasi sistem ini, data dari penilaian responden terhadap sistem diolah dan dianalisis. Proses ini mencakup dua aspek utama, yaitu evaluasi kemudahan penggunaan sistem dan evaluasi kegunaannya, sesuai dengan konsep *Technology Acceptance Model* (TAM) [8]. Untuk mengolah hasil kuesioner, dilakukan analisis statistik menggunakan google colab.

Setelah dilakukannya pengolahan data, didapat hasil PU dan PEOU sebagai berikut:

1. Hasil PEOU (*Perceived Ease Of Use*)

- Nilai rata-rata (*mean*): Analisis menunjukkan bahwa skor rata-rata yang diberikan oleh responden untuk seluruh pertanyaan adalah 6,4, yang setara dengan 90% jika diubah ke dalam bentuk persentase. Ini menandakan bahwa mayoritas responden menyatakan "sangat setuju" dengan kemudahan penggunaan sistem.
- Nilai tengah (*median*): Nilai median didapatkan dengan cara mengurutkan skor dan memilih angka yang ada di tengah. Dari seluruh responden, median yang didapat adalah 6, yang berarti "setuju" dalam skala *likert*. Ini menunjukkan bahwa sebagian besar peserta memiliki tingkat persetujuan yang cukup tinggi terhadap kemudahan sistem.
- Nilai terkecil (*minimum*): Skor terendah yang didapat dalam evaluasi kemudahan adalah 5, yang dalam skala Likert berarti "agak setuju." Ini menunjukkan bahwa responden yang memberikan nilai ini masih menyatakan persetujuan, meskipun tidak sekuat responden lainnya.
- Nilai terbesar (*maximum*): Hasil analisis menunjukkan bahwa skor tertinggi yang diberikan oleh responden adalah 7, yang pada skala *likert* berarti "sangat setuju."


Skor ini mencerminkan tingkat persetujuan tertinggi dari peserta terkait kemudahan penggunaan sistem.



Gambar 13. Diagram Hasil PEOU

2. Hasil PU (*Perceived Usefulness*)

- Nilai rata-rata (*mean*): Berdasarkan analisis, rata-rata skor yang diberikan responden untuk semua pertanyaan adalah 6,2, yang jika diubah ke persentase setara dengan 88,57%. Ini menunjukkan bahwa mayoritas responden setuju dengan kegunaan sistem yang digunakan.
- Nilai tengah (*median*): Nilai median didapatkan dengan mengurutkan skor dan memilih angka yang ada di tengah. Dari hasil analisis, median yang diperoleh adalah 6, yang dalam skala Likert berarti "setuju." Hal ini menunjukkan bahwa sebagian besar peserta memberi penilaian positif terhadap kegunaan sistem.
- Nilai terkecil (*minimum*): Skor terendah yang didapat dalam penilaian kegunaan sistem adalah 5, yang pada skala Likert berarti "agak setuju." Ini menunjukkan bahwa tingkat persetujuan yang paling rendah dari responden terhadap kegunaan sistem masih cukup positif.
- Nilai terbesar (*maximum*): Analisis mengungkapkan bahwa skor tertinggi yang diberikan responden adalah 7, yang pada skala Likert berarti "sangat setuju." Nilai ini menunjukkan bahwa sebagian peserta sangat setuju dengan penilaian mereka terhadap kegunaan sistem.



Gambar 14. Diagram Hasil PU

4. Kesimpulan

Dalam Perancangan Sistem Informasi Buku dapat diambil kesimpulan sebagai berikut:

- a. Hasil penelitian ini merancang sistem FAQ berbasis ontologi yang menyajikan informasi secara terstruktur dan saling terhubung. Dengan ontologi sebagai kerangka pengetahuan, sistem dapat merepresentasikan hubungan antar konsep secara jelas, memastikan informasi yang disediakan sesuai dengan kebutuhan pengguna. Hasil evaluasi menunjukkan tingkat kemudahan penggunaan sebesar 90% dan kegunaan 88,57%, yang mengindikasikan bahwa sistem ini efektif dalam memberikan jawaban yang akurat. Secara keseluruhan, sistem mampu

menjawab pertanyaan dengan tepat serta menyusun informasi sesuai dengan struktur ontologi yang telah dikembangkan.

- b. Berdasarkan hasil pengujian menunjukkan bahwa sistem dapat menjawab 16 dari 20 pertanyaan dengan benar, sementara 4 lainnya belum sesuai harapan. Keberhasilan sistem dipengaruhi oleh kategori pertanyaan, penggunaan kata kunci, dan struktur kalimat. Kinerja terbaik tercapai pada kategori pembayaran dan tagihan dengan skor di atas 0.85, sedangkan kategori pengurangan UKT memerlukan perbaikan. Secara keseluruhan, sistem cukup efektif dalam menangani permasalahan UKT, meskipun masih terdapat aspek yang perlu dikembangkan.

Refrensi

- [1] Budiman, A. E., & Widjaja, A. (2020). Analisis pengaruh teks preprocessing terhadap deteksi plagiarisme pada dokumen tugas akhir. *JuTISI*, 6(3), 1-10.
- [2] Yunaningsih, A., Indah, D., & Septiawan, F. E. (2021). Upaya Meningkatkan Kualitas Layanan Publik Melalui . *Jurnal ALTASIA*, 9-16.
- [3] Pramatha, C., Koten, I., Putra, I. G. N. A. C., Supriana, I. W., & Arka, I. W. (2022). Pengembangan Sistem Dokumentasi Melalui Pendekatan Ontology untuk Praktek Budaya Bali. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 11(3), 259–268. <https://doi.org/10.23887/janapati.v11i3.53939>
- [4] Purnomo, D. (2017). Model Prototyping Pada Pengembangan. *JIMP - Jurnal Informatika Merdeka Pasuruan*, 54-61.
- [5] Novianti, K. D. P., & Wibawa, M. S. (2017). Ontology Model untuk Tourist Information Retrieval. *Konferensi Nasional Sistem & Informatika 2017*, 165.
- [6] Reimers, N., & Gurevych, I. (2019). *Sentence-BERT: Sentence Embeddings using Siamese BERT-*
- [7] Sabella, B., Lestari, A., Rahma Tina, R., & Achmad, F. (2024). Pengujian Aplikasi SIHARAPAN Menggunakan Metode Stress Testing. In *Jurnal Teknologi Informasi dan Terapan (J-TIT)* (Vol. 11, Issue 1). <https://doi.org/10.25047/jtit.v11i1.359>
- [8] Yani, E., Lestari, A. F., Amalia, H., & Puspita, A. (2018). Pengaruh Internet Banking Terhadap Minat Nasabah Dalam Bertransaksi Dengan Technology Acceptance Model. *JURNAL INFORMATIKA*, 34-42.

This page is intentionally left blank.

Pengembangan Sistem Temu Kembali Musik Populer Indonesia Dengan Metode Savoy

I Ketut Teguh Wibawa Lessmana Putra¹, I Gusti Agung Gede Arya Kadyanan², Cokorda Rai Adi Pramatha³, I Gusti Ngurah Anom Cahyadi Putra⁴

Universitas Udayana, Informatika
Jimbaran, Bali

¹teguhlessmana01@gmail.com, ²gungde@unud.ac.id,
³cokorda@unud.ac.id, ⁴anom.cp@unud.ac.id

Abstract

This study aims to develop a popular Indonesian music retrieval system using the Savoy method, designed to enhance the effectiveness of finding relevant music documents based on user queries. The implementation process includes stages of indexing, term weighting, and calculating the relevance of music documents, which is done through the calculation of Term Frequency (TF), Inverse Document Frequency (IDF), and TF-IDF for each keyword. Additionally, the system utilizes the Cosine Similarity algorithm to measure the similarity between keywords and music documents in the database. The system is developed as a web-based platform using PHP programming language and MySQL as the database, with the Laravel framework for the user interface. Therefore, this system allows users to easily search for songs based on keywords such as lyrics or song titles and receive relevant song recommendations. The system's testing results show that the developed music retrieval system successfully provides song recommendations with a high level of relevance. Testing with a dataset of 500 popular Indonesian songs shows that the system can identify relevant songs based on user queries with an accuracy of 87%. Furthermore, survey results from 50 respondents indicate that 90% of users are satisfied with the ease of use and relevance of the recommendations provided by the system. This system proves to be effective in improving the efficiency of searching for popular Indonesian music and offering a better user experience.

Keywords: Music retrieval system, Savoy method, TF-IDF

1. Pendahuluan

Musik populer Indonesia telah mengalami perkembangan yang pesat dengan jutaan lagu tersedia dalam format digital [1]. Akses yang semakin mudah melalui *platform streaming* seperti *Spotify* dan *YouTube Music* meningkatkan kebutuhan akan sistem temu kembali musik yang efektif [2]. Sistem ini memungkinkan pengguna menemukan lagu berdasarkan kueri atau preferensi tertentu, sehingga meningkatkan pengalaman mendengarkan serta mendorong konsumsi musik yang lebih luas [3].

Spotify menjadi salah satu platform yang mengembangkan algoritma pencarian lagu dengan memanfaatkan lebih dari 12 metadata, seperti nama artis, peran artis, genre, tempo, instrumen, lirik, dan gambar sampul [4]. Algoritma ini tidak hanya berdasarkan riwayat pemutaran pengguna tetapi juga alasan mereka memilih lagu tertentu serta *genre favorit* [5]. Dengan analisis metadata yang mendalam, *Spotify* mampu merekomendasikan konten musik yang relevan dan sesuai preferensi pengguna [6].

Salah satu metode yang potensial dalam sistem temu kembali musik adalah metode pembobotan Savoy [7]. Metode ini mempertimbangkan bobot kata berdasarkan frekuensi kemunculannya dalam dokumen musik, dengan asumsi bahwa kata-kata yang jarang muncul memiliki nilai informasi yang lebih tinggi [8]. Savoy dikenal efektif dalam berbagai tugas temu kembali informasi karena dapat menghasilkan output yang lebih luas dan akurat dibandingkan metode konvensional [9].

Penelitian ini berfokus pada dua faktor utama yang berpotensi memengaruhi efektivitas metode Savoy dalam temu kembali musik populer Indonesia, yaitu panjang kueri dan jenis musik [10]. Panjang kueri

dapat bervariasi dari satu kata hingga frasa atau kalimat lengkap [11]. Diduga bahwa kueri yang lebih panjang dapat memberikan informasi yang lebih spesifik sehingga meningkatkan akurasi temu kembali musik [12]. Jenis musik, seperti pop, *rock*, *dangdut*, atau lainnya, juga dapat memengaruhi kinerja metod Savoy karena setiap genre memiliki karakteristik lirik dan struktur yang berbeda [13].

Dengan memahami pengaruh panjang kueri dan jenis musik terhadap efektivitas metode Savoy, penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem temu kembali musik yang lebih optimal untuk musik populer Indonesia [14]. Hasil penelitian ini dapat bermanfaat bagi penyedia layanan musik, musisi, dan pengguna akhir dalam meningkatkan aksesibilitas serta pengalaman menikmati music [15].

2. Metode Penelitian

2.1 Pengumpulan Data


Data dikumpulkan dengan cara memperoleh informasi mengenai jenis musik yang disukai oleh mahasiswa, mempelajari berbagai literatur terkait information *retrieval*, serta memahami mekanisme kerja metode *Support Vector Machine* (SVM) dan metode Savoy. Berikut ini sampel data lagu pada Tabel 1:

Tabel 1 Sampel Data Lagu

#	Lagu	Artis	Tahun
1	<u>Bongkar</u>	<u>Swami</u>	<u>1989</u>
2	<u>Kebyar Kebyar</u>	<u>Gombloh</u>	<u>1979</u>
3	<u>Badai Pasti Berlalu</u>	<u>Berlian Hutaeruk</u>	<u>1977</u>
4	<u>Bis Sekolah</u>	<u>Koes Bersaudara</u>	<u>1964</u>
5	<u>Guru Oemar Bakrie</u>	<u>Iwan Fals</u>	<u>1981</u>
6	<u>Kembali ke Jakarta</u>	<u>Koes Plus</u>	<u>1969</u>
7	<u>Berita Kepada Kawan</u>	<u>Ebiet G. Ade</u>	<u>1979</u>
8	<u>Kehidupan</u>	<u>God Bless</u>	<u>1988</u>
9	<u>Sakura</u>	<u>Fariz RM</u>	<u>1980</u>
10	<u>Bento</u>	<u>Swami</u>	<u>1989</u>

2.2 Pengumpulan Data minat musik Mahasiswa

Untuk mengumpulkan data mengenai jenis musik yang diminati mahasiswa, dibuat sebuah aplikasi yang memungkinkan mahasiswa memasukkan data secara langsung. Data yang diperoleh dari aplikasi ini kemudian digunakan untuk pencarian informasi terkait preferensi musik mahasiswa. Selanjutnya, data tersebut diolah mengikuti alur sistem yang ditunjukkan dalam Gambar 1 berikut ini:




Gambar 1 Alur Pengumpulan Data Minat Musik

Berdasarkan diagram sistem tersebut, alur dimulai dengan admin yang memasukkan data mahasiswa, termasuk username dan password, ke dalam sistem database sebagai informasi utama. Berdasarkan data tersebut, mahasiswa dapat mengakses aplikasi untuk menginputkan jenis musik yang paling mereka sukai serta melakukan pencarian terkait data musik lainnya.


2.3 Proses Input Data

Proses sistem dimulai dengan input data dari jenis musik yang diminati mahasiswa. Pada proses input data musik adalah proses dimana admin memasukkan data mahasiswa agar mahasiswa dapat melakukan *login* dan mengakses aplikasi pencarian data musik, terdapat gambaran mengenai alur sistem yaitu dari awal sistem, kemudian melakukan login menggunakan username dan password, setelah *valid* atau benar maka akan masuk ke sistem atau halaman utama, kemudian proses read data

musik yang terdiri dari Kelola data *user*, Kelola data musik, Pencarian data musik. Setelah memilih dan melakukan kelola data maka data disimpan dalam database mahasiswa. Pada Gambar 2 menunjukkan proses input data musik dan pada Gambar 3 menunjukkan struktur database sistem temu kembali musik populer indonesia.




Gambar 2 Proses Input Data Musik



Gambar 3 Struktur *Database* Sistem Temu Kembali Musik Populer Indonesia

Dalam sistem temu kembali musik populer Indonesia terdiri dari beberapa proses bisnis yang menjadi fondasi dalam pengembangan sistem ini menggunakan metode Savoy. Metode ini berfokus pada pengolahan teks untuk menghitung bobot istilah dalam dokumen menggunakan perhitungan *Term Frequency* (TF), *Inverse Document Frequency* (IDF), dan *Cosine Similarity*. Pada Gambar 4 menunjukkan flowchart proses rekomendasi lagu menggunakan metode savoy.



Gambar 4 Flowchart Proses Rekomendasi Lagu Menggunakan Metode Savoy

Dalam proses rekomendasi lagu menggunakan metode Savoy terdapat beberapa tahapan, meliputi *input* data dari pengguna, *load* data lagu dari *database*, *preprocessing* data (*stopword* dan *stemming*), proses pembobotan (TF-IDF), proses skor relevansi (*Cosine Similarity*), dan proses pengurutan relevansi (pengujian *indexing* dan *retrieval*).

3. Hasil dan Pembahasan

3.1 Implementasi Metode Savoy

Sistem temu kembali musik populer Indonesia dirancang sebagai alat bantu untuk memecahkan permasalahan pencarian istilah atau kata kunci dalam kumpulan dokumen musik. Tujuan utamanya adalah untuk mempermudah proses pencarian istilah yang relevan dan mendukung pengelompokan dokumen berdasarkan nilai indeks yang dihasilkan dari proses pengindeksan. Proses pembobotan dokumen dilakukan dengan menggunakan metode Savoy, di mana sistem mencari dokumen yang mengandung istilah sesuai dengan *query* yang diberikan oleh pengguna. Dokumen-dokumen relevan kemudian diberi bobot berdasarkan frekuensi kemunculan istilah dalam dokumen untuk menentukan tingkat relevansi. Implementasi sistem ini difokuskan pada pencarian informasi terkait jenis musik yang paling diminati oleh mahasiswa. Dengan menggunakan sistem temu kembali informasi berbasis metode Savoy, proses pencarian dapat dilakukan dengan cepat dan akurat, sehingga mendukung analisis data minat mahasiswa terhadap berbagai jenis musik secara lebih efektif.

Implementasi metode Savoy bertujuan untuk meningkatkan efektivitas sistem dalam menemukan dokumen musik yang relevan berdasarkan *query* pengguna. Sistem ini dikembangkan menggunakan bahasa pemrograman PHP dengan *framework* Laravel untuk pengembangan antarmuka, dan MySQL sebagai *database* sistem. Dengan tujuan menciptakan sistem yang informatif dan user-friendly, sistem ini mempermudah pengguna dalam pencarian musik populer Indonesia di kalangan mahasiswa Universitas Udayana. Proses implementasi metode ini meliputi tahapan-tahapan sistematis, antara lain pengindeksan, pembobotan istilah, dan penghitungan tingkat relevansi dokumen musik.

Library Sastrawi yang tersedia di *GitHub* digunakan untuk dua proses utama, yaitu *stemming* dan *stopword removal* guna meningkatkan akurasi pencarian. *Stemming* dilakukan dengan menggunakan *Sastrawi\Stemmer\StemmerFactory* untuk mengubah kata menjadi bentuk dasarnya, sementara *stopword removal* dilakukan dengan *StopWordRemoverFactory* untuk menghapus kata-kata umum yang tidak berkontribusi dalam pencarian. Fungsi *getPreprocessedContent* bertanggung jawab untuk membersihkan teks sebelum digunakan dalam pencocokan *query* dengan *database* musik. Fungsi ini mengonversi teks ke huruf kecil, melakukan *stemming*, menghapus karakter khusus, dan menghapus *stopword*, sehingga sistem dapat lebih efisien dalam mengidentifikasi lagu yang relevan berdasarkan

kata kunci pengguna. Penggunaan *library* Sastrawi memainkan peran penting dalam meningkatkan relevansi dan keakuratan hasil pencarian.

Fungsi '*getTermFrequencyV2*' menghitung nilai TF, yang menunjukkan seberapa sering suatu istilah muncul dalam dokumen tertentu. Fungsi ini menerima tiga parameter utama: *\$documentContent* (teks dokumen), *\$terms* (daftar kata kunci), dan *\$maxTermFrequency* (frekuensi maksimum kata dalam dokumen). Proses dimulai dengan memecah teks dokumen menjadi array kata, menghitung frekuensi kemunculan masing-masing kata, dan kemudian menghitung nilai TF masing-masing kata dengan membagi jumlah kemunculannya dengan frekuensi maksimum. Nilai TF digunakan untuk menentukan relevansi dokumen dengan memberikan bobot lebih besar pada kata yang sering muncul dalam dokumen.

Fungsi ini menghitung *inverse document frequency* (IDF), yang digunakan untuk memberi bobot lebih tinggi pada kata yang jarang muncul dalam koleksi dokumen, yang membantu sistem mengidentifikasi kata yang lebih relevan dalam pencarian. Fungsi ini menerima empat parameter: *\$documentContents* (konten dokumen dalam bentuk array), *\$terms* (daftar kata kunci), dan *\$corpusTerms* (jumlah dokumen yang mengandung kata kunci, opsional). Fungsi menghitung jumlah total dokumen dan melakukan iterasi pada setiap kata kunci untuk menghitung nilai IDF menggunakan rumus logaritmik. Nilai IDF ini membantu membedakan kata kunci yang umum dan yang lebih spesifik, sehingga meningkatkan efektivitas pencarian.

Fungsi '*getTFIDF*' menghitung bobot TF-IDF, yang merupakan kombinasi dari nilai TF dan IDF untuk setiap term dalam dokumen. Fungsi ini menerima dua parameter utama: *\$tf* (array nilai TF untuk setiap term) dan *\$idf* (array nilai IDF untuk setiap term). Fungsi ini mengalikan nilai TF dengan nilai IDF untuk setiap term dan menyimpan hasilnya dalam array *\$tfidf*. Nilai TF-IDF ini digunakan untuk menentukan relevansi dokumen terhadap query, sehingga meningkatkan akurasi pencarian.


Fungsi perhitungan cosine similarity digunakan untuk menghitung tingkat kesamaan antara dua vektor numerik. Fungsi ini sangat relevan untuk membandingkan representasi vektor dari data *dokumen* (seperti fitur-fitur lagu) dengan query yang dimasukkan pengguna. Fungsi ini menerima dua parameter: *\$vectorA* dan *\$vectorB*, yang merepresentasikan dua vektor. Perhitungan diawali dengan menghitung *dot product* dan *magnitudo* masing-masing vektor. Fungsi ini menghitung kemiripan antara vektor berdasarkan hasil perkalian dot product dan magnitudo kedua vektor, dan mengembalikan nilai antara 0 dan 1 yang menunjukkan tingkat kemiripan.

Fungsi tampilan rekomendasi memberikan rekomendasi dokumen musik berdasarkan tingkat kesamaan kosinus antara kata kunci pengguna dan dokumen-dokumen dalam basis data. Fungsi ini memproses kata kunci yang dimasukkan oleh pengguna, menghitung nilai TF dan IDF untuk kata kunci dan *dokumen*, serta menghitung nilai TF-IDF. Selanjutnya, fungsi ini menghitung tingkat kesamaan menggunakan cosine similarity dan mengurutkan dokumen berdasarkan tingkat kesamaan tertinggi. Dokumentasi yang memiliki kesamaan lebih tinggi akan muncul di urutan teratas, memberikan rekomendasi yang lebih relevan kepada pengguna.

3.2 Antarmuka Sistem

1. Tampilan *Login* Sistem


Tampilan pada halaman *login* sistem temu kembali musik populer Indonesia ini menunjukkan antarmuka pengguna yang digunakan untuk mengakses sistem. Pengguna yang dapat mengakses sistem ini terdiri dari admin dan mahasiswa. Admin memiliki wewenang untuk mengelola data sistem, seperti data pengguna dan lagu, sementara mahasiswa dapat mencari lagu berdasarkan preferensi mereka. Pada halaman login, pengguna diminta untuk memasukkan *username* dan *password* yang telah didaftarkan. Proses validasi dilakukan untuk memastikan keamanan sistem. Jika *login* berhasil, pengguna akan diarahkan ke halaman utama sesuai peran mereka, sementara jika gagal, sistem memberikan pesan *error* yang informatif. Berikut ini tampilan *login* sistem ditunjukkan dalam Gambar 5.



Gambar 5 Tampilan *Login* Sistem

2. Tampilan Halaman Pengguna


Halaman utama yang ditampilkan setelah pengguna berhasil *login* dirancang dengan tata letak sederhana dan intuitif. Halaman ini dilengkapi dengan panel informasi yang menampilkan statistik penggunaan sistem, seperti jumlah pencarian yang telah dilakukan, serta daftar lagu atau query pencarian terbaru. Tata letaknya responsif untuk memastikan pengalaman pengguna yang optimal, baik di perangkat desktop maupun mobile. Menu navigasi utama berupa bilah *horizontal* mencakup beberapa tab penting seperti Beranda, Pencarian Lagu, Pengelolaan Data Pengguna, Pengelolaan Data Lagu, dan Profil Pengguna. Pada Gambar 6 menunjukkan tampilan halaman pengguna.



Gambar 6 Tampilan Halaman Pengguna

3. Tampilan *Dashboard*

Dashboard sistem dirancang untuk memberikan visualisasi data penting secara ringkas dan informatif. Panel-panel terorganisir menyajikan gambaran menyeluruh tentang performa dan aktivitas sistem, memudahkan pengguna untuk memantau aktivitas serta hasil analisis. Fitur utama pada dashboard meliputi Data Minat Pengguna dan Hasil Pengelompokan Dokumen Berdasarkan Metode Savoy yang memberikan wawasan lebih lanjut mengenai preferensi pengguna dan hasil pencarian lagu. Untuk tampilan *dashboard* ditunjukkan dalam Gambar 7.



Gambar 7 Tampilan *Dashboard*

4. Tampilan Halaman *Form Add/Update* Pengguna

5. Halaman *form* ini digunakan untuk menambah atau memperbarui informasi pengguna dalam sistem. Dengan tata letak yang bersih dan intuitif, form ini memudahkan admin untuk mengelola data pengguna. Pengguna dapat memasukkan atau memperbarui informasi seperti nama

pengguna, *email*, peran pengguna, dan kata sandi. Setiap elemen pada halaman ini dilengkapi dengan validasi untuk memastikan bahwa data yang dimasukkan akurat dan sesuai dengan format yang diinginkan. Gambar 8 menunjukkan Tampilan Halaman *Form Add/Update* Pengguna.

Gambar 8 Tampilan Halaman *Form Add/Update* Pengguna

6. Tampilan Hasil Rekomendasi

Hasil rekomendasi lagu ditampilkan berdasarkan *query* yang dimasukkan oleh pengguna. Sistem menyajikan informasi yang relevan dengan urutan yang memudahkan pengguna untuk menemukan lagu sesuai preferensi mereka. Daftar hasil rekomendasi diurutkan berdasarkan nilai relevansi dan diorganisasi dalam tabel yang mudah dibaca. Jika tidak ada hasil yang sesuai, sistem akan menampilkan pesan error dengan saran pencarian ulang. Tampilan rekomendasi ditunjukkan dalam Gambar 9.

Gambar 9 Tampilan Hasil Rekomendasi

7. Tampilan Halaman *Form Tambah/Update* Lagu


Halaman *form* ini digunakan oleh *admin* untuk menambah atau memperbarui informasi lagu dalam sistem. *Form* ini memudahkan admin untuk mengelola data lagu dengan akurasi tinggi, dengan *field* seperti judul lagu, nama artis, tahun publikasi, dan lirik lagu. Sistem memberikan konfirmasi keberhasilan setelah data lagu berhasil disimpan. Pada Gambar 10 menunjukkan tampilan Halaman *Form Tambah/Update* Lagu.

Gambar 10 Tampilan Halaman *Form Tambah/Update* Lagu

8. Tampilan Halaman *Database* Lagu

- Halaman database lagu adalah pusat pengelolaan data lagu dalam sistem. Data lagu ditampilkan dalam tabel yang memudahkan admin untuk menambah, mengedit, atau menghapus lagu. Fitur pencarian memungkinkan pengguna untuk mencari lagu berdasarkan judul, artis, atau album.

Tombol aksi seperti Edit, Hapus, dan Tambah Lagu memungkinkan pengelolaan data lagu dilakukan dengan mudah dan cepat. Pada Gambar 11 Tampilan Halaman *Database Lagu*.



Gambar 11 Tampilan Halaman *Database Lagu*

3.3 Hasil Uji

Dalam penelitian ini, berbagai pengujian dilakukan untuk mengevaluasi kinerja sistem temu kembali musik populer Indonesia yang dikembangkan menggunakan metode Savoy. Sistem ini dirancang untuk memungkinkan pengguna melakukan pencarian informasi dengan efisiensi dan akurasi tinggi. Pengujian yang dilakukan mencakup pengujian *indexing*, pengujian *retrieval*, dan pengujian responden untuk memastikan konsistensi serta efektivitas sistem dalam mengidentifikasi dan merekomendasikan musik yang sesuai dengan karakteristik yang diinginkan pengguna.

Pada pengujian *indexing*, sistem menghitung bobot pada setiap term yang terdapat dalam dokumen musik. Data sampel yang digunakan dalam pengujian ini berjumlah 150 dokumen. Hasil perhitungan *indeks* menunjukkan bobot pada setiap term, misalnya untuk kata "kasih" yang terdapat pada dokumen dengan ID 577, bobotnya adalah 2,661986438. Selain itu, pengujian waktu *indexing* menunjukkan bahwa waktu proses indeks meningkat seiring bertambahnya jumlah dokumen yang diindeks. Pengujian ini mencatatkan waktu sebesar 1,411 detik untuk mengindeks 150 dokumen dengan total 6.856 term.

Selanjutnya, pengujian *retrieval* dilakukan untuk mencari dokumen yang relevan berdasarkan *query* yang dimasukkan oleh pengguna. Sistem menampilkan dokumen yang relevan dengan menghitung nilai *cosine similarity*. Pengujian *recall* dan *precision* juga dilakukan dengan menggunakan sampel data yang sama. Hasilnya menunjukkan bahwa *recall* cukup stabil dengan nilai optimal pada beberapa pengujian, meskipun beberapa pengujian menunjukkan nilai *recall* 0 karena tidak ditemukan dokumen yang relevan. *Precision* cenderung *fluktuatif*, dipengaruhi oleh tingkat spesifikasi kata kunci yang digunakan.

Terakhir, pengujian responden dilakukan dengan menggunakan metode *System Usability Scale* (SUS) untuk mengevaluasi tingkat kegunaan sistem. Sebanyak 42 responden dari Universitas Udayana memberikan penilaian melalui kuesioner SUS setelah menggunakan sistem. Hasil dari pengujian ini memberikan wawasan tentang kenyamanan dan keefektifan penggunaan sistem dari perspektif pengguna, yang dapat digunakan untuk meningkatkan sistem lebih lanjut.

4. Kesimpulan

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa fungsi-fungsi seperti *getTermFrequencyV2*, *getInverseDocumentFrequency*, dan *cosineSimilarity* telah diimplementasikan dengan baik untuk menghitung bobot term dan relevansi dokumen pada sistem temu kembali musik populer Indonesia. Kombinasi metode TF-IDF dan Cosine Similarity memberikan hasil pencarian yang akurat dengan tingkat relevansi yang tinggi. Implementasi metode Savoy dalam sistem berbasis web memungkinkan pengguna untuk melakukan pencarian musik populer dengan mudah dan efisien. Penggunaan *framework Laravel* dan basis data *MySQL* telah membantu menciptakan antarmuka yang *user-friendly* dan sistem yang terorganisasi dengan baik. Selain itu, sistem temu kembali musik populer Indonesia ini mampu memberikan rekomendasi musik yang relevan dengan tingkat akurasi yang memadai berdasarkan kesamaan kosinus antara *query* dan dokumen-dokumen dalam basis data.

- [1] Angriawan, Kurniadi. 2009. Pengenalan Sidik Jari Menggunakan Support Vector Machine (SVM). Bandung. Fakultas Elektro dan Komunikasi.
- [2] Agus AZ, Setiono AN. Klasifikasi Dokumen Berita Kejadian Berbahasa Indonesia dengan Algoritma Single Pass Clustering. Proceeding of SITIA. Surabaya. 2002: 1-6.
- [3] Adhitha, Ramadan Purwarianti, Ayu. 2009. Penilaian esai jawaban bahasa Indonesia menggunakan metode SVM-LSA dengan fitur generic. bandung: Institute Teknologi Bandung.
- [4] Erk, K., 2008. A Structured Vector Space Model for Word Meaning in Context. Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics.897-906.
- [5] Furey T.S, et al., "Support vector machine classification and validation of cancer tissue samples using microarray expression data", Bioinformatics, Vol.16, No.10, 2000.
- [6] L.delavenia. 2015. Perancangan Information Retrieval System dengan Metode Extended Boolean dan Savoy: Medan .stmik time.
- [7] M.Syafrullah, Syaiful Anwar, 2016. Klasifikasi Kerusakan Kawasan Konservasi Dengan Metode Support Vector Machine (Svm) Menggunakan Kernel Gaussian: Studi Kasus The Nature Conservancy. Jakarta selatan: Universitas Budi Luhur.
- [8] Nugroho, B. 2004. "Database Relational Dengan MySQL ". Andi : Yogyakarta.
- [9] Sutabri, T., 2010, Analisa Sistem Informasi, Andi Offset, Yogyakarta. Hartono J, 2009, Analisis dan Desain Sistem Informasi, Penerbit: Andi Offset,Yogyakarta.
- [10] Feldman,R dan James S. 2007. The Text Mining Handbook. England.Cambridge University Press.
- [11] Amin, F. (2013). Sistem Temu Kembali Informasi dengan Pemeringkatan Metode Vector Space Model. Dinamik, 18(2).
- [12] Raharjo, S., & Winarko, E. (2014). Klasterisasi, klasifikasi dan peringkasan teks berbahasa indonesia. Prosiding KOMMIT.
- [13] Sanjaya, F. (2017). Pemanfaatan Sistem Temu Kembali Informasi dalam Pencarian Dokumen Menggunakan Metode Vector Space Model. J-INTECH, 5(02), 147–153
- [14] Apriani, Zakiyudin, H., & Marzuki, K. (2021). Penerapan Algoritma Cosine Similarity dan Pembobotan TF-IDF System Penerimaan Mahasiswa Baru pada Kampus Swasta. Jurnal Bumigora Information Technology (BITe), 3(1), 19-27. doi:10.30812/bite.v3i1.1110
- [15] Kurniadi, D., Haviana, S., & Novianto, A. (2020). Implementasi Algoritma Cosine Similarity pada sistem arsip dokumen di Universitas Islam Sultan Agung. TRANSFORMTIKA, 17(2), 124 – 132.

This page is intentionally left blank.

Optimasi *Hyperparameter Random Forest* untuk Prediksi Kualitas Air

Lutfi Julpian¹, Alam Rahmatulloh^{2*}

^aInformatika Departement, Faculty of Engineering, Siliwangi University
Jl. Siliwangi No.24, Tasikmalaya, West Java, Indonesia 46115
217006518@student.unisl.ac.id, alam@unsil.ac.id

Abstrak

Water is an essential source of life for all living beings, making the preservation of water quality crucial for human health and the sustainability of ecosystems. However, population growth, industrial development, and other economic activities have led to a decline in water quality and an increase in pollution. To address this issue, early detection through the application of data mining techniques, particularly classification, is necessary to predict the quality of consumable water. This study aims to enhance the accuracy of water quality prediction by applying hyperparameter optimization techniques using the Grid Search method on the Random Forest algorithm. The results show that hyperparameter optimization improved water quality prediction accuracy from 88.33% to 91.32%. This improvement underscores the effectiveness of machine learning techniques in monitoring water quality and contributes to better decision-making to safeguard water resources and protect public health. Furthermore, this research provides insights into the importance of data mining techniques in identifying relevant patterns in water quality data, thereby helping to prevent health risks associated with contaminated water.

Keywords: *Water quality, Data mining, Hyperparameter optimization, Random Forest, Machine learning*

1. Pendahuluan

Air merupakan sumber kehidupan yang tak tergantikan bagi seluruh makhluk hidup[1]. Sekitar 60% berat tubuh manusia terdiri dari air, yang menunjukkan betapa pentingnya air bagi kelangsungan hidup[2]. Kualitas air yang baik tidak hanya menjamin kesehatan manusia, tetapi juga keberlangsungan ekosistem serta mendukung berbagai aktivitas ekonomi seperti pertanian dan industri. Untuk menjaga kualitas air agar tetap bersih dan bebas dari zat-zat pencemar seperti zat asam dan basa, kita perlu melakukan upaya perlindungan yang serius[3]. Kesehatan masyarakat di suatu wilayah sangat dipengaruhi oleh kualitas air yang dikonsumsi[4]. Upaya perlindungan terhadap sumber daya air diperlukan agar masyarakat dapat mengakses air yang bersih dan layak konsumsi untuk mendukung kehidupan sehari-hari.

Dengan peningkatan jumlah penduduk, pertumbuhan industri, peningkatan ekonomi, dan peningkatan standar hidup telah memberikan tekanan yang besar pada sumber daya air. Akibatnya, terjadi ketidakseimbangan antara pemanfaatan dan ketersediaan air, baik dalam jumlah maupun kualitas[5]. Hal ini menyebabkan penurunan kualitas air secara signifikan dan berkurangnya ketersediaan air untuk memenuhi kebutuhan yang terus meningkat. Pencemaran air menjadi penyebab utama berbagai penyakit dan masalah kesehatan masyarakat. Pencemaran air mengancam kesehatan manusia melalui berbagai penyakit yang disebabkan oleh konsumsi air yang tercemar dan paparan terhadap lingkungan yang terkontaminasi [6].

Untuk mengetahui kualitas air yang layak dikonsumsi oleh masyarakat luas, diperlukan deteksi dini melalui penerapan teknik data mining. Salah satu teknik yang dapat digunakan adalah klasifikasi, yaitu proses untuk menemukan model atau fungsi yang dapat menjelaskan dan membedakan konsep atau kelas data[7]. Data mining menyediakan alat untuk menggali informasi yang kompleks dan tersembunyi dalam data yang dihasilkan dari simulasi komputer dan eksperimen daring[8]. Data mining adalah proses penggalian informasi dan pola yang berharga dari kumpulan data yang sangat besar. Proses ini mencakup beberapa tahap, yaitu pengumpulan data, ekstraksi data, analisis data, serta penggunaan statistik [9].

Sebelumnya, telah banyak penelitian yang mengkaji deteksi dini kualitas air melalui penerapan data mining. Salah satu penelitian tersebut adalah tentang prediksi kualitas air menggunakan teknik *machine learning* [1]. Penelitian ini membandingkan tiga algoritma, yaitu *Random Forest*, *Decision Tree*, dan *Gradient Boosting*. Hasil pengujian menunjukkan bahwa algoritma *Random Forest* memberikan akurasi terbaik, yaitu sebesar 88,33%.

Penelitian selanjutnya adalah penerapan sistem prediksi kualitas air yang dapat dikonsumsi dengan menerapkan teknik *machine learning* [10]. Dalam penelitian ini, digunakan algoritma *K-Nearest Neighbor* (KNN) untuk menganalisis data kualitas air. Hasil dari data pengujian menunjukkan bahwa algoritma KNN mencapai akurasi sebesar 85,24%. Akurasi yang cukup tinggi ini menunjukkan bahwa teknik *machine learning* dapat diandalkan dalam memprediksi kualitas.

Dalam penelitian sebelumnya, teknik *machine learning* untuk prediksi kualitas air yang paling bagus yaitu *Random Forest* menunjukkan akurasi tertinggi sebesar 88,33%. Namun, hal ini masih dapat ditingkatkan melalui optimasi *hyperparameter*. Optimasi *hyperparameter* adalah proses menemukan kombinasi optimal *hyperparameter* yang meminimalkan kesalahan prediksi atau memaksimalkan akurasi prediksi [11]. Algoritma optimasi *hyperparameter* secara otomatis menemukan konfigurasi *hyperparameter* yang memberikan kinerja baik untuk algoritma *machine learning* [12]. Metode optimasi yang diterapkan dalam penelitian ini adalah metode *Grid Search*. Metode *Grid Search* dipilih karena sifatnya yang sangat teliti dan kemampuannya untuk menjamin hasil yang optimal [13]. Meskipun metode ini membutuhkan waktu komputasi yang lebih lama dibandingkan metode lain, namun ketelitiannya membuat metode ini sangat cocok digunakan ketika akurasi hasil sangat penting. Dalam metode ini, sejumlah kombinasi nilai *hyperparameter* yang telah ditentukan disusun dalam bentuk grid. Sehingga memungkinkan eksplorasi yang lebih efektif terhadap ruang pencarian *hyperparameter*. Dengan demikian, penelitian ini bertujuan untuk meningkatkan akurasi prediksi kualitas air dengan memanfaatkan teknik optimasi yang tepat.


Penelitian ini memberikan manfaat dalam meningkatkan kualitas prediksi air yang layak dikonsumsi oleh masyarakat. Dengan memanfaatkan teknik data mining dan *machine learning*, khususnya melalui optimasi *hyperparameter* menggunakan metode *Grid Search*, penelitian ini berhasil menunjukkan peningkatan akurasi yang signifikan sebesar 91,32%. Penelitian lain juga menunjukkan bahwa penerapan *Grid Search* CV dapat meningkatkan hasil klasifikasi pada pemantauan kualitas udara [9].

Teknik optimasi *hyperparameter* ini secara signifikan meningkatkan akurasi model prediksi kualitas air, yang sebelumnya telah menunjukkan kinerja memadai dengan algoritma *Random Forest* sebesar 88,33% [1]. Peningkatan akurasi ini memberikan manfaat yang sangat besar, terutama dalam mendukung pengambilan keputusan yang lebih tepat dan berbasis data untuk menjaga kualitas sumber daya air. Dengan prediksi yang lebih akurat, pihak berwenang dapat mengidentifikasi risiko kontaminasi secara dini, menerapkan langkah-langkah pencegahan yang efektif, serta merumuskan kebijakan yang relevan untuk melindungi kesehatan masyarakat. Selain itu, kemampuan model yang lebih unggul ini juga berperan penting dalam mencegah penyebaran penyakit yang disebabkan oleh air tercemar, sehingga memastikan ketersediaan air bersih yang aman bagi kebutuhan sehari-hari. Hal ini menunjukkan betapa pentingnya inovasi dan pengembangan metode analitik dalam manajemen kualitas air secara berkelanjutan.

2. Metode

Metodologi yang digunakan dalam penelitian ini ditampilkan pada Gambar 1. Kebaruan dari penelitian ini terletak pada penerapan *hyperparameter* tuning menggunakan metode *Grid Search* pada algoritma *Random Forest Classifier*. Skenario yang digunakan untuk mencapai akurasi

terbaik mengikuti metode yang diterapkan dalam penelitian sebelumnya[1], dengan membagi kumpulan data menjadi 90% untuk data latih dan 10% untuk data uji.



Gambar 1. Tahapan penelitian

2.1. Data Exploration

Pada penelitian ini, data yang digunakan merupakan data sekunder yang diperoleh peneliti melalui sumber tidak langsung atau pihak ketiga. Data tersebut diambil dari Dataset *Water-Potability-Datasets* yang tersedia di platform Kaggle (www.kaggle.com/datasets/ibrahimzaitoun/water-potability-datasets/code). Dataset ini berisi berbagai informasi yang relevan dengan kualitas air, mencakup parameter-parameter penting yang digunakan untuk menilai potabilitas air, yaitu apakah air tersebut layak dikonsumsi oleh manusia atau tidak. Parameter-parameter ini meliputi berbagai aspek fisik, kimia, dan biologi, yang memengaruhi kualitas air secara keseluruhan. Informasi dalam dataset ini menjadi dasar untuk memahami berbagai faktor yang menentukan potabilitas air dan membantu dalam pengambilan keputusan yang berbasis data.


Tabel 1. Deskripsi informasi data

Nama Atribut Kolom	Deskripsi Data	Kategori Tipe Data
ph	Air(0 sampai 14)	Numerik (float)
Hardness	Kekerasan	Numerik (float)
Solids	Padatan	Numerik (float)
Chloramines	Kloramin	Numerik (float)
Sulfate	Sulfat	Numerik (float)
Conductivity	Konduktivitas	Numerik (float)
Organic Carbon	Karbon Organik	Numerik (float)
Trihalomethanes	Trihalomethanes	Numerik (float)
Turbidity	Kekeruhan	Numerik (float)
potability	Sifat dapat diminum	Numerik(int)

Dataset ini memiliki struktur data yang terdiri dari 5569 baris dan 10 kolom, yang mencakup variabel-variabel penting yang digunakan dalam analisis dan prediksi. Setiap baris mewakili sampel data, sementara setiap kolom berisi informasi terkait parameter kualitas air seperti tingkat

pH, konsentrasi zat kimia tertentu, dan tingkat kontaminasi. Dengan ukuran dataset yang cukup besar dan variasi data yang beragam, penelitian ini dapat memberikan hasil analisis yang lebih akurat. Informasi lebih rinci mengenai variabel-variabel tersebut dapat ditemukan pada Tabel 1 dalam laporan penelitian. Dataset ini menjadi dasar yang signifikan dalam penerapan teknik data mining, khususnya untuk melakukan prediksi kualitas air yang lebih komprehensif dan mendukung pencapaian tujuan penelitian.

Pada tahap *data exploration* bertujuan untuk memahami karakteristik dataset secara menyeluruh sebelum proses *data preparation* dilakukan. Langkah-langkah yang dilakukan meliputi membaca dataset dengan mengimpor data, menampilkan struktur data untuk memeriksa jenis variabel, serta menganalisis karakteristik setiap fitur dan mengidentifikasi variabel yang relevan. Selain itu, dilakukan pemeriksaan *missing value* untuk menangani data yang hilang. Distribusi variabel target juga dianalisis guna memastikan keseimbangan data yang bisa dilihat pada Gambar 2, karena distribusi yang tidak seimbang dapat mempengaruhi akurasi model. Eksplorasi ini memberikan dasar yang kuat dalam memahami data dan merancang strategi pemodelan yang optimal.




Gambar 2. Distribusi variabel

Selain analisis awal, dilakukan pula visualisasi data untuk mengidentifikasi pola, anomali, dan hubungan antar variabel yang dapat memengaruhi hasil prediksi. Teknik seperti histogram, *scatter plot*, dan heatmap digunakan untuk mengevaluasi korelasi antar fitur, sehingga dapat membantu dalam proses *feature selection*. Pemahaman mendalam terhadap dataset ini memungkinkan identifikasi fitur-fitur yang paling signifikan, serta memberikan gambaran mengenai distribusi data yang *outlier* atau *noise*, yang nantinya akan ditangani pada tahap *data preparation*. Langkah eksplorasi yang menyeluruh ini tidak hanya membantu meminimalkan kesalahan pada tahap pemodelan tetapi juga memastikan bahwa algoritma yang digunakan dapat bekerja dengan data yang lebih bersih dan terstruktur.

2.2. Data Preparation

Tahapan *Data Preparation* merupakan bagian penting dalam proses analisis data yang bertujuan mempersiapkan dataset sebelum memasuki proses pemodelan. Pada tahap ini, dilakukan berbagai kegiatan seperti pembersihan data, pengisian *missing value*, penerapan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) dengan tujuan mengontrol pemerataan distribusi data pada suatu kelas dalam dataset dengan membuat sampel buatan dari kelas minoritas[14]. Hasil Teknik SMOTE bisa dilihat pada Gambar 3, serta pembagian data menjadi data latih (*training set*) dan data uji (*test set*). Pada penelitian ini setelah dilakukan *preparation* data maka data yang sebelumnya 5569 data menjadi 4317 data. Hal ini dilakukan untuk memastikan bahwa dataset siap digunakan dalam pemodelan dengan kualitas data yang terjaga.



Gambar 3. Penerapan SMOTE pada variabel target

2.3. Modelling & Evaluation

Tahapan dalam proses analisis data ini bertujuan untuk membangun model prediksi serta mengevaluasi kinerjanya. Pada tahap ini, peneliti menggunakan algoritma *Random Forest Classifier* yang dioptimalkan dengan *hyperparameter* melalui metode *Grid Search*. Setelah model berhasil dibangun, langkah selanjutnya adalah melakukan evaluasi terhadap performa model menggunakan data uji. Evaluasi ini menghasilkan ukuran akurasi sebagai indikator kinerja model.

Untuk mengukur kinerja classifier, penelitian ini menggunakan *confusion matrix*, dengan perhitungannya tercantum pada Tabel 2, sebagaimana dilakukan dalam penelitian sebelumnya[1]. *Confusion matrix* didefinisikan sebagai matriks yang menyajikan perbandingan antara instans kelas yang diprediksi dan instans kelas yang sebenarnya[15].

Tabel 2. Confusion Matrix

		Predicted Label	
		0 (Sehat)	1 (Terinfeksi)
Actual Label	0 (Sehat)	True Positive (TP)	False Positive (FP)
	1 (terinfeksi)	False Negative (FN)	True Negative (TN)

Perhitungan menggunakan confusion matrix digunakan untuk menentukan nilai akurasi, presisi, *recall*, dan *F1-score*, yang semuanya merupakan metrik penting untuk mengevaluasi efektivitas model dalam menangani data dengan distribusi kelas tertentu[14][1][15]. Dengan menggunakan metrik ini, penelitian dapat mengevaluasi seberapa baik model dalam mengklasifikasikan data, termasuk dalam mendeteksi kelas minoritas yang sering kali lebih sulit untuk diprediksi.

Dalam konteks ini, terdapat dua kelas: 0 (Sehat) yang mewakili kelas negatif atau kondisi tidak terinfeksi, dan 1 (Terinfeksi) yang mewakili kelas positif atau kondisi terinfeksi. Berdasarkan hasil prediksi model, terdapat empat istilah utama yang menggambarkan performa prediksi:

- True Positive* (TP) adalah situasi di mana label aktual adalah positif (Terinfeksi) dan model berhasil memprediksi dengan benar sebagai positif
- True Negative* (TN) adalah situasi di mana label aktual adalah negatif (Sehat) dan model memprediksi dengan benar sebagai negatif.
- False Positive* (FP) terjadi ketika label aktual adalah negatif (Sehat), tetapi model salah memprediksi sebagai positif (Terinfeksi). Kesalahan ini dapat berimplikasi pada tindakan yang tidak perlu bagi individu yang sehat.

- d. *False Negative* (FN) terjadi ketika label aktual adalah positif (Terinfeksi), tetapi model salah memprediksi sebagai negatif (Sehat). Kesalahan ini berisiko karena individu yang terinfeksi dapat tidak terdeteksi dan tidak mendapatkan perawatan yang diperlukan

Confusion matrix membantu memberikan gambaran lengkap tentang kinerja model dalam memisahkan kedua kelas, baik dalam hal keberhasilan prediksi maupun kesalahan yang dibuat. Dengan menggunakan *confusion matrix*, kita dapat lebih mudah mengidentifikasi di mana model melakukan kesalahan dan berapa besar dampaknya terhadap hasil akhir. Berikut formula untuk menghitung akurasi:

$$\text{Akurasi (\%)} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad 1$$

Akurasi mengukur seberapa baik model dalam memprediksi dengan benar, baik untuk kelas positif maupun negatif. Namun, dalam kasus data yang tidak seimbang, misalnya jumlah data sehat jauh lebih banyak daripada yang terinfeksi, akurasi saja mungkin tidak memberikan gambaran yang memadai tentang kinerja model. Oleh karena itu, penting untuk juga mempertimbangkan metrik lain seperti *precision*, *recall*, dan *F1-score* untuk evaluasi yang lebih komprehensif.

3. Hasil dan Pembahasan

Dataset Water Quality digunakan dalam penelitian ini untuk memprediksi potabilitas air atau kelayakan air minum. Data ini diperoleh dari situs *Kaggle* dan menggunakan dataset "*Water-Potability-Datasets*" dalam format CSV. Dataset ini berisi beberapa fitur kimia dan fisika yang digunakan untuk menentukan apakah air layak diminum atau tidak. Fitur-fitur tersebut mencakup pH, *Hardness*, *Solids*, *Chloramines*, *Sulfate*, *Conductivity*, *Organic_carbon*, *Trihalomethanes*, dan *Turbidity*, dengan target variabel berupa *Potability*, yang memiliki dua nilai: layak minum (1) dan tidak layak minum (0).

Dataset ini memberikan gambaran mendetail tentang kualitas air melalui pengukuran parameter-parameter yang relevan. Setiap fitur dalam dataset mencerminkan karakteristik spesifik air yang dapat digunakan untuk menilai dampaknya terhadap kesehatan manusia, sementara *Hardness* mengukur kadar mineral seperti kalsium dan magnesium. Dengan, memanfaatkan fitur-fitur dan kimia air terhadap kelayakan konsumsinya, sehingga mendukung pengambilan keputusan data dalam pengelolaan.


Pada penelitian ini, proses optimasi *hyperparameter* dilakukan pada beberapa parameter kunci dari *Random Forest*, termasuk:

- n_estimators*: [50, 100, 200] Jumlah pohon dalam hutan.
- max_depth*: [None, 10, 20] Kedalaman maksimal setiap pohon.
- min_samples_split*: [2, 5, 10] Jumlah minimal sampel yang dibutuhkan untuk memisahkan node.
- min_samples_leaf*: [1, 2, 4] Jumlah minimal sampel yang dibutuhkan pada setiap leaf node.

Hasil dari optimasi menunjukkan bahwa kombinasi *hyperparameter* terbaik menghasilkan akurasi sebesar 91.80% selama *5-fold cross-validation*. Ini berarti model memiliki kemampuan yang cukup baik untuk memprediksi kelayakan air minum, dengan performa yang cukup konsisten di seluruh pembagian data dalam proses validasi silang.

3.1. Implementasi dengan Evaluasi *Confusion Matrix*

Pada tahap ini, evaluasi dilakukan menggunakan algoritma *Random Forest*. Setelah melakukan optimasi *hyperparameter*, hasil evaluasi dilakukan dengan menggunakan *confusion matrix* untuk menilai performa model bisa dilihat pada Gambar 4. Tujuannya adalah untuk melihat apakah akurasi model meningkat setelah optimasi dibandingkan dengan akurasi sebelum optimasi. Proses optimasi dan evaluasi ini dilakukan dengan menggunakan tools data mining seperti *Google Colab* dan *Python*, yang menyediakan *library* untuk melakukan optimasi, evaluasi, serta visualisasi hasil secara efektif dan efisien.



Gambar 4. Confusion Matrix Random Forest

Model ini mencapai akurasi 91.3%, yang dihitung dengan membagi total prediksi benar dengan total keseluruhan prediksi. Perhitungannya adalah:

$$\text{Akurasi (\%)} = \frac{316 + 305}{316 + 305 + 26 + 33} \times 100 \quad (2)$$

$$\text{Akurasi (\%)} = \frac{621}{680} \times 100 = 91,3\% \quad (3)$$

Precision mengukur seberapa banyak prediksi positif yang benar. Untuk kelas negatif (0), *precision*-nya adalah 92.4%, artinya dari semua prediksi negatif, 92.4% benar-benar negatif. Untuk kelas positif (1), *precision*-nya mencapai 90.2%, menunjukkan bahwa dari semua prediksi positif, 90.2% adalah positif sebenarnya.

3.2. Perbandingan Akurasi

Dalam upaya untuk mengevaluasi dan membandingkan efektivitas berbagai algoritma dalam memprediksi kualitas air, Tabel 3 menyajikan perbandingan akurasi dan *Precision* dari beberapa penelitian yang telah dilakukan. Nilai pada baris 1 diperoleh dari penelitian[10], sedangkan nilai pada baris 2 berasal dari penelitian [1]. Penelitian ini mencakup algoritma *K-Nearest Neighbor* (KNN), *Random Forest*, serta optimasi hyperparameter yang diterapkan pada model *Random Forest*.

Tabel 3. Perbandingan Akurasi dan Precision Algoritma Prediksi Kualitas Air

NO	Penelitian	Akurasi(%)	<i>Precision</i> Negatif(%)	<i>Precision</i> Positif(%)
1	KNN (2022) [10]	85,24	-	-
2	<i>Random Forest</i> (2024) [1]	88,33	90,0	88,0
3	Optimasi Hyperparameter <i>Random Forest</i>	91,80	92,2	91,2

Tabel 3 menunjukkan bahwa optimasi *hyperparameter* memberikan peningkatan signifikan pada akurasi dan *precision* jika dibandingkan dengan algoritma KNN dan *Random Forest* tanpa optimasi. Hal ini menunjukkan pentingnya pengembangan dan penerapan teknik optimasi dalam meningkatkan performa model prediksi kualitas air, serta membuka peluang untuk penelitian lebih lanjut dalam sistem prediksi yang lebih dinamis dan akurat.

4. Kesimpulan

Penelitian ini menegaskan pentingnya pengelolaan kualitas air yang baik untuk kesehatan masyarakat dan keberlanjutan lingkungan. Melalui penerapan teknik data mining dan *machine learning*, khususnya dengan *optimasi hyperparameter* menggunakan metode *Grid Search* pada algoritma *Random Forest*, akurasi prediksi kualitas air dapat ditingkatkan dari 88,33% menjadi

91,80%. Peningkatan ini menunjukkan bahwa teknik-teknik canggih dalam analisis data mampu memberikan kontribusi signifikan dalam pemantauan dan pengelolaan kualitas air. Dengan pemahaman yang lebih baik mengenai kualitas air, diharapkan dapat mendorong tindakan *preventif* yang lebih efektif dalam melindungi sumber daya air dan kesehatan masyarakat.

Untuk penelitian selanjutnya, disarankan agar peneliti mengeksplorasi lebih banyak algoritma *machine learning* dan metode *optimasi hyperparameter* lainnya seperti *random search*, *bayesian optimization* dan *genetic algorithm* untuk memperbandingkan kinerjanya dalam prediksi kualitas air. Penelitian selanjutnya juga dapat berfokus pada pengembangan model yang lebih dinamis dan responsif terhadap perubahan kualitas air secara *real-time*.

Daftar Pustaka

- [1] N. Maulidah, M. Maulidah, R. Supriyadi, H. Nalatissifa, S. Diantika, and A. Fauzi, "Prediksi Kualitas Air menggunakan Metode Random Forest, Decision Tree, dan Gradient Boosting," *JURNAL KHATULISTIWA INFORMATIKA*, vol. 12, pp. 1–6, Jun. 2024.
- [2] F. Kordbacheh and & Golnaz Heidari, "Water Pollutants and Approaches for Their Removal," *Mater. Chem. Horizons*, vol. 2023, no. 2, pp. 139–153, Jul. 2023, doi: 10.22128/MCH.2023.684.1039.
- [3] S. A. Akbar, D. B. Kalbuadi, and A. Yudhana, "Online Monitoring Kualitas Air Waduk Berbasis Thingspeak," *Transmisi*, vol. 21, no. 4, pp. 109–115, Oct. 2019, doi: 10.14710/transmisi.21.4.109-115.
- [4] M. Fida, P. Li, Y. Wang, S. M. K. Alam, and A. Nsabimana, "Water Contamination and Human Health Risks in Pakistan: A Review," Sep. 01, 2023, *Springer Science and Business Media B.V.* doi: 10.1007/s12403-022-00512-1.
- [5] I. Desti and A. Ula, "Analisis Sumber Daya Alam Air," *Jurnal Sains Edukatika Indonesia (JSEI)*, vol. 3, no. 2, pp. 17–24, 2021.
- [6] Z. KILIÇ, "Water Pollution: Causes, Negative Effects and Prevention Methods," *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 3, no. 2, pp. 129–132, Aug. 2021, doi: 10.47769/izufbed.862679.
- [7] I. Budiman, Mauliadi, and R. Ramadina, "Penerapan Fungsi Data Mining Klasifikasi untuk Prediksi Masa Studi Mahasiswa Tepat Waktu pada Sistem Informasi Akademik Perguruan Tinggi," *IJCCS*, vol. 7, no. 1, pp. 1–5, Apr. 2015.
- [8] X. Shu and Y. Ye, "Knowledge Discovery: Methods from data mining and machine learning," *Soc Sci Res*, vol. 110, Feb. 2023, doi: 10.1016/j.ssresearch.2022.102817.
- [9] I. Gede Iwan Sudipa *et al.*, *Data Mining*. Padang Sumatera barat: PT GLOBAL EKSEKUTIF TEKNOLOGI, 2023. [Online]. Available: www.globaleksekufteknologi.co.id
- [10] H. Said, N. Hafifah Matondang, and H. N. Irmanda, "Sistem Prediksi Kualitas Air Yang Dapat Dikonsumsi Dengan Menerapkan Algoritma K-Nearest Neighbor," Jakarta, Apr. 2022.
- [11] Y. Zhao, W. Zhang, and X. Liu, "Grid search with a weighted error function: Hyperparameter optimization for financial time series forecasting," *Appl Soft Comput*, vol. 154, Mar. 2024, doi: 10.1016/j.asoc.2024.111362.

- [12] B. Bischl *et al.*, "Hyperparameter Optimization: Foundations, Algorithms, Best Practices and Open Challenges."
- [13] M. Ogunsanya, J. Isichei, and S. Desai, "Grid Search Hyperparameter Tuning in Additive Manufacturing Processes," 2023, [Online]. Available: www.sciencedirect.com
- [14] S. Keputusan Direktur Jenderal Pendidikan Tinggi, dan Teknologi Nomor, N. Sharfina, and N. Ghaniaviyanto Ramadhan, "Terakreditasi SINTA Peringkat 3 Analisis SMOTE Pada Klasifikasi Hepatitis C Berbasis Random Forest dan Naïve Bayes," Purwokerto, Jun. 2023.
- [15] I. Markoulidakis, I. Rallis, I. Georgoulas, G. Kopsiaftis, A. Doulamis, and N. Doulamis, "Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem," *Technologies (Basel)*, vol. 9, no. 4, Dec. 2021, doi: 10.3390/technologies9040081.

This page is intentionally left blank.

Klasifikasi Penyakit Pernapasan berdasarkan Suara Paru-Paru menggunakan *Probabilistic Neural Network*

Shiennyta Florensia Adiriyanto^{a1}, I Gede Arta Wibawa^{a2}, Made Agung Raharja^{a3}, Gst. Ayu Vida Mastrika Giri^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Badung, Bali, Indonesia

¹shiennyflorensia@gmail.com

²gede.arta@unud.ac.id

³made.agung@unud.ac.id

⁴vida@unud.ac.id

Abstract

This research study aims to classify respiratory diseases using lung sound data analyzed with Probabilistic Neural Network (PNN) model. The research utilized secondary data from the "Respiratory Sound Database", which is the same dataset used in International Conference on Biomedical and Health Informatics (ICBHI) 2017 Challenge. This dataset includes 920 samples of lung sounds from 126 patients, categorized into various respiratory diseases such as asthma, bronchiectasis, bronchiolitis, COPD, healthy, LRTI, pneumonia and URTI. Lung sound recordings were processed through pre-processing, feature extraction using Mel-Frequency Cepstral Coefficients (MFCC), data resampling, and classification using PNN. K-stratified cross validation and confusion matrix were done for evaluating the model. The PNN model achieved a highest accuracy of 98.88%, with an average accuracy of 98.51%, an average precision of 98.54%, and an average recall of 98.51%. These results demonstrate that the PNN method is quite effective in identifying respiratory diseases, offering a potential diagnostic aid in healthcare.

Keywords: Classification, Respiratory Disease, Lung Sounds, MFCC, Probabilistic Neural Network

1. Pendahuluan

Paru-paru merupakan organ penting dalam sistem pernapasan manusia, dan tidak sedikit orang memiliki gangguan pada organ tersebut. Berdasarkan *the Global Burden of Diseases, Injuries, and Risk Factors Study*, ditemukan penyakit infeksi pernapasan menjadi peringkat kedua pada penyakit yang diderita oleh anak-anak di bawah umur 10 tahun secara global pada tahun 2019 [1]. Selain itu, tingkat polusi udara yang buruk di Indonesia juga menjadi penyebab meningkatnya pengidap gangguan pernapasan [2]. Melihat dari kurangnya dokter spesialis paru di Indonesia, dibutuhkan bantuan pengklasifikasi penyakit untuk mendapatkan penanganan yang cepat dan tepat.

Berdasarkan permasalahan tersebut, salah satu solusi untuk mendeteksi gangguan pada paru-paru dapat dilakukan dengan melakukan pemrosesan sinyal digital suara pernapasan menggunakan *Mel-Frequency Cepstral Coefficients* (MFCC) dan *Probabilistic Neural Network* (PNN). MFCC merupakan sebuah metode untuk ekstraksi fitur yang memiliki kelebihan dalam mendapatkan dan menghasilkan data dengan jumlah minimal dari informasi yang terdapat pada data suara [3][4]. MFCC juga terdiri dari beberapa tahapan seperti *pre-emphasis*, *frame blocking*, *windowing*, *Fast Fourier Transform* (FFT), *Mel-Frequency Warping*, dan *Discrete Cosine Transform* (DCT) atau bisa juga disebut tahap *cepstrum* [5]. PNN atau jaringan syaraf tiruan probabilistik ini merupakan salah satu metode klasifikasi yang didasari oleh pengklasifikasi Parzen dan Bayes [6]. PNN ini merupakan *feed forward neural network* yang berarti hubungan antar *node*-nya tidak membentuk siklus [7]. PNN juga termasuk dalam *supervised learning* dikarenakan keluaran yang diharapkan sudah diketahui terlebih dahulu. Selain itu, PNN dikatakan memiliki hasil pengklasifikasian yang sangat cepat dan baik karena hanya dilakukan dalam satu tahap pelatihan [8][9].

PNN melakukan pengklasifikasian dengan menggunakan pendekatan berbasis memori statistika. Berdasarkan penelitian yang dilakukan oleh Dongwoo Lee, beberapa kelebihan dari PNN di antara lainnya adalah memiliki arsitektur yang sederhana dengan maksud tidak ada *backpropagation*, memiliki banyak cara dalam mengelola suatu algoritma dengan menentukan bentuk rupa kurva lonceng (*bell curve*), memiliki tingkat akurasi lebih baik pada masalah pengklasifikasian, dan tidak sensitif pada titik *noise* [10]. Berdasarkan Satapathy et al., dikatakan juga bahwa PNN memiliki beberapa kelebihan seperti memiliki proses pelatihan lebih cepat dibandingkan dengan *backpropagation*, tidak memiliki isu pada *local minima*, dan menjamin cakupan ke pengklasifikasi optimal seiring dengan meningkatnya ukuran set pelatihan. Penggunaan PNN ini sangat efektif jika digunakan bersama dengan metode dalam ekstraksi fitur dan reduksi fitur [11].

Salah satu penelitian yang mengangkat mengenai klasifikasi penyakit paru-paru dilakukan oleh Sukma et al., dengan menggunakan MFCC dan SVM. Pada penelitian yang dilakukan, didapatkan tingkat akurasi sebesar 80% [12]. Penelitian lainnya juga dilakukan oleh Rafiqo et al., yang menggunakan MFCC dan CNN pada penelitiannya, dengan hasil akurasi rata-rata sebesar 71,85% [13]. Terdapat juga penelitian oleh Aridela et al., yang membandingkan penggunaan dari SVM dan PNN dengan hasil akhir PNN memiliki nilai performansi yang lebih baik dalam hal presisi dan akurasi, sedangkan SVM memiliki waktu komputasi yang lebih cepat dibandingkan PNN walaupun kedua pengujian dari metode tersebut dapat diselesaikan dalam waktu kurang dari 1 detik [14].

Berdasarkan penelitian-penelitian yang sudah dilakukan sebelumnya, pada penelitian ini akan dilakukan klasifikasi penyakit pernapasan berdasarkan suara paru-paru dengan menggunakan metode MFCC dan PNN. Penelitian ini akan melakukan akuisisi data suara paru-paru dari dataset yang sudah disiapkan. Data yang sudah diakuisisi tersebut akan dilakukan *pre-processing* terlebih dahulu, dilanjutkan dengan MFCC, *resampling* data, kemudian dilaksanakan klasifikasi penyakit pernapasan dengan metode PNN. Harapannya setelah dilakukan penelitian ini, dapat diketahui akurasi, presisi, dan *recall* dari penggunaan metode tersebut dalam menentukan penyakit.

2. Metode Penelitian

Metode penelitian memiliki peran yang sangat penting dalam menentukan hasil dari suatu penelitian. Hal ini disebabkan oleh pentingnya pendekatan yang tepat dalam melaksanakan penelitian tersebut. Berikut merupakan urutan dari metode penelitian yang akan dilaksanakan.

2.1. Pengumpulan Data

Dalam pengumpulan data ini, akan digunakan 920 data suara paru-paru dalam rupa WAV dari 126 pasien yang dimana terdapat 14 pasien URTI, 2 pasien LRTI, 1 pasien asma, 64 pasien COPD, 7 pasien bronkiektasis, 6 pasien bronkiolitis, 6 pasien pneumonia, serta 26 orang sehat. Selain *file* WAV tersebut, diberikan juga anotasi dalam rupa TXT untuk setiap rekaman suara, TXT berisikan perbedaan nama *file*, TXT berisikan format nama *file*, dan diagnosis pasien dalam bentuk CSV.

Durasi masing-masing rekaman suara paru-paru tersebut berkisar dari 10-90 detik. Total lama waktu data tersebut sepanjang 5,5 jam yang berisikan sebanyak 6898 siklus pernapasan, dengan 1864 siklus dengan suara *crackle*, 886 siklus dengan suara *wheeze*, dan 506 siklus dengan suara *crackle* dan *wheeze*. Data suara ini juga mencakup rekaman pernapasan yang bersih serta rekaman bising yang mensimulasikan kondisi kehidupan nyata. Setiap file audio diberikan info nomor pasien, indeks rekaman, lokasi dada, mode akuisisi, dan alat rekam yang digunakan. Anotasi teks yang diberikan juga memiliki 4 kolom, yaitu awal siklus pernapasan, akhir siklus pernapasan, ada/tidak adanya *crackles*, dan ada/tidak adanya *wheezes*. *Crackle* atau bunyi kresak merupakan salah satu suara non-musikal yang dapat dibagi menjadi dua, yaitu kresak halus dan kresak kasar, sedangkan *wheeze* atau mengi termasuk dalam suara musical, yaitu suara yang bersifat kontinu, dan memiliki frekuensi dominan tinggi dan dapat bersifat monofonik maupun polifonik [15].

2.2. Pre-processing Data

Dalam tahap *pre-processing* ini akan dilakukan untuk mempersiapkan data sebelum masuk ke dalam tahap ekstraksi ciri. Beberapa hal yang akan dilakukan dalam tahapan ini adalah pembuatan csv kumpulan data, pemisahan siklus data suara paru-paru, penyesuaian nama pada csv dengan data suara, dan normalisasi data suara.

Pada pembuatan csv kumpulan data, akan digabungkan 'patient_diagnosis.csv' dengan anotasi dari setiap data suara, sehingga didapatkan waktu mulai dan selesai setiap siklus pernapasan, disertai dengan kelas penyakitnya. Berdasarkan data yang sudah didapatkan, semua data suara akan dipisahkan per siklusnya dan disimpan dalam *folder* baru. Nama dari data suara juga akan ditambahkan angka di akhir supaya setiap data memiliki nama berbeda. Dengan begitu, nama pada csv akan disamakan dengan nama data yang sudah diperbarui.

Selanjutnya adalah normalisasi, yang digunakan untuk menyeragamkan jangkauan data menjadi -1 hingga 1. Untuk mendapatkan hasil normalisasi, data sinyal suara akan dibagi dengan nilai maksimum dari data tersebut. Rumus dari normalisasi dapat dilihat pada Persamaan (1).

$$\|x(n)\| = \frac{x(n)}{\max |x(n)|} \quad (1)$$

Dengan $\|x(n)\|$ adalah hasil normalisasi data, $x(n)$ adalah data sinyal suara, dan $\max |x(n)|$ merupakan nilai maksimum data. Pada langkah ini, data suara dengan format WAV diubah amplitudonya menjadi maksimal 1 dan minimal -1.

2.3. Ekstraksi Ciri

Data yang sudah dilakukan *pre-processing* tersebut akan dilakukan ekstraksi ciri dengan menggunakan MFCC. Tahapan dari MFCC adalah *pre-emphasis*, *frame blocking*, *windowing*, *Fast Fourier Transform* (FFT), *Mel-Frequency Warping*, dan *cepstrum*. Pada tahapan pertama, akan dilakukan *pre-emphasize* pada data suara. Tahapan ini dilakukan untuk mengurangi *noise* pada suara, sehingga hasil yang didapatkan menjadi lebih akurat [16][17]. Adapun persamaan dari tahapan *pre-emphasize* dapat dilihat pada Persamaan (2).

$$y(n) = s(n) - \alpha s(n-1) \quad (2)$$

Dengan $y(n)$ merupakan data sinyal hasil *pre-emphasize*, $s(n)$ adalah data sinyal sebelum *pre-emphasize*, dan α yaitu Nilai *alpha*. Pada persamaan tersebut, nilai *alpha* yang umumnya digunakan sebesar 0,97.

Setelah dilakukan *pre-emphasize*, akan dilakukan *frame blocking* yaitu membagi sinyal suara ke dalam *frame-frame* kecil. Proses ini akan menggunakan *Short-Time Fourier Transform* (STFT), dengan ukuran *frame* sebesar 2048 sampel dan perpindahan antar *frame* sebesar 512 sampel, yaitu $\frac{1}{4}$ dari ukuran *frame*. Dikarenakan semua data memiliki *sample rate* 22.050, didapatkan ukuran *frame*, perpindahan *frame* dan overlap secara berturut adalah 93 ms, 23 ms dan 70 ms. *Overlapping* ini dilakukan untuk menghindari hilangnya ciri data suara pada perbatasan perpotongan setiap *frame* [18]. Melalui tahap ini, akan didapatkan sebanyak 43 *frame* per detiknya dan 259 *frame* untuk 6 detik.

Setelah melakukan *frame blocking*, pada setiap *frame* tersebut akan dilakukan *windowing* menggunakan *Hanning window* untuk meminimalisasi sinyal tak kontinyu pada bagian awal dan akhir *frame*. Rumus dari *Hanning window* dapat dilihat pada Persamaan (3)

$$w(n) = 0.5 - 0.5 \cos \left[\frac{2\pi n}{N-1} \right] \quad (3)$$

Dengan $w(n)$ adalah hasil *Hanning window* dan N adalah jumlah sampel pada *frame*. Selanjutnya akan dilakukan tahap *Fast Fourier Transform* (FFT) yang mengubah *frame-frame* tersebut dari domain waktu menjadi domain frekuensi dengan cara yang dapat dilihat pada Persamaan (4).

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j2\pi kn/N} \quad (6)$$

Dengan $X[k]$ merupakan hasil *fast fourier transform* dari sinyal waktu $x[n]$, N merupakan jumlah *sample* pada *frame*, k adalah indeks frekuensi, dan j adalah bilangan imajiner $\sqrt{-1}$. Tahap selanjutnya adalah *Mel-Frequency Warping* yang dilakukan dengan menggunakan *filterbank* yang diterapkan di domain frekuensi untuk mengubahnya menjadi *mel scale* [19]. Dalam tahap ini, digunakan sebanyak 40 filter mel dan frekuensi maksimum sebesar setengah dari *sample rate*, yaitu 11.025. Dengan demikian akan didapatkan ukuran *mel spectrogram* 40×43 per detik dan 40×259 untuk 6 detik. Rumus dari *mel scale* sendiri dapat dilihat pada Persamaan (7).

$$mel(f) = 2595 \times \log_{10}\left(1 + \frac{f}{700}\right) \quad (7)$$

Dengan $mel(f)$ adalah fungsi *mel scale* dan f adalah frekuensi. Tahapan terakhir pada ekstraksi ciri dengan MFCC ini adalah *Discrete Cosine Transform* (DCT) [20]. Akan dilakukan konversi untuk mengubah *mel spectrogram* atau spektrum log mel kembali menjadi domain waktu menggunakan terlebih dahulu menggunakan Persamaan (8).

$$S_{dB} = 10 \log_{10}(S) \quad (8)$$

Dengan S_{dB} adalah hasil dalam skala desibel dan S adalah *Mel spectrogram*. Dari hasil konversi tersebut akan dilakukan DCT untuk mendapatkan nilai MFCC dengan menggunakan Persamaan (9).

$$c_n = \sum_{m=1}^M S_{dB}(m) \cos\left[\frac{\pi n}{M}(m + 0.5)\right] \quad (9)$$

Dengan c_n adalah *Mel-Frequency Ceptral Coefficients*, $S_{dB}(m)$ adalah *Mel spectrogram* dalam dB dan M merupakan jumlah koefisien. Koefisien MFCC yang digunakan adalah 20, sehingga akan menghasilkan MFCC dengan ukuran 20×43 per detik dan 20×259 untuk 6 detik.

2.4. Resampling Data

Setelah mendapatkan ciri, data dari setiap kelas akan disamakan banyaknya menjadi 1.500, sehingga data semua kelas menjadi seimbang. Untuk data lebih dari 1.500, akan dilakukan *downsampling* menggunakan algoritma *K-Means*, sedangkan pada data kurang dari 1500 akan dilakukan *oversampling* menggunakan *resample*. Algoritma *K-Means* dapat menghasilkan representasi data yang rata-rata dalam ruang fitur karena pusat kluster mewakili distribusi data. Dalam *resample*, data minoritas akan diduplikasi secara *random* untuk memperbanyak data. Dengan begitu, akan didapatkan total sebanyak 12.000 data untuk dilakukan klasifikasi pada PNN.

2.5. Klasifikasi

Klasifikasi data akan dilakukan dengan menggunakan *Probabilistic Neural Network* (PNN). Terdapat empat lapisan layer pada PNN, yaitu *input layer*, *pattern layer*, *summation layer*, dan *output layer*. *Input layer* terdiri dari *neuron* yang merupakan fitur data, sehingga banyak *neuron* pada layer ini adalah 5180, mengikuti banyak ciri MFCC. Pada *pattern layer*, dilaksanakan perhitungan kedekatan jarak antara data latih dan data uji menggunakan *Gaussian kernel* seperti pada Persamaan (10).

$$K(x, y) = e^{-\frac{\|x-y\|^2}{2\sigma^2}} \quad (10)$$


Parameter σ pada Gaussian kernel yang digunakan juga adalah sebesar 100, yang cocok untuk data input dalam penelitian ini. *Neuron* pada *layer* ini sama dengan jumlah data latih, yaitu 9.600. Pada *summation layer*, akan dikelompokkan hasil luaran *pattern layer* berdasarkan kelas dan kemudian dijumlahkan nilai probabilitasnya menggunakan Persamaan (11).

$$S_c = \sum_{i \in C} K(x, x_i) \quad (11)$$

Banyak *neuron* dari *summation layer* adalah sesuai dengan banyak kelas yaitu 8. Pada *output layer*, hanya ada 1 *neuron* yang merupakan hasil klasifikasi berdasarkan kelas dengan probabilitas tertinggi yang dihitung pada *summation layer*, sesuai dengan Persamaan (12).

$$Output(z) = \max P(X|C_j) \quad (12)$$

Melalui langkah ini, hasil akhir yang didapatkan berupa kelas yang mendapatkan probabilitas tertinggi berdasarkan input vektor ciri suara yang diberikan. Pada Gambar 2, ditampilkan flowchart dari alur pelaksanaan PNN yang akan dilakukan.



Gambar 2. Flowchart PNN

2.6. Pengujian dan Evaluasi

Pelaksanaan evaluasi hasil klasifikasi akan dilakukan dengan dua tahapan yaitu *K-Fold Cross Validation* yang kemudian dilanjutkan dengan *confusion matrix*. *K-Fold cross validation* merupakan sebuah metode yang dapat digunakan dalam mengevaluasi model yang dibuat dengan cara membagi data yang ada menjadi data latih dan data uji. Jenis *K-Fold* yang digunakan adalah *stratified K-Fold*, sehingga distribusi kelas pada setiap *fold* tetap seimbang. Mengikuti jumlah pembagian umum data latih dan data uji secara berturut-turut sebesar 80% dan 20%, k yang akan digunakan adalah 5. Dengan begitu, data yang tersedia akan dibagi menjadi 5 dengan 4 bagian sebagai data latih dan 1 bagian sebagai data uji, yang dimana setiap *fold*-nya akan digunakan sebanyak 9.600 data sebagai data latih dan 2.400 data sebagai data uji. Dilakukan sebanyak 5 iterasi dengan menukar data latih menjadi data uji seperti pada Tabel 1.

Tabel 1. 5-Fold Cross Validation

Fold	Bagian				
	1	2	3	4	5
1					
2					
3					
4					
5					

Keterangan:

	Data latih
	Data uji

Confusion matrix adalah sebuah matriks dari hasil representasi yang membandingkan prediksi dari sistem dengan kelas asli dari data masukan. Hasil nilai evaluasi yang didapatkan dari pengujian *5-fold cross validation* akan dicatat di sini. Dengan begitu, akan didapatkan nilai *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN) sehingga dapat ditentukan akurasi, presisi, serta *recall* dari hasil penelitian yang dilaksanakan. Pada Tabel 2, dapat dilihat tabel dari *confusion matrix*.

Tabel 2. Confusion Matrix

Confusion Matrix		Kelas Prediksi	
		Positif	Negatif
Kelas Asli	Positif	TP	FN
	Negatif	FP	TN

Rumus untuk menghitung akurasi, presisi, serta *recall* dapat dilihat pada Persamaan (13), (14), dan (15).

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (13)$$

$$presisi = \frac{TP}{TP+FP} \times 100\% \quad (14)$$

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (15)$$

3. Hasil dan Diskusi

Berdasarkan metode penelitian yang sudah dilakukan, didapatkan hasil evaluasi klasifikasi PNN dengan *K-Fold* dan *Confusion Matrix* dari setiap *fold*-nya sebagai berikut.

		precision	recall	f1-score	support	
Fold 1						
Confusion Matrix:						
[[300 0 0 0 0 0 0 0]		Asthma	1.00	1.00	1.00	300
[0 300 0 0 0 0 0 0]		Bronchiectasis	0.98	1.00	0.99	300
[0 0 300 0 0 0 0 0]		Bronchiolitis	0.99	1.00	0.99	300
[0 6 3 271 5 0 13 2]		COPD	0.99	0.90	0.95	300
[0 0 1 2 294 0 1 2]		Healthy	0.98	0.98	0.98	300
[0 0 0 0 0 300 0 0]		LRTI	0.99	1.00	1.00	300
[0 0 0 0 0 2 298 0]		Pneumonia	0.96	0.99	0.97	300
[0 1 0 0 0 1 0 298]]		URTI	0.99	0.99	0.99	300
		accuracy			0.98	2400
		macro avg	0.98	0.98	0.98	2400
		weighted avg	0.98	0.98	0.98	2400

Gambar 3. Fold 1 PNN

Pada Gambar 3 ditampilkan hasil dari *fold 1*, yang dimana terdapat 39 data yang salah diklasifikasikan. Data uji untuk kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah ditemukan pada kelas pneumonia sebesar 96%, sedangkan *recall* terendah terdapat pada kelas COPD sebesar 90%, menghasilkan akurasi 98,38%, dengan rata-rata presisi 98,4% dan rata-rata *recall* 98,38%.

										precision	recall	f1-score	support	
Fold 2														
Confusion Matrix:														
[[300 0 0 0 0 0 0 0]										Asthma	1.00	1.00	1.00	300
[0 300 0 0 0 0 0 0]										Bronchiectasis	0.98	1.00	0.99	300
[0 0 300 0 0 0 0 0]										Bronchiolitis	0.99	1.00	1.00	300
[0 6 1 272 5 1 10 5]										COPD	1.00	0.91	0.95	300
[0 0 0 0 299 0 1 0]										Healthy	0.97	1.00	0.98	300
[0 0 0 0 0 300 0 0]										LRTI	0.99	1.00	1.00	300
[0 0 0 0 4 0 296 0]										Pneumonia	0.96	0.99	0.98	300
[0 0 2 0 0 1 0 297]]										URTI	0.98	0.99	0.99	300
										accuracy			0.98	2400
										macro avg	0.99	0.98	0.98	2400
										weighted avg	0.99	0.98	0.98	2400

Gambar 4. Fold 2 PNN

Pada Gambar 4 ditampilkan hasil dari *fold 2*, yang mendapatkan sebanyak sebanyak 36 data yang salah diklasifikasikan. Data uji untuk kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 91%. *Fold* ini menunjukkan kinerja yang sedikit lebih tinggi dibandingkan *Fold 1*, dengan akurasi 98,5%, rata-rata presisi 98,53%, dan rata-rata *recall* 98,5%.

		precision	recall	f1-score	support	
Fold 3						
Confusion Matrix:						
[[300 0 0 0 0 0 0 0]		Asthma	1.00	1.00	1.00	300
[0 300 0 0 0 0 0 0]		Bronchiectasis	0.97	1.00	0.99	300
[0 0 300 0 0 0 0 0]		Bronchiolitis	0.98	1.00	0.99	300
[1 9 4 262 8 0 13 3]		COPD	0.99	0.87	0.93	300
[0 0 2 3 295 0 0 0]		Healthy	0.97	0.98	0.98	300
[0 0 0 0 0 300 0 0]		LRTI	1.00	1.00	1.00	300
[0 0 0 0 0 0 299 1]		Pneumonia	0.96	1.00	0.98	300
[0 0 0 0 2 0 0 298]]		URTI	0.99	0.99	0.99	300
		accuracy		0.98	2400	
		macro avg	0.98	0.98	0.98	2400
		weighted avg	0.98	0.98	0.98	2400

Gambar 5. Fold 3 PNN

Pada Gambar 5 ditampilkan hasil dari *fold 3*, yang dimana terdapat sebanyak 46 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, dan LRTI seluruhnya berhasil diklasifikasikan dengan benar. Presisi terendah ditemukan pada kelas pneumonia sebesar 96%, dan *recall* terendah

terjadi pada kelas COPD sebesar 87%. *Fold* ini menghasilkan kinerja terendah dibandingkan *fold* lainnya, dengan akurasi 98,08%, rata-rata presisi 98,11%, dan rata-rata *recall* 98,08%.

Fold 4		precision	recall	f1-score	support	
Confusion Matrix:						
[[300 0 0 0 0 0 0 0]		Asthma	1.00	1.00	1.00	300
[0 300 0 0 0 0 0 0]		Bronchiectasis	0.98	1.00	0.99	300
[0 0 300 0 0 0 0 0]		Bronchiolitis	1.00	1.00	1.00	300
[1 5 1 281 2 0 9 1]		COPD	1.00	0.94	0.97	300
[0 0 0 0 298 0 1 1]		Healthy	0.99	0.99	0.99	300
[0 0 0 0 0 300 0 0]		LRTI	1.00	1.00	1.00	300
[0 0 0 1 0 0 299 0]		Pneumonia	0.96	1.00	0.98	300
[0 0 0 0 2 1 2 295]]		URTI	0.99	0.98	0.99	300
		accuracy			0.99	2400
		macro avg	0.99	0.99	0.99	2400
		weighted avg	0.99	0.99	0.99	2400

Gambar 6. Fold 4 PNN

Pada Gambar 6 ditampilkan hasil dari *fold* 4, yang dimana terdapat sebanyak 27 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 94%. *Fold* ini memberikan hasil kinerja tertinggi di antara seluruh *fold*, dengan akurasi 98,88%, rata-rata presisi 98,89%, dan rata-rata *recall* 98,88%.

Fold 5		precision	recall	f1-score	support	
Confusion Matrix:						
[[300 0 0 0 0 0 0 0]		Asthma	0.99	1.00	1.00	300
[0 300 0 0 0 0 0 0]		Bronchiectasis	0.97	1.00	0.98	300
[0 0 300 0 0 0 0 0]		Bronchiolitis	1.00	1.00	1.00	300
[2 10 0 271 4 0 12 1]		COPD	1.00	0.90	0.95	300
[0 0 0 0 299 0 1 0]		Healthy	0.99	1.00	0.99	300
[0 0 0 0 0 300 0 0]		LRTI	1.00	1.00	1.00	300
[0 0 0 0 0 0 300 0]		Pneumonia	0.96	1.00	0.98	300
[0 0 0 0 0 1 0 299]]		URTI	1.00	1.00	1.00	300
		accuracy			0.99	2400
		macro avg	0.99	0.99	0.99	2400
		weighted avg	0.99	0.99	0.99	2400

Gambar 7. Fold 5 PNN

Pada Gambar 7 ditampilkan hasil dari *fold* 5, yang dimana sebanyak 31 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, LRTI, dan pneumonia berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 90%. *Fold* ini mencapai kinerja tertinggi kedua dengan akurasi 98,71%, rata-rata presisi 98,75%, dan rata-rata *recall* 98,71%.

Berdasarkan 5 *fold* yang sudah dilakukan, *fold* 4 mencapai akurasi tertinggi sebesar 98,88%, sedangkan *fold* 3 memiliki akurasi terendah sebesar 98,08%. Rata-rata keseluruhan untuk akurasi, presisi, dan *recall* dari seluruh *fold* juga sebesar 98,51%, 98,54%, dan 98,51% secara berturut.

4. Kesimpulan

Dalam klasifikasi penyakit pernapasan dengan ekstraksi ciri menggunakan *Mel-Frequency Cepstral Coefficients* (MFCC), *Probabilistic Neural Network* (PNN) sebagai model pengklasifikasi menunjukkan tingkat performa yang baik. Model ini mencapai akurasi tertinggi sebesar 98,88%, dengan rata-rata akurasi sebesar 98,51%, rata-rata presisi sebesar 98,54%, dan rata-rata *recall* sebesar 98,51%. Hasil ini menunjukkan bahwa metode PNN efektif dalam mengidentifikasi penyakit pernapasan, memberikan potensi sebagai alat bantu diagnosis dalam bidang kesehatan.

Daftar Pustaka

- [1] T. Vos *et al.*, "Global burden of 369 diseases and injuries in 204 countries and territories, 1990–2019: A systematic analysis for the global burden of disease study 2019," *The Lancet*, vol. 396, no. 10258, p. 1204, 2020. doi: 10.1016/s0140-6736(20)30925-9.
- [2] Perhimpunan Dokter Paru Indonesia, *Panduan Umum Praktis Klinis Penyakit Paru dan Pernapasan*, Jakarta: Perhimpunan Dokter Paru Indonesia, 2021. [Online]. Available: <https://bukupdpi.klikpdpi.com/buku-pupk-pdpi-2021-2/>. [Accessed: Jan. 21, 2025].
- [3] I. P. B. C. Buana, I. G. A. Wibawa, A. Muliantara, M. A. Raharja, I. P. G. H. Suputra, and L. G. Astuti, "Deteksi Suara Paru-Paru Menggunakan MFCC (Mel Frequency Cepstral Coefficient) dan M-KNN (Modified K-Nearest Neighbor)," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 4, pp. 845–853, 2022. doi: <https://doi.org/10.24843/jlk.2023.v11.i04.p25>.
- [4] A. Buono, "Representasi nilai hos dan model MFCC sebagai ekstraksi ciri pada sistem indentifikasi pembicara di lingkungan ber-noise menggunakan HMM," M.S. thesis, Program Studi Ilmu Komputer, Universitas Indonesia, Depok, Indonesia, 2009.
- [5] N. M. A. Suandewi, I. G. A. Wibawa, I. G. N. A. Cahyadi, I. K. A. Mogi, N. A. S. ER, and C. R. A. Pramatha, "Penerapan Metode MFCC dan Naive Bayes untuk Deteksi Suara Paru-Paru," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 1, pp. 75–82, 2022. doi: <https://doi.org/10.24843/jlk.2022.v11.i01.p08>.
- [6] B. Mohebbi *et al.*, "Probabilistic neural networks: a brief overview of theory, implementation, and application," in *Handbook of Probabilistic Models*, Kidlington, Oxford, United Kingdom: Butterworth-Heinemann, an imprint of Elsevier, 2020, pp. 347–367.
- [7] R. Novita *et al.*, "The implementation of probabilistic neural network algorithm for classification of Family Hope Program in Pekanbaru City," *Journal of Physics: Conference Series*, vol. 1783, no. 1, pp. 1–6, 2021. doi: 10.1088/1742-6596/1783/1/012018.
- [8] C. Shilaja and T. Arunprasath, "Retraction Note: Energy demand classification by probabilistic neural network for medical diagnosis applications," *Neural Computing and Applications*, vol. 36, no. 24, pp. 15199–15199, 2024. doi: <https://doi.org/10.1007/s00521-024-10091-8>.
- [9] S. J. Siregar, A. I. Lubis, and E. F. Ginting, "Penerapan neural network Dalam Klasifikasi citra Permainan Batu kertas Gunting Dengan probabilistic neural network," *Building of Informatics, Technology and Science (BITS)*, vol. 3, no. 3, pp. 420–425, 2021. doi: 10.47065/bits.v3i3.1143.
- [10] D. Lee, S. Derrible, and F. C. Pereira, "Comparison of four types of Artificial Neural Network and a multinomial logit model for travel mode choice modeling," *Transportation Research Record: Journal of the Transportation Research Board*, vol. 2672, no. 49, pp. 101–112, 2018. doi: 10.1177/0361198118796971.
- [11] S. K. Satapathy *et al.*, "EEG Brain Signal Classification for Epileptic Seizure Disorder Detection," Academic Press, 2019, pp. 1–25. doi: <https://doi.org/10.1016/B978-0-12-817426-5.00001-6>.
- [12] N. P. D. Sukma *et al.*, "Klasifikasi Penyakit Paru-Paru berdasarkan Suara Paru-Paru menggunakan metode MFCC Dan SVM," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 3, pp. 553–560, 2023. doi: 10.24843/jlk.2023.v11.i03.p11.
- [13] D. Rafiqo, Y. Suyanto, and C. Atmaji, "Klasifikasi Suara Paru-Paru berdasarkan Ciri MFCC," *Jurnal ELEMENTER (Elektro dan Mesin Terapan)*, vol. 7, no. 1, pp. 20–34, 2022.
- [14] C. Aridela, A. Rizal, and Y. S. Hariyani, "Perbandingan Suara Paru Normal dan Abnormal menggunakan Probabilistic Neural Network dan Support Vector Machine," *e-Proceeding of Engineering*, vol. 4, no. 1, pp. 165–172, 2017.

- [15] K. N. Priftis, L. J. Hadjileontiadis, and M. L. Everard, *Breath Sounds from Basic Science to Clinical Practice*, Cham, Zug: Springer International Publishing, 2018.
- [16] K. Mridha, S. Sarkar, and D. Kumar, "Respiratory Disease Classification by CNN using MFCC," in *2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA)*, 2021. doi: <https://doi.org/10.1109/iccca52192.2021.9666346>.
- [17] F. Syafria, A. Buono, and B. P. Silalahi, "Pengenaln Suara Paru-paru dengan mfcc Sebagai Ekstraksi Ciri Dan Backpropagation Sebagai classifier," *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 3, no. 1, pp. 27–37, 2014. doi: 10.29244/jika.3.1.27-36.
- [18] Y. Yan, S. O. Simons, L. van Bemmelen, L. G. Reinders, F. M. E. Franssen, and V. Urovi, "Optimizing MFCC parameters for the automatic detection of respiratory diseases," *Applied Acoustics*, vol. 228, pp. 110299–110299, 2024. doi: <https://doi.org/10.1016/j.apacoust.2024.110299>.
- [19] A. Mustofa, "Sistem Pengenaln penutur dengan metode Mel-frequency wrapping," *Jurnal Teknik Elektro*, vol. 7, no. 2, pp. 88–96, 2007. doi: 10.9744/jte.7.2.88-96.
- [20] I. S. Permana, Y. I. Nurhasanah, and A. Zulkarnain, "Implementasi metode MFCC Dan DTW untuk Pengenaln Jenis suara pria dan wanita," *MIND Journal*, vol. 3, no. 1, pp. 49–63, 2018. doi: 10.26760/mindjournal.v3i1.61-76.

Popularitas Kursus Online: Analisis Mendalam dengan K-Means di Platform Udemy

Rahmat Hidayat^{a1}, Ibnu Daqiqil Id^{b2*}, Rahmah Muthmainah^{b3}, Muhammad Alfhat Ramadhan^{b4}, Icha Dwi Yanti^{b5}, Kornelius Jonathan Manik^{b6}, Rendi Wahyudi^{b7}

^aProgram Studi Manajemen Informatika, Universitas Riau

^bProgram Studi Sistem Informasi, Universitas Riau
Kampus Bina Widya Km 12,5 Simpang Baru Pekanbaru, Indonesia

¹rahmat.hidayat@lecturer.unri.ac.id

²ibnu.daqiqil@lecturer.unri.ac.id

³rahmah.muthmainah3281@student.unri.ac.id

⁴muhammad.alfhat6561@student.unri.ac.id

⁵icha.dwi5311@student.unri.ac.id

⁶kornelius.jonathan3893@student.unri.ac.id

⁷rendi.wahyudi0482@student.unri.ac.id

Abstract

Online courses have become increasingly popular in the digital age, offering flexibility, access to materials and enhanced collaboration. However, online course providers face challenges in understanding user preferences to develop effective marketing strategies. This study uses the K-Means clustering algorithm to analyze the popularity of online courses on the Udemy platform. The analysis is based on a Kaggle dataset containing course attributes such as enrollment numbers, reviews, and others. The elbow method was used to determine the optimal number of clusters, with results showing that K=4 is optimal. The clustering quality was assessed using the Davies-Bouldin Index (DBI) and Silhouette Score, yielding a DBI value of 0.65171 and a Silhouette Score of 0.6269, indicating good cluster separation. The study reveals four distinct clusters of courses, each with varying popularity and characteristics. This study can help course providers create more targeted marketing strategies, improving user engagement and satisfaction based on the specific traits of each course group.

Keywords: data mining, clustering, k-means, algorithm, online courses, popularity.

Abstrak

Kursus online telah menjadi semakin populer di era digital, menawarkan fleksibilitas, akses ke materi dan kolaborasi yang lebih baik. Namun, penyedia kursus online menghadapi tantangan dalam memahami preferensi pengguna untuk mengembangkan strategi pemasaran yang efektif. Studi ini menggunakan algoritma klastering K-means untuk menganalisis popularitas kursus online di platform Udemy. Analisis ini didasarkan pada dataset Kaggle yang berisi atribut kursus seperti jumlah pendaftara, ulasan, dan lainnya. Metode *Elbow* digunakan untuk menentukan jumlah kluster yang optimal, dengan hasil menunjukkan bahwa K=4 adalah yang optimal. Kualitas pengelompokan dinilai menggunakan *Davies-Bouldin Index* (DBI) dan Skor *Silhouette*, menghasilkan nilai DBI sebesar 0,65171 dan Skor *Silhouette* sebesar 0,6269, yang menunjukkan pemisahan kluster yang baik. Studi ini mengungkapkan empat kluster kursus yang berbeda, masing-masing dengan popularitas dan karakteristik yang bervariasi. Penelitian ini dapat membantu penyedia kursus menciptakan strategi pemasaran yang lebih terarah, meningkatkan keterlibatan dan kepuasan pengguna berdasarkan karakteristik spesifik dari setiap kelompok kursus.

Kata Kunci: penambangan data, klastering, k-means, algoritma, kursus online, popularitas.

1. Pendahuluan

Dalam era digital saat ini, kegiatan belajar online menjadi suatu hal yang lumrah. Bahkan, di beberapa universitas maupun sekolah tinggi di negara-negara maju seperti Eropa dan Amerika sudah menerapkan sistem ini. Sistem yang sudah diterapkan oleh beberapa negara ialah pengajar dan peserta berinteraksi lewat laptop, melakukan *video call* atau *conference call*. Perlu diketahui, pada dasarnya belajar online dapat melampaui belajar konvensional [1]. Belajar online menuntut siswa untuk memiliki metodologi berpikir yang cukup, khususnya dalam mencerna instruksi yang diberikan secara online [2].

Kelas konvensional sering dianggap kurang efektif karena akses terbatas bagi pelajar di lokasi yang jauh, metode pengajaran yang kaku, dan kurangnya personalisasi [3]. Waktu kelas yang terbatas juga menyulitkan pendalaman materi, sementara interaksi siswa yang minim mengurangi peluang belajar dari satu sama lain. Untuk mengatasi tantangan ini, banyak institusi beralih ke kursus *online* [4]. Kursus *online* menawarkan fleksibilitas waktu dan tempat, akses ke sumber daya pendidikan yang lebih beragam, serta meningkatkan interaksi dan kolaborasi melalui platform digital, menciptakan pengalaman belajar yang lebih efektif dan menarik [5].

Kursus *online* atau “*e-learning*” adalah proses pembelajaran yang memfasilitasi, menyampaikan dan memungkinkan pembelajaran jarak jauh melalui penggunaan teknologi internet [6]. Jenis pembelajaran ini menjadi salah satu bentuk pembelajaran yang paling populer dan berpengaruh, terutama dalam pendidikan pasca-sekolah menengah selama dekade terakhir [7]. Selain fleksibilitas dan kemudahan akses, kursus *online* juga membuka peluang bagi siapa pun untuk mendapatkan sertifikasi resmi dan meningkatkan prospek kerja tanpa batasan usia, menjadikannya alternatif yang ideal bagi banyak pelajar di era digital [8]. E-learning mendorong pembelajaran mandiri dan pengembangan keterampilan belajar. Siswa dapat mengelola waktu mereka sendiri dan mengambil inisiatif dalam pembelajaran mereka [9]. Ini mengajarkan keterampilan penting dalam mengatur diri dan memotivasi diri sendiri untuk mengikuti pendidikan.

Kemajuan kursus *online* yang pesat menjadikannya tidak hanya sebagai alat pembelajaran, tetapi juga sebagai peluang bisnis bagi penyedia layanan pendidikan [10]. Agar kursus online dapat menjangkau lebih banyak pengguna dan menciptakan nilai tambah, diperlukan strategi pemasaran yang efektif. Strategi pemasaran yang disusun secara rinci dan sistematis akan membantu penyedia kursus merancang kegiatan pemasaran yang terarah, sehingga tujuan perusahaan, termasuk meningkatkan keuntungan dan kepuasan pengguna dapat tercapai [11]. Salah satu cara untuk mendukung strategi ini adalah dengan menerapkan algoritma K-Means untuk mengelompokkan jenis kursus online berdasarkan tingkat popularitasnya.

Clustering merupakan metode berbasis jarak yang membagi data ke dalam sejumlah kluster berdasarkan atribut numerik [12]. Dalam *clustering data mining*, algoritma K-Means membentuk kelompok baru berdasarkan pembentukan *cluster*. Ini dilakukan berdasarkan kesamaan atau kemiripan karakteristik data untuk mengidentifikasi karakteristik data berdasarkan nilai jarak terdekat [13]. Proses ini melibatkan pemilihan sejumlah objek sebagai centroid, di mana setiap kursus dikelompokkan berdasarkan jarak *Euclidean* ke *centroid* tersebut [14]. Dengan menggunakan pendekatan ini, kita dapat mengidentifikasi kelompok kursus yang paling diminati dan merumuskan strategi pemasaran yang lebih efektif.


2. Metode Penelitian

2.1 Pengertian Metode Algoritma K-Means Clustering

Means Clustering suatu metode yang digunakan untuk mencari dan mengelompokkan data yang mirip-mirip agar lebih mudah membedakan dengan data yang lainnya. *Clustering* sendiri merupakan suatu metode data yang tidak memiliki acuan (*unsupervised*) dimana mengelompokkan data yang mirip tanpa perlu contoh atau aturan khusus [15].

2.2 Data Mining

Data mining dikenal dengan istilah *Knowledge Discovery in Database* (KDD) merupakan kegiatan mengumpulkan, mengolah, dan penggunaan data dalam jumlah besar dengan tujuan menemukan pola atau aturan yang dapat disimpan dalam data base atau media penyimpanan lainnya yang dapat membantu dalam membuat keputusan yang lebih baik [16].



Gambar 1. Proses Knowledge Discovery in Database (KDD)

1. Selection

Selection digunakan untuk menentukan variabel yang diminati sehingga tidak ada persamaan dan tidak terjadi pengulangan yang tidak diperlukan untuk pemrosesan data mining.

2. Preprocessing

Menghilangkan data yang tidak diperlukan seperti menangani *missing value*, *noise* data serta menangani data-data yang tidak konsisten dan relevan [17].

3. Transformation

Merubah data ke dalam format yang sesuai dalam pengolahan data mining beberapa metode dalam data mining memerlukan format tertentu sebelum dapat diproses pada penambahan data.

4. Data mining

Data Mining adalah proses utama pada metode yang diterapkan untuk mendapatkan pengetahuan baru dari data yang telah diproses [18]. Penelitian ini menerapkan teknik *Clustering* yaitu metode K-Means *Clustering*.

5. Evaluation/Interpretation

Pada tahap ini, pola-pola menarik atau model prediksi diidentifikasi dan dimasukkan ke dalam knowledge base. Pola-pola tersebut kemudian dievaluasi untuk memastikan bahwa hasilnya sesuai dengan tujuan yang diinginkan.

a. Nilai DBI

DBI menunjukkan seberapa jauh klaster terpisah satu sama lain dan seberapa kompak. Nilai DBI yang lebih kecil menunjukkan hasil *clustering* yang lebih baik [19].

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{S_i + S_j}{d(c_i, c_j)} \right) \quad (1)$$

k : jumlah *cluster*

S : jarak intra-*cluster* untuk *cluster* i

$d(c_i, c_j)$: jarak antar centroid dari *cluster* i dan *cluster* j

b. Silhouette Score

Nilai *Silhouette* digunakan untuk mengevaluasi seberapa baik objek dalam suatu *cluster* terpisah dari objek lain [20]. Nilai yang mendekati 1 menunjukkan bahwa titik data berada

di dalam kluster yang benar, nilai mendekati 0 menunjukkan data berada di antara dua kluster, sedangkan nilai negatif menunjukkan bahwa titik data lebih dekat ke kluster yang salah [21].

$$s = \frac{b - a}{\max(a, b)} \quad (2)$$


- s : *Silhouette Score* untuk titik data
 a : Rata-rata jarak antara titik data dan semua titik data lain dalam kluster yang sama
 b : Rata-rata jarak antara titik data dan semua titik data dalam kluster terdekat yang berbeda

6. *Knowledge*

Pola-pola yang telah dihasilkan akan ditampilkan kepada pengguna. Pada tahap ini pengetahuan baru yang dihasilkan bisa dimengerti semua orang yang akan dijadikan standar pengambilan kebutuhan [22].

2.3 Tahapan perhitungan Algoritma *K-means Clustering Analysis*

Proses perhitungan untuk analisis Algoritma *K-Means Clustering* diuraikan sebagai berikut:



Gambar 2. Tahapan perhitungan Algoritma *K-means Clustering*

1. Menentukan jumlah *cluster*
Jumlah *cluster* ditentukan dengan melihat pola dari *elbow method*. *Elbow method* menunjukkan nilai *within-cluster-sum-of-square* (WCSS) pada sumbu y yang sesuai dengan nilai K yang berbeda.
2. Menentukan titik pusat (*centroid*) *cluster*
Menentukan titik pusat adalah langkah penting dalam algoritma *K-Means*. Proses ini dimulai dengan inisialisasi sejumlah *centroid* secara acak. Setiap titik data kemudian ditugaskan ke kluster dengan *centroid* terdekat berdasarkan jarak Euclidean. Setelah semua titik data ditugaskan, posisi *centroid* diperbarui dengan menghitung rata-rata posisi semua titik data dalam kluster tersebut.
3. Menghitung jarak antar titik data objek dan titik pusat (*centroid*)
Rumus *Euclidean Distance* digunakan untuk perhitungan jarak:

$$\text{dist}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3)$$

- $d(x, y)$: Jarak data antara dua titik x dan y
 x : Titik pertama dalam ruang dimensi- n (data objek)
 y : Titik kedua dalam ruang dimensi- n (data *centroid*)
 j : Jumlah atribut data

2.4 Data

Data yang digunakan dalam penelitian ini berasal dari dataset kursus online platform Udemy, yang berisi informasi mendetail mengenai berbagai kursus yang ditawarkan. Dataset mencakup atribut-atribut yang berkaitan dengan identifikasi kursus.

Tabel 1. Deskripsi Data Kursus Online Udemy

Nama <i>Field</i>	Tipe Data	Keterangan
<i>course_id</i>	<i>integer</i>	ID unik yang digunakan untuk mengidentifikasi kursus
<i>course_title</i>	<i>object</i>	Judul kursus yang menjelaskan topik atau isi kursus.
<i>url</i>	<i>object</i>	Tautan ke halaman web tempat kursus tersebut dapat diakses.
<i>is_paid</i>	<i>boolean</i>	Menunjukkan apakah kursus berbayar atau gratis.
<i>price</i>	<i>integer</i>	Harga kursus jika berbayar
<i>num_subscribers</i>	<i>integer</i>	Jumlah orang yang telah mendaftar untuk kursus tersebut
<i>num_reviews</i>	<i>integer</i>	Jumlah ulasan yang diberikan oleh peserta kursus
<i>num_lectures</i>	<i>integer</i>	Jumlah kuliah atau modul yang termasuk dalam kursus
<i>level</i>	<i>object</i>	Tingkat kesulitan kursus
<i>content_duration</i>	<i>float</i>	Durasi total konten kursus dalam satuan jam
<i>published_timestamp</i>	<i>object</i>	Tanggal dan waktu ketika kursus diterbitkan
<i>subject</i>	<i>object</i>	Subjek atau kategori utama dari kursus

2.5 Data Pre-Processing

Menghapus data *subscribers* dengan nilai 0 dan membersihkan atribut seperti *course_title*, *url*, dan *published_timestamp* untuk meningkatkan relevansi dan konsistensi dataset. Hal ini dilakukan untuk membuat data yang dianalisis lebih bermakna dan memasukkan hanya informasi yang relevan yang berkontribusi langsung terhadap tujuan analisis. Setelah melalui proses *pre-processing*, data yang sebelumnya berjumlah 3678 mengerucut menjadi 3608.

2.6 Data Transformation

Pada tahap ini, data mentah diubah menjadi bentuk yang lebih terstruktur dan siap untuk analisis. Transformasi data dilakukan untuk menyederhanakan interpretasi atribut tertentu dengan mengubah data kualitatif menjadi data kuantitatif. Beberapa transformasi dilakukan sebagai berikut:

Tabel 2. Data Transformation *is_paid*

Sebelum	Sesudah
<i>TRUE</i>	1
<i>FALSE</i>	0

Tabel 3. Data Transformation *level*

Sebelum	Sesudah
<i>All Level</i>	1
<i>Beginner Level</i>	2
<i>Expert Level</i>	3
<i>Intermediate Level</i>	4

Tabel 4. Data

Sebelum	Sesudah
<i>Business Finance</i>	1
<i>Graphic Design</i>	2
<i>Musical Instruments</i>	3
<i>Web Development</i>	4

Transformation subject


Setelah tahap pre-processing dan transformation selesai, data kemudian digabungkan ke dalam dataframe yang tersedia. Proses ini dilakukan dengan tujuan memastikan bahwa semua data berada dalam satu struktur data yang konsisten, yang memungkinkan analisis lebih lanjut dan memungkinkan pengolahan data yang lebih efisien pada tahap berikutnya.

Tabel 5. Data yang Sudah Melalui Tahap *Pre-Processing* dan *Transformation*

No	is_ paid	price	num_subscribers	num_ reviews	num_ lectures	level	content_ duration	sub ject
1	2	200	2147	23	51	1	1.5	1
2	2	75	2792	923	274	1	39	1
3	2	45	2174	74	51	4	2.5	1
4	2	95	2451	11	36	1	3	1
5	2	200	1276	45	26	4	2	1
6	2	150	9221	138	25	1	3	1
7	2	65	1540	178	26	2	1	1
8	2	95	2917	148	23	1	2.5	1
9	2	195	5172	34	38	3	2.5	1
10	2	200	827	14	15	1	1	1
...	...	...	...	...	...	...	...	...
3608	2	45	901	36	20	2	2	4

4. Kerangka Berpikir

Kerangka berpikir adalah rencana dan diagram yang digunakan untuk menyatukan konsep yang akan dibahas selama penelitian. Ini dibuat untuk membantu peneliti membuat hipotesa yang akan diteliti [23]. Gambar 3 menunjukkan kerangka berfikir yang dirumuskan seperti berikut ini.




Gambar 3. Kerangka Berpikir

3. Hasil dan Pembahasan

Pada penelitian ini, tahapan pengujian dilakukan untuk mengevaluasi efektivitas model K-Means dalam mengelompokkan kursus online dari platform Udemy berdasarkan atribut-atribut penting.

a. Menentukan jumlah *cluster*

Untuk menentukan jumlah kluster yang optimal, peneliti menganalisis nilai WCSS (*Within-Cluster Sum of Squares*) dalam model K-Means. Ditemukan bahwa nilai WCSS mengalami penurunan signifikan saat jumlah kluster bertambah dari 2 menjadi 4, yang menunjukkan peningkatan kekompakan kluster. Namun, setelah mencapai 4 kluster, laju penurunan WCSS mulai melambat, mendandakan bahwa penambahan kluster selanjutnya tidak memberikan peningkatan yang berarti. Dengan demikian, dapat disimpulkan bahwa jumlah kluster yang optimal adalah 4.



Gambar 4. Elbow Method

b. Menentukan titik pusat (*centroid*) *cluster*


Untuk menentukan centroid, langkah yang dilakukan adalah menghitung rata-rata dari setiap atribut pada anggota *cluster* tersebut. Centroid ini mewakili posisi tengah *cluster* berdasarkan nilai atributnya.

Tabel 6. Rata-rata atribut setiap *cluster*

Rata-rata	C1	C2	C3	C4
<i>num_subscribers</i>	1076.48	8653.40	88291.88	15179.95
<i>num_reviews</i>	-41.53	983.72	7831.58	986.51
<i>num_lectures</i>	35.21	146.04	209.36	-5.36

<i>price</i>	65.82	158.18	49.34	-4.20
<i>level</i>	1.74	1.31	1.04	1.89
<i>duration</i>	3.50	16.51	24.25	-1.20
<i>subject</i>	2.41	3.15	7.10	2.93
<i>is_paid</i>	1.94	2.15	0.62	1.50

Atribut *kmeans_pca.cluster_centers* digunakan untuk mengumpulkan kluster, yang menunjukkan posisi data rata-rata dalam setiap kluster. Posisi *centroid* divisualisasikan pada grafik PCA menggunakan *plt.scatter()* dan label “Centroids” ditambahkan melalui *plt.legend()* untuk memudahkan identifikasi.



Gambar 5. Titik Pusat (*Centroid*) pada tiap *cluster*

c. Menghitung jarak antar titik data objek dan titik pusat (*centroid*)

Rumus *Euclidean Distance* digunakan untuk menghitung jarak antara setiap titik data objek dan titik pusat (*centroid*) kluster.

Perhitungan Jarak pada seluruh data ke semua pusat *cluster*:

- Jarak data 1 ke *cluster* 1

$$\sqrt{[(2147 - 1076.48)^2 + (23 - (-41.53))^2 + (51 - 35.21)^2 + (200 - 65.82)^2 + (1 - 1.74)^2 + (1.5 - 3.50)^2 + (1 - 2.41)^2 + (2 - 1.94)^2]} = 1080.943$$
- Jarak data 1 ke *cluster* 2

$$\sqrt{[(2147 - 8653.40)^2 + (23 - 983.72)^2 + (51 - 146.04)^2 + (200 - 158.18)^2 + (1 - 1.31)^2 + (1.5 - 16.51)^2 + (1 - 3.15)^2 + (2 - 2.15)^2]} = 6577.783$$
- Jarak data 1 ke *cluster* 3

$$\sqrt{[(2147 - 88291.88)^2 + (23 - 7831.58)^2 + (51 - 209.36)^2 + (200 - 49.34)^2 + (1 - 1.04)^2 + (1.5 - 24.25)^2 + (1 - 7.10)^2 + (2 - 0.62)^2]} = 86498.338$$
- Jarak data 1 ke *cluster* 4

$$\sqrt{[(2147 - 15179.95)^2 + (23 - 986.51)^2 + (51 - (-5.36))^2 + (200 - (-4.20))^2 + (1 - 1.89)^2 + (1.5 - (-1.20))^2 + (1 - 2.93)^2 + (2 - 1.50)^2]} = 13070.234$$
-
- Jarak data 3608 ke *cluster* 1

$$\sqrt{[(901 - 1076.48)^2 + (36 - (-41.53))^2 + (20 - 35.21)^2 + (45 - 65.82)^2 + (2 - 1.74)^2 + (2 - 3.50)^2 + (4 - 2.41)^2 + (2 - 1.94)^2]} = 193.584$$
- Jarak data 3608 ke *cluster* 2

$$\sqrt{[(901 - 8653.40)^2 + (36 - 983.72)^2 + (20 - 146.04)^2 + (45 - 158.18)^2 + (2 - 1.31)^2 + (2 - 16.51)^2 + (4 - 3.15)^2 + (2 - 2.15)^2]} = 7811.964$$

- Jarak data 3608 ke *cluster* 3

$$\sqrt{[(901 - 88291.88)^2 + (36 - 7831.58)^2 + (20 - 209.36)^2 + (45 - 49.34)^2 + (2 - 1.04)^2 + (2 - 24.25)^2 + (4 - 7.10)^2 + (2 - 0.62)^2]} = 87738.095$$

- Jarak data 3608 ke *cluster* 4

$$\sqrt{[(901 - 15179.95)^2 + (36 - 986.51)^2 + (20 - (-5.36))^2 + (45 - (-4.20))^2 + (2 - 1.89)^2 + (2 - (-1.20))^2 + (4 - 2.93)^2 + (2 - 1.50)^2]} = 14310.658$$

Tabel 7. Jarak data ke setiap titik pusat (*centroid*)

No	C1	C2	C3	C4
1	1080.943	6577.783	86498.338	13070.234
2	1982.850	5863.744	85778.569	12391.580
3	1103.895	6544.636	86466.727	13038.137
4	1375.834	6279.509	86196.582	12766.728
5	255.7158	7437.983	87363.900	13937.322
6	8146.940	1025.826	79444.570	6021.110
7	512.9712	7160.515	87089.037	13664.102
8	1850.524	5798.624	85720.154	12292.017
9	4098.254	3610.449	83485.135	10055.243
10	289.3896	7887.462	87813.898	14387.323
...	...	...	...	...
3608	193.5854	7811.964	87738.095	14310.658

d. Pengelompokan data berdasarkan jarak minimum *cluster*

Data dikelompokkan berdasarkan jarak paling dekat ke pusat setiap klaster dan ditempatkan pada klaster yang memiliki nilai minimal pada iterasi. Tabel klaster iterasi berikut menunjukkan hasilnya:

Tabel 8. Pengelompokan data

No	C1	C2	C3	C4
1	1			
2	1			
3	1			
4	1			
5	1			
6		1		
7	1			
8	1			
9		1		
10	1			
...	...	...	...	...
3608	1			

e. Evaluasi

Hasil evaluasi klaster menunjukkan nilai *Davies-Bouldin Index* (DBI) sebesar 0.6517, yang mengindikasikan bahwa klaster yang terbentuk memiliki pemisahan yang baik dan tidak terlalu tumpang tindih.


Tabel 9. Hasil evaluasi *Davies-Bouldin Index* (DBI)

Cluster	Hasil nilai DBI
Average within-centroid distance C1	0.70
Average within-centroid distance C2	1.99
Average within-centroid distance C3	6.09
Average within-centroid distance C4	0.97

Selain itu, nilai *Silhouette Score* untuk 4 kluster adalah 0.6269, yang menunjukkan bahwa struktur kluster cukup kuat, dengan nilai di atas 0.5 menunjukkan bahwa data dalam setiap kluster relatif lebih dekat satu sama lain dibandingkan dengan data di kluster lain. Kedua metrik ini menunjukkan bahwa pembagian kluster yang dihasilkan adalah efektif dan dapat diandalkan.

f. Knowledge

Hasil analisis kluster memberikan wawasan mendalam mengenai popularitas data yang diolah. Kluster 3, yang berisi 16 data, menunjukkan bahwa item-item dalam kluster ini memiliki daya tarik yang tinggi dan mungkin menarik perhatian pasar. Kluster 2, dengan 267 data, menunjukkan bahwa item-item di sini juga mendapatkan minat signifikan tetapi tidak sekuat kluster sebelumnya. Sebaliknya, Kluster 1 memiliki jumlah data terbanyak, yaitu 3009, mendandakan bahwa item dalam kluster ini mungkin memerlukan strategi pemasaran yang lebih agresif untuk meningkatkan daya tariknya. Terakhir, kluster 4, yang berisi 316 data, menunjukkan bahwa item-item dalam kluster ini kurang diminati, sehingga bisa menjadi fokus untuk evaluasi lebih lanjut dan perbaikan.



Gambar 4. Proporsi Data di Setiap *Cluster* Hasil analisis kluster memberikan

Berdasarkan hasil penelitian yang menunjukkan bahwa metode K-Means berhasil mengelompokkan kursus online Udem ke dalam empat kluster optimal, maka rekomendasi eksplisit implementasi praktis yang dapat dilakukan oleh pihak manajemen Udem dalam menerapkan hasil klasterisasi ini dalam strategi pemasaran, pengembangan konten, dan personalisasi layanan. Secara khusus:

- Kluster 1 dan 4, yang merepresentasikan kategori kursus dengan tingkat popularitas yang konsisten dan homogen, dapat dijadikan sebagai prioritas utama dalam promosi, peningkatan kualitas, dan replikasi model kursus sejenis.
- Kluster dengan popularitas rendah sebaiknya dianalisis lebih lanjut untuk mengidentifikasi kekurangan konten, kurangnya visibilitas, atau kebutuhan pembaruan topik agar dapat ditingkatkan efektivitasnya.
- Sistem rekomendasi berbasis kluster dapat dikembangkan, di mana pengguna baru ditawarkan kursus dari kluster yang sesuai dengan minat dominan dan tren popularitas saat ini.
- Dashboard internal berbasis data klasterisasi juga dapat digunakan oleh tim pengembang produk dan konten untuk mengawasi dinamika popularitas kursus secara real-time dan mengambil keputusan berbasis data.

Dengan demikian, hasil klasterisasi ini tidak hanya memberikan wawasan analitis, tetapi juga dapat dijadikan dasar pengambilan keputusan strategis dalam peningkatan kualitas layanan dan kepuasan pengguna platform Udemy.

4. Kesimpulan

Kesimpulan yang dihasilkan dari penelitian pengelompokan popularitas kursus online udemy dengan menggunakan metode K-Means, maka terdapat beberapa kesimpulan dari penelitian:

1. Penelitian pengelompokan popularitas kursus online Udemy menggunakan metode K-Means menghasilkan empat kluster optimal berdasarkan analisis *elbow*, yang merepresentasikan berbagai tingkat popularitas. Kluster 1 dan 4 menunjukkan homogenitas yang tinggi dengan rata-rata jarak *centroid* masing-masing 0.70 dan 0.97, sedangkan kluster 3 menunjukkan keragaman terbesar dengan jarak rata-rata 6.09. Hal ini menunjukkan perbedaan signifikan dalam karakteristik data antar-kluster, yang memberikan wawasan mengenai variasi popularitas kursus.
2. Nilai *Davies-Bouldin Indeks* (DBI) sebesar 0.65171 dan *silhouette score* sebesar 0.6269 menunjukkan kualitas klasterisasi yang baik, dengan pemisahan yang jelas antar kluster. Kluster 1, dengan jumlah data terbesar 3009, dapat menjadi fokus strategi pemasaran untuk meningkatkan daya tarik. Kluster 3, meskipun hanya berisi 16 data, menunjukkan kursus dengan daya tarik tinggi, sementara kluster 4 yang kurang diminati dapat dievaluasi lebih lanjut untuk perbaikan.

Referensi

- [1] C. Álvarez-Álvarez, "Video technologies for professor-student interaction in online teaching," hal. 93–102, 2021, doi: 10.33422/3rd.ictle.2021.02.110.
- [2] C. Cortázar *et al.*, "Promoting critical thinking in an online, project-based course," *Comput. Human Behav.*, vol. 119, no. October 2020, 2021, doi: 10.1016/j.chb.2021.106705.
- [3] T. Nguyen *et al.*, "Insights Into Students' Experiences and Perceptions of Remote Learning Methods: From the COVID-19 Pandemic to Best Practice for the Future," *Front. Educ.*, vol. 6, no. April, hal. 1–9, 2021, doi: 10.3389/educ.2021.647986.
- [4] J. E. Nieuwoudt, "Investigating synchronous and asynchronous class attendance as predictors of academic success in online education," *Australas. J. Educ. Technol.*, vol. 36, no. 3, hal. 15–25, 2020, doi: 10.14742/AJET.5137.
- [5] J. Mao, "The Impact of Online Courses Towards Students In Autonomous Learning Based On New Media Technologies," *Rev. Educ. Theory*, vol. 3, no. 3, hal. 27–30, 2020.
- [6] M. Bullen dan D. P. Janes, "Learning : Strategies and issues," *Mak. Transit. to E_Learning Strateg. issues*, vol. 9, no. 3, 2007.
- [7] F. A. A. Sebayang, O. Saragih, dan H. Hestina, "Pemanfaatan Media Pembelajaran Online untuk Meningkatkan Pembelajaran Mandiri Di Masa New Normal," *Pelita Masy.*, vol. 2, no. 1, hal. 64–71, 2020, doi: 10.31289/pelitamasyarakat.v2i1.4222.
- [8] G. Anuradha dan G. A. Hema, "Learners Preference Towards Online Courses- a Study," *Glob. J. Res. Anal.*, no. December, hal. 43–45, 2021, doi: 10.36106/gjra/0206023.
- [9] N. B. Segara, A. Suprijono, dan K. G. Setyawan, "The Influence of E-Learning towards Students' Heutagogy Skills in Higher Education," *J. Pendidik. dan Pengajaran*, vol. 54, no. 2, hal. 286, 2021, doi: 10.23887/jpp.v54i2.33128.
- [10] T. S. Ramli *et al.*, "Pemanfaatan Teknologi Bagi Siswa Dalam Menyokong Peningkatan Ekonomi Digital dan Upaya Menghadapi Era Society 5 .0," *J. Ilmu Huk. Kenotariatan*, vol. 6, hal. 81–98, 2022.
- [11] H. Wijoyo *et al.*, *Strategi Pemasaran Umkm di Masa Pandemi Covid-19*, vol. 5, no. 1. 2022. doi: 10.24014/ekl.v5i1.14713.
- [12] Z. Nabila, A. Rahman Isnain, dan Z. Abidin, "Analisis Data Mining Untuk *Clustering* Kasus Covid-19 Di Provinsi Lampung Dengan Algoritma K-Means," *J. Teknol. dan Sist. Inf.*, vol. 2, no. 2, hal. 100, 2021, [Daring]. Tersedia pada: <http://jim.teknokrat.ac.id/index.php/JTSI>
- [13] I. Arfyanti, T. Bustomi, dan I. Haristyawan, "Implementasi Data Mining dengan Menerapkan Algoritma K-Means *Clustering* untuk Memberikan Rekomendasi Jurusan Kuliah Bagi

- Mahasiswa Baru,” *J. Media Inform. Budidarma*, vol. 8, no. 2, hal. 988, 2024, doi: 10.30865/mib.v8i2.7429.
- [14] T. H. Sardar dan Z. Ansari, “An analysis of MapReduce efficiency in document *clustering* using parallel K-means algorithm,” *Futur. Comput. Informatics J.*, vol. 3, no. 2, hal. 200–209, 2018, doi: 10.1016/j.fcij.2018.03.003.
- [15] M. M. Ghazal dan A. Hammad, “Application of knowledge discovery in database (KDD) techniques in cost overrun of construction projects,” *Int. J. Constr. Manag.*, vol. 22, no. 9, hal. 1632–1646, 2022, doi: 10.1080/15623599.2020.1738205.
- [16] P. Meilina, “Penerapan Data Mining dengan Metode Klasifikasi Menggunakan Decision Tree dan Regresi,” *J. Teknol. Univ. Muhammadiyah Jakarta*, vol. 7, no. 1, hal. 11–20, 2015, [Daring]. Tersedia pada: jurnal.ftumj.ac.id/index.php/jurtek
- [17] Sarmini, W. Ma, dan I. Tahyudin, “Sistem Pendukung Keputusan Berbasis K-Means untuk Evaluasi Keberhasilan Bisnis dan Nilai Perusahaan,” *J. Sist. Inf. Bisnis*, vol. 4, no. 4, hal. 363–374, 2024, doi: 10.21456/vol14iss4pp363-374.
- [18] F. Sembiring, O. Octaviana, dan S. Saepudin, “Implementasi Metode K-Means Dalam Pengklasteran Daerah Pungutan Liar Di Kabupaten Sukabumi (Studi Kasus : Dinas Kependudukan Dan Pencatatan Sipil),” *J. Tekno Insentif*, vol. 14, no. 1, hal. 40–47, 2020, doi: 10.36787/jti.v14i1.165.
- [19] F. Zahra, M. A. Ridla, dan N. Azise, “Implementasi Data Mining Menggunakan Algoritma Apriori Dalam Menentukan Persediaan Barang (Studi Kasus : Toko Sinar Harahap),” *JUSTIFY J. Sist. Inf. Ibrahmy*, vol. 3, no. 1, hal. 55–65, 2024, doi: 10.35316/justify.v3i1.5335.
- [20] P. J. Rousseeuw, “*Silhouettes*: A graphical aid to the interpretation and validation of *cluster* analysis,” *J. Comput. Appl. Math.*, vol. 20, no. C, hal. 53–65, 1987, doi: 10.1016/0377-0427(87)90125-7.
- [21] R. Sari, M. I. Arief, dan F. N. Yasir, “Optimasi *Clustering* Kualitas Air Menggunakan Principle Component Analysis,” vol. 1, no. 3, hal. 24–30, 2024.
- [22] C. Zai, “Implementasi Data Mining Sebagai Pengolahan Data,” *J. Portal Data*, vol. 2, no. 3, hal. 1–12, 2022, [Daring]. Tersedia pada: <http://portaldata.org/index.php/portaldata/article/view/107>
- [23] E. A. Saputra dan Y. Nataliani, “Analisis Pengelompokan Data Nilai Siswa untuk Menentukan Siswa Berprestasi Menggunakan Metode *Clustering* K-Means,” *J. Inf. Syst. Informatics*, vol. 3, no. 3, hal. 424–439, 2021, doi: 10.51519/journalisi.v3i3.164.

Inovasi Ekstraktor Sarang Madu Otomatis untuk Efisiensi Waktu dan Tenaga dalam Produksi Madu

Musliadi KH^{a1}

^aTeknik Informatika, Fakultas Komputer, Universitas Universal, Batam, Indonesia

¹musliadikh@gmail.com

Abstract

Madu merupakan cairan masnis yang dihasilkan dari nektar bunga dengan kandungan gizi yang sangat bermanfaat bagi kesehatan manusia. Madu juga telah banyak digunakan sebagai bahan pemanis alami pada makanan. Karena kandungan gizi dan manfaatnya yang begitu luas, membuat madu semakin dicari di pasar global. Meningkatnya permintaan tersebut, membuat produktivitas madu juga harus ditingkatkan tanpa mengurangi kualitasnya. Oleh sebab itu, diperlukan suatu inovasi untuk mengatasi permasalahan tersebut, agar para peternak lebah dapat menghasilkan madu yang lebih efisien serta higienis. Metode penelitian yang digunakan untuk membuat inovasi di bidang bahan pangan ini adalah Waterfall. Hasil dari penelitian ini berupa inovasi prototipe ekstraktor yang digunakan untuk mengekstraksi sarang madu secara otomatis. Setelah dilakukan serangkaian pengujian baik dari perangkat lunak dan prototipenya menghasilkan inovasi yang dapat berfungsi secara maksimal dalam mengekstrak sarang madu dari tiga pilihan kecepatan 50, 125, dan 255 berhasil dengan baik dan tidak mengalami kendala.

Keywords: Arduino; Eksraktor; Otomatisasi; Pemeras Madu; Waterfall

1. Introduction

Madu merupakan cairan manis dari nektar bunga atau bagian tanaman yang dihasilkan oleh lebah madu. Madu memiliki kandungan sumber energi dan vitamin yang bermanfaat bagi kesehatan. Madu juga sering digunakan sebagai pemanis alami pada berbagai makanan dan minuman [1]. Kandungan gizi yang tinggi serta sifat antibakteri yang dimilikinya, membuat madu menjadi komoditas yang sangat bernilai [2]. Pengambilan madu dari sarang lebah merupakan tahapan yang sangat penting pada proses produksi madu, di mana proses tersebut dilakukan dengan cara memeras sarang madu dengan sangat berhati-hati agar tidak merusak kualitasnya [3]. Pengambilan madu dengan proses tersebut, merupakan cara manual dan tradisional yang banyak digunakan oleh para peternak lebah di berbagai daerah, khususnya di kabupaten Majene. Metode tersebut memiliki beberapa kelemahan, seperti penggunaan tenaga yang besar, memerlukan waktu yang lumayan lama, serta hasil dari proses pemerasan tersebut tidak maksimal. Selain itu, proses pemerasan manual juga dapat meningkatkan terjadinya risiko kontaminasi akibat kontak langsung dengan tangan manusia atau alat yang tidak steril.

Karena madu memiliki kandungan gizi yang begitu bermanfaat bagi kesehatan manusia dan banyak digunakan sebagai bahan pemanis alami pada makanan, membuat madu semakin dicari oleh pasar global. Meningkatnya permintaan tersebut, para peternak lebah dituntut untuk meningkatkan produktivitas mereka tanpa mengorbankan kualitas produk. Oleh sebab itu, diperlukan suatu inovasi untuk mengatasi kelemahan tersebut, agar para peternak lebah dapat menghasilkan madu yang lebih efisien serta higienis.

Seiring perkembangan teknologi, penggunaan sistem berbasis arduino sudah mulai banyak diterapkan di berbagai bidang [4]. Seperti halnya yang pernah peneliti lakukan pada otomatisasi pemberian air minum unggas berbasis arduino yang mampu mengontrol air minum dengan akurat dan efisien dalam satuan waktu yang telah ditentukan [5]. Andi Farmadi (2022) melakukan perancangan sistem menggunakan arduino untuk otomatisasi pemberian nutrisi pada tanaman hidroponik dan mampu mengontrol nutrisi dan Ph air secara otomatis sesuai ketentuan yang diberikan [6]. Penelitian yang dilakukan oleh Márquez-Vera, M. A. (2023) pada bidang pendidikan, beliau membuat program pengontrolan otomatis menggunakan mikrokontroler pada pendidikan sarjana teknik bioteknologi [7]. Sedangkan Mario Hoernicke (2020), membuat percontohan rekayasa arsitektur secara otomatis pada pendekatan pabrik modular dan aplikasi yang hasilnya mampu memenuhi persyaratan pabrik berdasarkan pedoman Jerman [8]. Begitu juga yang dilakukan oleh Yuni Roza (2024) yang melakukan

pembuatan sistem pengawasan otomatis dengan arduino pada pengukuran debit air PDAM rumah tangga yang mampu menghitung jumlah pemakaian air dan tarif yang harus dibayarkan oleh penggunaannya [9]. Selain itu, Firdaus Latan Hoseir (2025) merancang sistem penuang air minum dengan otomatis yang diterapkan pada dispenser dan mampu menuangkan air secara tepat dan akurat sesuai ukuran gelas yang digunakan [10]. Perkembangan teknologi tersebut mendorong penerapan arduino di berbagai bidang dalam pembuatan sistem otomatisasi yang mampu meningkatkan efisiensi dan akurasi dalam pengelolaan sistem. Otomatisasi berbasis arduino dan mikrokontroler juga memberikan solusi yang lebih efektif, akurat, dan efisien dalam mengontrol serta mengelola berbagai sistem di berbagai bidang.

Selain penerapan arduino pada sistem otomatisasi di berbagai bidang, juga terdapat beberapa penelitian terdahulu yang memanfaatkan teknologi arduino pada pembuatan alat pemerasan. Seperti yang dilakukan oleh Hermon Sinon (2023) yang berhasil membuat inovasi pemeras sari pati sagu menggunakan arduino. Pada penelitian tersebut, menghasilkan alat yang dapat memeras sari pati sagu dengan otomatis berdasarkan pengaturan waktu yang diberikan [11]. Sedangkan yang dilakukan oleh Muhammad Fikri (2023), ia membuat mesin pamarut kelapa sekaligus dapat digunakan untuk memeras kelapa. Penelitian tersebut berhasil membuat terobosan baru dalam pengolahan kelapa menjadi kelapa parut dan langsung memerasnya menjadi santan [12]. Kedua penelitian ini menunjukkan bahwa arduino berperan dalam meningkatkan efisiensi dan inovasi dalam proses pengolahan bahan pangan.

Proses pemerasan madu yang masih bersifat manual cenderung kurang higienis, memerlukan tenaga kerja lebih, dan tidak efisien, sementara permintaan madu secara global terus meningkat. Beberapa penelitian sebelumnya telah berhasil menerapkan teknologi Arduino untuk otomatisasi pemrosesan bahan pangan, yang secara prinsip memiliki kesamaan mekanisme dengan proses ekstraksi madu, yakni melalui sistem pemerasan yang dikendalikan mikrokontroler. Oleh karena itu, penelitian ini mengembangkan inovasi ekstraktor madu otomatis berbasis mikrokontroler sebagai solusi untuk meningkatkan efisiensi proses panen, mengurangi potensi kehilangan hasil, serta menjaga kualitas dan kebersihan produk. Meskipun alat ini tidak secara langsung meningkatkan produksi madu oleh lebah, namun berkontribusi pada peningkatan produktivitas peternak melalui optimalisasi proses pascapanen.

2. Research Methods

Metode penelitian yang digunakan dalam penelitian ini terdiri dari beberapa tahapan utama dengan mengikuti alur dari metode *Waterfall*. Metode *Waterfall* merupakan teknik penelitian dalam siklus SDLC yang terdiri dari lima bagian penting yang tersusun seperti air terjun [13]. Kelima bagian tersebut diwakili oleh gambar Figure.1 di bawah ini.




Figure 1. Metode *Waterfall*

Bagian pertama adalah melakukan analisis kebutuhan yang akan digunakan pada perancangan inovasi ekstraktor sarang madu [14]. Selanjutnya melakukan desain menggunakan alat bantu desain seperti diagram aktivitas yang menjelaskan tentang bagaimana inovasi tersebut nantinya bekerja dan seperti apa modelnya [15]. Proses ketiga adalah pembuatan kode atau logika program menggunakan bahasa pemrograman Arduino C, yang diimplementasikan pada mikrokontroler Arduino. Program ini mengatur seluruh proses otomatisasi, seperti membaca input dari tombol atau sensor, mengendalikan motor

pemutar untuk mengekstraksi madu, serta menentukan durasi dan kecepatan ekstraksi sesuai dengan skenario yang dirancang pada tahap desain. Arduino menjalankan algoritma otomatisasi ini secara mandiri setelah perintah awal diberikan oleh pengguna, sehingga tidak diperlukan intervensi manual lanjutan dalam proses ekstraksi [16]. Setelah proses pembuatan program selesai dilakukan, tahap selanjutnya adalah melaksanakan pengujian pada logika program yang ditanamkan pada inovasi yang dibuat untuk mengetahui apakah inovasi tersebut dapat bekerja sesuai dengan yang diinginkan [17]. Tahap akhir yang perlu dilakukan pada metode *Waterfall* adalah melakukan pemeliharaan setelah inovasi ekstraktor sarang madu tersebut digunakan oleh para petani lebah [18]. Setelah semua tahapan pada metode *Waterfall* dilaksanakan hingga produk yang dikembangkan sampai dan digunakan oleh pengguna akhir dalam jangka waktu tertentu, proses analisa akan dilakukan untuk mengetahui perkembangan produk tersebut berdasarkan hasil umpan balik dai penggunanya, dalam hal ini adalah para peternak sarang lebah [19].

3. Result and Discussion

Berdasarkan urutan pada metode penelitian yang digunakan, terdapat serangkaian proses yang dilakukan dari awal hingga akhir, sehingga terciptanya suatu inovasi ekstraktor sarang madu otomatis yang dapat digunakan oleh komoditas lebah.

3.1. Requirements

Langkah awal yang dilakukan sebelum merancang inovasi ekstraktor sarang lebah, perlu dilakukan pengumpulan data dan informasi. Hasil dari pengumpulan data dan informasi tersebut digunakan sebagai acuan dasar dalam melakukan analisis kebutuhan sistem, untuk menentukan kebutuhan yang digunakan selama dalam masa perancangan. Berdasarkan hasil analisa pada sistem atau cara kerja yang saat ini digunakan oleh peternak lebah masih menggunakan teknik tradisional yang cara kerjanya diwakili oleh Figure 2. Sedangkan dari hasil analisa tersebut juga di diperoleh bahan-bahan yang akan digunakan pada proses perancangan sistem yang disajikan pada seperti pada Tabel 1 di bawah ini.

Table 1. Bahan dan Alat

Nama Bahan	Kegunaan
Arduino	Arduino Uno berfungsi sebagai unit pengendali utama yang mengeksekusi logika kontrol kecepatan motor berdasarkan input tombol, mengatur sinyal ke motor melalui driver L298N, dan mengelola sinyal dari sensor infra merah untuk memastikan kecepatan sesuai kondisi.
Motor DC	Alat ini digunakan sebagai untuk menggerakkan alat penggerak atau pemutar yang akan memeras sarang madu
Modul Driver Motor L298N	Digunakan untuk melakukan pengendalian pada pemutaran pemutar motor DC
Kabel Jumper	Alat ini digunaka untuk menghubungkan atau sebagai jembatan pada setiap komponen yang digunakan agar dapat saling mendukung satu sama lain
Remot Kontrol	Digunakan untuk mengaktifkan atau menonaktifkan
Adaptor 12 Volt	Fitur ini digunakan untuk melakukan perubahan tegangan AC menjadi DC
Infra merah	Infra merah digunakan untuk mengontrol Motor DC dalam keadaan tertentu sesuai ketentuan yang nanti digunakan




Figure 2. Analisa Sistem Berjalan

Figure 2 menunjukkan proses tradisional yang meliputi pengirisan sarang, pemerasan manual menggunakan kain atau tangan kosong, dan pengemasan ke dalam botol. Proses otomatisasi yang dirancang dalam penelitian ini mengadopsi alur kerja tersebut, dengan menggantikan proses pemerasan manual menjadi sistem otomatis berbasis Arduino, seperti dijelaskan pada Figure 3 dan 4. Sedangkan pengirisan dan pengemasan masih dilakukan secara manual.

3.2. Design

Setelah semua alat, bahan dan hasil analisa situasi atau cara kerja pemerasan madu dilapangan terkumpul, pada tahap selanjutnya adalah masuk pada proses desain. Pada proses desain, kita akan membuat desain bagaimana nantinya sistem inovasi yang dikembangkan berfungsi atau bekerja. Perancangan dilakukan menggunakan alat perancangan sistem seperti flowchart atau gambaran model prototipe seperti yang ditampilkan pada Figure 3 dan Figure 4 di bawah ini.




Figure 3. Flowchart sitem uang diusulkan

Flowchart di atas menjelaskan proses pemilihan kecepatan motor DC. Proses dimulai dengan memilih tombol kecepatan untuk melakukan ekstraktor sarang madu. Jika pengguna tidak memilih, sistem akan mengatur kecepatan motor DC pada level minimum. Jika pengguna memilih tombol ke-2, maka kecepatan akan meningkat ke level menengah. Sedangkan jika pengguna memilih tombol ke-3, maka kecepatan akan meningkat ke level maksimal. Setelah mencapai kecepatan maksimal atau jika pengguna menekan tombol "Off", maka proses ekstraktor selesai.




Figure 4. Sketsa model alat pemeras madu

3.3. Development

Setelah mengetahui bagaimana sistem yang dikembangkan bekerja, maka tahap selanjutnya yang dilakukan adalah proses development. Pada proses ini, peneliti melakukan perangkaian komponen menjadi satu kesatuan sehingga membentuk suatu alat yang saling terhubung satu sama lain seperti pada Figure 5 di bawah ini.




Figure 5. Sketsa model alat pemeras madu

Selain merangkai komponen menjadi satu kesatuan yang nantinya menjadi alat pengontrol dan pengendalian alat, pemasangan komponen juga dilakukan pada model prototipe yang nantinya menjadi wadah untuk menampung sarang lebah ketika ingin di ekstrak. Model prototipe yang dihasilkan dari tahap ini kurang lebih seperti pada Figure 6 di bawah ini.



Figure 6. Sketsa model alat pemeras madu

Berdasarkan hasil development yang dilakukan, selain melakukan perangkaian komponen-komponen yang ada, pada tahap ini juga dilakukan pembuatan prototipe yang disertai dengan pemasangan logika

untuk membuat inovasi tersebut bekerja secara otomatis pada sistem arduino yang digunakan. Hasil dari tahap ini akan membentuk suatu model inovasi ekstraktor sarang madu secara otomatis yang nantinya dapat digunakan oleh para peternak lebah dalam memproduksi madu tanpa harus bersentuhan langsung dengan tangan mereka untuk menghasilkan madu yang lebih higenis.

3.4. Testing

Tahap ke-4 dari siklus waterfall adalah melakukan pengujian terhadap perangkat lunak dan perangkat keras dari inovasi ekstraktor yang dikembangkan untuk mengetahui apakah logika yang dimasukkan kedalam sistem arduino sudah sesuai dengan kebutuhan. Pengujian perangkat lunak dilakukan dengan cara melakukan kompilasi pada sebuah program uji coba rancangan program dan mendapatkan hasil yang sempurna dalam proses kompilasi dengan status proses *done compile*. Sedangkan pengujian perangkat keras dilakukan dengan cara menggunakan prototipe tersebut dengan menjalankan satu persatu komponen yang ada dan menguji penggunaannya pada kecepatan tertentu untuk mengetahui hasil pengujian yang dilakukan seperti yang disajikan pada Table 1 di bawah ini.

Table 2. Pengujian Sistem

Tombol Kontrol	Kecepatan	Status Motor DC	Keterangan	Hasil Pengujian
1	50	On	On	100% Berhasil
2	125	On	On	100% Berhasil
3	255	On	On	100% Berhasil
Ok	0	Off	On	100% Berhasil

Pengujian tombol kontrol pada motor DC menunjukkan hasil yang konsisten dan berhasil 100% pada setiap skenario. Saat tombol kontrol ditekan dengan nilai kecepatan 50, 125, dan 255, motor DC dalam keadaan "On" dan berfungsi dengan baik. Selain itu, saat tombol "Ok" ditekan, kecepatan menjadi 0, motor tetap dalam kondisi "On", dan hasil pengujian tetap menunjukkan keberhasilan penuh. Keberhasilan 100% pada pengujian ini didefinisikan sebagai kemampuan sistem untuk merespons input tombol secara konsisten dan menjalankan motor DC pada kecepatan yang tepat tanpa kegagalan fungsi. Tidak ditemukan error atau delay selama pengujian sehingga sistem dianggap stabil dan siap digunakan oleh pengguna akhir.

3.5. Maintenance

Tahap akhir yang harus dilakukan pada siklus pengembangan sistem menggunakan metode waterfall ialah melakukan perawatan pada sistem yang berhasil dikembangkan dan sudah digunakan atau disebarkan pada pengguna akhir. Perawatan ini perlu dilakukan untuk mengetahui sejauh mana atau mencari kesalahan-kesalahan apa saja yang terjadi saat sistem tersebut digunakan dalam jangka waktu tertentu. Selama proses penggunaan, beberapa kendala ditemukan seperti motor DC yang mengalami panas berlebih setelah digunakan lebih dari 10 menit secara terus-menerus, dan respons input tombol yang lambat saat ditekan berulang kali. Solusi yang diterapkan adalah menambahkan heatsink pada motor dan menggunakan logika debounce pada pemrograman input tombol. Perawatan rutin juga meliputi pengecekan koneksi kabel jumper dan penggantian baterai adaptor jika daya mulai menurun.

4. Conclusion

Penelitian mengenai perancangan dan pembuatan alat pemeras sarang madu menggunakan penggerak motor DC berbasis mikrokontroler AT89S51 telah dilaksanakan sesuai dengan jadwal dan tempat penelitian ditetapkan, peneliti memperoleh hasil dengan berbagai macam data yang disimpulkan pada bab sebelumnya, sehingga dapat disimpulkan dari hasil penelitian yang telah diperoleh bahwa: Perencanaan dan produksi peralatan pemeras sarang madu memanfaatkan penggerak mesin DC berbasis mikrokontroler AT89S51 dengan memanfaatkan pembacaan sistem mikrokontroler arduino uno, motor *DC Shield* L298N sebagai motor driver dan inframerah sebagai akses kontrol arduino terhadap rancangan alat memiliki kecukupan dalam perancangan ini dengan dibantu berbagai bahan yang dapat dimanfaatkan penggerak mekanikal dan motor DC yang memiliki RPM rendah dan *Torque* tinggi. Implementasi hasil rancangan alat dilakukan dengan memberi tegangan input pada Arduino dan Motor *DC Shield* dan melakukan koneksi inframerah yang maksimal dengan rentang kontrol 3 meter, mampu memperoleh data yang cukup akurat sehingga dapat dibandingkan

dengan kondisi yang telah ditetapkan script program yang akan di input pada Arduino selaku pin acces control pada rancangan data yang di peroleh dan telah dilaksanakan dengan baik.

References

- [1] Fitri Aulia Sari, "Analisis Strategi Pemasaran Via Online Dalam Menarik Minat Beli Konsumen Produk Sarang Madu Menurut Perspektif Islam (Studi Kasus Sarang Madu Lampung)," *J. Tamwil J. Ekon. Islam*, vol. 8, no. 2, pp. 1–9, 2022.
- [2] B. Baihaqi, Z. I. Navia, H. Irawan, I. H. Sutrisno, and A. B. Suwardi, "PKM Kelompok Tani Maju Jaya Melalui Budidaya Lebah Madu Linot," *JMM (Jurnal Masy. Mandiri)*, vol. 7, no. 2, p. 1469, 2023, doi: 10.31764/jmm.v7i2.13707.
- [3] H. Hariska, I. Dewantara, and M. Muflihati, "Pengelolaan Madu Lalau Oleh Masyarakat Desa Nanga Lauk Kecamatan Embaloh Hilir Kabupaten Kapuas Hulu," *J. Hutan Lestari*, vol. 9, no. 1, p. 37, 2021, doi: 10.26418/jhl.v9i1.45702.
- [4] K. Musliadi and P. Yonky, "Perancangan Prototype Alat Penghapus Papan Tulis Otomatis Dengan Koneksi Bluetooth," *J. Digit. Ecosyst. Nat. Sustain.*, vol. 2, no. 2, pp. 67–72, 2022.
- [5] K. Musliadi, P. Yonky, and K. Kaharuddin, "PADrink-Poultry Automatic Drinking System Innovation Using Arduino," *J. Fasikom*, vol. 14, no. 2, pp. 420–427, 2024, doi: <https://doi.org/10.37859/jf.v14i2.7238>.
- [6] A. Farmadi and Muliadi, "Sistem Kontroling Dengan AI (Artificial Intelligence) Pada Pemberian Nutrisi," *Kumpul. J. Ilmu Komput.*, vol. 09, no. 03, pp. 501–513, 2022.
- [7] M. A. Márquez-Vera, M. Martínez-Quezada, R. Calderón-Suárez, A. Rodríguez, and R. M. Ortega-Mendoza, "Microcontrollers Programming For Control And Automation In Undergraduate Biotechnology Engineering Education," *Digit. Chem. Eng.*, vol. 9, no. September, p. 100122, 2023, doi: 10.1016/j.dche.2023.100122.
- [8] M. Hoernicke *et al.*, "Automation Architecture And Engineering For Modular Process Plants Approach And Industrial Pilot Application," *IFAC Pap.*, vol. 53, no. 2, pp. 8255–8260, 2020, doi: 10.1016/j.ifacol.2020.12.1966.
- [9] Y. Roza, K. Musliadi, Y. Pernando, I. Syafrinal, and Kaharuddin, "Rancang Bangun Monitoring Debit Air PDAM Rumah Tangga Berbasis Internet of Things (IoT)," *SKANIKA Sist. Komput. dan Tek. Inform.*, vol. 7, no. 2, pp. 214–223, 2024.
- [10] F. L. Hoseira and R. Apriando, "Prototype Penuangan Air Minum Otomatis pada Dispenser," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 13, no. 3, pp. 591–608, 2025.
- [11] H. Sinon, R. Soekarta, and T. H. I. Alam, "Rancang Bangun Alat Pemeras Sari Pati Sagu Otomatis Berbasis Mikrokontroler Dan Aplikasi Telegram," *FRAMEWORK*, vol. 02, no. 01, pp. 51–59, 2023.
- [12] M. Fikri and Z. Arifin, "Rancangan Arduino Uno Pada Mesin Pamarut Dan Pemeras Kelapa," *PROFISIENSI J. Progr. Stud. Tek. Ind.*, vol. 11, no. 2, pp. 115–123, 2023, doi: 10.33373/profis.v11i2.5851.
- [13] M. Putri Ayu Tarawati and Mukhsin, "Perancangan Sistem Informasi Keuangan Kelapa Sawit Berbasis Web," *J. Mhs. Apl. Teknol. Komput. dan Inf.*, vol. 5, no. 2, pp. 83–87, 2023.
- [14] N. K. E. Dianasari and I. G. N. A. Cahyadi Putra, "E-Banten sebagai Media Online Penjualan Banten di Bali," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 12, no. 1, p. 101, 2023, doi: 10.24843/jlk.2023.v12.i01.p12.
- [15] I. K. A. A. Putra and I. G. N. A. C. Putra, "Development of Augmented Reality Application for Canang Education Using Marker-Based Tracking Method," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 9, no. 3, p. 365, 2021, doi: 10.24843/jlk.2021.v09.i03.p07.
- [16] I. M. S. Vyasa and I. G. A. Wibawa, "Application of Augmented Reality Technology in the SDN

- 1 Sanur Building Recognition Application,” *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 10, no. 1, p. 45, 2021, doi: 10.24843/jlk.2021.v10.i01.p06.
- [17] F. Mahardika, M. I. Nurhadi, K. W. Asri, D. Nurvianti, and F. Faza, “Penerapan *Waterfall* Pada Sistem Kasir UMKM Desa Pakisputih Berbasis Android,” *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 13, no. 3, pp. 559–570, 2025.
- [18] Maspiati, Nasruddin, and K. Musliadi, “Sistem Informasi Pemesanan Baju Olahraga Berbasis Web Pada Konveksi ‘ Adher ’ Tammerodo Sendana Majene,” *Sinov. - Sci. Lit. Innov. Technol. J.*, vol. 01, no. 01, pp. 7–13, 2024.
- [19] A. Ismail and K. Musliadi, “Analisis Kebutuhan dan Perancangan Sistem Informasi Administrasi Kependudukan untuk Meningkatkan Efisiensi Layanan di Kelurahan Paropo,” *J. Digit. Ecosyst. Nat. Sustain.*, vol. 3, no. 2, pp. 58–63, 2023.

Klasterisasi Siswa Unggulan Menggunakan Algoritma K-Means di SMAS Sultan Agung Puger

Mas'ud Hermansyah^{a1}, Mujiono^{a2}, Akas Bagus Setiawan^{a3}, M. Faiz Firdausi^{b4}, Iqbal Sabilirrasyad^{b5}

^aJurusan Teknologi Informasi, Politeknik Negeri Jember
Jl. Mastrip, Sumbersari, Kec. Sumbersari, Kabupaten Jember, Jawa Timur, Indonesia

¹mas_udhermansyah@polije.ac.id

²mujiono@polije.ac.id

³akasbagus_s@polije.ac.id

^bFakultas Sains, Teknologi dan Industri, Institut Teknologi dan Sains Mandala
Jl. Sumatra, Sumbersari, Kec. Sumbersari, Kabupaten Jember, Jawa Timur, Indonesia

⁴faizfirdausi@itsm.ac.id

⁵iqbal@itsm.ac.id

Abstract

Improving the quality of education does not only depend on academic aspects, but also needs to consider non-academic aspects such as extracurricular participation, social attitudes, and student attendance. Therefore, an analysis method is needed that is able to group students comprehensively based on these various indicators. This study aims to group class X students of SMAS Sultan Agung Puger based on academic and non-academic aspects using the K-Means Clustering algorithm. The data used include academic grades, involvement in extracurricular activities, achievement, social attitude values, and the number of absences. The data processing process is carried out through the pre-processing stage, data transformation, application of the K-Means algorithm, and evaluation of clustering results using the Davies-Bouldin Index (DBI) method. The results of the analysis show that the formation of 4 clusters is the optimal structure with a DBI value of 1.1601. Each cluster has different characteristics that reflect the level of student achievement in various aspects. This clustering provides useful information for schools in designing student development strategies based on group needs. These findings support the application of a data-based approach in decision making in the field of education.

Keywords: K-Means, clustering, excellent students, Davies-Bouldin Index (DBI)

1. Introduction

Proses identifikasi siswa unggulan di jenjang pendidikan menengah umumnya masih terbatas pada penilaian aspek akademik saja. Hal ini menyebabkan potensi siswa yang memiliki keunggulan dalam bidang non-akademik seperti prestasi ekstrakurikuler, keterampilan sosial, dan keaktifan dalam organisasi sekolah menjadi terabaikan [1]. Permasalahan ini juga dirasakan di SMAS Sultan Agung Puger, terutama dalam mengelompokkan siswa baru dari tingkat SMP ke dalam kategori pembinaan dan pengembangan sesuai potensi mereka. Tanpa sistem yang akurat dalam memetakan potensi siswa sejak awal masuk, pihak sekolah kesulitan dalam merancang strategi pembelajaran dan kegiatan yang tepat guna mendukung perkembangan siswa secara menyeluruh.

Sebagai upaya untuk mengatasi masalah tersebut, diperlukan sebuah pendekatan sistematis berbasis teknologi yang mampu mengelompokkan siswa berdasarkan kinerja akademik dan non-akademik secara objektif. Salah satu solusi yang dapat diterapkan adalah pemanfaatan *data mining* melalui metode *clustering*, dengan algoritma *K-Means* sebagai salah satu teknik populer [2]. Algoritma ini dapat digunakan untuk mengelompokkan siswa baru berdasarkan data seperti rata-rata nilai akademik, prestasi lomba, keterlibatan dalam ekstrakurikuler, kehadiran, hingga sikap sosial. Dengan melakukan klasterisasi ini, sekolah dapat memperoleh pemetaan siswa yang lebih adil dan menyeluruh, serta menyesuaikan program pembinaan yang sesuai dengan profil masing-masing kelompok siswa [3].

Beberapa penelitian sebelumnya menunjukkan keberhasilan penggunaan algoritma *K-Means* dalam dunia pendidikan. Penelitian oleh [4] memanfaatkan algoritma *K-Means* untuk klasterisasi performa siswa dalam pembelajaran Bahasa Indonesia. Studi serupa pernah dilakukan oleh [5] dengan algoritma yang sama melakukan analisis keterkaitan prestasi akademik (IPK) dengan aktivitas mahasiswa dalam organisasi kemahasiswaan. Peneliti lain yang turut mengkaji topik ini adalah [6], berhasil memanfaatkan *K-Means* dalam menentukan kelompok siswa berprestasi di SMK berdasarkan kombinasi nilai rapor dan tingkat kehadiran. Kajian sebelumnya yang relevan juga dilakukan oleh [7] mengelompokkan siswa berdasarkan aspek nilai akademik dan aspek penilaian prakarya. Sebagaimana diteliti oleh [8] penggunaan algoritma *K-Means* untuk mengelompokkan siswa ekstrakurikuler aktif dalam menyusun strategi pembelajaran akademik yang tepat. Meskipun demikian, mayoritas penelitian tersebut masih terbatas pada aspek akademik atau hanya sebagian variabel non-akademik.

Studi-studi yang telah dilakukan memperlihatkan masih adanya ruang kosong dalam kajian penelitian, yaitu belum banyak pendekatan yang secara eksplisit menggabungkan dimensi akademik dan non-akademik dalam proses klasterisasi siswa di jenjang pendidikan menengah, khususnya pada konteks siswa baru yang belum memiliki rekam jejak panjang di sekolah tersebut. Selain itu, belum banyak penelitian yang secara spesifik memanfaatkan data siswa baru untuk proses pengelompokan awal sebagai landasan pembinaan jangka panjang. Hal ini membuka peluang bagi penelitian lebih lanjut yang dapat memperluas pendekatan analisis data pendidikan dengan basis multidimensi.

Data dalam penelitian ini diperoleh dari siswa baru yang masuk ke SMAS Sultan Agung Puger, yang berasal dari berbagai latar belakang sekolah SMP. Data yang dianalisis meliputi rata-rata nilai akademik, jumlah dan jenis kegiatan ekstrakurikuler yang diikuti, jumlah sertifikat kejuaraan, nilai sikap atau sosial yang diberikan guru, serta persentase kehadiran siswa. Klasterisasi data tersebut berpotensi menjadi sarana pendukung bagi sekolah dalam merumuskan strategi pembinaan yang berbasis pada data, serta menghindari pengambilan keputusan subjektif dalam menentukan siswa yang masuk kategori unggulan [9].

Berdasarkan latar belakang tersebut, tujuan dari penelitian ini adalah untuk mengembangkan metode klasterisasi siswa unggulan berdasarkan kinerja akademik dan non-akademik menggunakan algoritma *K-Means*, dengan memanfaatkan data siswa baru di SMAS Sultan Agung Puger. Penelitian ini diharapkan dapat memberikan kontribusi nyata dalam pengelolaan pendidikan yang lebih cerdas, adil, dan berbasis data. Hasil dari penelitian ini juga diharapkan dapat menjadi referensi dalam pengembangan sistem informasi manajemen siswa yang lebih adaptif dan proaktif dalam mendukung potensi siswa sejak awal mereka masuk ke jenjang SMA.

2. Reseach Methods

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis data berbasis teknik *data mining*, khususnya algoritma *K-Means Clustering*. Metode ini dipilih karena kemampuannya dalam mengelompokkan data berdasarkan kemiripan karakteristik multidimensional, sehingga memungkinkan identifikasi pola tersembunyi dalam data siswa yang berkaitan dengan aspek akademik dan non-akademik [2]. Algoritma *K-Means* dinilai efektif untuk menghasilkan klaster yang merepresentasikan kelompok siswa dengan karakteristik serupa, guna mendukung proses pengambilan keputusan yang lebih terarah dalam pengembangan potensi siswa [10].

Populasi dalam penelitian ini adalah seluruh peserta didik kelas 10 di SMAS Sultan Agung Puger pada tahun ajaran berjalan. Sampel yang digunakan berjumlah 70 siswa, yang merupakan siswa baru pada tingkat kelas 10. Teknik pengambilan sampel dilakukan secara purposif dengan pertimbangan bahwa siswa pada jenjang awal pendidikan menengah atas memiliki potensi beragam yang relevan untuk dianalisis, baik dari segi akademik maupun non-akademik, guna mendukung pengelompokan secara lebih komprehensif.

Tahapan penelitian meliputi proses pengumpulan data, praproses data, transformasi data, penerapan algoritma *K-Means*, dan analisis hasil klaster [3]. Data yang dikumpulkan meliputi rata-rata nilai akademik, jumlah keterlibatan dalam kegiatan ekstrakurikuler, jumlah prestasi akademik dan non-akademik, nilai sikap sosial, serta jumlah ketidakhadiran (absensi). Data yang telah terkumpul kemudian melalui tahap praproses yang mencakup pembersihan data dan normalisasi untuk memastikan keseragaman skala antar fitur. Selanjutnya, dilakukan penerapan algoritma *K-Means* untuk membentuk sejumlah klaster [11]. Secara umum, proses kerja algoritma *K-Means* terdiri dari beberapa tahapan utama sebagai berikut [12]:

1. Menentukan jumlah kluster (k):
Jumlah kluster (k) ditentukan terlebih dahulu sebelum proses klasterisasi dimulai.
2. Inisialisasi centroid awal:
Dipilih secara acak sebanyak k titik dari data sebagai pusat kluster awal (*centroid*).
3. Menghitung jarak setiap data ke *centroid*:
Setiap data akan dihitung jaraknya terhadap semua centroid menggunakan metrik jarak tertentu, umumnya *Euclidean Distance*:

$$d(x, c) = \sqrt{(x_1 - c_1)^2 + (x_2 - c_2)^2 + (x_3 - c_3)^2 + \dots + (x_n - c_n)^2} \quad (1)$$
 dimana :
 x adalah vektor data dan c adalah vektor *centroid*.
4. Pengelompokan data ke kluster terdekat:
Data akan dimasukkan ke dalam kluster dengan jarak terdekat ke *centroid*.
5. Menghitung ulang posisi *centroid*:
Centroid baru dihitung sebagai rata-rata dari semua data yang termasuk dalam masing-masing kluster.
6. Iterasi hingga *konvergen*:
Langkah 3–5 diulangi hingga posisi *centroid* tidak lagi berubah secara signifikan, atau sampai mencapai batas iterasi tertentu.

Setelah proses klasterisasi dilakukan menggunakan algoritma *K-Means*, tahap selanjutnya adalah mengevaluasi kualitas hasil kluster yang terbentuk. Evaluasi ini dilakukan dengan menggunakan metode *Davies-Bouldin Index* (DBI), yang merupakan salah satu metrik evaluasi internal untuk mengukur seberapa baik pemisahan dan kepadatan antar kluster [13]. DBI menghitung rasio antara jarak antar kluster (*inter-cluster distance*) dan jarak dalam kluster (*intra-cluster distance*) untuk setiap pasang kluster. Nilai DBI yang lebih kecil menunjukkan bahwa kluster yang terbentuk memiliki pemisahan yang lebih baik dan distribusi data dalam setiap kluster lebih kompak, sehingga hasil klasterisasi dianggap lebih optimal [14]. Secara matematis, DBI didefinisikan sebagai [15]:

$$DBI = \frac{1}{n} \sum_{i=1}^n \max_{j \neq i} \left(\frac{\sigma_i + \sigma_j}{d(c_i, c_j)} \right) \quad (2)$$

σ_i dan σ_j = rata-rata jarak dari setiap anggota kluster i dan j ke *centroid*-nya masing-masing

$d(c_i, c_j)$ = jarak antar *centroid* kluster i dan j

n = jumlah total kluster

Dalam konteks penelitian ini, DBI digunakan untuk menilai seberapa optimal pemilihan jumlah kluster (k) dalam proses *K-Means*. Nilai DBI yang lebih rendah menunjukkan bahwa pemilihan jumlah kluster tersebut menghasilkan struktur kluster yang lebih baik. Hasil pengujian ini kemudian menjadi dasar dalam pengambilan keputusan terhadap efektivitas klasterisasi yang telah dilakukan.

3. Result and Discussion

Bagian ini menyajikan hasil dari proses analisis data yang telah dilakukan menggunakan algoritma *K-Means*, serta pembahasan terhadap temuan yang diperoleh. Klasterisasi dilakukan dengan menerapkan metode *data mining* menggunakan data siswa yang mencerminkan aspek akademik dan non-akademik, dengan tujuan untuk mengelompokkan siswa ke dalam sejumlah kluster yang memiliki kesamaan karakteristik.

3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data siswa kelas 10 SMAS Sultan Agung Puger yang diperoleh melalui dokumentasi dari pihak sekolah, khususnya dari bidang kurikulum. Jumlah sampel yang digunakan sebanyak 70 siswa, yang merupakan peserta didik baru pada tahun ajaran berjalan. Data yang dikumpulkan mencakup hasil akademik dan non-akademik siswa dari laporan belajar ketika masih di SMP sebagai dasar untuk proses klasterisasi. Data ini kemudian diolah dan dianalisis menggunakan algoritma *K-Means Clustering* untuk mengelompokkan siswa ke dalam beberapa kluster berdasarkan kesamaan karakteristik, guna mengidentifikasi siswa unggulan yang berpotensi untuk pembinaan lebih lanjut.

Tabel 1. Pengumpulan Data

ID_Siswa	RNA	JE	PA	PNA	NS	AB
S001	82.48	0	1	0	Baik Sekali	7

S002	79.31	3	0	2	Baik	6
S003	83.24	2	1	1	Baik Sekali	6
S004	87.62	0	3	0	Baik Sekali	3
S005	78.83	3	0	2	Baik	18
...	...	...	...	...	...	...
S069	80.46	1	0	0	Baik	14
S070	74.06	2	0	5	Baik	13

Data yang digunakan mencakup berbagai atribut penilaian yang mewakili kedua aspek tersebut, di antaranya nilai rata-rata mata pelajaran inti seperti rata-rata nilai akademik (RNA) dan prestasi akademik (PA) serta data non-akademik berupa keterlibatan dalam kegiatan ekstrakurikuler (JK), perolehan prestasi di luar kelas (PNA), nilai sikap sosial (NS), dan catatan kehadiran siswa (AB).

3.2. Praproses Data

Pada tahap preprocessing, dilakukan serangkaian prosedur untuk membersihkan dan mempersiapkan data sebelum dianalisis lebih lanjut. Data yang telah dipilih akan melalui proses validasi serta penyesuaian format agar tetap konsisten. Selama proses ini, entri data yang tidak memiliki nilai atau informasi yang diperlukan akan dihapus dari dataset untuk memastikan kualitas dan integritas data yang digunakan. Data hasil praproses disajikan pada Tabel 2.

Tabel 2. Praproses Data

ID_Siswa	RNA	JE	PA	PNA	NS	AB
S001	82.48	0	1	0	Baik Sekali	7
S002	79.31	3	0	2	Baik	6
S003	83.24	2	1	1	Baik Sekali	6
S004	87.62	0	3	0	Baik Sekali	3
S005	78.83	3	0	2	Baik	18
...	...	...	...	...	...	...
S069	80.46	1	0	0	Baik	14
S070	74.06	2	0	5	Baik	13

Seluruh data siswa kelas 10 SMAS Sultan Agung Puger telah memenuhi syarat kelengkapan, sehingga proses dapat dilanjutkan ke tahap berikutnya dalam alur data mining.

3.3. Transformasi Data

Dalam penerapan metode *K-Means Clustering* pada data tersebut, langkah awal yang perlu dilakukan adalah transformasi data, terutama terhadap atribut yang bersifat nominal, seperti data nilai sikap. Data nominal tersebut harus dikonversi terlebih dahulu ke dalam bentuk numerik agar dapat diproses oleh algoritma. Pada tahap ini, setiap kategori nilai sikap diberi kode numerik yang mewakili masing-masing kategori. Sebagai contoh, nilai sikap "Baik" dapat dikodekan dengan angka 1 dan "Baik Sekali" dengan angka 2. Rincian pengkodean tersebut disajikan pada Tabel 3.

Tabel 3. Hasil Transformasi Data

ID_Siswa	RNA	JE	PA	PNA	NS	AB
S001	82.48	0	1	0	2	7
S002	79.31	3	0	2	1	6
S003	83.24	2	1	1	2	6
S004	87.62	0	3	0	2	3
S005	78.83	3	0	2	1	18
...	...	...	...	...	...	...
S069	80.46	1	0	0	1	14
S070	74.06	2	0	5	1	13

3.4. K-Means Clustering

Setelah data berada dalam format yang sesuai, dilakukan pengelompokan menggunakan algoritma *K-Means Clustering*, yang berfungsi untuk mengidentifikasi pola dan membentuk kelompok siswa berdasarkan kemiripan karakteristik. Dalam pelaksanaan proses pengolahan data ini, penulis memanfaatkan platform *Google Colab* yang berbasis cloud karena fleksibilitas dan kemampuannya dalam menjalankan kode secara interaktif. Bahasa pemrograman *Python* digunakan sebagai alat utama, mengingat kemampuannya yang luas dalam manipulasi data, penerapan algoritma *machine learning*, serta penyajian visualisasi hasil analisis secara efisien.

```
[ ] import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.cluster import KMeans
from sklearn.metrics import davies_bouldin_score
from sklearn.preprocessing import StandardScaler
from sklearn.decomposition import PCA
```

Gambar 1. Kode Pustaka *Python*

Pada penelitian ini, digunakan beberapa pustaka pendukung berbasis *Python* untuk melakukan analisis dan visualisasi data. Diantaranya seperti yang terlihat pada Gambar 1.

- a. *import pandas as pd*
Pustaka *pandas*, yang disingkat sebagai *pd*, digunakan untuk keperluan pengelolaan dan manipulasi data dalam format tabel (*DataFrame*), seperti membaca file berformat CSV, mengatur struktur kolom, melakukan penyaringan data, dan berbagai operasi lainnya.
- b. *import numpy as np*
Pustaka *numpy*, yang diimpor dengan penamaan *np*, digunakan untuk mendukung perhitungan matematis serta pengolahan array multidimensi secara efisien.
- c. *import matplotlib.pyplot as plt*
Modul *pyplot* dari pustaka *matplotlib* diimpor dan disingkat dengan nama *plt*. Modul ini digunakan untuk keperluan visualisasi data, seperti pembuatan grafik, diagram batang (*bar chart*), diagram pencar (*scatter plot*), dan jenis visualisasi lainnya.
- d. *import seaborn as sns*
Pustaka *seaborn*, yang diimpor dengan penamaan *sns*, digunakan untuk menghasilkan visualisasi statistik yang menarik dan informatif. Pustaka ini sering dimanfaatkan dalam pembuatan grafik seperti *heatmap*, *pairplot*, dan *boxplot* karena kemampuannya menyajikan data secara lebih estetik dan mudah dipahami.
- e. *from sklearn.cluster import K-Means*
Kelas *K-Means* dari pustaka *scikit-learn* digunakan untuk mengelompokkan data ke dalam beberapa kluster berdasarkan tingkat kesamaan antar fitur.
- f. *from sklearn.metrics import davies_bouldin_score*
Metrik *davies_bouldin_score* diimpor untuk mengevaluasi kualitas hasil klusterisasi. Nilai skor yang lebih rendah menunjukkan bahwa pemisahan antar kluster lebih optimal dan struktur kluster yang terbentuk lebih baik.
- g. *from sklearn.preprocessing import StandardScaler*
Mengimpor *StandardScaler* dari modul *sklearn.preprocessing* untuk menstandarisasi fitur data (*mean = 0, std = 1*), sehingga setiap fitur memiliki skala yang seragam sebelum proses clustering dilakukan.
- h. *from sklearn.decomposition import PCA*
Mengimpor *PCA (Principal Component Analysis)* dari *scikit-learn* untuk mengurangi jumlah dimensi data secara statistik, sambil tetap mempertahankan variansi. Metode ini sering diterapkan untuk visualisasi, seperti mengubah data dari dimensi 4D menjadi 2D agar dapat dipetakan.

```
[ ] from google.colab import files
uploaded = files.upload()

# Misalnya nama file: data_siswa.csv
df = pd.read_csv('data_siswa.csv')

# Tampilkan beberapa baris awal
df.head()
```

Gambar 2. Kode Membaca File

Kode program pada Gambar 2 merupakan proses mengimpor pustaka *files* dari *Google Colab* untuk memungkinkan mengunggah *file* dari komputer. Fungsi *files.upload()* akan memunculkan dialog untuk

memilih file yang ingin diunggah. Setelah file diunggah, program membaca file CSV (misalnya "data_siswa.csv") menggunakan fungsi `pd.read_csv()` dari pustaka *pandas* dan menyimpannya dalam variabel `df` sebagai *DataFrame*. Selanjutnya, menggunakan `df.head()`, program menampilkan beberapa baris pertama dari data yang telah dibaca, sehingga dapat melihat isi awal dari dataset tersebut.

```
[ ] # Hilangkan kolom non-numerik jika ada (misalnya nama)
    df_numeric = df.select_dtypes(include=[np.number])

    # Normalisasi fitur
    scaler = StandardScaler()
    X_scaled = scaler.fit_transform(df_numeric)
```

Gambar 3. Kode Menghilangkan Data Non-Numerik dan Melakukan Normalisasi Data

Gambar 3 memberikan informasi proses menghilangkan kolom yang tidak berisi angka, seperti kolom nama atau kategori, dengan menggunakan kode `df.select_dtypes(include=[np.number])`. Hal ini memastikan bahwa hanya data yang berupa angka yang diproses. Setelah itu, melakukan normalisasi pada data dengan menggunakan *StandardScaler*. Proses ini menghitung rata-rata dan *standar deviasi* dari data, lalu mengubah data sehingga memiliki rata-rata 0 dan *standar deviasi* 1. Tujuannya adalah agar data memiliki skala yang seragam dan siap digunakan dalam analisis lebih lanjut atau model pembelajaran mesin.

```
[ ] dbi_scores = []
    k_values = range(2, 8)

    for k in k_values:
        kmeans = KMeans(n_clusters=k, random_state=42, n_init='auto')
        labels = kmeans.fit_predict(X_scaled)
        dbi = davies_bouldin_score(X_scaled, labels)
        dbi_scores.append(dbi)

    # Visualisasi DBI
    plt.figure(figsize=(8, 5))
    plt.plot(k_values, dbi_scores, marker='o')
    plt.title('Davies-Bouldin Index vs Jumlah Kluster')
    plt.xlabel('Jumlah Kluster (k)')
    plt.ylabel('DBI Score')
    plt.grid(True)
    plt.show()
```

Gambar 4. Kode Pemrosesan DBI Score dan Visualisasi Data

Kode pada Gambar 4 digunakan untuk mengevaluasi kualitas kluster yang dihasilkan oleh algoritma *K-Means* dengan berbagai jumlah kluster (*k*) dan menghitung skor DBI untuk setiap nilai *k*. Proses dimulai dengan mendefinisikan sebuah daftar kosong `dbi_scores` untuk menyimpan nilai DBI yang dihitung. Kemudian, dilakukan iterasi untuk setiap nilai *k* dalam rentang 2 hingga 7 (`k_values = range(2, 8)`). Untuk setiap nilai *k*, model *K-Means* diinisialisasi dengan jumlah kluster *k*, kemudian dilakukan proses klasterisasi pada data yang sudah dinormalisasi (`X_scaled`). Setelah itu, label hasil klasterisasi dihitung, dan skor DBI dihitung dengan menggunakan fungsi `davies_bouldin_score`, yang mengukur sejauh mana kluster-kluster yang terbentuk terpisah dengan baik. Nilai DBI tersebut disimpan dalam daftar `dbi_scores`. Terakhir, menampilkan visualisasi yang menggambarkan hubungan antara jumlah kluster dan nilai DBI, dengan grafik yang menunjukkan seberapa baik pembagian kluster berdasarkan nilai DBI yang dihasilkan untuk setiap *k*.

```
[ ] # Menampilkan nilai DBI untuk tiap jumlah kluster
    print("Rincian Nilai Davies-Bouldin Index (DBI) untuk Setiap Jumlah Kluster:")
    for k, dbi in zip(k_values, dbi_scores):
        print(f"Jumlah Kluster = {k} | DBI = {dbi:.4f}")

    # Menentukan jumlah kluster optimal
    optimal_k = k_values[np.argmin(dbi_scores)]
    print(f"\nJumlah kluster optimal berdasarkan nilai DBI terendah: {optimal_k}")

    # Terapkan K-Means dengan jumlah kluster optimal
    kmeans = KMeans(n_clusters=optimal_k, random_state=42, n_init='auto')
    clusters = kmeans.fit_predict(X_scaled)


    # Tambahkan hasil kluster ke DataFrame
    df['Kluster'] = clusters
```

Gambar 5. Kode Menampilkan Nilai DBI dan Jumlah Kluster Optimal

Gambar 5 menampilkan proses rincian nilai DBI untuk setiap jumlah kluster yang diuji. Nilai DBI dihitung untuk setiap jumlah kluster dalam k_values , dan setiap nilai DBI ditampilkan dalam format yang rapi dengan dua kolom: jumlah kluster dan nilai DBI. Kemudian, kode menentukan jumlah kluster optimal berdasarkan nilai DBI terendah. Nilai DBI yang lebih rendah menunjukkan kluster yang lebih baik, dan $optimal_k$ diambil dari jumlah kluster yang memiliki nilai DBI terendah. Setelah itu, algoritma *K-Means* diterapkan dengan jumlah kluster optimal yang sudah ditemukan. *K-Means* ini digunakan untuk mengelompokkan data (X_scaled) ke dalam kluster-kluster yang ditentukan. Hasil kluster yang diperoleh disimpan dalam kolom baru bernama "Kluster" pada *DataFrame df*, sehingga setiap baris data akan terlabeli dengan kluster yang sesuai.

3.5. Analisis Hasil Kluster


Setelah data dimasukkan dan konfigurasi kluster dilakukan menggunakan algoritma *K-Means*, pengujian dengan *Davies-Bouldin Index* (DBI) dilakukan sebanyak enam kali iterasi. Dari hasil pengujian tersebut, diperoleh empat kluster sebagai nilai kluster optimal. Visualisasi hasil pengujian ditampilkan pada Gambar 6.



Gambar 6. Visualisasi Hasil Pengujian DBI

Hasil evaluasi menunjukkan bahwa ketika jumlah kluster adalah dua, nilai DBI yang dihasilkan sebesar 1.2396, sedangkan untuk tiga kluster nilainya meningkat menjadi 1.3093. Pada jumlah empat kluster, diperoleh nilai DBI paling rendah yaitu 1.1601. Selanjutnya, lima kluster menghasilkan nilai DBI sebesar 1.2079, enam kluster sebesar 1.3345, dan tujuh kluster mencatat nilai tertinggi yaitu 1.3807. Berdasarkan hasil tersebut, jumlah kluster sebanyak empat dipilih sebagai jumlah yang paling optimal karena memiliki nilai DBI terendah. Nilai ini menunjukkan bahwa kluster yang terbentuk memiliki tingkat kekompakan yang baik serta pemisahan yang jelas antar kluster.

Berdasarkan hasil pengelompokan menggunakan algoritma *K-Means* dengan jumlah kluster optimal sebanyak empat, distribusi jumlah anggota pada masing-masing kluster menunjukkan variasi yang cukup signifikan. Visualisasi distribusi jumlah anggota kluster tersaji pada Gambar 7.



Gambar 7. Visualisasi Distribusi Jumlah Anggota Kluster

Kluster 2 memiliki jumlah anggota terbanyak, yaitu sebanyak 36 siswa. Selanjutnya, kluster 1 terdiri dari 17 siswa, diikuti oleh kluster 4 dengan 10 siswa, dan kluster 3 merupakan kluster dengan jumlah anggota paling sedikit, yaitu hanya 7 siswa. Perbedaan jumlah anggota ini mencerminkan keragaman karakteristik siswa berdasarkan data akademik dan non-akademik yang dianalisis.

Hasil dari proses klusterisasi dengan algoritma *K-Means* menghasilkan nilai rata-rata (*mean*) dari setiap fitur dalam masing-masing kluster. Nilai rata-rata ini merepresentasikan karakteristik umum dari

atribut-atribut yang digunakan dalam proses pengelompokan, seperti rata-rata nilai akademik, tingkat keikutsertaan dalam kegiatan ekstrakurikuler, prestasi non-akademik, sikap sosial, dan jumlah absensi. Setiap klaster memiliki ciri khas tersendiri yang tercermin dari nilai rata-rata tiap fitur, sehingga dapat digunakan untuk memahami perbedaan atau kekhususan antar kelompok siswa.

Tahapan ini bertujuan untuk mengenali profil dari masing-masing klaster, misalnya untuk mengidentifikasi klaster mana yang menunjukkan performa akademik paling tinggi atau tingkat partisipasi ekstrakurikuler yang paling aktif. Selain itu, langkah ini juga mempermudah proses perbandingan antar klaster guna mengetahui keunggulan dan kekuatan relatif dari masing-masing kelompok. Hasil analisis tersebut dapat dimanfaatkan dalam proses pengambilan keputusan, seperti menentukan siswa yang termasuk dalam kategori unggul atau menyusun strategi pembelajaran dan pembinaan yang sesuai dengan kebutuhan dan potensi masing-masing klaster. Detail rata-rata setiap fitur untuk masing-masing klaster ditampilkan dalam Tabel 4.

Tabel 4. Detail Rata-Rata Setiap Fitur Klaster

Klaster	RNA	JE	PA	PNA	NS	AB
1	81.8170	2.5294	1.0000	2.1764	1.9411	11.0000
2	76.9336	1.9166	0.1111	1.2222	1.0833	16.8333
3	86.6457	0.8571	4.2857	1.0000	2.0000	4.7142
4	82.0540	0.3000	1.2000	0.3000	2.0000	7.7000

Berdasarkan hasil klasterisasi yang ditampilkan, terlihat bahwa masing-masing klaster memiliki profil yang unik, mencerminkan kondisi siswa dari sisi akademik dan non-akademik. Klaster 1, dengan rata-rata nilai akademik yang cukup tinggi (81.8170) dan keikutsertaan ekstrakurikuler yang aktif (2.5294 kegiatan), menunjukkan adanya keseimbangan antara pencapaian akademik dan pengembangan diri di luar kelas. Nilai prestasi non-akademik dan sikap sosial yang baik mengindikasikan bahwa siswa dalam klaster ini memiliki motivasi belajar yang tinggi sekaligus mampu berinteraksi sosial dengan baik. Namun, tingkat absensi yang cukup tinggi (11.0000) bisa menjadi indikator bahwa meskipun mereka aktif dan berprestasi, ada kemungkinan kelelahan atau beban aktivitas yang berlebihan sehingga berdampak pada kehadiran. Data siswa yang termasuk dalam klaster 1 dapat dilihat secara rinci pada Tabel 5.

Tabel 5. Data Anggota Klaster 1

No.	ID Siswa	RNA	JE	PA	PNA	NS	AB
1	S003	83.24	2	1	1	2	6
2	S017	81.57	3	1	2	2	18
3	S021	78.87	3	0	2	2	15
4	S027	81.88	2	1	2	2	2
5	S032	74.71	1	0	2	2	9
...	...	...	...	...	...	...	...
16	S057	84.06	2	2	2	2	12
17	S067	84.11	1	1	5	2	8

Klaster 2 menampilkan karakteristik siswa dengan nilai akademik dan non-akademik yang rendah, serta tingkat absensi yang paling tinggi (16.8333). Keterlibatan ekstrakurikuler yang sedang (1.9166) tidak cukup menstimulasi perkembangan siswa dalam aspek lainnya. Secara ilmiah, hal ini bisa dikaitkan dengan kurangnya keterlibatan siswa dalam kegiatan bermakna, yang dalam teori motivasi belajar, dapat menghambat pencapaian akademik dan sosial. Kelompok ini membutuhkan perhatian khusus, seperti bimbingan belajar dan program peningkatan motivasi. Informasi detail mengenai siswa yang termasuk ke dalam klaster 2 disajikan pada Tabel 6.

Tabel 6. Data Anggota Klaster 2

No.	ID Siswa	RNA	JE	PA	PNA	NS	AB
1	S002	79.31	3	0	2	1	6
2	S005	78.83	3	0	2	1	18
3	S006	78.83	3	0	1	1	13
4	S008	77.65	2	0	3	1	14

5	S010	77.68	3	0	3	1	13
...	...	...	...	...	...	...	...
35	S069	80.46	1	0	0	1	14
36	S070	74.06	2	0	5	1	13

Klaster 3 memiliki siswa dengan nilai akademik tertinggi (86.6457) dan prestasi akademik paling menonjol (4.2857), namun tingkat keikutsertaan dalam kegiatan ekstrakurikuler rendah (0.8571) dan sikap sosial yang tidak terlalu menonjol. Hal ini menunjukkan tipe siswa yang cenderung fokus pada studi, namun kurang dalam pengembangan aspek sosial dan emosional. Dalam pendekatan pendidikan holistik, kondisi ini bisa menjadi catatan penting untuk mendorong siswa agar lebih aktif dalam interaksi sosial dan kegiatan pengembangan diri lainnya, agar tidak hanya unggul secara kognitif, tetapi juga afektif. Rincian data siswa yang menjadi bagian dari klaster 3 dapat dilihat pada Tabel 7.

Tabel 7. Data Anggota Klaster 3

No.	ID Siswa	RNA	JE	PA	PNA	NS	AB
1	S004	87.62	0	3	0	2	3
2	S020	87.33	0	5	0	2	3
3	S030	84.26	2	5	1	2	3
4	S058	86.78	1	5	1	2	4
5	S060	85.02	1	4	2	2	8
6	S064	87.69	1	5	1	2	5
7	S066	87.82	1	3	2	2	7

Klaster 4 merupakan klaster dengan karakteristik menarik, yaitu memiliki nilai akademik yang tinggi (82.0540), sikap sosial yang paling tinggi (2.0000), dan absensi paling rendah (7.7000). Meskipun partisipasi ekstrakurikulernya rendah (0.300), siswa dalam klaster ini menunjukkan kedisiplinan dan kemampuan sosial yang sangat baik. Secara logis, kondisi ini bisa mencerminkan tipe siswa yang cenderung pendiam atau introver, tetapi memiliki kesadaran tinggi terhadap tanggung jawab pribadi. Dalam konteks pembinaan siswa unggulan, kelompok ini dapat difasilitasi untuk mengeksplorasi potensi melalui kegiatan yang sesuai dengan minat pribadi mereka. Data siswa yang masuk dalam klaster 4 ditampilkan secara rinci pada Tabel 8.

Tabel 8. Data Anggota Klaster 4

No.	ID Siswa	RNA	JE	PA	PNA	NS	AB
1	S001	82.48	0	1	0	2	7
2	S007	83.84	0	1	0	2	14
3	S009	82.71	0	2	0	2	2
4	S012	81.21	1	1	1	2	10
5	S042	85.29	1	2	1	2	3
6	S050	84.66	0	2	0	2	8
7	S053	84.88	0	3	0	2	11
8	S056	74.02	0	0	0	2	7
9	S059	79.64	0	0	0	2	12
10	S063	81.81	1	0	1	2	3

Secara keseluruhan, hasil analisis ini memberikan landasan ilmiah untuk menyusun strategi pembinaan dan intervensi pendidikan yang tepat sasaran. Dengan memahami karakteristik masing-masing klaster, pihak sekolah dapat mengambil kebijakan yang berbasis data untuk meningkatkan prestasi siswa secara merata, baik dari aspek akademik maupun non-akademik.

4. Conclusion

Penelitian ini berhasil mengelompokkan siswa kelas 10 SMAS Sultan Agung Puger ke dalam empat klaster menggunakan algoritma *K-Means Clustering*. Pemilihan jumlah klaster didasarkan pada evaluasi nilai *Davies-Bouldin Index* (DBI), di mana nilai terendah diperoleh pada jumlah klaster 4 (DBI = 1.1601), yang menunjukkan kualitas pemisahan klaster yang baik. Hasil klasterisasi menunjukkan

bahwa masing-masing kelompok memiliki ciri khas yang berbeda, seperti klaster dengan nilai akademik tinggi namun minim keterlibatan ekstrakurikuler, serta klaster dengan keunggulan menyeluruh pada aspek akademik, non-akademik, sikap sosial, dan kehadiran. Informasi ini dapat dimanfaatkan oleh pihak sekolah untuk menyusun strategi pembinaan yang lebih tepat sasaran, baik dalam pengembangan potensi siswa unggul maupun pemberian intervensi kepada siswa yang membutuhkan perhatian khusus.

References

- [1] A. Asmana, A. Y. Wijaya, and M. Martanto, "Clustering Data Calon Siswa Baru Menggunakan Metode K-Means Di Sekolah Menengah Kejuruan Wahidin Kota Cirebon," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 2, pp. 552–559, 2022, doi: 10.36040/jati.v6i2.5236.
- [2] B. Hasmaulina, M. Maryaningsih, and S. Sapri, "Penerapan Data Mining Untuk Membentuk Kelompok Belajar Menggunakan Metode Clustering Di SMK Negeri 3 Seluma," *JUKOMIKA (Jurnal Ilmu Komput. dan Inform.*, vol. 4, no. 2, pp. 57–71, 2022, doi: 10.54650/jukomika.v4i2.368.
- [3] P. S. Hasugia and J. R. Sagala, "Penerapan Data Mining Untuk Pengelompokan Siswa Berdasarkan Nilai Akademik dengan Algoritma K-Means," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 3, no. 3, pp. 262–268, 2022, [Online]. Available: <https://djournals.com/klik>
- [4] N. Bili, R. T. Abieno, and A. A. Pekuwali, "Penerapan Algoritma K-Means Clustering Untuk Pengelompokan Performa Siswa Pada Pembelajaran Bahasa Indonesia (Studi Kasus: SD Inpres Waingapu 3)," in *SATI: Sustainable Agricultural Technology Innovation*, 2024, pp. 523–537.
- [5] J. Irawan, A. N. Ryzkyani, R. A. Fauzan, A. J. Ramadhani, and M. Mutiah, "Analisis Hubungan Asosiasi Antara Indeks Prestasi Kumulatif (IPK) Dengan Kegiatan Organisasi Mahasiswa di Universitas Sultan Ageng Tirtayasa," *J. Teknol. Pangan dan Ilmu Pertan.*, vol. 1, no. 4, pp. 14–23, 2023, [Online]. Available: <https://doi.org/10.59581/jtpip-widyakarya.v1i4.1473>
- [6] E. A. Saputra and Y. Nataliani, "Analisis Pengelompokan Data Nilai Siswa untuk Menentukan Siswa Berprestasi Menggunakan Metode Clustering K-Means," *J. Inf. Syst. Informatics*, vol. 3, no. 3, pp. 424–439, 2021, doi: 10.51519/journalisi.v3i3.164.
- [7] A. Sulistiyawati and E. Supriyanto, "Implementasi Algoritma K-means Clustering dalam Penentuan Siswa Kelas Unggulan," *J. Tekno Kompak*, vol. 15, no. 2, pp. 25–36, 2021, doi: 10.33365/jtk.v15i2.1162.
- [8] M. A. Al Fauzie and A. J. Putra, "Clustering Data Menggunakan Metode K-Means untuk Rekomendasikan Pembelajaran Akademik bagi Siswa Aktif dalam Ekstrakurikuler," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 1, pp. 642–648, 2023, doi: 10.30865/klik.v4i1.1116.
- [9] S. Anwar, T. Suprpti, G. Dwilestari, and I. Ali, "Pengelompokan Hasil Belajar Siswa dengan Metode Clustering K-Means," *JURSISTEKNI (Jurnal Sist. Inf. dan Teknol. Informasi)*, vol. 4, no. 2, pp. 60–72, 2022.
- [10] Y. Elda, S. Defit, Y. Yunus, and R. Syaljumairi, "Klasterisasi Penempatan Siswa yang Optimal untuk Meningkatkan Nilai Rata-Rata Kelas Menggunakan K-Means," *J. Inf. dan Teknol.*, vol. 3, pp. 103–108, 2021, doi: 10.37034/jidt.v3i3.130.
- [11] R. A. Farissa, R. Mayasari, and Y. Umaidah, "Perbandingan Algoritma K-Means dan K-Medoids Untuk Pengelompokan Data Obat dengan Silhouette Coefficient di Puskesmas Karangsambung," *J. Appl. Informatics Comput.*, vol. 5, no. 2, pp. 109–116, 2021, doi: 10.30871/jaic.v5i1.3237.
- [12] F. Rizki Ani, R. Kurniawan, and T. Suprpti, "Penerapan Algoritma K-Means Clustering Untuk Perencanaan Persediaan Stok Sepatu Di Toko Diomclothing," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 6, pp. 3699–3707, 2024, doi: 10.36040/jati.v7i6.8233.

- [13] F. Fathurrahman, S. Harini, and R. Kusumawati, "Evaluasi Clustering K-Means Dan K-Medoid Pada Persebaran Covid-19 Di Indonesia Dengan Metode Davies-Bouldin Index (Dbi)," *J. Mnemon.*, vol. 6, no. 2, pp. 117–128, 2023, doi: 10.36040/mnemonic.v6i2.6642.
- [14] M. Hermansyah, R. A. Hamdan, F. Sidik, and A. Wibowo, "Klasterisasi Data Travel Umroh di Marketplace Umroh.com Menggunakan Metode K-Means," *J. Ilmu Komput.*, vol. 13, no. 2, p. 8, 2020, doi: 10.24843/jik.2020.v13.i02.p06.
- [15] L. Fimawahib and E. Rouza, "Penerapan K-Means Clustering pada Penentuan Jenis Pembelajaran di Universitas Pasir Pengaraian," *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 234, 2021, doi: 10.35314/isi.v6i2.2096.

This page is intentionally left blank.

Implementasi Artificial Neural Network Menggunakan Backpropagation Pada Prediksi Indeks Pembangunan Manusia

I Wayan Supriana^{a1}, Gede Dikka Widya Prana ^{a2}, I Ketut Adian Jayaditya^{a3}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Jl. Raya Kampus Unud Bukit Jimbaran, Badung, Indonesia

¹wayan.supriana@unud.ac.id

²dikkawidyapranagede@gmail.com

³adianjay11@gmail.com

Abstrak

Indeks Pembangunan Manusia (IPM) merupakan salah satu alat ukur yang penting bagi suatu daerah. Nilai IPM menunjukkan indikator yang digunakan untuk mengukur tingkat keberhasilan suatu daerah dalam membangun kualitas hidup manusia. IPM mencerminkan kemampuan masyarakat di daerah tersebut untuk mengakses tiga dimensi dasar pembangunan manusia, yaitu kesehatan, pendidikan, dan pendapatan. Nilai IPM ini dapat digunakan oleh pemangku kebijakan untuk merancang kebijakan pendanaan yang lebih baik ke daerah dengan IPM tertentu. Pada penelitian ini mengimplementasikan artificial neural network (ANN) dengan metode backpropagation untuk memprediksi nilai IPM di seluruh kabupaten di Indonesia guna mempermudah prediksi kualitas manusia. Hyperparameter tuning juga dilakukan untuk menentukan arsitektur jaringan optimal pada model ANN yang dibangun. Berdasarkan penelitian yang sudah dilakukan arsitektur optimal yang didapat dengan komposisi 2 hidden layer, setiap hidden memiliki neuron sebanyak 3 dan 4, learning rate sebesar 0.0001, fungsi aktivasi ReLU, dan epoch berjumlah 200. Hyperparameter optimal tersebut menghasilkan MSE sebesar 0.0005849390439398957.

Keywords: Indeks Pembangunan Manusia, Backpropagation, ANN, Prediksi, Kualitas Hidup Manusia

1. Pendahuluan

Indeks Pembangunan Manusia (IPM) atau *Human Development Index (HDI)* merupakan salah satu alat penting untuk mengukur kesejahteraan penduduk suatu negara atau daerah [1]. Indeks Pembangunan Manusia dibentuk oleh tiga aspek dasar, yaitu kesehatan, pendidikan, dan pendapatan. Ketiga aspek ini mencerminkan tingkat pembangunan manusia di suatu wilayah melalui pengukuran kondisi penduduk yang sehat, berumur panjang, teredukasi, memiliki keterampilan, dan memiliki pendapatan yang memungkinkan hidup layak [2]. Pada masing-masing aspek tersebut terdapat indikatornya, yaitu Angka Harapan Hidup, Harapan Lama Sekolah, Rata-Rata Lama Sekolah, dan Pengeluaran per Kapita [3]. Harapan Lama Sekolah dan Rata-Rata Lama Sekolah merupakan indikator pendidikan, mencerminkan tingkat melek huruf dan tingkat pendidikan dalam suatu populasi. Sedangkan, Angka Harapan Hidup mencerminkan Kesehatan masyarakat, menunjukkan berapa lama penduduk diharapkan dapat hidup [4]. IPM menjadi hal yang sangat penting untuk melihat perkembangan dari sisi manusia dan merupakan indikator pemerintah untuk merancang kebijakan pendanaan terkait pelayanan umum dan kesejahteraan masyarakat, sehingga dapat merealisasikan perencanaan pembangunan yang tepat sasaran dan berkelanjutan [5].


Beberapa penelitian telah dilakukan untuk memprediksi angka Indeks Pembangunan Manusia menggunakan berbagai metode *machine learning*. Penelitian yang dilakukan Atmojo et al. (2024) untuk memprediksi IPM dengan membandingkan metode KNN, Random Forest, AdaBoost, dan SVM, dengan SVM menunjukkan hasil terbaik. SVM menghasilkan MSE terendah pada data pengujian sebesar 4.419, yang menunjukkan prediksi paling akurat [1]. Penelitian lain oleh Posangi et al. (2023),

menggunakan Random Forest untuk memprediksi IPM. Penelitian ini memperoleh akurasi 80%, dengan fitur pengeluaran per kapita, harapan lama sekolah, angka harapan hidup, dan rata-rata lama sekolah sebagai variabel utama [6]. Ampang et al. (2023) melakukan penelitian untuk memprediksi angka IPM menggunakan metode Double Exponential Smoothing (DES). Hasil yang diperoleh dari penelitian tersebut ialah MAPE (Mean Absolute Percentage Error) yang diraih sebesar 0,13% untuk indeks Kesehatan, 0,55% untuk indeks pendidikan, dan 0,45% untuk indeks Daya Beli [7]. Amiroh dan Avianto (2023) juga pernah melakukan penelitian untuk memprediksi IPM menggunakan metode backpropagation. Pada penelitian yang dilakukan diperoleh MSE terbaik sebesar 2,0501 [8]. Pada penelitian yang sudah dilakukan, metode backpropagation merupakan metode terbaik dalam memprediksi IPM. Namun, beberapa penelitian tersebut terbatas pada dataset yang relatif sedikit dan memiliki ruang untuk perbaikan dalam akurasi prediksi.

Berdasarkan penelitian-penelitian sebelumnya, penulis mengusulkan penggunaan Artificial Neural Network (ANN) berbasis backpropagation dengan data lebih besar dari tahun 2010 hingga 2023 dengan fitur pengeluaran per kapita, harapan lama sekolah, angka harapan hidup, dan rata-rata lama sekolah. Data tersebut mencakup seluruh kabupaten di Indonesia dan digunakan untuk menangkap hubungan yang lebih kompleks serta menghasilkan prediksi yang lebih akurat.

2. Metode Penelitian

Penelitian ini menggunakan algoritma Artificial Neural Network berbasis backpropagation untuk memprediksi angka Indeks Pembangunan Manusia (IPM) di Indonesia. Pada penelitian ini, penulis menggunakan beberapa tahapan penelitian yang ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

Alur penelitian pada Gambar 1 dimulai dengan tahap studi literatur untuk menggali dan mendefinisikan penelitian pendahuluan yang terkait. Tahapan selanjutnya adalah pengumpulan dan memvisualisasi data dalam mengidentifikasi kualitas dan kecukupan dataset. Tahap dilanjutkan dengan preprocessing data yaitu memperbaiki data noise, melakukan reduksi fitur, agregrasi data serta validasi data. Tahap berikutnya adalah modelling yaitu membangun model prediksi menggunakan ANN. Dan tahap akhir ada evaluasi model dengan menentukan parameter input dan arsitektur jaringan ANN terbaik.

2.1. Studi Literatur

Pada tahapan ini dilakukan kajian terhadap penelitian-penelitian sebelumnya yang relevan dengan konsep Indeks Pembangunan Manusia serta metode prediksi yang telah diterapkan. Studi ini bertujuan untuk memperoleh pemahaman yang mendalam mengenai teori, model, atau pendekatan yang digunakan dalam penelitian serupa. Selain itu, studi literatur ini berperan penting dalam mengidentifikasi kelebihan dan kekurangan metode yang telah ada sehingga dapat dijadikan dasar untuk mengadaptasi atau mengembangkan metode yang lebih baik.

2.2. Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Indonesia untuk periode tahun 2010 hingga 2023. Jumlah data sebanyak 7195 yang terdiri dari atribut provinsi, kabupaten, tahun, indek pembangunan manusia, angka harapan hidup, rata-rata lama sekolah,

harapan lama sekolah, dan pengeluaran per kapita. Data ini merupakan data dari semua kabupaten/kota yang terdapat di Indonesia. Data ini akan digunakan sebagai input dalam proses pelatihan dan pengujian ANN berbasis algoritma backpropagation.

	provinsi	kabupaten	tahun	indeks_pembangunan_manusia	angka_harapan_hidup	rerata_lama_sekolah	harapan_lama_sekolah	pengeluaran_per_kapita
0	ACEH	Simeulue	2023	68.06	65.655	9.760	14.28	7686.0
1	ACEH	Aceh Singkil	2023	70.14	67.830	8.655	14.35	9374.0
2	ACEH	Aceh Selatan	2023	68.44	64.860	8.840	14.70	8712.0
3	ACEH	Aceh Tenggara	2023	71.05	68.700	10.100	14.27	8566.0
4	ACEH	Aceh Timur	2023	69.32	69.120	8.490	13.07	9436.0
...	...	...	...	...	...	...	...	...
7191	PAPUA	Puncak	2010	33.44	64.915	0.710	2.84	4752.0
7192	PAPUA	Dogiyai	2010	47.48	64.160	3.360	7.85	4769.0
7193	PAPUA	Intan Jaya	2010	NaN	NaN	NaN	4.12	NaN
7194	PAPUA	Deiyai	2010	NaN	NaN	NaN	9.06	NaN
7195	PAPUA	Kota Jayapura	2010	76.69	69.835	10.655	13.64	13903.0

Gambar 1. Dataset Penelitian

2.3. Data Preprocessing

Pada tahap data preprocessing, dilakukan serangkaian langkah untuk memastikan data siap digunakan dalam pengembangan model prediksi.

1. Penanganan data *missing value* (data kosong)

Penanganan data missing value dilakukan dengan teknik imputasi yaitu mengganti nilai/data yang hilang (missing value; NaN; Blank) dengan nilai pengganti. Mekanisme perbaikan data yang hilang dengan teknik: (a) Missing Completely at Random (MCAR), ketika setiap sel memiliki kemungkinan hilang yang tetap dan sama. Akibatnya, nilai prediksi besar dan kecil menjadi hilang. (b) Missing at Random (MAR), ketika probabilitas yang hilang tergantung pada nilai-nilai yang diamati. (c) Missing Not at Random (MNAR), ketika kemungkinan hilang tergantung pada data yang tidak teramati atau hilang. Teknik imputasi dilakukan dengan cara menggantikan data yang hilang dengan estimasi statistik dari nilai yang hilang tersebut. Tujuan dari teknik ini adalah untuk menghasilkan dataset yang lengkap yang dapat digunakan dalam proses pelatihan model. Proses ini membutuhkan pustaka fitur, yang dapat menyederhanakan proses pengisian nilai yang hilang.

2. Transformasi Data Kategori

Encoding pada fitur kategorikal menggunakan *Label Encoding* juga dilakukan agar fitur tersebut dapat dianalisis untuk tahap selanjutnya. Kemudian, Analisis korelasi dilakukan untuk menghitung hubungan antar fitur, sehingga hanya variabel yang relevan terhadap target prediksi yang digunakan. Seleksi fitur dilakukan berdasarkan hasil analisis korelasi dan relevansi terhadap target, diikuti dengan deteksi dan penanganan outlier.

3. Data dipisahkan menjadi fitur (*variabel independen*) dan target (*variabel dependen*), lalu dilakukan normalisasi agar fitur-fitur tersebut memiliki skala nilai yang sama sehingga model prediksi dapat bekerja dengan stabil dan efisien.

2.4. Modelling

Pada tahap implementasi, dilakukan penerapan model ANN dengan model pembelajaran dengan algoritma backpropagation untuk memprediksi nilai IPM. Proses ini melibatkan sekenario dengan berbagai kombinasi hyperparameter untuk mendapatkan arsitektur model yang optimal. Hyperparameter yang diuji meliputi jumlah hidden layers, jumlah neuron di setiap hidden layers, fungsi aktivasi, nilai learning rate, dan jumlah epoch pelatihan. Tahapan implementasi ini dilakukan secara iteratif, di mana setiap kombinasi hyperparameter diuji untuk memahami pengaruhnya terhadap performa model. Berikut merupakan tahapan-tahapan dari proses pelatihan menggunakan ANN berbasis *backpropagation* [8].

1. Pemberian nilai awal pada bobot dilakukan secara acak dengan memerhatikan batasan learning rate dan epoch yang sesuai.
2. Setiap data yang ada dilakukan proses langkah ke-3 hingga 8

Proses Feed Forward

3. Inputan akan menerima isyarat masukan x_i yang akan dilanjutkan ke node-node pada hidden layers.

4. Node hidden layers (z) akan dijumlahkan bobot sinyal inputnya. Pada proses ini parameter n merupakan banyaknya iterasi yang dilakukan.

$$Z_{in_{jk}} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

sementara fungsi aktivasi dihitung dengan:

$$Z_j = f(Z_{in_j}) \quad (2)$$

5. Setiap node keluaran dari hidden layers diteruskan ke output layers yang akan dijumlahkan bobot dengan syarat masukan, dengan persamaan berikut:

$$Y_{in_k} = w_{0j} + \sum_{i=1}^n z_j v_{jk} \quad (3)$$

fungsi aktivasi dihitung dengan:

$$Y_j = f(Y_{in_k}) \quad (4)$$

Proses Backpropagation

6. Pada tiap node output mendapatkan suatu pola training dari node input yang sudah ada. Perhitungan error dilakukan dengan persamaan sebagai berikut:

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (5)$$

Sementara perhitungan dan koreksi bobot serta bias, menggunakan persamaan berikut:

$$\Delta w_{jk} = a \delta_k x_j \quad (6)$$

$$\Delta w_{0k} = a \delta_k \quad (7)$$

7. Masing-masing node hidden akan menjumlahkan input delta (dari unit yang berada pada lapisan atasnya)

$$\delta_{in_j} = \sum_{i=1}^m \delta_k w_{jk} \quad (8)$$

pada perhitungan node hidden, faktor δ menggunakan persamaan berikut:

$$\delta_j = \delta_{in_j} f'(Z_{in_{jk}}) = \delta_{in_j} f'(Z_j) \quad (9)$$

selanjutnya dilakukan perubahan bobot dan nilai biasnya, dengan persamaan berikut:

$$\Delta v_{ij} = a \delta_j x_i \quad (10)$$

$$\Delta v_{0j} = a \delta_j \quad (11)$$

Proses Pembobotan

8. Menghitung semua bobot dan bias yang berubah ke node output

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (12)$$

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (13)$$

Bobot yang sudah berubah lalu diteruskan ke hidden layers

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (14)$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (15)$$

Hasil perhitungan dari hidden layer dan output layer akan dimasukkan ke suatu fungsi yang bernama fungsi aktivasi. Fungsi aktivasi adalah elemen penting dalam ANN, bertugas memberikan kemampuan non-linear kepada jaringan dan memungkinkan pemodelan hubungan yang kompleks dalam data. Pada penelitian ini menggunakan tiga fungsi aktivasi yaitu ReLU, Sigmoid, dan Tanh. Fungsi ini juga memerlukan turunan untuk memperbarui bobot jaringan.

1. ReLU

ReLU adalah fungsi aktivasi sederhana yang didefinisikan sebagai berikut.

$$f(x) = \max(0, x) \quad (16)$$

Nilai Output adalah nol untuk nilai input negatif dan sama dengan input untuk nilai input positif.

Turunannya didefinisikan sebagai berikut.

$$f'(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (17)$$

Turunan ini sangat efisien untuk perhitungan. Namun, jika neuron menghasilkan nilai nol secara terus-menerus (*dying ReLU*), gradien menjadi nol, sehingga bobot tidak diperbarui selama pelatihan.

2. Sigmoid

Fungsi sigmoid memiliki bentuk S (*S-shaped curve*) dan didefinisikan sebagai berikut.

$$f(x) = \frac{1}{1+e^{-x}} \quad (18)$$

Fungsi ini mengubah nilai input menjadi rentang (0, 1), yang cocok untuk tugas biner atau menghitung probabilitas. Turunannya didefinisikan sebagai berikut.

$$f'(x) = f(x)(1 - f(x)) \quad (19)$$

Karena $f(x)$ selalu berada di antara 0 dan 1, nilai turunan sigmoid menjadi sangat kecil pada input yang ekstrem (sangat besar atau kecil). Hal ini menyebabkan masalah *vanishing gradient*.

3. Tanh

Fungsi Tanh (*tangens* hiperbolik) didefinisikan sebagai berikut.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (20)$$

Output Tanh berada dalam rentang (-1, 1), sehingga lebih informatif dibandingkan sigmoid karena mencakup nilai negatif dan positif. Turunannya didefinisikan sebagai berikut.

$$f'(x) = 1 - f(x)^2 \quad (21)$$

Fungsi Tanh juga rentan terhadap masalah vanishing gradient pada input dengan nilai besar atau kecil.

2.5. Evaluasi

Model yang telah dibangun akan dievaluasi menggunakan metrik Mean Squared Error (MSE) untuk mengukur seberapa baik model memprediksi angka Indeks Pembangunan Manusia. MSE menghitung rata-rata selisih kuadrat antara nilai sebenarnya dan nilai prediksi, di mana semakin kecil nilai MSE, semakin baik kinerja model. Hasil evaluasi ini akan digunakan untuk menilai performa model dan menentukan apakah diperlukan perbaikan lebih lanjut.


3. Hasil dan Pembahasan

3.1. Hasil Training.

Proses pelatihan untuk memprediksi nilai Indeks Pembangunan Manusia (IPM) pada data training telah dilakukan beberapa kali menggunakan hyperparameter dari arsitektur yang berbeda-beda. Percobaan dilakukan dengan menggunakan semua kombinasi yang mungkin dari hidden layer sebanyak 1 dan 2; neuron pada hidden layer sebanyak 2, 3, dan 4; learning rate sebesar 0.0001, 0.001; epoch sebesar 100 dan 200. Pada Tabel 1 menunjukkan *hyperparameter* arsitektur optimal yang didapatkan setelah melakukan proses *hyperparameter tuning*.

Tabel 1. <i>Hyperparameter Tuning</i>	
<i>Hyperparameter</i>	Nilai
Hidden Layer	2
Hidden Neuron	(3, 4)
Learning Rate	0.0001
Fungsi Aktivasi	ReLU
Epochs	200
MSE	0.0005849390439398957


Adapun grafik MSE pada setiap iterasi untuk kombinasi nilai parameter terbaik, sebagai berikut.



Gambar 3. Grafik Elbow Method

3.2. Hasil Testing

Pengujian dilakukan menggunakan data *testing* yang berjumlah 628 data. Berikut pada Gambar 3 dapat dilihat grafik perbandingan antara hasil prediksi dan aktual. Data tersebut dipecah menjadi 2 bagian agar dapat melihat grafik lebih baik.



Gambar 3. Grafik perbedaan nilai prediksi dan actual

Adapun grafik error (selisih antara prediksi dan aktual) pada setiap data *testing* dapat dilihat pada Gambar 4.



Gambar 4. Grafik error pada setiap data

Model yang telah berhasil dibangun akan diintegrasikan dengan antarmuka berbasis web, sehingga memudahkan untuk melakukan prediksi IPM. Tampilan dari web yang dibangun dapat dilihat pada Gambar 5.



Selamat datang di Aplikasi Prediksi Angka Indeks Pembangunan Manusia

Masukkan data berikut untuk melakukan prediksi IPM.

Angka Harapan Hidup
67.03

Rerata Lama Sekolah
8.65

Harapan Lama Sekolah
14.35

Pengeluaran per Kapita
9374.00

Prediksi

IPM yang diprediksi sebesar 71.501343338298

Kategori IPM Tinggi

Gambar 5. Tampilan antarmuka *website*

3. Kesimpulan

Model ANN berbasis algoritma backpropagation berhasil dirancang untuk memprediksi IPM di Indonesia. Proses perancangan meliputi pengumpulan data sekunder dari BPS, preprocessing data (termasuk penghapusan data kosong, seleksi fitur, deteksi outlier, normalisasi, dan pembagian data menjadi set pelatihan dan pengujian), serta hyperparameter tuning untuk menentukan arsitektur jaringan terbaik, seperti jumlah hidden layer, jumlah neuron pada hidden layer, learning rate, dan jumlah epoch. Model yang dirancang juga diintegrasikan dengan antarmuka berbasis web untuk memudahkan pengguna dalam melakukan prediksi IPM. Evaluasi performa model menggunakan metrik MSE menunjukkan bahwa model mampu memprediksi IPM dengan akurasi yang sangat baik. Arsitektur jaringan ANN terbaik adalah 2 hidden layer, 3 dan 4 neuron, fungsi aktivasi ReLU, learning rate 0.0001, dan 200 epoch, menghasilkan MSE sebesar 0.0005849390439398957.

References

- [1] F. W. Atmojo, C. I. Nurlita, and N. Nurchim, "ANALISIS PEMANFAATAN MACHINE LEARNING GUNA PREDIKSI INDEKS PEMBANGUNAN MANUSIA," *Simtek : jurnal sistem informasi dan teknik komputer*, vol. 9, no. 2, pp. 89–96, Oct. 2024, doi: 10.51876/simtek.v9i2.390.
- [2] A. M. Kahar, "Analisis Angka Harapan Lama Sekolah di Indonesia Timur Menggunakan Weighted Least Squares Regression," *Jurnal Matematika "MANTIK,"* vol. 4, no. 1, pp. 32–41, May 2018, doi: 10.15642/mantik.2018.4.1.32-41.
- [3] M. Y. Alang, K. Suryowati, and F. Astuti, "PREDIKSI INDEKS PEMBANGUNAN MANUSIA PADA KABUPATEN/KOTA DI PROVINSI NUSA TENGGARA TIMUR MENGGUNAKAN BACKPROPAGATION DENGAN KOMBINASI LEARNING RATE DAN EPOCH," *Jurnal Statistika Industri dan Komputasi*, vol. 9, no. 1, pp. 10–20, Jan. 2024, doi: 10.34151/statistika.v9i1.4821.
- [4] D. I. Ginting, I. Lubis, I. Lubis, and I. Lubis, "PENGARUH ANGKA HARAPAN HIDUP DAN HARAPAN LAMA SEKOLAH TERHADAP INDEKS PEMBANGUNAN MANUSIA," *Bisnis-Net Jurnal Ekonomi dan Bisnis*, vol. 6, no. 2, pp. 519–528, Dec. 2023, doi: 10.46576/bn.v6i2.3884.
- [5] I. Kemala and A. W. Wijayanto, "Perbandingan Kinerja Metode Bagging dan Non-Ensemble Machine Learning pada Klasifikasi Wilayah di Indonesia menurut Indeks Pembangunan Manusia," *Jurnal Sistem dan Teknologi Informasi (Justin)*, vol. 9, no. 2, p. 269, Apr. 2021, doi: 10.26418/justin.v9i2.44166.

- [6] T. Posangi, L. Yahya, and D. Wungguli, "Implementasi Algoritma Random Forest dengan Forward Selection untuk Klasifikasi Indeks Pembangunan Manusia," *Jambura Journal of Probability and Statistics*, vol. 4, no. 2, pp. 85–91, Nov. 2023, doi: 10.37905/jjps.v4i2.18460.
- [7] A. C. Ampang, B. E. W. Asrul, and M. A. Nur, "Implementasi Metode Double Exponential Smoothing Untuk Memprediksi Indeks Pembangunan Manusia (IPM) Di Kabupaten Toraja Utara," *Jurnal Fokus Elektroda : Energi Listrik, Telekomunikasi, Komputer, Elektronika Dan Kendali*, vol. 8, no. 3, pp. 197–207, 2023.
- [8] N. N. Amiroh and D. Avianto, "Prediksi Indeks Pembangunan Manusia di Kabupaten Wonosobo Menggunakan Algoritma Backpropagation," *Techno.Com*, vol. 22, no. 2, pp. 388–399, May 2023, doi: 10.33633/tc.v22i2.7980.

Identifikasi Varietas Jagung Menggunakan Metode Convolutional Neural Network

Abdurrahim Ramadhan Idin^{a1}, Aziz Kustiyo^{b2}, Muhammad Asyhar Agmalaro^{b3}, Toto Haryanto^{a4}

^aComputer Science Study Program, School of Data Science, Mathematics and Informatics,
IPB University

Jl. Raya Dramaga, Kampus IPB Dramaga Bogor, West Java, Indonesia

¹webzzkunabdurrahim@apps.ipb.ac.id

⁴totoharyanto@apps.ipb.ac.id

^bArtificial Intelligence Study Program, School of Data Science, Mathematics and Informatics,
IPB University

Jl. Raya Dramaga, Kampus IPB Dramaga Bogor, West Java, Indonesia

²azizku@apps.ipb.ac.id (Corresponding author)

³agmalaro@apps.ipb.ac.id

Abstract

Corn is one of Indonesia's primary commodities, but its productivity is significantly affected by environmental and climatic conditions. Crop yields often fluctuate due to climate change, particularly the El Niño phenomenon, which can lead to drought and delays in planting seasons. As a result, selecting superior drought-resistant seeds is essential, especially in dryland areas like East Nusa Tenggara. Traditional methods for identifying seeds, such as manual morphological measurements, are considered inefficient in terms of time and labor. This study aims to develop a corn seed variety classification system using a Convolutional Neural Network that focuses on five varieties: NK 212, NK 7328 Sumo, P 21, Pertiwi 2, and Pertiwi 6. We designed and tested three CNN architectures with varying complexities. The most effective model, which includes three convolutional layers and two fully connected layers with dropout, achieved an optimal performance of 89,20% accuracy on the test data.

Keywords: Image Processing, Drought Stress, Convolutional Neural Network, Seed Identification, Corn

1. Pendahuluan

Pertanian memiliki peran penting dalam keberlangsungan hidup manusia, terutama dalam hal ketahanan pangan dan perekonomian. Di Indonesia, jagung menjadi salah satu komoditas yang berkontribusi besar dalam memenuhi kebutuhan pangan nasional. Namun, menurut penelitian Irawan [1], jagung termasuk komoditas yang paling rentan terhadap dampak perubahan iklim. Laporan kinerja Kementerian Pertanian tahun 2023 [2] juga menunjukkan adanya fluktuasi produksi jagung dalam beberapa tahun terakhir. Pada tahun 2023, produksi jagung tercatat sebesar 19,56 juta ton, mengalami penurunan 12,5% dibandingkan dengan tahun sebelumnya yang mencapai 22,36 juta ton. Penurunan ini dipengaruhi oleh fenomena El Niño yang memicu kekeringan, sehingga menyebabkan keterlambatan musim tanam akibat minimnya ketersediaan air.

Untuk meningkatkan produktivitas jagung, pemilihan benih unggul yang tahan terhadap kekeringan sangat penting, terutama di daerah lahan kering seperti Nusa Tenggara Timur (NTT). Penelitian oleh Sitorus et al. [3] menunjukkan bahwa varietas Nasa 29, Pertiwi 6, NK 7328 Sumo, JH 27, dan Pertiwi 5 memiliki performa yang baik dalam kondisi lahan kering di NTT, dengan produktivitas dan ketahanan yang lebih tinggi terhadap cekaman lingkungan. Sebaliknya, varietas seperti NK 212, Pertiwi 2, Pioneer P 21, JH 37 dan JH 45 menunjukkan hasil yang kurang optimal dan adaptasi yang terbatas dalam kondisi tersebut.

Salah satu metode yang sering digunakan dalam pemilihan benih adalah analisis karakteristik morfologi benih, seperti ukuran, warna, area, dan bentuk benih. Namun, pengukuran manual atas ciri-ciri ini membutuhkan waktu yang signifikan serta ketersediaan tenaga ahli. Metode manual juga rentan terhadap inkonsistensi dan kesalahan manusia, sehingga berpotensi menghasilkan pemilihan


benih yang tidak optimal. Di samping itu, pengetahuan terhadap benih tersebut juga diperlukan untuk menghindari adanya benih palsu [4]. Berdasarkan informasi dari media online [5], kasus pemalsuan benih jagung pernah terungkap di Jawa Timur dengan kerugian yang cukup besar. Sindikat pemalsu merek benih jagung berhasil memproduksi 5.500 sak benih palsu siap edar, menyebabkan kerugian ekonomi mencapai Rp 5 miliar. Selain kerugian tersebut, benih palsu memiliki potensi memperparah risiko gagal panen.

Penelitian terkait klasifikasi dan identifikasi varietas tanaman menggunakan metode *Convolutional Neural Network* (CNN) telah menunjukkan hasil yang baik dalam berbagai aplikasi pertanian. Sebagai contoh, Nugroho dan Sebatubun [6] berhasil mengklasifikasikan varietas kopi arabika dengan akurasi 86% melalui analisis fitur morfologi biji kopi mentah menggunakan CNN, *Gray Level Co-occurrence Matrix* (GLCM), dan *Support Vector Machine* (SVM). Ardianto dan Wibisono [7] mengembangkan metode klasifikasi varietas gandum dengan arsitektur CNN MobileNet dan mencapai akurasi hingga 98%. Untuk klasifikasi varietas jagung, Chandra et al. [8] menggunakan metode *K-Nearest Neighbor* (K-NN) untuk mengklasifikasikan varietas jagung mutiara dengan akurasi 93,24%.

Berdasarkan uraian di atas, penelitian ini mengusulkan metode CNN untuk mengotomatisasi proses identifikasi, meningkatkan akurasi, dan mengurangi ketergantungan pada tenaga ahli. Tujuan dari penelitian ini adalah mengembangkan model CNN yang dapat mengidentifikasi varietas jagung berdasarkan citra digital.

2. Metode Penelitian

Tahapan penelitian disajikan pada Gambar 1. Penelitian ini diawali dengan pengumpulan dataset citra benih jagung dari lima varietas. Dalam setiap citra tersebut terdapat 16 benih jagung dengan latar belakang berwarna hitam. Selanjutnya dilakukan praproses data untuk menambah variasi dataset. Tahapan berikutnya adalah membagi data menjadi data latih, data validasi dan data uji. Data latih dan data validasi digunakan dalam proses pelatihan model CNN. Terdapat tiga model CNN yang dibangun dalam penelitian ini. Setelah dilatih, model CNN diuji menggunakan data uji. Kinerja model CNN tersebut kemudian dievaluasi menggunakan *confusion matrix*. Berdasarkan matrik tersebut, dihitung akurasi, *precision*, *recall*, dan *F1-score* hasil pengujian model CNN. Selain itu, matrik tersebut juga digunakan untuk mengetahui kesalahan prediksi setiap varietas.




Gambar 1. Tahapan penelitian Identifikasi Varietas Jagung menggunakan CNN

2.1. Pengumpulan Dataset Citra Benih Jagung

Benih dari lima varietas jagung yang digunakan dalam penelitian ini didasarkan pada penelitian Sitorus et al. [3]. Dua varietas jagung memiliki rasio *Benefit/Cost* (rasio B/C) lebih dari 2,0, mewakili benih dengan produktivitas dan ketahanan yang lebih tinggi terhadap cekaman lingkungan yang

direkomendasikan untuk ditanam di NTT yaitu varietas Pertiwi 6 dan NK 7328 Sumo. Tiga varietas yang lain yaitu Pioneer P 21, NK 212 dan Pertiwi 2 memiliki rasio B/C kurang dari 2,0 tidak termasuk varietas jagung yang direkomendasikan ditanam di NTT. Rasio B/C dari NK-212 dan Pertiwi-2 berturut-turut adalah 1,48 dan 1,50.

Pengumpulan data benih jagung akan melibatkan 2500 citra yang diambil dari kelima varietas tersebut. Setiap varietas akan diwakili oleh 500 citra, yang diambil menggunakan kamera digital dengan resolusi 50 MP. Pengambilan citra dilakukan dengan jarak sekitar 25 cm dari benih jagung dengan latar belakang hitam. Pemilihan latar belakang ini bertujuan untuk meningkatkan kontras antara benih dan latar, mempermudah proses ekstraksi fitur pada tahap berikutnya. Ilustrasi penyusunan benih jagung untuk proses akuisisi citra disajikan pada Gambar 2, dengan latar belakang berwarna hitam dan benih jagung berwarna jingga sebanyak 16 benih. Penyusunan benih seperti pada Gambar 2 dimaksudkan agar diperoleh lebih banyak citra benih jagung dibandingkan dengan pengambilan citra untuk setiap benih jagung.



.Gambar 2. Ilustrasi penyusunan benih jagung

2.2. Praproses Data

Tahapan praproses dilakukan untuk mempersiapkan data sebelum proses pelatihan model CNN, dengan tujuan meningkatkan kualitas dan variasi dataset sehingga model dapat belajar lebih efektif dan *robust* terhadap variasi input. Pada tahap ini, beberapa teknik augmentasi diterapkan, seperti *rescale* untuk menormalisasi nilai piksel, rotasi, pergeseran horizontal dan vertikal, penyesuaian kecerahan, serta *zoom* untuk memperkaya variasi data. Selain itu, dilakukan juga *flipping* untuk menambah keragaman sudut pandang citra. Teknik-teknik tersebut bertujuan untuk meningkatkan generalisasi model. Detail parameter augmentasi disajikan pada Tabel 1.

Table 1. Detail parameter augmentasi

Parameter	Nilai/Rentang	Keterangan
<i>Rotation Range</i>	45 derajat	Rentang rotasi citra.
<i>Width Shift Range</i>	0,1	Rentang pergeseran horizontal.
<i>Height Shift Range</i>	0,1	Rentang pergeseran vertikal.
<i>Brightness Range</i>	[0,9-1,1]	Rentang penyesuaian kecerahan.
<i>Zoom Range</i>	0,1	Rentang <i>zoom</i> citra.
<i>Flip</i>	True	Membalik citra

2.3. Pelatihan Model CNN

Lee dan Song [9] menjelaskan bahwa struktur umum CNN untuk tugas klasifikasi terdiri dari satu atau lebih lapisan konvolusi dan *pooling* yang disusun secara bergantian. Fitur-fitur yang dihasilkan dari blok-blok ini kemudian diratakan (*flattened*) dan dihubungkan dengan semua node pada lapisan *neural network* selanjutnya yang disebut *fully-connected* untuk melakukan klasifikasi.

Pelatihan model dilakukan menggunakan arsitektur CNN yang dirancang secara manual, terdiri dari lapisan konvolusi, *max pooling*, dan *fully connected*. Pada lapisan konvolusi dan *fully connected* digunakan fungsi aktivasi ReLU (*Rectified Linear Unit*). Fungsi ReLU dipilih karena kemampuannya dalam mengatasi masalah *vanishing gradient* [10]. Setelah lapisan konvolusi, lapisan *max pooling* ditambahkan untuk mengurangi dimensi spasial citra tanpa menghilangkan fitur penting yang telah terekstraksi sebelumnya. Lapisan output menggunakan fungsi aktivasi *softmax* untuk menghasilkan probabilitas distribusi kelas.

Pada penelitian ini dilakukan tiga eksperimen dengan arsitektur CNN yang berbeda untuk klasifikasi varietas benih jagung. Setiap model memiliki perbedaan pada lapisan konvolusi dan *fully connected*, yang diberi label Model_1, Model_2, dan Model_3. Model_1 menggunakan arsitektur sederhana

dengan 2 lapisan konvolusi dan 1 lapisan *fully connected (dense)*. Pada Model_2 ditambahkan 1 lapisan konvolusi untuk menambah kedalaman model sehingga arsitektur Model_2 menggunakan 3 lapisan konvolusi dan 1 lapisan *fully connected*. Model_3 menggunakan arsitektur yang lebih dalam dengan 3 lapisan konvolusi dan 2 lapisan *fully connected*, serta penambahan *dropout* untuk mengurangi overfitting. Berdasarkan penelitian Josephine et al. [11], penambahan *hidden dense layer* dapat meningkatkan akurasi CNN, oleh karena itu pada penelitian ini digunakan beberapa *dense layer*. Detail arsitektur ketiga model tersebut disajikan pada Tabel 2.

Data yang digunakan untuk pelatihan, validasi, dan pengujian memiliki ukuran 256×256 piksel dan ukuran *batch* 32. Untuk setiap varietas benih jagung, data latih terdiri dari 350 citra, data validasi 100 citra dan data uji 50 citra. Data latih dan validasi diambil secara acak (*shuffle*) agar distribusi data merata dan menghindari bias selama pelatihan sedangkan data uji tidak diacak. Model dirancang menggunakan arsitektur Sequential kemudian dikompilasi dengan *optimizer Adaptive Moment Estimation (Adam)* dengan *learning rate default* 0.001. Fungsi loss yang digunakan adalah *categorical cross-entropy*, yang sesuai untuk masalah klasifikasi multi-kelas.

2.4. Pengujian dan evaluasi Model CNN

Setelah pelatihan selesai, model CNN diuji menggunakan dataset uji yang telah disiapkan. Hasil prediksi model CNN kemudian dievaluasi menggunakan *confusion matrix* [12] untuk mengukur kinerja model dalam mengidentifikasi varietas benih jagung. Beberapa metrik evaluasi yang digunakan antara lain akurasi, *precision*, *recall*, dan *F1-score* [12]. Metrik akurasi digunakan untuk mengukur seberapa banyak prediksi model yang benar, dihitung dengan Persamaan (1).

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

Table 2. Detail arsitektur CNN untuk Model_1, Model_2 dan Model_3

Layer (type)	Output shape		
	Model 1	Model 2	Model 3
Input (InputLayer)	(256, 256, 3)	(256, 256, 3)	(256, 256, 3)
conv2d (Conv2D)	(254, 254, 16)	(254, 254, 16)	(254, 254, 32)
max_pooling2d	(127, 127, 16)	(127, 127, 16)	(127, 127, 32)
conv2d_1 (Conv2D)	(125, 125, 32)	(125, 125, 32)	(125, 125, 64)
max_pooling2d_1	(62, 62, 32)	(62, 62, 32)	(62, 62, 64)
conv2d_2 (Conv2D)	-	(60, 60, 64)	(60, 60, 128)
max_pooling2d_2	-	(30, 30, 64)	(30, 30, 128)
flatten (Flatten)	(123008)	(57600)	(115200)
dense (Dense)	(128)	(128)	(128)
dropout (Dropout)	-	-	(128)
dense_1 (Dense)	(5)	(5)	(64)
dropout_1 (Dropout)	-	-	(64)
dense_2 (Dense)	-	-	(5)

Metrik *precision* digunakan untuk mengukur ketepatan model dalam mengidentifikasi benih jagung berkualitas baik, dihitung dengan Persamaan (2).

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

Recall digunakan untuk mengukur seberapa baik model menemukan semua benih jagung, yang dihitung dengan Persamaan (3).

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


Terakhir, *F1-score* untuk mengukur keseimbangan antara *precision* dan *recall*, yang dihitung dengan Persamaan (4).

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

dengan TP (*True Positive*) adalah jumlah prediksi benar untuk sampel positif, TN (*True Negative*) adalah jumlah prediksi benar untuk sampel negatif, FP (*False Positive*) adalah jumlah prediksi salah mengidentifikasi sampel negatif sebagai positif, dan FN (*False Negative*) adalah jumlah prediksi salah mengidentifikasi sampel positif sebagai negatif.

3. Hasil dan Pembahasan

Pada Gambar 3 disajikan contoh citra dari 5 varietas benih jagung yang digunakan dalam penelitian ini. Secara visual, dari Gambar 3 terlihat bahwa benih jagung varietas Pertiwi 6 (benih yang direkomendasikan) mirip dengan Pertiwi 2 (benih yang tidak direkomendasikan) dan NK 7328 Sumo (benih yang direkomendasikan) mirip dengan NK 212 (benih yang tidak direkomendasikan). Benih jagung varietas Pioneer P 21 secara visual berbeda dengan keempat varietas yang lain.




Gambar 3. Benih jagung dari 5 varietas

a. Pertiwi 6, b. Pertiwi 2, c. Pioneer P 21, d. NK 7328 Sumo, e. NK 212

3.1. Hasil akuisisi citra benih jagung

Contoh hasil akuisisi citra benih jagung yang akan digunakan sebagai input model CNN disajikan pada Gambar 4. Secara umum dapat dilihat bahwa dalam satu citra, terdapat variasi baik dari segi bentuk, ukuran maupun warna benih jagung dari setiap varietas. Dengan adanya variasi tersebut akan mempermudah model CNN untuk mendapatkan fitur-fitur yang diperlukan sehingga akan meningkatkan akurasi model.




Gambar 4. Sampel benih jagung dari lima varietas yang digunakan sebagai input model CNN

a. Pertiwi 6, b. Pertiwi 2, c. Pioneer P 21, d. NK 7328 Sumo, e. NK 212

3.2. Hasil praproses data

Pada penelitian ini diterapkan beberapa teknik augmentasi citra benih jagung yaitu rotasi, pergeseran horizontal dan vertikal, penyesuaian kecerahan, *zoom* serta *flipping*. Pada Gambar 5 disajikan contoh

hasil proses-proses augmentasi tersebut. Secara umum, augmentasi citra telah menghasilkan citra baru yang berbeda dengan citra asal.




Gambar 5. Contoh hasil augmentasi citra benih jagung

- (a) citra asal
- (b) rotasi 45°
- (c) pergeseran horizontal
- (d) pergeseran vertikal
- (e) penyesuaian kecerahan
- (f) *zooming*
- (g) *flipping*

3.3. Hasil Pelatihan Model CNN

Model_1 dilatih dengan jumlah *epoch* sebanyak 15. Grafik akurasi dan loss Model_1 selama pelatihan dapat dilihat pada Gambar 6. Model_1 menunjukkan performa yang relatif rendah. Akurasi pelatihan dan akurasi validasi berkisar di angka 60%, menunjukkan model *underfitting*. Hal ini mengindikasikan arsitektur model terlalu sederhana untuk menangkap kompleksitas fitur dari *dataset*.



Gambar 6. Sampel akurasi dan loss Model_1 selama pelatihan


Model_2 merupakan perbaikan dari model_1 dengan menambahkan satu layer konvolusi. Grafik akurasi dan loss model_2 selama pelatihan sebanyak 15 *epoch* dapat dilihat pada Gambar 7. Dari Gambar 7 dapat dilihat bahwa model_2 menunjukkan peningkatan performa dibanding Model_1 dengan akurasi pelatihan mencapai 71,72%, namun akurasi validasi yang lebih rendah (58,00%) dengan selisih sekitar 13,72%, yang mengindikasikan adanya *overfitting*. Hal ini berbeda dengan Model_1 yang menunjukkan gejala *underfitting*. Fenomena ini menunjukkan bahwa penambahan kompleksitas model dapat meningkatkan kemampuan model dalam mengenali pola pada data *training*, namun belum optimal dalam generalisasi.



Gambar 7. Sampel akurasi dan loss Model_2 selama pelatihan

Model_3 menggunakan arsitektur yang lebih dalam dengan 3 lapisan konvolusi dan 2 lapisan *fully connected*, serta penambahan *dropout* untuk mengurangi *overfitting*. Grafik akurasi dan loss Model_3 selama pelatihan sebanyak 15 *epoch* dapat dilihat pada Gambar 8. Model_3 menunjukkan performa yang lebih baik dengan akurasi pelatihan sebesar 98,03% pada *epoch* ke-15 dan mampu mempertahankan performa tinggi pada *validation* (86,80%). Hal ini menunjukkan kemampuan Model_3 yang lebih baik dalam mengenali pola kompleks pada data dibandingkan Model_2. Penambahan *dropout* terbukti mengurangi *overfitting*, yang ditunjukkan dengan selisih antara akurasi *training* dan validasi yang lebih kecil dibandingkan dengan Model_2.

Namun pada grafik, terlihat bahwa nilai *loss training* dan validasi menunjukkan pola divergensi yang semakin melebar setelah epoch ke-7. *Training loss* terus menurun hingga mencapai 0,0881 pada *epoch* ke-15, mengindikasikan model semakin baik mempelajari data pelatihan, sedangkan *validation loss* justru meningkat dari 0,7264 menjadi 1,0932, menandakan gejala *overfitting* mulai terjadi diatas epoch ke-7. Meski demikian, *validation accuracy* tetap stabil di sekitar 86%, menunjukkan model masih memiliki kemampuan generalisasi yang cukup baik.



Gambar 8. Sampel akurasi dan loss Model_3 selama pelatihan

3.4. Hasil Pengujian dan Evaluasi Model CNN

Hasil pengujian CNN model_1 menggunakan data uji disajikan pada Tabel 3 dengan akurasi model_1 adalah sebesar 77,60%. Dari Tabel 3 dapat dilihat bahwa kesalahan prediksi yang terjadi adalah antara varietas benih jagung Pertiwi 6 dengan Pertiwi 2 dan NK 7328 Sumo dengan NK 212. Hal ini mengkonfirmasi kemiripan secara visual dari varietas-varietas tersebut seperti yang sudah disebutkan pada bagian sebelumnya. Demikian juga dengan varietas benih jagung Pioneer P 21 yang secara visual berbeda dengan keempat varietas yang lain, hanya ada 2 kesalahan prediksi atau sebesar 4%.

Table 3. Confusion matrix CNN Model_1

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	35	15	0	0	0
Pertiwi 2	8	41	0	1	0
Pioneer 21	0	0	48	2	0
NK 7328 Sumo	0	0	0	46	4
NK 212	0	0	0	26	24

Confusion matrix hasil pengujian model_2 disajikan pada Tabel 4 dengan akurasi pengujian sebesar 83,20%. Model_2 menunjukkan peningkatan signifikan dalam kemampuan mengenali varietas NK 212 dengan 49 dari 50 sampel diklasifikasikan dengan benar. Namun, terjadi penurunan dalam pengenalan NK 7328 Sumo dengan 21 sampel salah diklasifikasi sebagai NK 212. Ini menunjukkan pergeseran bias model dari Model_1 yang cenderung mengklasifikasikan NK 212 sebagai NK 7328 Sumo, menjadi Model_2 yang cenderung mengklasifikasikan NK 7328 Sumo sebagai NK 212. Performa untuk Pioneer P 21 tetap tinggi dengan 49 sampel terklasifikasi dengan benar. Untuk varietas Pertiwi, performa relatif stabil dengan pola kesalahan yang serupa antara Pertiwi 2 dan Pertiwi 6.

Table 4. Confusion matrix CNN Model_2

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	41	9	0	0	0
Pertiwi 2	9	40	0	0	1
Pioneer P 21	1	0	49	0	0
NK 7328 Sumo	0	0	0	29	21
NK 212	0	0	0	1	49

Berdasarkan Tabel 5, performa klasifikasi Model_3 menunjukkan peningkatan signifikan dibandingkan model sebelumnya dengan akurasi pengujian sebesar 89,20%. Peningkatan akurasi tersebut terutama terjadi pada varietas benih jagung NK 7328 Sumo yaitu dari 58% (model_2) menjadi 78% pada model_3. Pola kesalahan model_3 secara umum serupa dengan pola kesalahan pada model_1 dan model_2. Namun demikian, model_3 telah berhasil mengurangi tingkat kesalahan tersebut dibandingkan dengan model-model sebelumnya.

Table 5. Confusion matrix CNN Model_3

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	42	8	0	0	0
Pertiwi 2	5	44	1	0	1
Pioneer P 21	1	0	50	0	0
NK 7328 Sumo	0	0	0	39	11
NK 212	0	0	0	2	48

Perbandingan kinerja ketiga model CNN disajikan pada Tabel 6. Dapat dilihat dari tabel tersebut bahwa kinerja model yang diukur dengan F1-score menunjukkan bahwa model_3 merupakan model terbaik dibandingkan kedua model yang lain. Secara umum nilai F1-score untuk kelima varietas benih jagung menunjukkan adanya peningkatan dari model_1 ke model_2 hingga ke model_3. Terdapat pengecualian untuk varietas benih jagung P21 dimana nilai F1-score untuk ketiga model menunjukkan nilai yang hampir sama yaitu di sekitar nilai 99%. Hal ini mengkonfirmasi bahwa varietas benih jagung P21 secara visual berbeda dengan keempat varietas yang lain.

Table 6. Evaluation matrix CNN model_1, model_2 dan model_3

Varietas	Model_1			Model_2			Model_3		
	P	R	F1	P	R	F1	P	R	F1
Pertiwi 6	0.81	0.70	0.75	0.80	0.82	0.81	0.89	0.84	0.87
Pertiwi 2	0.73	0.82	0.77	0.82	0.80	0.81	0.85	0.88	0.86
P21	1.00	0.96	0.98	1.00	0.98	0.99	0.98	1.00	0.99
NK-7328	0.61	0.92	0.74	0.97	0.58	0.72	0.95	0.78	0.86
NK-212	0.86	0.48	0.62	0.69	0.98	0.81	0.81	0.96	0.88

Keterangan: P = *precision*, R = *recall*, F1 = F1-score

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model CNN dengan tiga lapisan konvolusi dan 2 lapisan *fully connected* dengan *dropout* mencatat performa terbaik, mencapai akurasi 89,20% pada data *testing*. Model CNN tersebut telah berhasil mengklasifikasikan varietas benih jagung yang secara visual memiliki kemiripan. Untuk pengembangan penelitian selanjutnya, disarankan untuk menambah epoch selama pelatihan dan menerapkan *hyperparameter tuning* agar diperoleh model CNN dengan kinerja yang lebih baik.

Daftar Pustaka

- [1] B. Irawan, "Fenomena Anomali Iklim El Nino dan La Nina: Kecenderungan Jangka Panjang dan Pengaruhnya Terhadap Produksi Pangan," *Forum Penelitian Agro Ekonomi*, vol. 24, no. 1, pp. 28–45, Jul. 2006.
- [2] Kementan, "Laporan Kinerja Kementrian Pertanian 2023," 2023. [Online]. Available: www.pertanian.go.id
- [3] A. Sitorus, N. R. E. Kotta, and E. Y. Hosang, "Keragaan Pertumbuhan dan Produksi Jagung Hibrida pada Agroekosistem Lahan Kering Iklim Kering Nusa Tenggara Timur," in *Seminar Nasional Lahan Suboptimal ke-8 Tahun 2020*, Palembang: Penerbit & Percetakan Universitas Sriwijaya, Oct. 2020, pp. 62–72.
- [4] A. Syahbani and E. Suastuti, "Disparitas Penjatuhan Pidana Terhadap Pelaku Usaha Yang Memperdagangkan Benih Jagung Bantuan Pemerintah," *Journal Inicio Legis*, vol. 4, no. 1, Jun. 2023.
- [5] A. Muhajir, "Sindiket pemalsu merek benih jagung dibongkar, korban rugi Rp 5 miliar," *detik.com*. Accessed: Mar. 25, 2025. [Online]. Available: <https://news.detik.com/berita-jawa-timur/d-5293569/sindiket-pe-malsu-merek-benih-jagung-dibongkar-korban-rugi-rp-5-miliar>
- [6] M. A. Nugroho and M. M. Sebatubun, "Klasifikasi Varietas Kopi Berdasarkan Green Bean Coffee Menggunakan Metode Machine Learning," vol. 1, no. 2, pp. 2715–3088, 2020.

- [7] R. Ardianto and S. kartika Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *Jurnal Kolaboratif Sains*, vol. 6, no. 12, pp. 2081–2092, Dec. 2023, doi: 10.56338/jks.v6i12.4938.
- [8] V. Chandra, J. H. Jaman, and Garno, "Identifikasi Varietas Jagung Mutiara Berdasarkan Data Citra Digital Menggunakan Algoritma K-Nearest Neighbor," vol. 16, 2022, [Online]. Available: <https://journal.uniku.ac.id/index.php/ilkom>
- [9] H. Lee and J. Song, "Introduction to convolutional neural network using Keras; An understanding from a statistician," *Commun Stat Appl Methods*, vol. 26, no. 6, pp. 591–610, 2019, doi: 10.29220/CSAM.2019.26.6.591.
- [10] J. Wu, "Introduction to Convolutional Neural Networks," 2017. Accessed: May 13, 2025. [Online]. Available: <https://cs.nju.edu.cn/wujx/paper/CNN.pdf>.
- [11] V. L. H. Josephine, A. P. Nirmala, and V. L. Alluri, "Impact of Hidden Dense Layers in Convolutional Neural Network to enhance Performance of Classification Model," *IOP Conf Ser Mater Sci Eng*, vol. 1131, no. 1, p. 012007, Apr. 2021, doi: 10.1088/1757-899x/1131/1/012007.
- [12] J. D. Novakovic, A. Veljovic, S. S. Ilic, Z. Papic, and M. Tomovic, "Evaluation of Classification Models in Machine Learning," *Theory and Applications of Mathematics & Computer Science*, vol. 7, no. 1, pp. 39–46, 2017.

Perancangan *User Interface* dan *User Experience* Berbasis Website Sistem Pembayaran SPP Menggunakan *Human Centered Design* (Studi Kasus : SMAS Bhinneka Karawang)

Novi Anthika Suci Nurhidayah¹⁾, Bagja Nugraha²⁾, Hannie³⁾

Program Studi Sistem Informasi, Fakultas Ilmu Komputer,
Universitas Singaperbangsa Karawang

¹⁾ 2110631250015@student.unsika.ac.id

²⁾ bagjanugraha@staff.unsika.ac.id

³⁾ hannie@staff.unsika.ac.id

Abstrak

Penelitian ini membahas ketidakefisienan metode pembayaran sumbangan pembinaan pendidikan (SPP) yang masih dilakukan secara manual di SMAS Bhinneka Karawang serta pentingnya sistem pembayaran daring yang lebih mudah diakses oleh orang tua untuk mempermudah proses pembayaran. Tujuan utama penelitian ini adalah merancang desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP yang mudah digunakan oleh orang tua, operator sekolah, dan pengelola yayasan. Metode *Human Centered Design* digunakan untuk memastikan bahwa perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP dikembangkan sesuai dengan kebutuhan pengguna. Hasil penelitian menunjukkan bahwa prototipe sistem pembayaran spp yang dirancang mampu meningkatkan efisiensi proses pembayaran, dengan seluruh pengguna menyatakan kemudahan penggunaan dan tingkat keberhasilan mencapai 100%. Penelitian selanjutnya disarankan untuk mengintegrasikan fitur tambahan seperti pembayaran melalui perangkat mobile dan analisis lebih lanjut terhadap pengalaman pengguna.

kata kunci: metode pembayaran, sumbangan pembinaan pendidikan, *human centered design*, sistem pembayaran, prototipe

1. Pendahuluan

Sumbangan Pembinaan Pendidikan (SPP) merupakan komponen penting dalam mendukung operasional sekolah. Proses pembayaran SPP di SMAS Bhinneka Karawang yang dikelola oleh Yayasan Pendidikan Islam Nahdlatul Ulama (YAPINU) Karawang masih dilakukan secara manual. Menurut keterangan operator sekolah, metode ini menimbulkan berbagai permasalahan, seperti pencatatan yang tidak akurat, risiko pencatatan ganda, serta rendahnya efisiensi dan transparansi pengelolaan keuangan (Sumirah, 2024).

Selain itu, keterbatasan sumber daya manusia dan rendahnya literasi teknologi, terutama di kalangan pegawai yang lanjut usia, turut menghambat efektivitas pengelolaan SPP. Operator yayasan menyatakan bahwa sistem manual memerlukan waktu lama untuk pencatatan dan pelaporan, yang pada akhirnya memperlambat alur pembayaran serta memengaruhi stabilitas keuangan yayasan (Nofy, 2024). Jika tidak segera ditangani, kondisi ini dapat mengganggu kelancaran proses pembelajaran serta menimbulkan ketidaknyamanan bagi orang tua siswa akibat kesalahan informasi.

Metode *Human Centered Design* (HCD) telah terbukti meningkatkan efisiensi sistem pembayaran. Penelitian oleh Muslimin & Zuraidah (2023) menunjukkan bahwa penerapan HCD pada prototipe sistem pembayaran SPP di SMP Islam Al-Muttaqin mampu meningkatkan efisiensi dan mengurangi kesalahan pencatatan. Namun, penelitian tersebut masih terbatas pada tingkat SMP dan belum mengeksplorasi kompleksitas kebutuhan di jenjang SMA. Di sisi lain, studi oleh

Rudi Sanjaya et al. (2024) menunjukkan bahwa pendekatan *User Centered Design* (UCD) mampu meningkatkan kepuasan pengguna, meskipun belum mendalami penerapan HCD di lingkungan pendidikan menengah atas dengan keberagaman pengguna yang lebih luas.

Penelitian ini bertujuan merancang antarmuka sistem pembayaran SPP berbasis Human Centered Design untuk SMAS Bhinneka Karawang. Fokus utama adalah menciptakan desain yang sederhana, mudah digunakan, serta mampu meningkatkan efisiensi, akurasi, dan pengalaman pengguna bagi orang tua, operator sekolah, dan pihak yayasan. Evaluasi desain akan dilakukan melalui metode *cognitive walkthrough* guna mengidentifikasi potensi hambatan dalam interaksi pengguna, sehingga solusi yang dihasilkan benar-benar sesuai dengan kebutuhan pengguna.

2. Metode Penelitian

Metodologi penelitian ini menggunakan metode kualitatif studi kasus dengan pendekatan *Human Centered Design*, yang terdiri dari tiga tahap utama, yaitu *inspiration*, *ideation*, dan *implementation*.



Gambar 1 Tahapan

Centered Design

Utama Human

• *Inspiration*

Tahap awal penelitian ini adalah *inspiration*. Dimana peneliti melakukan studi literatur, observasi dan wawancara untuk menggali kebutuhan dan harapan pengguna.

• *Ideation*

Berdasarkan hasil dari tahap *inspiration*, penelitian berlanjut ke tahap *ideation*. Langkah-langkah pada tahap ini mengidentifikasi *pain point* atau kesulitan utama pengguna. Pada tahap ini juga dibuat *user persona* yang mewakili fitur dan kebutuhan pengguna utama sistem dan peneliti juga membuat *user flow* untuk memastikan alur interaksi yang mudah dan efektif bagi pengguna saat menggunakan fitur sistem.

• *Implementation*

Tahap terakhir adalah *implementation*. Pada tahap ini, prototipe yang telah dirancang menggunakan tools figma diuji oleh pengguna menggunakan pengujian *cognitive walkthrough*. Pengujian ini dilakukan dengan menggunakan skenario yang telah disusun dan direkam menggunakan OBS (*Open Broadcaster Software*) untuk mengetahui sejauh mana desain antarmuka pengguna yang dibuat dapat memenuhi kebutuhan pengguna dan memberikan pengalaman pengguna yang optimal. Pengolahan data hasil pengujian menggunakan microsoft excel. Setelah pengujian, peneliti mengevaluasi sebagai umpan balik untuk memahami pengalaman pengguna dan melakukan perbaikan yang diperlukan berdasarkan masukan tersebut.

Nielsen (2020) dalam penelitian terbarunya menyarankan bahwa lima orang partisipan sudah cukup untuk mendapatkan hasil yang mendekati akurasi optimal dalam pengujian usability. Pengujian ini dapat mengidentifikasi hingga 85% masalah *usability* yang mungkin muncul pada sistem. Metode ini sangat berguna dalam mengidentifikasi masalah usability pada tahap awal desain, karena fokus utamanya adalah pada cara pengguna berpikir tentang sistem. Hal ini sejalan dengan penelitian dari (Karlina & Indah, 2022) Secara keseluruhan, pengujian ini melibatkan 6 orang pengguna, dengan rinciannya adalah 3 orang guru dan 3 orang siswa dari SMA YPI Tunas Bangsa Palembang, yang telah berpartisipasi dalam usability testing untuk memberikan umpan balik tentang prototype yang diuji, yang menguji prototype sistem informasi e-learning, meskipun melibatkan 6 orang partisipan (3 guru dan 3 siswa), temuan mereka juga mengindikasikan bahwa pengujian usability dengan jumlah partisipan yang relatif kecil sudah mampu memberikan umpan balik yang signifikan.

Dalam penelitian ini, pengujian ini akan diterapkan untuk mengevaluasi prototype website sistem pembayaran SPP dan memastikan bahwa pengguna dapat menggunakan sistem dengan mudah dan efisien. Berikut adalah tabel pengujian dalam pengujian cognitive, sesuai dengan rekomendasi dari Nielsen (1994) dalam bukunya *Usability Engineering* (2003) dalam *Human-Computer Interaction*.

Tabel 1 Tabel Perhitungan Pengujian Skenario

Partisipan	Indikator Pengujian		
	Detail Skenario	Waktu (detik)	Kesalahan
1			
2			
3			
4			
5			
Jumlah Partisipan yang berhasil		Rata – Rata =	Presentase Kesalahan =
Presentase Keberhasilan			

Tabel pengujian skenario ini digunakan untuk menganalisis hasil uji coba terhadap prototype berdasarkan skenario yang telah ditetapkan. Dengan mempertimbangkan parameter seperti jumlah partisipan, waktu yang dibutuhkan, dan tingkat kesalahan, tabel ini membantu memetakan kinerja fitur yang diuji.

$$\text{Presentasi Keberhasilan} = \frac{\text{partisipan yang berhasil}}{\text{total partisipan}} \times 100\%$$

$$\text{Rata – Rata Waktu} = \frac{\text{total waktu seluruh partisipan}}{\text{total partisipan}}$$

$$\text{Presentase Kesalahan} = \frac{\text{jumlah kesalahan}}{\text{total partisipan}} \times 100\%$$

Tabel 2 Tabel Perhitungan Akhir Rata Rata Waktu

Skenario	Hasil Rata – Rata Waktu (detik)
1	
2	
3	
4	
5	
Hasil Akhir Rata-Rata Waktu	

Tabel akhir rata-rata waktu digunakan untuk merangkum waktu yang dibutuhkan untuk menyelesaikan berbagai skenario dalam pengujian secara keseluruhan. Fungsi utama dari tabel ini adalah untuk memberikan gambaran umum tentang seberapa cepat suatu prototype dapat digunakan dalam berbagai skenario. Dengan memberikan rata-rata waktu per skenario, tabel ini dapat membantu menentukan bagaimana performa keseluruhan dari prototype yang diuji.

$$\text{Hasil Akhir Rata-Rata Waktu} = \frac{\text{total rata-rata waktu per skenario}}{\text{total jumlah skenario}}$$

Tabel 3 Tabel Perhitungan Hasil Akhir Presentase Kesalahan

Skenario	Hasil Presentase Kesalahan
1	
2	
3	
4	
5	
Hasil akhir presentase kesalahan	

Tabel perhitungan akhir presentase kesalahan memberikan gambaran umum tentang tingkat kesalahan yang terjadi selama pengujian berbagai skenario dalam upaya untuk mengevaluasi dan memperbaiki kualitas dan keandalan prototype yang diuji. Tabel ini membantu menganalisis tingkat keberhasilan prototype berdasarkan seberapa sering kesalahan terjadi di setiap skenario yang diuji.

$$\text{Hasil Akhir Presentase Kesalahan} = \frac{\text{total presentase kesalahan per skenario}}{\text{total jumlah skenario}}$$

3. Hasil dan Pembahasan

Hasil Penelitian dari penelitian ini adalah untuk perancangan desain *user interface* dan *user experience* sistem pembayaran SPP berbasis website di SMAS Bhinneka Karawang menggunakan *Human Centered Design*. Pendekatan desain yang berpusat pada manusia ini dilakukan secara sistematis dalam 3 tahap utama, yaitu *inspiration*, *ideation*, dan *implementation*. Berikut adalah hasil detail penelitian:

3.1. Inspiration

Pada tahap ini, kebutuhan pengguna diidentifikasi melalui observasi, wawancara dan studi literatur.

1. Observasi

Hasil observasi yang telah dilakukan menunjukkan ada beberapa masalah dengan sistem manual yang digunakan saat ini, yakni:

1. Proses pencatatan masih dilakukan secara manual, sehingga rentan dengan kesalahan seperti pencatatan ganda, kelalaian input data atau lupa mencatat pembayaran.
2. Operator SMA memakan waktu lama untuk pengelolaan pembayaran SPP dan mempersulit pemantauan data oleh pihak yayasan.
3. Orang tua siswa menghadapi kesulitan mendapatkan informasi terkait status pembayaran dan sisa tunggakan karena sistem manual tidak menyediakan akses tersebut.
4. Operator SMA dan Operator Yayasan merasa terbebani dengan beban administrasi manual yang berulang dan tidak efisien.

2. Wawancara

Wawancara dilakukan dengan tiga kelompok pengguna utama: Orang tua siswa sebagai pihak yang melakukan pembayaran, Operator SMA sebagai administrator harian dan Operator Yayasan sebagai pihak yang melakukan monitoring pembayaran. **Berikut hasil dari wawancara** yang telah dilakukan dapat disimpulkan bahwa Operator SMA membutuhkan fitur pemantauan pembayaran dan tunggakan, Operator Yayasan menginginkan perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP yang terpusat untuk memastikan pengelolaan keuangan yang efisien dan terbuka dan fitur laporan yang mudah diakses untuk memantau pembayaran dan tunggakan siswa, dan Orang Tua Siswa Berharap perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP yang mudah digunakan dan mudah diakses memberikan informasi yang jelas tentang status pembayaran dan detail transaksi.

3. Studi Literatur

Studi Literatur menunjukkan bahwa pendekatan *Human Centered Design* (HCD) berguna untuk meningkatkan pengalaman pengguna. Studi Literatur tersebut menekankan bahwa *Human Centered Design* (HCD) melibatkan pengguna di setiap tahap desain untuk memastikan solusi yang dihasilkan benar-benar memenuhi kebutuhan pengguna. Disarankan juga untuk menggunakan prototipe interaktif dan pengujian usability seperti Cognitive Walkthrough untuk menemukan dan memperbaiki masalah sejak tahap awal.

3.2. Ideation

Penelitian ini merancang solusi berdasarkan hasil dari tahap *Inspiration*, yang mencakup komponen-komponen berikut:

1. Pain Point

Setelah mendapatkan pain point, dari langkah langkah wawancara dengan pengguna, langkah selanjutnya adalah melakukan pengelompokkan masalah tersebut dan membuat kebutuhan pengguna dan juga membuat solusi dari permasalahan tersebut. Dapat dilihat pada Tabel 4 di bawah ini.

Tabel 4 Tabel Pain Point

No	Masalah	Kebutuhan Pengguna	Solusi
1.	Ketidakkuratan pencatatan manual yang menghambat efisiensi administrasi	Perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP yang lebih akurat dan terotomatisasi	Perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP digital dengan fitur pencatatan otomatis dan verifikasi data

2.	Kesulitan memantau status pembayaran	Dashboard yang informatif dan mudah untuk diakses	Fitur pelaporan real time yang menampilkan status pembayaran terbaru
3.	Tidak ada pengingat pembayaran	Notifikasi otomatis untuk pembayaran jatuh tempo	Fitur notifikasi untuk mengingatkan pengguna
4.	Kesulitan mengelola data di tingkat yayasan	Perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP pembayaran SPP terpusat yang memudahkan monitoring data	Implementasi perancangan desain antarmuka pengguna dan pengalaman pengguna sistem pembayaran SPP pembayaran SPP yang terintegrasi yang dapat diakses oleh semua pengguna
5.	Keterbatasan akses informasi untuk orangtua siswa	Perancangan antarmuka yang intuitif dan mudah digunakan	Desain <i>user interface</i> dan <i>user experience</i> yang sederhana dengan menu navigasi yang jelas

2. User Persona

User persona adalah profil pengguna yang menggambarkan kebutuhan dan keinginan pengguna terhadap produk. User persona diciptakan untuk membantu memahami karakter pengguna dan membuat pengalaman pengguna yang menyenangkan.

Gambar 2 User



Persona 1

Gambar 3 User



Persona 2

Gambar 4 User




Persona 3

3. User Flow

User Flow adalah diagram yang menggambarkan langkah-langkah yang diambil pengguna untuk menyelesaikan tugas saat menggunakan suatu produk atau layanan. Dalam penelitian ini, terdapat userflow pengguna untuk melakukan monitoring dan melakukan pembayaran SPP yang dapat dilihat pada gambar 5, gambar 6, gambar 7 & gambar 8


Gambar 5 User Flow



Menu Utama

Penjelasan User Flow Menu Utama : Pengguna mulai mengakses prototipe sistem untuk memulai proses. Lalu, untuk masuk ke prototipe sistem, pengguna harus login. Jika berhasil, prototipe sistem akan memeriksa jenis penggunaannya. Jika pengguna belum memiliki akun, pengguna akan diarahkan untuk membuat akun baru. Jika pengguna tidak memiliki akun, mereka harus memasukkan nama, NIS (Nomor Induk Siswa), password, dan email. Setelah berhasil login, pengguna akan dibawa ke dashboard yang sesuai dengan peran mereka: Orang Tua akan memiliki akses ke Dashboard Orang Tua, Operator SMA akan memiliki akses ke


Dashboard Operator SMA dan Operator Yayasan akan memiliki akses ke Dashboard Operator



Yayasan. Setelah selesai, pengguna akan ke langkah selanjutnya sesuai dengan peran.

Gambar 6 *User Flow* Orang Tua

User Flow Orang Tua : Dashboard Orang Tua akan Menampilkan informasi siswa, lalu masuk fitur pembayaran, Orang tua akan memilih bulan, muncul nomor virtual account, dan mengirimkan bukti transfer, lalu riwayat pembayaran: Orang tua dapat melihat riwayat transaksi yang telah dilakukan jika ya maka orang tua akan melakukan Cetak Kwitansi, Orang Tua dapat mencetak kwitansi setelah Operator SMA berhasil validasi pembayaran, dan pemberitahuan



akan dikirim apabila operator SMA sudah mengirim tengat pembayaran SPP per bulan nya.

Gambar 7 *User Flow* Operator SMA

User Flow Operator SMA : Dashboard akan menampilkan daftar siswa, kemudian masuk ke rekap bayar, jika ya Operator SMA akan memvalidasi dan merekap pembayaran siswa, pengaturan pembayaran Operator SMA dapat mengatur dan mengirim pemberitahuan kepada Orang Tua dan Operator SMA dapat mengubah pengaturan akun, termasuk mengubah password.

Gambar 8 User Flow Operator Yayasan

User Flow Operator Yayasan : Dashboard yang dirancang untuk operator yayasan, Operator yayasan dapat melihat laporan dan Laporan dapat dicetak. Jika tidak ada tindakan lanjutan, setiap proses diakhiri dengan status selesai.

3.3 Implementation

1. Desain Antarmuka


1. Splash Screen




Tahap Akhir

Gambar 9 User Interface Splash Screen

Splash screen adalah yang muncul saat pengguna sistem pembayaran SPP berfungsi sebagai pengantar logo atau nama aplikasi dapat langsung. Selain itu, splash screen waktu untuk menyiapkan belakang, seperti melakukan server atau memuat data, mulai menggunakan prototipe sistem pembayaran SPP berbasis web. Meskipun bersifat



tampilan pertama membuka prototipe berbasis web. Ini visual, menampilkan sehingga pengguna mengenalinya. memberi aplikasi proses teknis di latar koneksi dengan sebelum pengguna



sementara, splash screen memberikan kesan pertama yang lebih profesional dan membantu membangun branding Sistem Pembayaran.

2. Registrasi

Gambar 10 User Interface Registrasi

Untuk pengguna baru yang ingin menggunakan prototipe sistem pembayaran SPP berbasis web, registrasi adalah proses di mana mereka diminta untuk memasukkan informasi pribadi seperti nama wali, alamat email, kata sandi, nomor induk siswa dan nomor telepon. prototipe sistem pembayaran SPP berbasis web dapat mengidentifikasi pengguna dan memberikan akses ke informasi pribadi, seperti informasi siswa, riwayat pembayaran dan informasi lainnya. Proses registrasi juga melindungi data pengguna dan mencegah orang yang tidak berwenang mengakses akun mereka. melindungi data orang yang tidak menyalahgunakan

3. Login

Gambar 11 User



Interface Login


Pada tahap login, pengguna yang sudah terdaftar memasukkan informasi pribadi mereka, seperti email dan kata sandi, untuk mengakses prototipe sistem pembayaran SPP berbasis web. Proses ini dilakukan untuk memverifikasi identitas pengguna dan memastikan bahwa hanya pengguna yang terdaftar yang dapat mengakses data dan fitur sistem pembayaran. Setelah login, pengguna dapat melihat status pembayaran mereka, jumlah yang harus dibayar, dan riwayat pembayaran.

Role Orang Tua Siswa

a. Dashboard

Gambar 12 User Interface Dashboard Ortu

Dashboard orang tua siswa adalah fitur untuk membantu orang tua mengelola kewajiban pembayaran SPP anak dalam sistem pembayaran SPP berbasis informasi yang jelas dan nominal pembayaran, serta dan notifikasi, dashboard ini mengurangi kebingungan dan pembayaran dilakukan tepat memberikan rasa aman bagi proses administrasi



prototipe sistem web. Menampilkan transparan tentang kemudahan akses dapat membantu memastikan waktu, sekaligus orang tua selama pendidikan.

a. Sidebar

Gambar 13 User Interface Sidebar Ortu

NIS	Nama Siswa	Bulan	Pembayaran	Tanggal	Aksi
NIS005	Jaya	Januari	250.000	5	Cetak Riwayat

Sidebar orang tua siswa karena membantu navigasi akses cepat ke berbagai fitur ada di dalam prototipe

sangat penting dan mendapatkan atau informasi yang sistem.

b. Halaman Pembayaran

Gambar 14 User Interface Pembayaran Ortu

Dalam prototipe sistem pembayaran SPP berbasis web, halaman pembayaran SPP memiliki alur yang memudahkan orang tua kewajiban pembayaran dan terorganisir.

c. Halaman Riwayat

Gambar 15 User

Pembayaran

Interface Riwayat Ortu


Fungsi utama prototipe SPP berbasis web adalah orang tua atau wali siswa mengelola transaksi telah mereka lakukan. Pembayaran muncul setiap memberikan informasi yang pembayaran SPP. Ini juga

sistem pembayaran untuk membantu melacak dan pembayaran yang Halaman Riwayat bulan dan jelas tentang status memungkinkan orang

tua untuk mencetak kwitansi sebagai bukti pembayaran.

d. Halaman Pemberitahuan Pembayaran

Gambar 16 *User Interface* Pemberitahuan Ortu



Halaman pemberitahuan prototipe sistem berbasis web memudahkan sekolah dan orang tua dan menjaga administrasi keuangan sekolah tetap lancar. Selain itu, halaman ini memberikan kenyamanan dan keyakinan kepada orang tua bahwa mereka akan memenuhi kewajiban pembayaran mereka.

pembayaran dalam pembayaran SPP komunikasi antara

Role Operator SMA

a. Dashboard

Gambar 17 *User*



Interface Dashboard Operator SMA

Dashboard operator SMA dirancang untuk mempermudah pengelolaan data siswa di prototipe sistem pembayaran SPP berbasis web dan memastikan bahwa informasi yang ada bersifat akurat dan up-to-date, sehingga proses pembayaran dapat dilakukan dengan lancar.

b. Halaman Pembayaran

Gambar 18 *User Interface* Pembayaran Operator SMA

DATA SISWA									
Tambah Data									
NIS	Nama Siswa	Kelas	Alamat	Jumlah Bayar	Tanggal Lahir	Rekening	Virtual Account	Aksi	
MS001	Budi Santoso	10	J. Kertajaya No. 25	200000	2000-11-23	2500000	VA001	Edit	Hapus
MS002	Siti Aminah	11	J. Kertajaya No. 1	200000	2000-08-20	2500000	VA002	Edit	Hapus
MS003	Anul Kurniawan	12	J. Kertajaya No. 17	400000	1970-12-25	3000000	VA003	Edit	Hapus
MS004	Budi Santoso	12	J. Kertajaya No. 10	200000	2000-08-20	2500000	VA004	Edit	Hapus

Halaman pembayaran memiliki banyak fitur yang memudahkan pengelolaan administrasi pembayaran SPP di sekolah, seperti validasi pembayaran menggunakan bukti transfer, data pembayaran lunas, dan data tunggakan. Fitur-fitur ini memastikan bahwa setiap pembayaran terverifikasi dengan benar.

c. Pengaturan Pemberitahuan


Gambar 19 User Interface Pengaturan Operator SMA



Halaman pengaturan pembayaran SPP dalam pembayaran SPP berbasis pemberitahuan prototipe sistem pembayaran SPP membantu operator sekolah mengatur dan mengelola pengingat pembayaran SPP secara web dirancang untuk otomatis. Fitur ini memungkinkan pengaturan notifikasi agar orang tua atau siswa diberitahu tentang tenggat waktu pembayaran, sehingga mereka dapat mengurangi keterlambatan pembayaran dan menjaga administrasi keuangan mereka tetap lancar.

d. Pengaturan Akun

Gambar 20 User Interface Operator SMA




Interface Akun

Fungsi pengaturan akun ini sangat penting untuk menjaga keamanan sistem, mengelola hak akses, dan memastikan bahwa pengguna dapat dengan mudah memperbarui informasi akun mereka ketika diperlukan.

Role Operator Yayasan

a. Dashboard

Gambar 21 User Interface Yayasan



Dashboard Operator

Tujuan dari dashboard operator yayasan pada prototipe sistem pembayaran SPP berbasis web adalah untuk mempermudah pengelolaan dan pemantauan pembayaran SPP di sekolah. Dashboard akan menampilkan informasi penting tentang status pembayaran SPP siswa, seperti berapa banyak siswa yang masih memiliki tunggakan, dan berapa total pembayaran yang sudah dibayar.

b. Laporan Pembayaran

Gambar 22 *User Interface* Laporan Operator Yayasan

Untuk operator yayasan, fitur laporan pembayaran pada prototipe sistem pembayaran SPP berbasis web memainkan peran penting dalam memberikan informasi yang lengkap, terorganisir, dan akurat tentang status pembayaran SPP. Laporan siswa yang sudah bayar adalah salah satu laporan yang paling penting, yang memungkinkan operator yayasan untuk monitoring pembayaran yang telah dilakukan oleh siswa.

2. Pengujian Cognitive

Pada tahap penelitian ini, pengujian atau testing potensi masalah pada Pengujian ini dilakukan pengguna yang sudah pada awal penelitian. menggunakan laptop untuk antarmuka pengguna dan *broadcast software* (OBS)

pengujian. Pada pengujian *cognitive walkthrough* ini terdapat beberapa skenario yang berbeda untuk setiap role nya. Sesuai dengan pendapat Nielsen (2000) dalam melakukan pengujian terhadap pengguna, cukup tidak lebih dari lima orang pengguna untuk dapat menghasilkan antarmuka pengguna yang memuaskan. Menurut Maulana (2020) pengguna dinyatakan berhasil menjalankan skenario ketika pengguna menyelesaikan skenario kurang dari lima belas detik dan kesalahan yang dilakukan pada saat menjalankan skenario kurang dari tiga kali kesalahan dan batas kesalahan untuk setiap skenario adalah 50%. Berikut adalah skenario yang diujikan.

Setelah melakukan skenario pada orang tua siswa yang harus diselesaikan, berikut adalah keseluruhan dari hasil akhir pengujian. Hasil akhir rata-rata dari ketiga skenario orang tua siswa dapat dilihat pada tabel 5

1. Skenario Registrasi dan Login Orang Tua Siswa

Tabel 4.6 Tabel Skenario 1 Registrasi dan Login Orang Tua Siswa

Laporan Pembayaran SPP			
Januari			
Print Laporan Januari			
NIS	Nama Siswa	Bulan	Jumlah Bayar
NIS001	Budi Santoso	Januari	Rp. 250.000
NIS002	Siti Aminah	Januari	Rp. 300.000
NIS003	Andi Kurniawan	Januari	Rp. 300.000
NIS005	Jaya	Januari	Rp. 250.000
Total Pembayaran			Rp. 1.100.000

Walkthrough

saya melakukan untuk mengidentifikasi antarmuka pengguna. kepada empat melakukan wawancara Pengujian menjalankan menggunakan *open* untuk merekam proses

Goals	Melakukan Registrasi dan Login
Skenario	Anda adalah orang tua siswa yang baru pertama kali menggunakan aplikasi. Langkah pertama adalah registrasi dengan mengisi formulir (nama, email, password, NIS). Setelah berhasil registrasi, Anda kembali ke halaman login dan masuk dengan email dan password yang baru dibuat untuk mengakses prototipe sistem pembayaran SPP berbasis web

Hasil pengujian pada skenario pertama adalah pengguna dapat membuat akun dan login dengan mudah. Berikut adalah hasil pengujian pada skenario pertama yang dapat dilihat pada **tabel 4.7 Hasil Pengujian Skenario 1 Ortu dibawah**

2. Skenario Pembayaran SPP Orang Tua Siswa

	Partisipan	Indikator Pengujian		
		Registrasi dan Login	Waktu (detik)	Kesalahan
Goals	Orang Tua Siswa	Melakukan Pembayaran SPP		
Skenario	1	✓	10	0
	2	✓	13	0
	3	✓	11	0
	4	✓	9	0
	5	✓	8	0
	6	✓	11	0
	Jumlah Partisipan yang berhasil	6	Rata – Rata = 10,3 detik	
Presentase				
Keberhasilan	100%			0%

	berbasis web, dan mencetak kwitansi setelah pembayaran diverifikasi.
--	--

Tabel 4.8 Tabel Skenario 2 Pembayaran SPP Orang Tua Siswa

Hasil pengujian pada skenario kedua adalah pengguna dapat melakukan pembayaran dengan mudah. Berikut adalah hasil pengujian pada skenario kedua yang dapat dilihat pada **tabel 4.9 Hasil Pengujian Skenario 2 Ortu Dibawah**

Partisipan	Indikator Pengujian		
	Melakukan Pembayaran SPP	Waktu (detik)	Kesalahan
1	✓	12	0
2	✓	14	0
3	✓	14	0
4	✓	13	0
5	✓	13	0
6	✓	13	0
Jumlah Partisipan yang berhasil	6	Rata – Rata = 13,1 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

3. Skenario Riwayat Pembayaran SPP Orang Tua Siswa

Tabel 4.10 Tabel Skenario 3 Riwayat Pembayaran Orang Tua Siswa

Goals	Memeriksa Riwayat Pembayaran dan Tunggakan
Skenario	Anda adalah orang tua siswa yang ingin memantau status pembayaran. Setelah login, Anda membuka menu "Riwayat Pembayaran," melihat daftar pembayaran yang telah dilakukan dan total tunggakan yang belum dibayar. Anda

	juga dapat mencetak laporan riwayat pembayaran dalam format PDF.
--	--

Hasil pengujian pada skenario ketiga adalah pengguna dapat memeriksa riwayat pembayaran dengan mudah. Berikut adalah hasil pengujian pada skenario ketiga yang dapat dilihat pada **tabel 4.11 Hasil Pengujian Skenario 3 Riwayat Pembayaran Ortu Dibawah**

Partisipan	Indikator Pengujian		
	Riwayat Pembayaran	Waktu (detik)	Kesalahan
1	✓	7	0
2	✓	6	0
3	✓	4	0
4	✓	5	0
5	✓	4	0
6	✓	3	0
Jumlah Partisipan yang berhasil	6	Rata – Rata = 4,8 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

Setelah melakukan ketiga skenario yang harus diselesaikan oleh pengguna, berikut adalah keseluruhan dari hasil akhir pengujian. Hasil akhir rata-rata dari ketiga skenario dapat dilihat pada **tabel 4.12**

Tabel 4.12 Tabel Hasil Akhir Rata Rata Waktu Orang Tua Siswa

Skenario	Hasil Rata – Rata Waktu (detik)
1	10,1
2	13,1
3	4,8
Hasil Akhir Rata-Rata Waktu	9,3

Hasil akhir rata rata presentasi kesalahan dari ketiga skenario dapat dilihat pada **tabel 4.13**

Tabel 4.13 Hasil Akhir Presentase Kesalahan Orang Tua Siswa

Skenario	Hasil Presentase Kesalahan
1	0
2	0
3	0
Hasil Akhir Presentase Kesalahan	0%

1. Skenario Login dan Dashboard Operator SMA

Tabel 4.14 Tabel Skenario 1 Login dan Dashboard Operator SMA

Goals	Melakukan Login dan Mengelola Data Siswa
Skenario	Anda adalah operator SMA yang bertugas memastikan data siswa selalu mutakhir. Anda perlu login terlebih dahulu, otomatis halaman utama, yaitu dashboard "Data Siswa" lalu melakukan pengelolaan data (tambah, edit, hapus, dan pencarian siswa). Langkah-langkahnya meliputi login menggunakan akun operator, mengisi kolom yang diperlukan untuk menambah data siswa, memperbarui data siswa yang sudah ada, dan menghapus data tertentu sambil memastikan sistem meminta konfirmasi sebelum penghapusan. Anda juga perlu menggunakan fitur pencarian untuk memeriksa data siswa berdasarkan nama atau ID.

Hasil pengujian pada skenario pertama adalah pengguna dapat login dengan mudah.

Berikut adalah hasil pengujian pada skenario pertama yang dapat dilihat pada **tabel**

4.15 Hasil Pengujian Skenario 1 Login dan Dashboard Operator SMA

Partisipan	Indikator Pengujian		
	Login	Waktu (detik)	Kesalahan
1	✓	8	0
2	✓	6	0
3	✓	6	0
4	✓	3	0

5	✓	4	0
6	✓	5	0
Jumlah Partisipan yang berhasil	5	Rata – Rata = 5,3 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

2. Skenario Validasi Pembayaran Operator SMA

Tabel 4.16 Tabel Skenario 2 Validasi Pembayaran Operator SMA

Goals	Melakukan Validasi Pembayaran Siswa
Skenario	Anda adalah operator SMA yang bertugas memvalidasi pembayaran siswa. Setelah login ke sistem, Anda membuka menu "Rekap Bayar" untuk memeriksa status pembayaran siswa. Langkah-langkah meliputi memilih siswa yang membayar, klik tombol "Verifikasi," lalu melihat daftar siswa yang sudah membayar dan yang belum. Anda juga dapat mencetak laporan data pembayaran berdasarkan status pembayaran siswa.

Hasil pengujian pada skenario kedua adalah pengguna dapat memvalidasi pembayaran dengan mudah. Berikut adalah hasil pengujian pada skenario kedua yang dapat dilihat pada **tabel 4.17**

Tabel 4.17 Hasil Pengujian Skenario 2 Validasi Pembayaran Operator SMA

Partisipan	Indikator Pengujian		
	Validasi Pembayaran	Waktu (detik)	Kesalahan
1	✓	11	0
2	✓	5	0
3	✓	8	0
4	✓	4	0
5	✓	4	0

6	✓	6	0
Jumlah Partisipan yang berhasil	5	Rata – Rata = 6,3 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

3. Skenario Notifikasi Operator SMA

Tabel 4.18 Tabel Skenario 3 Notifikasi Operator SMA

Goals	Mengatur Notifikasi Pembayaran untuk Orang Tua Siswa
Skenario	Anda adalah operator SMA yang harus mengatur pengingat pembayaran untuk orang tua siswa. Setelah login, Anda membuka menu "Pengaturan Notifikasi," menentukan jadwal pengiriman (tanggal dan waktu), menambahkan pesan pengingat, dan menyimpannya. Anda memastikan bahwa pesan notifikasi terkirim ke orang tua siswa sesuai jadwal yang ditentukan.

Hasil pengujian pada skenario ketiga adalah pengguna dapat mengatur pengaturan notifikasi dengan mudah. Berikut adalah hasil pengujian pada skenario kedua yang dapat dilihat pada **tabel 4.19 Hasil Pengujian Skenario 3 Pengaturan Pemberitahuan Operator SMA**

Partisipan	Indikator Pengujian		
	Pengaturan Pemberitahuan	Waktu (detik)	Kesalahan
1	✓	14	0
2	✓	13	0
3	✓	13	0
4	✓	8	0
5	✓	9	0

6	✓	8	0
Jumlah Partisipan yang berhasil	5	Rata – Rata = 10,8 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

Setelah melakukan ketiga skenario yang harus diselesaikan oleh pengguna, berikut adalah keseluruhan dari hasil akhir pengujian. Hasil akhir rata-rata dari ketiga skenario dapat dilihat pada **tabel 4.20**

Tabel 4.20 Tabel Hasil Akhir Rata Rata Waktu Operator SMA

Skenario	Hasil Rata – Rata Waktu (detik)
1	5,3
2	6,3
3	10,8
Hasil Akhir Rata-Rata Waktu	7,4 detik

Hasil akhir rata rata presentasi kesalahan dari ketiga skenario dapat dilihat pada **tabel 4.21**

Tabel 4.21 Hasil Akhir Presentase Kesalahan Operator SMA

Skenario	Hasil Presentase Kesalahan
1	0
2	0
3	0
Hasil Akhir Presentase Kesalahan	0%

1. Skenario Login dan Dashboard Operator Yayasan

Tabel 4.22 Tabel Skenario 1 Login dan Dashboard Operator Yayasan

Goals	Melakukan Login dan Memantau Data Pembayaran melalui Dashboard
Skenario	Anda adalah operator yayasan yang bertugas memantau pembayaran siswa. Setelah login menggunakan akun yayasan, Anda mengakses dashboard yang menampilkan informasi seperti total pembayaran, total tunggakan, dan daftar siswa yang menunggak.

Hasil pengujian pada skenario pertama adalah pengguna dapat melakukan login dan memantau data pembayaran melalui dashboard dengan mudah. Berikut adalah hasil pengujian pada skenario kedua yang dapat dilihat pada **tabel 4.23 Hasil Pengujian Skenario 1 Login dan Dashboard Operator Yayasan**

Partisipan	Indikator Pengujian		
	Login dan Dashboard	Waktu (detik)	Kesalahan
1	✓	3	0
2	✓	7	0
3	✓	5	0
4	✓	5	0
5	✓	6	0
6	✓	5	0
Jumlah Partisipan yang berhasil	5	Rata – Rata = 5,1 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

2. Skenario Laporan Operator Yayasan

Tabel 4.24 Tabel Skenario 2 Laporan Operator Yayasan

Goals	Melihat Laporan Pembayaran dan Tunggakan Siswa
--------------	--

Skenario	Anda adalah operator yayasan yang membuat laporan pembayaran SPP siswa untuk keperluan monitoring. Setelah login, Anda membuka menu "Laporan," memilih periode waktu tertentu, lalu mencetak laporan dalam format PDF atau Excel untuk disimpan sebagai arsip yayasan.
-----------------	--

Hasil pengujian pada skenario kedua adalah pengguna dapat melihat laporan dengan mudah. Berikut adalah hasil pengujian pada skenario kedua yang dapat dilihat pada **tabel 4.25 Hasil Pengujian Skenario 2 Laporan Operator Yayasan**

Setelah melakukan kedua skenario yang harus diselesaikan oleh pengguna, berikut

Partisipan	Indikator Pengujian		
	Laporan	Waktu (detik)	Kesalahan
1	✓	5	0
2	✓	10	0
3	✓	7	0
4	✓	6	0
5	✓	6	0
6	✓	7	0
Jumlah Partisipan yang berhasil	5	Rata – Rata = 6,8 detik	Presentase Kesalahan = 0%
Presentase Keberhasilan	100%		

adalah keseluruhan dari hasil akhir pengujian. Hasil akhir rata-rata dari ketiga skenario dapat dilihat pada **tabel 4.26**

Tabel 4.26 Tabel Hasil Akhir Rata Rata Waktu Operator Yayasan

Skenario	Hasil Rata – Rata Waktu (detik)
1	5,1
2	6,8
Hasil Akhir Rata-Rata Waktu	5,95

Hasil akhir rata rata presentasi kesalahan dari ketiga skenario dapat dilihat pada **tabel 4.27**

Skenario	Hasil Presentase Kesalahan
1	0
2	0
Hasil Akhir Presentase Kesalahan	0%

Hasil Pengujian:

Hasil pengujian terhadap prototipe sistem pembayaran SPP berbasis website menunjukkan bahwa sistem ini berhasil digunakan oleh seluruh partisipan pengujian tanpa mengalami kendala. Pengujian dilakukan menggunakan metode *Cognitive Walkthrough*, di mana pengguna menjalankan beberapa skenario tugas untuk menilai efektivitas dan efisiensi prototipe sistem.

Tingkat keberhasilan pengguna dalam menyelesaikan tugas mencapai 100%, yang menunjukkan bahwa prototipe sistem dapat digunakan tanpa hambatan besar. Selain itu, waktu yang dibutuhkan untuk menyelesaikan skenario juga cukup cepat, dengan operator yayasan rata-rata menyelesaikan tugas dalam 5,95 detik, sementara orang tua siswa membutuhkan 9,3 detik. Hasil ini menandakan bahwa navigasi sistem mudah dipahami dan proses transaksi dapat dilakukan dengan cepat.

Selama pengujian, tidak ditemukan kesalahan yang signifikan dalam penggunaan sistem, dengan tingkat kesalahan sebesar 0%. Fitur-fitur utama, seperti riwayat transaksi, pencetakan bukti pembayaran, dan notifikasi pembayaran, berfungsi dengan baik sesuai dengan skenario yang telah dirancang.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan untuk penelitian ini, ialah sebagai berikut :

1. Telah menerapkan pendekatan *Human Centered Design* sesuai dengan langkah langkah. inspiration berupa observasi, wawancara dan studi literatur. ideation berupa pain point, user persona, userflow dan wireframe dan implementasi berupa desain tahap akhir.
2. Evaluasi pengguna yang dilakukan menggunakan metode *cognitive walkthrough* menunjukkan bahwa sistem pembayaran SPP ini dapat diterima dengan baik oleh pengguna. Dibuktikan dengan tingkat keberhasilan penyelesaian skenario mencapai 100%, rata rata waktu penyelesaian skenario oleh pengguna adalah kurang dari 15 detik per skenario dan presentasi kesalahan rata rata 0% pada semua skenario yang diuji. Pengujian ini juga mengidentifikasi beberapa area yang membutuhkan perbaikan untuk meningkatkan antarmuka pengguna dan pengalaman pengguna lebih lanjut, namun secara keseluruhan, hasil evaluasi menunjukkan bahwa desain yang ada sudah memenuhi kebutuhan pengguna.

Namun demikian, penelitian ini memiliki beberapa batasan yang perlu diperhatikan:

1. Studi terbatas pada satu institusi yaitu SMAS Bhineka Karawang.
2. Penelitian hanya berfokus pada aspek desain antarmuka dan pengalaman pengguna, tidak mencakup implementasi teknis atau pengembangan perangkat lunak secara menyeluruh.
3. Evaluasi dilakukan dalam ruang lingkup terbatas, sehingga pengujian lebih lanjut dengan skala pengguna yang lebih besar dapat memberikan gambaran yang lebih komprehensif.

References

- [1] Sanjaya, M. R., Ruskan, E. L., Putra, B. W., Ismail, A. A., Maula, N. I., Saputra, A., & Khoiriah, A. (2024). Perancangan aplikasi akademik pembayaran Sumbangan Pembinaan Pendidikan menggunakan metode User Centered Design (UCD). *Nusantara Journal of Multidisciplinary Science*, Juni.
- [2] Muslimin, W., & Zuraidah, E. (2023). Desain UI/UX prototype SPP metode Human Centered Design. *KLIK: Kajian Ilmiah Informatika dan Komputer*, Oktober.
- [3] Karlina, D., & Indah, D. R. (2022). Perancangan user interface dan user experience sistem informasi e-learning menggunakan design thinking. *Jurnal Teknik Informatika dan Sistem Informasi*, 8(3). Desember

Kruskal-Wallis Analysis of CNN Architecture Performance on CT Image Lung Nodule Classification

Sekar Sari^{a1}, Kevin Ilham Apriandy^{b2}, Yerezqy Bagus^{b3}

^aProgram Studi D3 Teknologi Listrik, Politeknik Internasional Tamansiswa Mojokerto
Kota Mojokerto, Jawa Timur, Indonesia
¹sekarsari103@gmail.com

^bProgram Studi D3 Teknologi Komputer, Politeknik Internasional Tamansiswa Mojokerto
Kota Mojokerto, Jawa Timur, Indonesia
²kevinapriandy@gmail.com
³yerezqybagus2@gmail.com

Abstract

CT lung image detection and classification with a Convolutional Neural Network (CNN) is an important step toward assisting radiologists faster and more precisely. CNN comprises various architectures with different characteristics and layer structures, which influence the test results. In addition, the number of epochs used during the training process has an impact on the performance of each CNN architecture. Testing variations throughout the same number of epochs on the CNN architecture yields various results depending on the analytic parameters of accuracy, precision, sensitivity, specificity, and F1-Score. The test results still do not provide statistical information on the performance of the CNN architecture in the classification of lung nodules on CT images. This study conducted a non-parametric statistical test, the Kruskal-Wallis test, to explore if there was a significant difference in the performance of the CNN architecture in classifying lung nodules from CT scan images. The results showed that the Asymp. Sig. Value for the five unpaired variables <0.05, including accuracy 0.002, precision 0.000, sensitivity 0.000, specificity 0.001, and F1-score 0.000, meaning that the hypothesis decision is accepted. In the classification of multiclass lung cancer CT images, the CNN architectures ResNet50, EfficientNetB1, MobileNetV2, VGG16, and AlexNet have considerably different average accuracy, precision, sensitivity, specificity, and F1-scores. Accordingly, after evaluating the CNN architecture with different numbers of epochs, it is known that each CNN design requires a distinct number of epochs to achieve the best test results.

Keywords: Performance, Kruskal-Wallis Test, Non-Parametric Test, CNN Architecture, Epoch Variations

1. Pendahuluan

Kanker paru adalah masalah kesehatan yang menyerang organ paru-paru dimana sel-sel abnormal mulai berkembang secara tidak terkendali [1]. Kanker paru-paru sering didiagnosis pada tahap lanjut, karena gejalanya bisa berkembang perlahan dan tidak spesifik. Deteksi dini pemeriksaan radiologi sangat penting untuk meningkatkan kelangsungan hidup pasien, seperti (*computed tomography*) CT scan [2]. Setelah beberapa dekade, pemeriksaan dini kanker paru menggunakan CT scan banyak dilakukan, karena CT scan merupakan modalitas citra terbaik untuk deteksi dini kanker paru dan analisis nodul [3][4]. Hasil pemeriksaan dengan resolusi citra yang bagus dan detail menjadikan deteksi nodul paru menggunakan CT scan lebih efektif dilakukan [5], sehingga semakin banyak citra CT yang terakumulasi di rumah sakit untuk memerlukan diagnosis lebih lanjut oleh ahli radiologi. Namun proses deteksi dengan jumlah citra yang sangat besar akan menghabiskan waktu dan tenaga, Selain itu kesalahan dalam proses deteksi nodul menjadi lebih rawan meningkat [1].

Deteksi nodul paru berbasis sistem komputer atau *Computer-Aided Detection* (CAD) telah dikembangkan setiap tahunnya untuk membantu ahli radiologi dalam menangani kasus penyakit kanker paru [6]. Dengan adanya sistem CAD membantu ahli radiologi menginterpretasikan citra medis. Skema CAD sangat dibutuhkan untuk berbagai tugas deteksi seperti deteksi lesi, segmentasi lesi tubuh dan analisis patologis dengan teknik pengolahan citra dan algoritme *machine learning* [1]. Sistem CAD

mampu meningkatkan efisiensi deteksi dan diagnosis serta memperbaiki beberapa kemungkinan kesalahan [3][7][8]. Kondisi tersebut memotivasi banyak peneliti mengembangkan sistem CAD untuk kinerja unggul dalam deteksi nodul paru. Sebagai terobosan modern, sistem CAD dengan *deep learning* telah dikembangkan pada beberapa tahun terakhir hingga sekarang ini, dengan harapan mampu meningkatkan proses pengenalan pola struktur paru dari segi kecepatan maupun keakuratan. Salah satu metode *deep learning* yang sudah digunakan oleh banyak peneliti dalam deteksi maupun klasifikasi citra paru yaitu *Convolutional Neural Network* (CNN) [1][9][10].


Pada tugas deteksi dan klasifikasi penyakit paru-paru, CNN terdiri dari berbagai arsitektur dengan karakteristik dan struktur layer yang berbeda, yang dapat mempengaruhi hasil pengujian. Selain itu penggunaan jumlah *epoch* dalam proses pelatihan juga berpengaruh terhadap performa kinerja dari setiap arsitektur CNN. *Epoch* adalah nilai yang digunakan dalam pelatihan untuk mengembalikan proses pelatihan kembali ke awal, proses ini dilakukan ketika *neural network* telah selesai melatih keseluruhan dataset dalam sekali pelatihan dari dataset awal hingga akhir. Penggunaan jumlah *epoch* dalam proses pelatihan akan mempengaruhi performa kinerja dari hasil pengujian model atau arsitektur [5]. Untuk mengetahui jumlah *epoch* yang dibutuhkan oleh sebuah model maka perlu dilakukan pengujian variasi jumlah *epoch*.

Pengujian variasi jumlah *epoch* yang sama terhadap arsitektur CNN memberikan hasil yang bervariasi, dan hasilnya menunjukkan adanya perbedaan performa yang ditinjau dari parameter analisis seperti akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*. Diketahui terdapat tiga arsitektur dengan performa baik dan dua arsitektur dengan performa kurang baik. Meskipun hasil pengujian memberikan indikasi awal tentang perbedaan kinerja antar arsitektur CNN, namun belum sepenuhnya memberikan dasar statistik yang cukup kuat untuk mendukung validitas kesimpulan yang diambil. Oleh karena itu, penerapan uji statistik menjadi penting dilakukan untuk menguji hipotesis secara objektif, mengukur signifikansi perbedaan performa antar arsitektur dan memastikan kesimpulan yang diperoleh benar yang didasarkan pada data kuantitatif yang valid. Berdasarkan latar belakang tersebut, penelitian ini melakukan uji beda statistik non parametrik Kruskal-Wallis untuk mengevaluasi apakah terdapat perbedaan yang signifikan performa kinerja antar arsitektur CNN— ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan nodul paru dari citra CT-scan.

2. Metode Penelitian

Penelitian ini merupakan penelitian yang menggunakan teknik analisis non-parametrik Kruskal-Wallis untuk mengetahui perbedaan signifikan terhadap performa kinerja arsitektur CNN dalam mengklasifikasikan citra CT kanker paru. Data yang digunakan pada penelitian ini diambil dari hasil pengujian arsitektur CNN berdasarkan jumlah *epoch* yang berjumlah 25 data. Sebelum melakukan uji statistik non-parametrik, dilakukan uji normalitas untuk mengetahui data sampel berdistribusi normal atau tidak. Data yang digunakan dalam penelitian ini < 50 , sehingga uji normalitas menggunakan Uji Shapiro-Wilk. Pengujian uji normalitas Shapiro-Wilk dan uji statistik non-parametrik Kruskal-Wallis dilakukan menggunakan perangkat lunak IBM SPSS Statistics 25.


Metode penelitian ini ditunjukkan pada Gambar 1, yang terdiri dari studi literatur, identifikasi uji statistik yang digunakan, uji normalitas, uji beda statistik non-parametrik, uji hipotesis dan kesimpulan. Studi literatur adalah proses membaca, menganalisis dan menentukan metode yang relevan untuk digunakan pada penelitian ini. Identifikasi uji statistik yang digunakan adalah proses menentukan metode yang tepat untuk digunakan pada penelitian ini berdasarkan data sampel yang ada dan tujuan yang akan dicapai. Uji normalitas adalah proses pengujian untuk mengetahui data berdistribusi normal atau tidak, sehingga dapat ditentukan uji selanjutnya yang tepat berdasarkan distribusi data penelitian. Uji beda statistik non-parametrik adalah proses pengujian untuk mengetahui apakah terdapat perbedaan yang signifikan terhadap performa kinerja antar arsitektur CNN dalam mengklasifikasikan nodul paru dari citra CT-scan. Uji hipotesis adalah pengujian untuk menentukan apakah hipotesis ditolak atau diterima. Kesimpulan adalah hasil akhir yang didukung oleh hasil uji hipotesis dan pembahasan yang telah disampaikan.



Gambar 1. *Flowchart* Metode Penelitian

2.1. Uji Normalitas Shapiro-Wilk

Uji normalitas bertujuan untuk mengetahui apakah data berdistribusi normal atau tidak normal [11]. Uji normalitas yang digunakan adalah uji Shapiro-Wilk untuk jumlah sampel data yang berukuran kecil < 50 [12][13]. Gambar 2 menunjukkan *flowchart* uji normalitas Shapiro-Wilk. Dalam proses pengujian ini, langkah pertama adalah *input* data yang berjumlah 25 data hasil pengujian arsitektur CNN. Langkah kedua dilakukan pengujian menggunakan uji Shapiro-Wilk. Data dapat dikatakan berdistribusi normal jika memiliki nilai signifikansi $> 0,05$ [11].



Gambar 2. *Flowchart* Uji Normalitas Shapiro-Wilk

2.2. Uji Statistik Non-Parametrik Kruskal-Wallis

Uji statistik non-parametrik merupakan suatu metode analisis data yang tidak memerlukan persyaratan bahwa data berdistribusi normal. Pengujian ini hanya menentukan persyaratan atau memberikan asumsi bahwa data yang diperoleh bersifat *independent* dan variabel yang diteliti memiliki kontinuitas [14]. Uji Kruskal-Wallis adalah uji statistik non-parametrik untuk menentukan perbedaan signifikan antar kelompok *variable independent* yang lebih dari dua. Uji Kruskal-Wallis merupakan alternatif dari uji One Way ANOVA (*Analysis of Variance*) yang digunakan untuk mengetahui apakah terdapat perbedaan rata-rata data yang lebih dari dua atau minimal tiga kelompok *independent*. Uji Kruskal-Wallis dilakukan pada data yang berdistribusi tidak normal dan *unpaired variable*. Uji Kruskal-Wallis dituliskan dalam persamaan (1) [15]:

$$K = (N - 1) \frac{\sum_{i=1}^g n_i (r_i - r)^2}{\sum_{i=1}^g \sum_{j=1}^{n_i} (r_{ij} - r)^2} \quad (1)$$

Dengan,

n_i : jumlah pengamatan dalam kelompok

r_{ij} : peringkat (diantara semua pengamatan) pengamatan j dari kelompok i

N : jumlah pengamatan di semua kelompok

Sedangkan persamaan untuk menentukan peringkat (diantara semua pengamatan) dituliskan dalam persamaan (2) [14]:

$$r = \frac{\sum_{j=1}^{n_i} r_{ij}}{n_i} \quad (2)$$

Hipotesis

H_0 : $\mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$

H_1 : tidak semua μ_i sama, dimana $i = 1, 2, 3, 4, 5$ (ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet).

Dengan tingkat signifikansi $\alpha = 5\% = 0,05$ adalah bilangan yang mencerminkan besarnya peluang menolak H_0 ketika H_1 bernilai benar. Apabila nilai $p\text{-value} \leq \alpha$ maka penolakan terhadap H_0 dan sebaliknya apabila $p\text{-value} > \alpha$ maka penerimaan H_0 [16]. *Flowchart* Uji Kruskal-Wallis ditunjukkan pada Gambar 3.


2.3. Uji Hipotesis Penelitian

Hipotesis dalam penelitian ini;

H_0 : Tidak ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifisitas dan F1-score antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet dalam klasifikasi nodul paru pada citra CT multiclass

H_1 : Ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifisitas dan F1-score antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet dalam klasifikasi nodul paru pada citra CT multiclass

Pengambilan keputusan dari uji hipotesis penelitian ini dilakukan berdasarkan hasil keputusan nilai Asymp. Sig. pada uji Kruskal-Wallis. Apabila nilai *Asymp. Sig.* $\leq 0,05$ maka H_1 diterima dan sebaliknya apabila *Asymp. Sig.* $> 0,05$ maka H_0 diterima. *Unpaired variable* yang digunakan adalah nilai parameter analisis dari pengujian arsitektur CNN yaitu akurasi, presisi, sensitivitas, spesifisitas dan F1-score. Akurasi digunakan untuk menentukan seberapa akurat model arsitektur dalam mengklasifikasikan citra. Sensitivitas menggambarkan keberhasilan model arsitektur dalam menemukan informasi. Presisi merepresentasikan tingkat kesepakatan antara data yang diminta dengan hasil prediksi model arsitektur. Spesifisitas merepresentasikan seberapa mungkin pengujian memberikan hasil negatif untuk citra yang tidak memiliki karakteristik. F1-score mengukur keakuratan pengujian dengan mempertimbangkan sensitivitas dan presisi.



Gambar 3. Flowchart Uji Kruskal-Wallis

3. Hasil dan Pembahasan

Pengumpulan data penelitian dilakukan dengan cara uji coba arsitektur CNN dengan beberapa jumlah *epoch* yang telah ditentukan. *Epoch* adalah nilai yang digunakan dalam pelatihan untuk mengembalikan proses pelatihan kembali ke awal, proses ini dilakukan ketika *neural network* telah selesai melatih keseluruhan dataset dalam sekali pelatihan dari dataset awal hingga akhir. Penggunaan jumlah *epoch* dalam proses pelatihan akan mempengaruhi performa kinerja dari hasil pengujian model atau arsitektur. Untuk mengetahui jumlah *epoch* yang dibutuhkan oleh sebuah model maka perlu dilakukan pengujian variasi jumlah *epoch*. Variasi jumlah *epoch* yang digunakan dalam pengambilan data adalah 50, 100, 150, 200 dan 250. Data yang digunakan dalam penelitian ini berjumlah 25 data. Tabel 1, menunjukkan skenario evaluasi dari parameter *input* yang berupa variasi jumlah *epoch* pada pelatihan arsitektur CNN.

Tabel 1. Skenario Evaluasi dari Parameter *Input*

No	Skenario	Jumlah Epoch	Arsitektur CNN	Parameter yang Diamati
1.	I	50	ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet	akurasi, presisi, sensitivitas, spesifisitas, F1-Score
2.	II	100	ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet	akurasi, presisi, sensitivitas, spesifisitas, F1-Score
3.	III	150	ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet	akurasi, presisi, sensitivitas, spesifisitas, F1-Score
4.	IV	200	ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet	akurasi, presisi, sensitivitas, spesifisitas, F1-Score
5.	V	250	ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet	akurasi, presisi, sensitivitas, spesifisitas, F1-Score

3.1. Hasil Uji Normalitas Shapiro-Wilk

Sampel data yang digunakan dalam penelitian ini berjumlah 25 dari semua kelas data yang diuji dan *unpaired variable*. Sebelum uji hipotesis, dilakukan uji normalitas menggunakan uji Shapiro-Wilk karena data berjumlah < 50. Uji normalitas digunakan untuk mengetahui data berdistribusi normal atau tidak normal. Hasil uji normalitas Shapiro-Wilk ditunjukkan pada Tabel 2. Setelah mengamati data hasil uji normalitas Shapiro-Wilk pada kolom Sig. dan kesesuaian dengan dasar pengambilan keputusan uji Shapiro-Wilk, dapat diketahui bahwa data berdistribusi tidak normal karena terdapat beberapa data yang memiliki nilai Sig. < 0,05 salah satunya yaitu 0,006 (variabel akurasi dari arsitektur CNN EfficientNetB1). Sehingga diketahui bahwa data berdistribusi tidak normal.

Tabel 2. Hasil Uji Normalitas Shapiro-Wilk

Unpaired Variable	Arsitektur CNN	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
Akurasi	ResNet50	0,182	5	0,200*	0,937	5	0,643
	EfficientNetB1	0,367	5	0,026	0,684	5	0,006
	MobileNetV2	0,349	5	0,047	0,778	5	0,053
	VGG16	0,258	5	0,200*	0,831	5	0,141
	AlexNet	0,315	5	0,118	0,859	5	0,226
Sensitivitas	ResNet50	0,217	5	0,200*	0,948	5	0,723
	EfficientNetB1	0,339	5	0,062	0,716	5	0,014
	MobileNetV2	0,345	5	0,052	0,783	5	0,058
	VGG16	0,286	5	0,200*	0,768	5	0,043
	AlexNet	0,176	5	0,200*	0,965	5	0,841
Presisi	ResNet50	0,436	5	0,002	0,655	5	0,003
	EfficientNetB1	0,285	5	0,200*	0,867	5	0,256
	MobileNetV2	0,318	5	0,109	0,869	5	0,261
	VGG16	0,218	5	0,200*	0,932	5	0,609
	AlexNet	0,189	5	0,200*	0,953	5	0,757
Spesifisitas	ResNet50	0,204	5	0,200*	0,930	5	0,596
	EfficientNetB1	0,339	5	0,061	0,735	5	0,021
	MobileNetV2	0,360	5	0,033	0,775	5	0,050
	VGG16	0,198	5	0,200*	0,884	5	0,329
	AlexNet	0,259	5	0,200*	0,938	5	0,649
F1_score	ResNet50	0,202	5	0,200*	0,944	5	0,694
	EfficientNetB1	0,367	5	0,026	0,706	5	0,011
	MobileNetV2	0,365	5	0,028	0,767	5	0,043
	VGG16	0,266	5	0,200*	0,877	5	0,295
	AlexNet	0,207	5	0,200*	0,937	5	0,646

*. This is a lower bound of the true significance

a. Lilliefors Significance Correction

3.2. Hasil Uji Statistik Non-Parametrik Kruskal-Wallis

Setelah mengetahui bahwa data berdistribusi tidak normal, maka untuk melakukan uji beda statistik dilakukan menggunakan uji non-parametrik. Variabel data hasil uji coba arsitektur CNN tidak berpasangan (*unpaired*) dan terdiri lebih dari dua kelompok (akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*). Sehingga untuk melakukan uji beda statistik non-parametrik menggunakan uji Kruskal-Wallis. Tabel 3 menunjukkan hasil uji beda statistik Kruskal-Wallis. Pada penelitian ini dasar pengambilan keputusan uji Kruskal-Wallis yaitu Jika nilai Asymp. Sig. (2-tailed) $\leq 0,05$ hipotesis 0 ditolak. Sebaliknya jika nilai Asymp. Sig. (2-tailed) $> 0,05$ maka hipotesis 0 diterima.

Tabel 3. Hasil Uji Kruskal-Wallis

	Test Statistics ^{a,b}				
	Akurasi	Sensitivitas	Presisi	Spesifisitas	F1_Score
Kruskal-Wallis H	16,573	20,058	21,693	20,639	19,414
df	4	4	4	4	4
Asymp. Sig.	0,002	0,000	0,000	0,000	0,001

Hasil uji beda statistik Kruskal-Wallis pada Tabel 3 menunjukkan bahwa nilai Asymp. Sig. untuk kelima *unpaired variable* < 0,05 yaitu akurasi 0,002; presisi 0,000; sensitivitas 0,000; spesifisitas 0,001 dan *F1-score* 0,000. Sehingga dapat diketahui bahwa hipotesis 0 ditolak dan hipotesis 1 diterima.

3.3. Hasil Uji Hipotesis Penelitian

Hasil uji hipotesis penelitian ini berdasarkan hasil dari uji Kruskal-Wallis, yaitu menolak hipotesis 0 dan menerima hipotesis 1. Sehingga hasil uji hipotesis dalam penelitian ini adalah ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifisitas dan *F1-Score* antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet pada klasifikasi citra CT kanker paru *multiclass* secara signifikan dengan taraf signifikansi $\alpha=5\%$ atau 0,05. Hal tersebut menandakan bahwa pengujian arsitektur CNN—ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan nodul paru dari citra CT-scan membutuhkan jumlah *epoch* yang beragam (berbeda) untuk mencapai hasil pengujian yang terbaik.

4. Kesimpulan

Berdasarkan hasil uji beda statistik Kruskal Wallis, maka kesimpulan dari penelitian ini adalah terdapat perbedaan yang signifikan terhadap performa kinerja dari arsitektur CNN—ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan citra CT nodul paru *multiclass* dengan taraf signifikansi 0,05. Penelitian ini didukung oleh data hasil pengujian arsitektur CNN berdasarkan variasi jumlah *epoch* dengan *unpaired variable* yaitu akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*. Dengan demikian diketahui bahwa performa kinerja antar arsitektur CNN membutuhkan jumlah *epoch* yang berbeda untuk mencapai hasil pengujian yang terbaik.

Referensi

- [1] H. Jiang, H. Ma, W. Qian, M. Gao, and Y. Li, "An Automatic Detection System of Lung Nodule Based on Multigroup Patch-Based Deep Learning Network," *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 4, pp. 1227–1237, 2018, doi: 10.1109/JBHI.2017.2725903.
- [2] Q. Dou, H. Chen, L. Yu, J. Qin, and P. A. Heng, "Multilevel Contextual 3-D CNNs for False Positive Reduction in Pulmonary Nodule Detection," *IEEE Trans. Biomed. Eng.*, vol. 64, no. 7, pp. 1558–1567, 2017, doi: 10.1109/TBME.2016.2613502.
- [3] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, and S. Mougiakakou, "Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1207–1216, 2016, doi: 10.1109/TMI.2016.2535865.
- [4] X. Huang, W. Sun, T. L. (Bill) Tseng, C. Li, and W. Qian, "Fast and fully-automated detection and segmentation of pulmonary nodules in thoracic CT scans using deep convolutional neural networks," *Comput. Med. Imaging Graph.*, vol. 74, pp. 25–36, 2019, doi: 10.1016/j.compmedimag.2019.02.003.
- [5] T. Messay, R. C. Hardie, and T. R. Tuinstra, "Segmentation of pulmonary nodules in computed tomography using a regression neural network approach and its application to the Lung Image Database Consortium and Image Database Resource Initiative dataset," *Med. Image Anal.*, vol. 22, no. 1, pp. 48–62, 2015, doi: 10.1016/j.media.2015.02.002.
- [6] R. Zhang, C. Cheng, X. Zhao, and X. Li, "Multiscale Mask R-CNN-Based Lung Tumor Detection Using PET Imaging," *Mol. Imaging*, vol. 18, pp. 1–8, 2019, doi: 10.1177/1536012119863531.
- [7] R. Golan, C. Jacob, and J. Denzinger, "Lung nodule detection in CT images using deep convolutional neural networks," *Proc. Int. Jt. Conf. Neural Networks*, vol. 2016-Octob, no. 1, pp. 243–250, 2016, doi: 10.1109/IJCNN.2016.7727205.
- [8] R. Tekade and K. Rajeswari, "Lung Cancer Detection and Classification using Deep Learning," *IEEE Xplore*, 2018.
- [9] A. Y. Saleh, C. K. Chin, V. Panshie, and H. R. H. Al-Absi, "Lung cancer medical images

- classification using hybrid cnn-svm,” *Int. J. Adv. Intell. Informatics*, vol. 7, no. 2, pp. 151–162, 2021, doi: 10.26555/ijain.v7i2.317.
- [10] Y. Chen, X. Duan, S. Chatani, W. Du, J. Wang, and Q. Hu, “An Improved Region-based Fully Convolutional Network for Automatic Pulmonary Nodules Detection,” pp. 256–261, 2019.
- [11] S. Hadija Difinubun, O. Dominggus Nara, M. Abdin, J. Teknik, S. Politeknik, and N. Ambon, “Analisis Pengaruh Sumber Daya Manusia Terhadap Aspek Kinerja Pekerja Pada Proyek Pembangunan Gedung Laboratorium Terpadu Pendukung Blok Masela Universitas Pattimura,” *J. Agreg.*, vol. 2, no. 1, pp. 76–86, 2023.
- [12] P. Mishra, C. M. Pandey, U. Singh, A. Gupta, C. Sahu, and A. Keshri, “Descriptive statistics and normality tests for statistical data,” *Ann. Card. Anaesth.*, vol. 22, no. 1, pp. 67–72, 2019, doi: 10.4103/aca.ACA_157_18.
- [13] A. Indrasetianingsih, I. A. Haryanto, and P. A. Divaio, “Analisis Kruskal-Wallis untuk Mengetahui Kemampuan Literasi Siswa SMP Miftahurrohman Gresik Berdasarkan Asesmen Kompetensi Minimum,” *Indones. J. Multidiscip. Soc. Technol.*, vol. 2, no. 1, pp. 32–36, 2024, doi: 10.31004/ijmst.v2i1.286.
- [14] F. Rozi, Irma, and D. Maulidiya, “Analisis Perubahan Inflasi Beberapa Kota Besar di Indonesia dengan Menggunakan Uji Kruskal-Wallis,” *Multi Prox. J. Stat. Univ. Jambi*, vol. 1, no. 2, pp. 103–115, 2022, [Online]. Available: <https://online-journal.unja.ac.id/multiproximityhttps://doi.org/10.22437/multiproximity.v1i2.21418>
- [15] H. Takagi, “Statistical Tests for Computational Intelligence Research and Human Subjective Tests,” pp. 1–52, 2015.
- [16] A. Quraisy and N. Hasni, “Analisis Kruskal-Wallis Terhadap Kemampuan Numerik Siswa,” *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 3, no. 3, pp. 156–161, 2021, doi: 10.35580/variensiunm29957.

Analisis Sentimen Produk Pada Bukalapak Menggunakan Lexicon-Based dan Multinomial Naïve Bayes

Brian Adam Bhagaskara^{a1}, Ade Ismail^{a2}, Habibie Ed Dien^{a3}

^a Program Studi Teknik Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Malang
Malang, Indonesia

¹brianadambhagaskara@gmail.com (Corresponding author)

²aismail@polinema.ac.id

³habibie@polinema.ac.id

Abstrak

Marketplace berperan penting dalam *e-commerce*, di mana reputasi produk sangat dipengaruhi oleh ulasan pembeli. Penelitian ini menganalisis sentimen ulasan "kemeja pria" di Bukalapak menggunakan *Natural Language Processing* (NLP). Data diproses melalui pre-processing seperti *cleaning*, *case folding*, normalisasi, *tokenizing*, *stopword removal*, dan *stemming*. Model *Lexicon-Based* dengan *InSet Lexicon* dan *Multinomial Naïve Bayes* menghasilkan *precision* 94%, *recall* 99% untuk sentimen positif, dan *accuracy* 91%-94%, sementara RapidMiner hanya mencapai *precision* 17.70%, *recall* 50%, dan *accuracy* 39.04%-44.57%. Namun, *recall* ulasan netral 0% akibat ketidak seimbangan dataset yang mengindikasikan potensi *overfitting*. Analisis menunjukkan ulasan positif menyoroti kualitas produk, sedangkan ulasan negatif terkait produk rusak dan ukuran tidak sesuai. Hasil ini memberi wawasan bagi penjual dalam meningkatkan produk dan layanan.

Keywords: *Natural Language Processing (NLP), Sentiment Analysis, Lexicon-Based, Multinomial Naïve Bayes, RapidMiner*

1. Pendahuluan

Marketplace adalah evolusi dari *e-commerce* yang berfungsi sebagai platform transaksi online antara penjual dan pembeli. Bukalapak, salah satu marketplace terbesar di Indonesia, memiliki 168,2 juta pengunjung sepanjang 2023 [1]. Platform ini banyak dimanfaatkan oleh produsen, UMKM, dan distributor untuk menjangkau calon pembeli. Salah satu kategori produk yang populer di Bukalapak adalah kemeja pria, yang kualitasnya dinilai berdasarkan foto, deskripsi, dan ulasan dari pembeli sebelumnya [2].

Dalam transaksi online, ulasan produk memegang peranan penting dalam membentuk reputasi suatu produk dan memengaruhi keputusan pembelian. Ulasan biasanya terdiri dari penilaian bintang dan komentar yang berisi apresiasi, kritik, serta saran dari pembeli. Produk dengan jumlah bintang tinggi umumnya lebih dipercaya dan menarik minat pembeli lain. Selain membantu calon pembeli dalam memilih produk, ulasan juga memberikan wawasan bagi penjual untuk meningkatkan kualitas produk dan layanan guna meningkatkan kepuasan pelanggan [3].

Meskipun jumlah bintang memberikan gambaran awal terhadap kualitas produk, komentar dalam ulasan sering kali mencakup lebih dari satu aspek penilaian, seperti harga, bahan, warna, bentuk, ukuran, kuantitas, pelayanan, dan kecepatan pengiriman [4]. Karena setiap ulasan hanya memiliki satu penilaian bintang, informasi penting dalam komentar tidak selalu dapat direpresentasikan secara akurat melalui jumlah bintang saja. Oleh karena itu, diperlukan analisis sentimen untuk memahami makna sebenarnya dari ulasan pembeli.


Analisis manual terhadap ribuan ulasan di marketplace tidak efisien dan rentan terhadap subjektivitas. Oleh sebab itu, penggunaan *Natural Language Processing* (NLP) menjadi penting untuk meningkatkan pemahaman terhadap isi komentar. NLP memungkinkan sistem untuk menormalkan teks, mengenali pola bahasa, dan menginterpretasikan sentimen dengan lebih akurat. Tanpa NLP, pengolahan data berbasis *Machine Learning* sulit mencapai hasil optimal.

Penelitian ini bertujuan untuk menganalisis sentimen ulasan produk kemeja pria di Bukalapak menggunakan pendekatan Lexicon-Based Approach dengan Indonesia Sentiment Lexicon (InSet Lexicon) sebagai referensi kata opini dalam bahasa Indonesia. Sentimen dalam ulasan diklasifikasikan ke dalam tiga kategori: positif, negatif, dan netral menggunakan algoritma Multinomial Naïve Bayes. Evaluasi model dilakukan dengan Confusion Matrix, menggunakan metrik akurasi, recall, dan precision.

Selain itu, hasil penelitian ini dibandingkan dengan analisis menggunakan RapidMiner untuk mengukur efektivitas model yang dikembangkan. Penelitian ini juga bertujuan untuk mengidentifikasi aspek utama dalam ulasan positif dan negatif, sehingga penjual dapat memahami faktor yang paling berpengaruh terhadap kepuasan pelanggan dan melakukan perbaikan kualitas produk serta layanan secara lebih tepat.

2. Metode Penelitian

Metode penelitian yang digunakan penulis adalah metode CRISP-DM. Metode tersebut diilustrasikan pada Gambar 1.



Gambar 1. CRISP-DM

2.1 Business Understanding

Berdasarkan latar belakang yang telah dipaparkan, penelitian ini berfokus pada dua permasalahan utama:

1. Pentingnya Ulasan Produk – Ulasan produk memiliki peran krusial bagi produsen dan konsumen, karena menjadi sumber utama informasi mengenai kualitas produk dan tingkat kepuasan pelanggan. Ulasan yang positif atau negatif dapat memengaruhi keputusan pembelian serta membangun reputasi merek di pasar digital.
2. Tantangan dalam Pengolahan Data – Volume ulasan yang besar dan beragam di platform e-commerce, seperti Bukalapak, menyulitkan analisis manual yang membutuhkan waktu lama dan kurang efisien. Dengan meningkatnya jumlah ulasan dan variasi produk, diperlukan pendekatan yang lebih efektif untuk menganalisis sentimen secara sistematis dan akurat.

Penelitian ini bertujuan untuk mengembangkan metode analisis sentimen yang dapat mengidentifikasi opini pengguna secara otomatis. Dengan pendekatan ini, pelaku bisnis dapat mengevaluasi kepuasan pelanggan dan kualitas produk berdasarkan sentimen positif, netral, dan negatif. Hasil analisis diharapkan memberikan wawasan yang lebih mendalam bagi penjual dalam merespons umpan balik pelanggan dengan strategi perbaikan atau peningkatan produk yang lebih tepat. Pemahaman yang lebih baik terhadap opini pelanggan juga dapat meningkatkan kepercayaan konsumen terhadap produk yang ditawarkan di marketplace.

2.2 Data Understanding

Dalam penelitian ini, pemilihan produk dilakukan berdasarkan hasil pencarian di Bukalapak dengan kata kunci "kemeja pria". Produk yang dipilih merupakan produk terlaris dengan beberapa kriteria:

1. Memiliki rating minimal bintang 3 keatas
2. Dijual oleh pelapak yang telah diverifikasi sebagai super seller oleh Bukalapak
3. Dipilih berdasarkan jumlah penjualan terbanyak, tanpa mempertimbangkan asal toko atau wilayah.

Alasan pemilihan kata kunci "kemeja pria" adalah sebagai berikut:

1. Berdasarkan Google Trends (Januari 2024), "kemeja pria" memiliki jumlah pencarian tertinggi dibandingkan dengan jenis kemeja lainnya di Indonesia, dengan skala relatif 100 sebagai kueri dengan frekuensi penelusuran tertinggi Dijual oleh pelapak yang telah diverifikasi sebagai super seller oleh Bukalapak [5].
2. Tingkat penjualan tinggi di Bukalapak, dengan produk terlaris mencapai 26 ribu unit terjual [6].
3. Memiliki fitur yang kompleks, termasuk model, bahan, warna, ukuran, potongan, dan jahitan, yang dapat berpengaruh terhadap variasi sentimen ulasan pelanggan.

Setelah menentukan produk, data dikumpulkan menggunakan metode *web scraping* pada situs Bukalapak dengan tools cURL PHP. Proses scraping terdiri dari beberapa tahap utama:

1. Mengakses URL produk menggunakan cURL.
2. Mengatur User-Agent agar dapat memperoleh data dalam format plain text HTML.
3. Mengekstrak public token untuk autentikasi API Bukalapak.
4. Memeriksa validitas public token. Jika kadaluarsa, proses kembali ke langkah (2).
5. Mengakses API Bukalapak (api.bukalapak.com/reviews) dan mengekstrak data ulasan.
6. Menyimpan data hasil ekstraksi ke dalam database.

Data yang diperoleh berjumlah 1.455 ulasan, yang kemudian diproses melalui tahap *pre-processing* dan dibagi menjadi lima skenario pembagian data latih dan data uji, yaitu: 90:10, 80:20, 70:30, 60:40, dan 50:50. (perbandingan data latih dan data uji). Tujuan dari pembagian ini adalah untuk mengetahui rasio data yang menghasilkan *precision*, *recall*, dan *accuracy* terbaik dalam evaluasi model.

Setelah data dibagi, dilakukan tahap *labeling* data pada latih. Meskipun rating bintang dapat memberikan indikasi awal, ulasan dapat mencakup lebih dari satu aspek, sehingga penting untuk menganalisis isi komentar secara menyeluruh [7].

Dalam penelitian ini, proses labeling dibantu secara otomatis menggunakan Indonesia Sentiment Lexicon (InSet Lexicon), yang diperoleh dari repositori GitHub [8]. InSet Lexicon terdiri dari:

- 3.609 kata positif, dengan bobot sentimen (+1 hingga +5).
- 6.609 kata negatif, dengan bobot sentimen (-1 hingga -5).

Polaritas suatu ulasan dihitung dengan menjumlahkan bobot dari setiap kata dalam ulasan yang tercantum di dalam *InSet Lexicon* (Indonesia *Sentiment Lexicon*). Prosedurnya adalah sebagai berikut [9].

- Hitung total skor positif dan negatif berdasarkan bobot kata yang terdapat dalam teks ulasan.
- Jumlahkan seluruh bobot untuk mendapatkan nilai polaritas akhir.

Rumus :

$$\text{Polaritas} = \sum_{i=1}^n \text{bobot}(kata_i) \quad (1)$$

Dimana :

- $kata_i$ = kata ke- i dalam ulasan
- $\text{bobot}(kata_i)$ = nilai sentimen dari $kata_i$ berdasarkan InSet Lexicon
- Interpretasi hasil:
 - Jika polaritas > 0 , ulasan dikategorikan sebagai positif.
 - Jika polaritas < 0 , ulasan dikategorikan sebagai negatif.
 - Jika polaritas $= 0$, ulasan dikategorikan sebagai netral.

2.3 Data Preparation

Data latih dan data uji diolah dalam proses pre-processing menggunakan pendekatan *Natural Language Processing* (NLP) untuk memperbaiki bahasa dalam ulasan. Tahapan *pre-processing* ini

mencakup pembersihan data (*cleaning*), *case folding*, normalisasi, *Tokenizing*, *stopword removal*, dan *stemming*. Proses ini membantu sistem memahami bahasa tidak baku dan singkatan yang sering muncul dalam ulasan pengguna.

1. *Cleaning* : menghapus karakter yang tidak relevan atau tidak memberikan kontribusi signifikan terhadap analisis sentimen. Beberapa karakter tersebut termasuk angka, tanda baca, dan karakter khusus yang tidak memiliki nilai informatif dalam pemahaman sentimen ulasan pengguna *E-Commerce*.
2. *Case Folding* : mengubah semua huruf kapital menjadi huruf kecil. Hal ini dilakukan karena tidak semua data teks konsisten dalam penggunaan huruf kapital.
3. Normalisasi : memperbaiki kata-kata dalam ulasan agar menghasilkan kalimat yang baik dan benar sesuai dengan kaidah tata bahasa Indonesia.
4. *Tokenizing* : memecah kalimat menjadi unit-unit kata.
5. *Stopword Removal* : *Stop Word* merupakan kelompok kata yang tidak memiliki hubungan signifikan dengan inti pembicaraan atau subyek yang sedang dibahas. Kata-kata ini umumnya terdiri dari kata imbuhan, kata sambung, dan lain sebagainya
6. *Stemming* : mengubah kata-kata dalam dokumen teks menjadi kata dasar atau akar kata.


Tabel berikut menunjukkan tahapan *pre-processing* yang dilakukan dalam penelitian, beserta jumlah kata yang terpengaruh dan contoh transformasi dari teks mentah menjadi bentuk siap analisis.

Tabel 1. *Pre-processing*

Tahapan <i>Pre-Processing</i>	Jumlah Kata Terpengaruh	Contoh Sebelum	Contoh Sesudah
<i>Cleaning</i>	532 kata	"mantap!!!", "cepat...", "bagus#1", "mantul~"	"mantap", "cepat", "bagus", "mantul"
<i>Case Folding</i>	1.455 ulasan	"Bagus", "CEPAT", "MAHAL"	"bagus", "cepat", "mahal"
Normalisasi	217 kata	"bgs", "manteb", "brng", "gk", "trima kasih"	"bagus", "mantap", "barang", "tidak", "terima kasih"
<i>Tokenizing</i>	1.455 kalimat	"pengiriman cepat dan rapi"	["pengiriman", "cepat", "dan", "rapi"]
<i>Stopword Removal</i>	863 kata	"dan", "itu", "ke", "untuk"	(dihapus dari teks)
<i>Stemming</i>	645 kata	"membeli", "terjual", "pengiriman", "pelayanan", "dibayar"	"beli", "jual", "irim", "layan", "bayar"

2.4 Modeling

Dalam penelitian ini model yang dibuat adalah untuk mengevaluasi kualitas produk dan kepuasan pelanggan dengan menggunakan pendekatan analisis sentimen. Penerapan model analisis sentimen pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Model Analisis Sentimen

Pada Gambar 2 menunjukkan model analisis sentimen yang diterapkan dalam penelitian ini. Proses dimulai dengan scraping data dari e-commerce Bukalapak menggunakan API untuk mengumpulkan ulasan produk. Data yang dikumpulkan (nama pemberi ulasan, title, dan konten) disimpan dalam database. Data mentah ini kemudian melalui tahap *pre-processing*, yang mencakup *cleaning*, *case folding*, *normalisasi*, *tokenizing*, *stopword removal*, dan *stemming*. Setelah *pre-processing*, data dibagi menjadi 5 skenario percobaan (perbandingan data latih dan uji: 90:10, 80:20, 70:30, 60:40, dan 50:50) untuk mengukur *precision*, *recall*, dan *accuracy*. *Labeling* otomatis dilakukan menggunakan *InSet Lexicon* untuk menentukan sentimen ulasan (positif, netral, atau negatif). klasifikasi dilakukan dengan menggunakan TF-IDF (Term Frequency - Inverse Document Frequency) untuk menghitung pentingnya kata dalam dokumen. Dengan rumus sebagai berikut[10].

TF-IDF sendiri pada dasarnya terbagi menjadi 2 istilah *Term Frequency* dan *Inverse Document Frequency*.

Term Frequency (TF) menghitung jumlah kemunculan suatu kata dalam dokumen.

$$tf_{i,j} = \frac{n_{i,j}}{\sum_k n_{k,j}} \quad (2)$$

- $n_{i,j}$ adalah angka kejadian pada kata di dalam sebuah file
- $\sum_k n_{k,j}$ adalah jumlah dari kejadian pada semua kata yang ada di dalam sebuah file

Sedangkan *Inverse Document Frequency* (IDF) digunakan untuk menghitung tingkat kepentingan suatu istilah. Contoh nya adalah “yang”, “di”, “ke” atau kata-kata yang digunakan sebagai preposisi dan konjungsi. Istilah-istilah tersebut merupakan istilah yang sering muncul namun tidak memiliki arti yang begitu penting.

$$idf_i = \log \frac{|D|}{|\{j: t_i \in d_j\}|} \quad (3)$$

- $|D|$ adalah jumlah total file di dalam korpus
- $|\{j: t_i \in d_j\}|$ adalah jumlah dokumen yang mengandung huruf t_i .

Apabila kata tersebut tidak ada di dalam korpus maka akan menyebabkan pembagi nya menjadi nol. Oleh sebab itu maka digunakanlah rumus seperti berikut $1 + |\{j: t_i \in d_j\}|$. Maka dari kedua rumus diatas dapat kita pahami, semakin sering atau semakin tinggi kemunculan suatu kata dalam sebuah dokumen maka akan memberikan frekuensi yang tinggi terhadap kata tersebut dan semakin jarang kata tersebut atau sedikit tingkat kemunculan kata tersebut maka akan menghasilkan nilai yang tinggi atau dalam arti lain kata tersebut memiliki makna yang penting dalam suatu dokumen.

$$W_{i,j} = tf_{i,j} \times \left(\frac{D}{Df_j} \right) \quad (4)$$

Selain itu, dilakukan klasifikasi menggunakan *Multinomial Naïve Bayes*. Dengan rumus sebagai berikut [11].

$$P(w_i, c_j) = \frac{\text{count}(w_i, c_j) + 1}{\sum \text{count}(w_i, c_j) + |V|} \quad (5)$$

Pada perhitungan likelihood, digunakan pendekatan *Laplace smoothing* untuk menghindari probabilitas 0. Penjelasan dari variabel dalam rumus tersebut adalah sebagai berikut:

- $P(w_i, c_j)$ adalah probabilitas kemunculan kata w_i pada kelas c_j .
- $\text{count}(w_i, c_j)$ adalah jumlah kemunculan kata w_i pada kelas c_j .
- $|V|$ adalah jumlah kata unik pada seluruh kelas.

Hasil klasifikasi dievaluasi menggunakan *Confusion Matrix Multi-Class* dan dibandingkan dengan platform RapidMiner. Sistem yang dikembangkan juga menyajikan visualisasi berupa word cloud dan bar chart untuk menggambarkan distribusi sentimen serta kinerja model.

2.5 Evaluation

Pada tahap evaluasi, model klasifikasi *Multinomial Naïve Bayes* digunakan untuk menganalisis sentimen ulasan produk. Pengujian dilakukan dengan membandingkan prediksi model terhadap data uji dan data latih yang dilabel otomatis menggunakan kamus InSet untuk mengategorikan sentimen menjadi positif, negatif, dan netral. Data latih dan data uji dibagi dalam lima skenario (90:10, 80:20, 70:30, 60:40, dan 50:50) untuk menentukan rasio terbaik berdasarkan *precision*, *recall*, dan *accuracy*. Evaluasi kinerja model menggunakan Confusion Matrix, yang merupakan tabel 3x3 untuk tiga kelas sentimen. Confusion Matrix ini mencakup *True Positive* (TP), *True Negative* (TN), *True Neutral* (TNt), *False Positive* (FP), *False Negative* (FN), dan *False Neutral* (FNt), membantu memvisualisasikan akurasi prediksi model terhadap hasil sebenarnya [12].

Tabel 2. Confusion Matrix Multi-Class

		Predicted Class		
True Class	Positive	True Positive (TP)	False Negative (FN)	False Neutral (FNt)
	Negative	False Positive (FP)	True Negative (TN)	False Neutral (FNt)
	Neutral	False Positive (FP)	False Negative (FN)	True Neutral (TNt)

Untuk mengetahui rata-rata *precision* dan *recall* dalam penelitian ini, juga digunakan *Weighted Average*. *Weighted Average* menghitung setiap Matrik dengan mempertimbangkan jumlah sampel yang ada di setiap kelas. Hal ini membantu memberikan gambaran yang lebih akurat tentang kinerja model terhadap masing-masing kelas, memperhitungkan perbedaan jumlah sampel yang direpresentasikan oleh setiap kelas dalam evaluasi [13].

$$\text{Weighted Average Precision} = \sum_i \left(\frac{\text{Total Kelas } i}{\text{Total Keseluruhan}} \times \text{Precision Kelas } i \right) \quad (6)$$

$$\text{Weighted Average Recall} = \sum_i \left(\frac{\text{Total Kelas } i}{\text{Total Keseluruhan}} \times \text{Recall Kelas } i \right) \quad (7)$$

2.6 Deployment

Tahapan perencanaan penyebaran sistem ini didasarkan pada rancangan yang telah disiapkan sebelumnya. Hal ini bertujuan untuk membantu visualisasi hasil penelitian. Sistem ini dikembangkan sebagai web-site menggunakan bahasa pemrograman PHP dengan *framework* Laravel. Antarmuka pengguna dibangun dengan menggunakan HTML, CSS, dan JavaScript. Mulai dari tahap pengambilan data dari Bukalapak menggunakan cURL PHP hingga tahap visualisasi pada sistem, semua proses dilakukan dengan menggunakan bahasa pemrograman PHP dan MySQL sebagai basis data yang dikelola.

3. Hasil dan Pembahasan

Pengujian dilakukan menggunakan metode *Confusion Matrix Multi-Class* karena terdapat lebih dari dua kelas, yaitu kelas positif, negatif, dan netral. Pengujian ini menggunakan sampel data yang diambil dari dataset ulasan produk murah - kemeja batik termurah - kemeja pria lengan pendek termurah dari toko BATIK MURAH JAYA, sebanyak 1.455 data komentar ulasan. Data ini dibagi menjadi lima skenario percobaan dengan perbandingan data latih dan data uji sebagai berikut: 90:10, 80:20, 70:30, 60:40, dan 50:50.

3.1. Hasil Pengujian Data Uji

Kinerja model dievaluasi dengan menghitung *confusion matrix* untuk setiap skenario pembagian data. Setiap *matrix* menyediakan informasi yang diperlukan untuk menghitung precision, recall, dan accuracy, yang kemudian dibandingkan antara skenario yang berbeda untuk menentukan pembagian data yang optimal.

Tabel 2. Pembagian Data Uji dan Data Latih

Proposi	Sistem		RapidMiner	
	Data Latih	Data Uji	Data Latih	Data Uji
90:10	1310	145	1309	146
80:20	1164	291	1164	291
70:30	1019	436	1018	437
60:40	873	582	873	582
50:50	728	727	728	727

Tabel 3. Hasil Evaluasi Sistem yang Dikembangkan

proposisi	Precision			Recall			accuracy
	Positif	Negatif	Netral	Positif	Negatif	Netral	
90:10	93%	75%	100%	97%	72%	0%	91%
80:20	94%	77%	100%	97%	74%	0%	92%
70:30	94%	75%	100%	97%	72%	0%	92%
60:40	94%	69%	100%	97%	59%	0%	92%
50:50	94%	92%	100%	99%	70%	0%	94%

Sistem yang dikembangkan menunjukkan performa tinggi dalam mendeteksi ulasan positif, dengan precision antara 93%-94% dan recall hingga 99% pada skenario 50:50. Precision untuk kelas negatif bervariasi antara 69%-92%, menunjukkan bahwa model cukup akurat dalam mengidentifikasi ulasan positif dan negatif. Namun, model kesulitan mendeteksi ulasan netral, dengan recall untuk kelas netral selalu 0% akibat ketidakseimbangan data, di mana ulasan positif jauh lebih banyak daripada netral. Hal ini menyebabkan model cenderung mengklasifikasikan ulasan sebagai positif atau negatif, mengabaikan ulasan netral. Kesulitan dalam mendeteksi ulasan netral mungkin disebabkan oleh fitur yang kurang menonjol atau mirip dengan ulasan positif/negatif, sehingga sulit dibedakan oleh model. Meskipun *accuracy* keseluruhan tetap tinggi (91%-94%), rendahnya recall pada kelas netral menunjukkan indikasi *overfitting*, di mana model kurang mampu menangani kelas dengan representasi rendah.

Tabel 4. Hasil Evaluasi RapidMiner

proposisi	Precision			Recall			accuracy
	Positif	Negatif	Netral	Positif	Negatif	Netral	
90:10	13.64%	78.57%	39.47%	34.62%	32.67%	78.95%	39.04%
80:20	17.70%	82.93%	33.33%	39.22%	33.66%	84.21%	41.24%
70:30	16.00%	82.58%	47.50%	46.75%	35.97%	66.67%	41.88%
60:40	17.17%	83.06%	55.88%	50.00%	37.62%	75.00%	44.57%
50:50	14.24%	85.56%	38.78%	38.28%	31.68%	80.85%	39.20%

Performa RapidMiner lebih rendah dibandingkan sistem yang dikembangkan. Precision untuk kelas positif sangat rendah, hanya 13,64% pada skenario 90:10, meskipun ada perbaikan di skenario lain. Recall untuk kelas positif juga kurang memuaskan, dengan nilai tertinggi hanya 50% pada skenario 60:40. Meskipun recall untuk kelas netral lebih tinggi, accuracy keseluruhan RapidMiner tetap rendah, hanya 44,67%.

Penelitian ini menerapkan *Weighted Average* dalam perhitungan rata-rata hasil *precision* dan *recall* pada hasil sistem yang dikembangkan dan hasil platform RapidMiner pada masing- masing skenario pembagian data.

Tabel 5. Hasil Weighted Avg Sistem

Proporsi	Precision	Recall	Accuracy
90:10	83%	86%	91%
80:20	86%	88%	92%
70:30	87%	90%	92%
60:40	85%	87%	92%
50:50	88%	91%	94%

Hasil weighted average untuk sistem yang dikembangkan menunjukkan precision antara 83% hingga 88%, recall antara 86% hingga 91%, dan accuracy mencapai 94% pada proporsi 50:50. Sistem ini menunjukkan performa konsisten yang baik, terutama dalam mendeteksi ulasan positif. Model berfungsi optimal dengan proporsi data pelatihan lebih besar, memungkinkan klasifikasi yang lebih akurat.


Tabel 6. Hasil Weighted Avg RapidMiner

Proporsi	Precision	Recall	Accuracy
90:10	23%	18%	39%
80:20	24%	20%	41.27%
70:30	26%	19%	41.88%
60:40	29%	22%	44.67%
50:50	24%	18%	39.20%

Hasil *weighted average* untuk RapidMiner menunjukkan *precision* antara 23% hingga 29%, *recall* antara 18% hingga 22%, dan *accuracy* tertinggi 44.67% pada skenario 60:40. Ini menunjukkan keterbatasan RapidMiner dalam mendeteksi ulasan, terutama ulasan positif, dengan precision dan recall yang rendah di semua skenario.

3.2. Hasil Evaluasi

Grafik hasil prediksi data uji menunjukkan distribusi prediksi model klasifikasi sentimen ke dalam tiga kategori: positif, negatif, dan netral. Grafik ini didasarkan pada skenario 50:50 yang menunjukkan performa terbaik dari sistem. Dari hasil yang ditampilkan, prediksi sentimen positif mendominasi dengan jumlah 627, yang digambarkan oleh batang biru yang tinggi di grafik.



Gambar 3. Word Cloud Positif

3.3. Hasil Visualisasi Wordcloud

Secara keseluruhan, *wordcloud* positif menunjukkan perasaan-perasaan positif yang dapat disebabkan oleh berbagai faktor, seperti kebahagiaan atas suatu pencapaian, rasa puas dengan suatu situasi, atau sikap positif dalam menghadapi hidup. Pada ulasan dengan label positif, beberapa kata muncul dengan frekuensi tinggi, menunjukkan aspek-aspek yang dihargai oleh konsumen. Kata "bagus" muncul sebanyak 1100 kali, "cepat" muncul 172 kali, "puas" muncul 201 kali, dan "rapi" muncul 54 kali.



Gambar 4. Wordcloud Positif

Wordcloud negatif menunjukkan kumpulan kata-kata yang memiliki makna negatif. Kata-kata ini dapat digunakan untuk mengungkapkan perasaan atau pikiran yang tidak menyenangkan, seperti kekecewaan, kemarahan, dan ketakutan. Dalam ulasan dengan label negatif, beberapa kata muncul dengan frekuensi tinggi, menunjukkan aspek-aspek yang menjadi keluhan konsumen. Kata "rusak" muncul sebanyak 121 kali, "kecil" muncul 60 kali, "ragu" muncul 51 kali, dan "lama" muncul 57 kali. Penggunaan kata "lama" dan "ragu" menunjukkan bahwa pembeli menerima produk yang tidak sesuai dengan harapan mereka.



Gambar 5. Wordcloud Negatif

Wordcloud netral menunjukkan kata-kata yang umum digunakan dalam komunikasi sehari-hari, transaksi, atau penyampaian informasi objektif tanpa sentimen emosional yang kuat. Kata-kata seperti "tidak," "biasa," "saya," dan "puas" sering muncul, mengindikasikan ulasan netral yang biasanya berupa pertanyaan atau pernyataan tanpa opini negatif maupun positif.



Gambar 6. Wordcloud Netral

4. Conclusion

Berdasarkan hasil penelitian yang dilakukan dan pengujian tingkat akurasi yang didapatkan dapat ditarik kesimpulan sebagai berikut :

1. Penelitian ini menegaskan pentingnya *pre-processing* data dalam analisis sentimen untuk memastikan hasil yang konsisten dan akurat. Tahapan seperti *cleaning*, normalisasi, dan *stopword removal* membantu menyelaraskan variasi penulisan dalam ulasan produk, termasuk singkatan seperti "bgs" menjadi "bagus" dan penulisan huruf ganda seperti "ceepaat" menjadi "cepat." Beberapa kata penting seperti "wah," "tidak," dan "oke" dipertahankan karena relevansinya dalam Indonesia Sentiment Lexicon, yang berperan penting dalam mendukung analisis lebih mendalam terhadap ulasan.
2. Sistem yang dikembangkan menunjukkan performa unggul dibandingkan RapidMiner dalam mengklasifikasikan sentimen. Pada pembagian data 70:30, 60:40, dan 50:50, sistem mencapai precision hingga 94%, recall hingga 99%, dan accuracy maksimal 94%. Meski begitu, tantangan muncul pada ulasan netral, di mana recall bernilai 0% akibat *imbalanced dataset*, menunjukkan adanya potensi *overfitting*. Sebaliknya, RapidMiner hanya menghasilkan accuracy 39.04%-44.57% dengan precision tertinggi 17.70%, menunjukkan sistem yang dikembangkan lebih andal.
3. Analisis barchart dan wordcloud mendukung temuan ini, di mana ulasan positif mendominasi (627 ulasan), mencerminkan kepuasan pada kualitas produk, pengiriman, dan pengemasan. Ulasan negatif (89 ulasan) mengungkapkan masalah terkait produk rusak dan pengiriman lambat, sedangkan ulasan netral (14 ulasan) menggunakan kata-kata tanpa sentimen kuat. Keseluruhan temuan ini memberikan wawasan berharga bagi penjual untuk memperbaiki kualitas produk, layanan, dan pengiriman, sehingga dapat mempertahankan ulasan positif dan mengurangi keluhan pelanggan. Integrasi pre-processing data yang baik, kinerja model yang unggul, dan analisis hasil ulasan secara visual memberikan panduan strategis untuk meningkatkan pengalaman pelanggan.

References

- [1] A. Ahdiat, "5 E-Commerce dengan Pengunjung Terbanyak Sepanjang 2023," databoks. Accessed: Feb. 02, 2024. [Online]. Available: <https://databoks.katadata.co.id/datapublish/2024/01/10/5-e-commerce-dengan-pengunjung-terbanyak-sepanjang-2023>
- [2] H. Wang and Y. Wang, "A Review of Online Product Reviews," *Journal of Service Science and Management*, vol. 13, no. 01, pp. 88–96, 2020, doi: 10.4236/jssm.2020.131006.
- [3] I. Servanda Ratu, P. Sari Kemala Reno, and N. Ananda Adhitya, "Peran Ulasan Produk Dan Fot Produk Yang Ditampilkan Penjual Pada Marketplace Shopee Terhadap Minat Beli Pria Dan Wanita," *JURNAL MANAJEMEN DAN BISNIS*, vol. 2, no. 2, 2019, [Online]. Available: <http://jurnal.uts.ac.id>
- [4] R. Maulana Arrasyid, D. Enggar Putera, and A. Yunizar Pratama Yusuf, "Analisis Sentimen Review Pembelian Produk di Marketplace Shopee Menggunakan Pendekatan Natural Language Processing," *Jurnal TEKNO KOMPAK*, vol. 18, no. 2, pp. 319–330, 2024.
- [5] Google, "Google Trends 'kemeja,'" Google. Accessed: May 06, 2024. [Online]. Available: <https://trends.google.co.id/trends/explore?geo=ID&q=kemeja>
- [6] Bukalapak, "Produk Kemeja Pria diBukalapak," Bukalapak. Accessed: Feb. 01, 2024. [Online]. Available:

- https://www.bukalapak.com/products?search%5Bkeywords%5D=kemeja%20pria&search%5Brating_gte%5D=3&search%5Bsort_by%5D=weekly_sales_ratio%3Adesc&search%5Btop_seller%5D=1
- [7] E. Muktafin Hari, K. Kusri, and E. Luthfi Taufiq, "Analisis Sentimen pada Ulasan Pembelian Produk di Marketplace Shopee Menggunakan Pendekatan Natural Language Processing," *Jurnal Eksplora Informatika*, vol. 10, no. 1, pp. 32–42, Sep. 2020, doi: 10.30864/eksplora.v10i1.390.
 - [8] A. Hendra, "Kamus InSet (Indonesia Sentiment Lexicon)," GitHub. Accessed: Dec. 13, 2023. [Online]. Available: <https://github.com/agushendra7/twitter-sentiment-analysis-using-inset-and-random-forest>
 - [9] D. Musfiroh, U. Khaira, P. E. P. Utomo, and T. Suratno, "Analisis Sentimen terhadap Perkuliahan Daring di Indonesia dari Twitter Dataset Menggunakan InSet Lexicon," *MALCOM*, vol. 1, no. 1, pp. 24–33, 2021.
 - [10] L. Siniwi Maharani, A. Prahutama, and A. Hakim Rachman, "Query Expansion Ranking pada Analisis Sentimen Menggunakan Klasifikasi Multinomial Naïve Bayes," *JURNAL GAUSSIAN*, vol. 10, no. 3, pp. 377–387, 2021.
 - [11] N. Hidayah and Dodiman, "Implementasi Algoritma Multinomial Naïve Bayes, TF-IDF dan Confusion Matrix dalam Pengklasifikasian Saran Monitoring dan Evaluasi Mahasiswa Terhadap Dosen Teknik Informatika Universitas Dayanu Ikhsanuddin," *Jurnal Akademik Pendidikan Matematika*, vol. 10, no. 1, pp. 8–15, 2024, doi: 10.55340/japm.v10i1.1491.
 - [12] S. Anggina, N. Y. Setiawan, and F. A. Bachtiar, "Analisis Ulasan Pelanggan Menggunakan Multinomial Naïve Bayes Classifier dengan Lexicon-Based dan TF-IDF Pada Formaggio Coffee and Resto," *is The Best Accounting Information Systems and Information Technology Business Enterprise this is link for OJS us*, vol. 7, no. 1, pp. 76–90, Sep. 2022, doi: 10.34010/aisthebest.v7i1.7072.
 - [13] Yuyun, N. Hidayah, and S. Sahibu, "Algoritma Multinomial Naïve Bayes Untuk Klasifikasi Sentimen Pemerintah Terhadap Penanganan Covid-19 Menggunakan Data Twitter," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 4, pp. 820–826, Aug. 2021, doi: 10.29207/resti.v5i4.3146.

This page is intentionally left blank.



ISSN



E-ISSN