



Kemajuan dalam Ilmu Informatika

Dari Decision Support System Menuju Artificial Intelligence

Virasanty Muslimah, Herman, Sunardi, Syahrani Lonang, Anton Yudhana, Muhammad Kunta Biddinika, Syifa'ah Setya Mawarni, Murinto, Sunardi, Fitriah, Imam Riadi, Muhammad Kunta Biddinika, Alya Masitha, Faiz Isnani Abdurrachman, Rusydi Umar, Ainin Maftukhah, Abdul Fadlil, Sunardi

Kemajuan dalam Ilmu Informatika: Dari Decision Support System Menuju Artificial Intelligence

Virasanty Muslimah, Herman, Sunardi, Syahrani Lonang, Anton Yudhana,
Muhammad Kunta Biddinika, Syifa'ah Setya Mawarni, Murinto, Sunardi,
Fitriah, Imam Riadi, Muhammad Kunta Biddinika, Alya Masitha, Faiz Isnani
Abdurrachman, Rusydi Umar, Ainin Maftukhah, Abdul Fadlil, Sunardi

**Sanksi Pelanggaran Pasal 113
Undang-Undang Nomor 28 Tahun 2014
Tentang Hak Cipta**

1. Setiap orang yang dengan tanpa hak melakukan pelanggaran hak ekonomi sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf i untuk penggunaan secara komersial dipidana dengan pidana penjara paling lama 1 (satu) tahun dan/atau pidana denda paling banyak Rp. 100.000.000 (seratus juta rupiah).
2. Setiap orang yang dengan tanpa hak dan/atau tanpa izin Pencipta atau pemegang Hak Cipta melakukan pelanggaran hak ekonomi Pencipta sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf c, huruf d, huruf f, dan/atau huruf h untuk penggunaan secara komersial dipidana dengan pidana penjara paling lama 3 (tiga) tahun dan/atau pidana denda paling banyak Rp. 500.000.000,00 (lima ratus juta rupiah).
3. Setiap orang yang dengan tanpa hak dan/atau tanpa izin Pencipta atau pemegang Hak Cipta melakukan pelanggaran hak ekonomi Pencipta sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf a, huruf b, huruf e, dan/atau huruf g untuk penggunaan secara komersial dipidana dengan pidana penjara paling lama 4 (empat) tahun dan/atau pidana denda paling banyak Rp. 1.000.000.000,00 (satu miliar rupiah).
4. Setiap orang yang memenuhi unsur sebagaimana dimaksud pada ayat (3) yang dilakukan dalam bentuk pembajakan, dipidana penjara paling lama 10 (sepuluh) tahun dan/atau pidana denda paling banyak Rp. 4.000.000.000,00 (empat miliar rupiah).

Kemajuan dalam Ilmu Informatika: Dari Decision Support System Menuju Artificial Intelligence

Virasanty Muslimah, Herman, Sunardi, Syahrani Lonang, Anton Yudhana,
Muhammad Kunta Biddinika, Syifa'ah Setya Mawarni, Murinto, Sunardi,
Fitriah, Imam Riadi, Muhammad Kunta Biddinika, Alya Masitha, Faiz Isnani
Abdurrachman, Rusydi Umar, Ainin Maftukhah, Abdul Fadlil, Sunardi

**Kemajuan dalam Ilmu Informatika:
Dari Decision Support System Menuju Artificial Intelligence**

Copyright © 2024 Virasanty Muslimah, dkk

ISBN: 978-xxx-xxxx-xx-x

e-ISBN: 978-xxx-xxxx-xx-x

21 x 29.7 cm, viii + 142 hlm

Cetakan Pertama, Februari 2024

Penulis:

Virasanty Muslimah, Herman, Sunardi, Syahrani Lonang, Anton Yudhana, Muhammad Kunta Biddinika, Syifa'ah Setya Mawarni, Murinto, Sunardi, Fitriah, Imam Riadi, Muhammad Kunta Biddinika, Alya Masitha, Faiz Isnani Abdurrachman, Rusydi Umar, Ainin Maftukhah, Abdul Fadlil, Sunardi

Editor: Herman

Layout: Tim UAD Press

Desain Cover: Tim Penulis

Diterbitkan oleh:

UAD PRESS

(Anggota IKAPI dan APPTI)

Alamat Penerbit:

Kampus II Universitas Ahmad Dahlan

Jl. Pramuka No. 46, Sidikan, Umbulharjo, Yogyakarta.

Telp. (0274) 563515, Phone (+62) 882 3949 9820

All right reserved. Semua hak cipta © dilindungi undang-undang. Tidak diperkenankan memproduksi ulang atau mengubah dalam bentuk apa pun melalui cara elektronik, mekanis, fotocopy, atau rekaman sebagian atau seluruh buku ini tanpa izin tertulis dari pemilik hak cipta.

Prakata

Alhamdulillah. Bersyukur kepada Allah SWT atas diterbitkannya buku ini. Dari tujuh Bab buku ini, lima bab mendiskusikan *machine learning*. Bab pertama menganalisis efektifitas teorema bayes pada sistem diagnosis penyakit bayi. Analisis dilakukan dengan teknik K-Fold Cross Validation. Bab 2 masih tentang persoalan klasifikasi, yaitu menganalisis kinerja *distance algorithms* pada model k-nearest neighbor dalam mendeteksi kekurangan gizi pada anak atau *stunting*. Penelitian ini membandingkan *distance algorithms* euclidean, manhattan, minkowski dan canberra. Bab 3 membahas *image processing*, yaitu bagaimana mengklasifikasikan citra medis dengan dengan support vector machine setelah terlebih dahulu diproses dengan teknik segmentasi *active contour*. Lanjut ke Bab 5. Disini model k-nearest neighbor dengan *distance algorithms* euclidean dan manhattan diterapkan pada studi kasus bagaimana memperkirakan pasien akan mengalami gagal jantung (*heart failure*). Bab 7 adalah bab terakhir yang membahas *machine learning*. Pada bab ini model *deep learning* convolutional neural network (CNN) digunakan untuk mengidentifikasi citra kupu-kupu. Sederhananya adalah untuk menentukan seekor kupu-kupu yang ada dalam sebuah citra termasuk jenis kupu-kupu apa, mengingat ada ribuan jenis kupu-kupu. Model CNN dalam penelitian ini menggunakan teknik segmentasi citra *multilevel thresholding*.

Dua bab lain dari buku ini mendiskusikan topik *decision support system*. Sistem ini sudah digunakan lama sebelum muncul dan berkembangnya *machine learning*. Meskipun begitu, pada beberapa bidang *decision support system* masih relevan digunakan saat ini. Bab 4 mendiskusikan algoritma apriori dan equivalence class transformation yang digunakan untuk mendapatkan *association rule* pada studi kasus usaha café & bakery. Bab 6 buku ini membahas *decision support system* untuk menentukan apoteker terbaik dari data yang dimiliki oleh Ikatan Apoteker Indonesia (IAI). Penelitian ini mengkombinasikan teknik pembobotan rank order centroid dengan metode multi attribute utility theory.

Sebagai naskah hasil penelitian yang merupakan ikhtiar untuk mencari kebaruan, alternatif solusi, dalam perkembangan ilmu pengetahuan tentunya segala kekurangan dan kekhilafan adalah keniscayaan dari buku ini. Saran, pendapat, kritikan kami harapkan dari pembaca semua. Terakhir ucapan terima kasih kami sampaikan kepada semua pihak yang telah berpartisipasi dalam mengupayakan buku ini sampai ke tangan pembaca. Semoga semua bantuan dan dukungan ikhlas serta ikhtiar kita semua ini menjadi amal sholeh di hadirat Allah SWT. Amin YRA.

Yogyakarta,

Penulis

Daftar Isi

Prakata	v
Daftar Isi	vii

Bab 1

Analisis Efektivitas Teorema Bayes pada Sistem Diagnosis Penyakit Bayi Menggunakan Teknik K-Fold Cross Validation

Virasanty Muslimah, Herman, Sunardi | 1

Bab 2

Analisis Kinerja Distance Algorithms pada Pemodelan Klasifikasi K-Nearest Neighbors dalam Mendeteksi Stunting

Syahrani Lonang, Anton Yudhana, Muhammad Kunta Biddinika | 21

Bab 3

Klasifikasi Citra Medis Menggunakan Segmentasi Active Contour dengan Algoritma Support Vector Machine

Syifa'ah Setya Mawarni, Murinto, Sunardi | 41

Bab 4

Evaluasi Algoritma Apriori dan Equivalence Class Transformation untuk Mendapatkan Association Rule: Studi Kasus Café & Bakery

Fitriah, Imam Riadi, Herman | 55

Bab 5

Perbandingan Algoritma Pengukuran Jarak Manhattan dan Euclidean pada Model Klasifikasi K-Nearest Neighbors Pendeteksi Gagal Jantung

Muhammad Kunta Biddinika, Herman, Alya Masitha | 71

Bab 6

Pembobotan Rank Order Centroid dalam Metode Multi Attribute Utility Theory pada Sistem Penentuan Apoteker Terbaik

Faiz Isnan Abdurrachman, Rusydi Umar, Herman | 93

Bab 7

Identifikasi Citra Kupu-Kupu Menggunakan Segmentasi Multilevel Thresholding dan Klasifikasi Convolutional Neural Network

Ainin Maftukhab, Abdul Fadlil, Sunardi | 105

Bab 1

Analisis Efektivitas *Teorema Bayes* Pada Sistem Diagnosis Penyakit Bayi Menggunakan Teknik *K-Fold Cross Validation*

Virasanty Muslimah, Herman, Sunardi

1.1. PENDAHULUAN

Teknologi telah memainkan peran penting dalam mendiagnosis suatu penyakit, dan ada beberapa pendekatan yang digunakan dalam bidang ini. Salah satunya adalah penggunaan sistem berbasis kecerdasan buatan, seperti *expert system*, *decision support system* (DSS), dan *machine learning*. *Expert system* adalah sistem komputer yang menggunakan pengetahuan dan pengalaman manusia untuk membuat keputusan yang kompleks dengan mengumpulkan data pasien dan menganalisisnya berdasarkan pengetahuan yang telah diprogram (Al-Masawabe & Abu-Naser, 2021). Sementara itu, *decision support system* (DSS) adalah sistem informasi yang dirancang untuk membantu pengambilan keputusan. Dalam konteks medis, DSS digunakan sebagai alat bantu dalam proses diagnosis untuk membantu dokter dalam membuat keputusan yang lebih baik dan tepat (Casal-Guisande dkk., 2022). Disisi lain, *machine learning* adalah studi dan teknik membangun mesin yang dapat dipelajari dari data sebelumnya (Ureel dkk., 2023). Sistem *machine learning* tidak diprogram secara eksplisit untuk tugas tertentu, tetapi dilatih untuk beberapa tugas (Mondal, 2020). Diagnosis menggunakan *machine learning* adalah proses di mana algoritma *machine learning* digunakan untuk menganalisis data pasien, seperti gejala, riwayat medis, dan hasil tes lainnya untuk menghasilkan prediksi atau diagnosis.

Pengobatan penyakit dapat dilakukan di Pusat Kesehatan Masyarakat (Puskesmas). Pengobatan atau diagnosa penyakit di Puskesmas dilakukan oleh dokter tetapi dokter spesialis masih sangat terbatas terutama di daerah yang sulit dijangkau. Akibat dari keterbatasan dokter spesialis di daerah yang sulit dijangkau yaitu pasien harus melakukan perjalanan jauh untuk mendapatkan layanan kesehatan. Selain itu, kurangnya dokter spesialis juga dapat menyebabkan penanganan penyakit yang tidak optimal dan terlambat, sehingga berdampak pada kesehatan pasien yang lebih buruk dan biaya pengobatan yang lebih tinggi.

Selain itu, diagnosis penyakit bayi memerlukan pertimbangan khusus karena adanya perbedaan dengan diagnosis pada orang dewasa. Faktor-faktor seperti sistem kekebalan tubuh yang belum sepenuhnya berkembang pada bayi, kesulitan dalam mengungkapkan gejala penyakit, serta perkembangan fisiologi yang cepat dalam tubuh dan otak bayi menjadi hal yang perlu dipertimbangkan dalam proses diagnosis dan perawatan kesehatan bayi (Hersh dkk., 2013). Semua ini mempertegas pentingnya pengembangan teknologi yang dapat membantu meningkatkan akurasi dan aksesibilitas diagnosis penyakit bayi, terutama di daerah yang sulit dijangkau oleh dokter spesialis.

1.2 TINJAUAN PUSTAKA

Sistem yang telah ada dan digunakan saat ini yaitu “*International Classification of Disease* (ICD)” dan “*Diagnostic and Statistical Manual of Mental Disorders* (DSM)”. ICD adalah sistem klasifikasi penyakit yang dikeluarkan oleh Organisasi Kesehatan Dunia (WHO). ICD digunakan secara luas di seluruh dunia untuk mendokumentasikan, mengklasifikasikan, dan melacak penyakit serta masalah kesehatan terkait (*International Statistical Classification of Diseases and Related Health Problems* (ICD), n.d.). DSM adalah sistem diagnostik yang digunakan untuk mengklasifikasikan gangguan mental. DSM diterbitkan oleh American Psychiatric Association (APA) dan digunakan oleh profesional kesehatan mental untuk diagnosis dan penelitian gangguan mental (*Diagnostic and Statistical Manual of Mental Disorders* (DSM-5-TR), n.d.).

Prediksi penyakit pneumonia pada bayi baru lahir berdasarkan analisis statistik kondisi ibu yang dilakukan pada wanita hamil yang melahirkan antara usia 15 sampai 35.

Pengumpulan data dilakukan dengan mensurvei daerah pedesaan Bangladesh. Prediksi tersebut menggunakan enam algoritma *machine learning* tradisional yaitu K-NN, Naïve Bayes classifier, Decision Tree, SVM, Neural Network algorithm, dan Random Forest. Setelah menerapkan enam algoritma tersebut, dikatakan bahwa ketepatan yang dihasilkan oleh algoritma tidak sama. Decision Tree mendapatkan akurasi terbaik, sehingga dapat diterapkan untuk prediksi penyakit pneumonia bayi baru lahir dan analisis statistik kondisi ibu (Hasan dkk., 2021).

Pengklasifikasi naïve Bayes untuk prediksi berat badan bayi pada ibu dengan kondisi hipertensi. Data yang diambil sebanyak 219 data ibu hamil, dibagi menjadi dua kelompok yaitu 188 data untuk data training dan 31 data untuk data testing. Data tersebut berasal dari rekam medis departemen Kebidanan dan Kandungan Rumah Sakit Muhammadiyah Pelambang dari bulan Januari 2017 hingga September 2017. Hasil penelitian dapat disimpulkan bahwa metode naïve Bayes dapat digunakan untuk memprediksi berat badan bayi terhadap kondisi ibu yang hipertensi dan tidak hipertensi. Hasil prediksi menunjukkan bahwa nilai rata-rata akurasi naïve Bayes menggunakan WEKA yaitu sebesar 80,372% (Desiani dkk., 2019).

Klasifikasi status gizi berdasarkan tiga indeks antropometri berdasarkan algoritma Naïve Bayes. Hasil klasifikasi tersebut diuji untuk mengetahui keberhasilan dengan metode K-Fold Cross Validation. Uji akurasi tersebut ditemukan bahwa indeks terbaik adalah indeks WFA dengan nilai 88% sedangkan nilai indeks WFH dan HFA memiliki nilai 68% dan 64% (Putri dkk., 2018).

Prediksi *Intra Uterine Growth Restriction* (IUGR) atau memprediksi suatu kondisi ketika bayi gagal tumbuh seperti yang diharapkan dan dapat mempengaruhi keselamatan ibu hamil serta janin yang dikandungnya pada kehamilan dengan metode Naïve Bayes. Data yang diambil sebanyak 205 data dengan hasil percobaan menghasilkan nilai akurasi rata-rata sebesar 84%. Hasil yang didapatkan tersebut menunjukkan kinerja yang cukup baik dari metode Naïve Bayes (Badriyah dkk., 2020).

Teknik pembelajaran mesin telah digunakan selama bertahun-tahun untuk mendeteksi dan mendiagnosis berbagai penyakit (Al-Issa dkk., 2022). Metode Naïve Bayes telah digunakan untuk memprediksi berat badan bayi terhadap kondisi ibu yang hipertensi dan non-hipertensi dapat menunjukkan hasil prediksi dengan baik (Desiani dkk., 2019), diagnosis IUGR pada kehamilan yang dapat mempengaruhi keselamatan ibu hamil serta janin dapat menunjukkan kinerja yang cukup baik (Badriyah dkk., 2020). Metode Teorema Bayes untuk memprediksi SARS-CoV2 dengan tes RT-PCR menunjukkan bahwa tingkat kesalahan (error rate) yang dimiliki lebih rendah (Bentley, 2021), memprediksi virus Covid-19 dengan menghitung angka kematian (CFR) tiap wilayah di Cina dan negara lain yang akan dilaporkan oleh WHO dan media (Chang dkk., 2020).

1.3 LANDASAN TEORI

Penting untuk memahami dasar-dasar teoritis yang menjadi landasan pembentukan model Teorema Bayes dalam proses diagnosis penyakit pada bayi. Di bawah ini akan dijelaskan landasan teori yang akan digunakan.

1.3.1 *ARTIFICIAL INTELLIGENCE*

Kecerdasan Buatan (AI) adalah teknologi yang paling menarik dalam decade ini karena sifatnya yang meniru kecerdasan manusia (Nti dkk., 2021). John McCarthy mendefinisikan

sebagai “ilmu pengetahuan dan teknik pembuatan mesin cerdas, terutama program komputer cerdas” (Jiang dkk., 2022; Kaul dkk., 2020; Mondal, 2020; Reddy dkk., 2019). Secara sederhana, AI berarti ilmu yang mempelajari pembuatan mesin dengan indera seperti manusia (merasakan), analisis atau pemahaman dan respon (Mondal, 2020). AI pertama kali dijelaskan pada tahun 1950; namun, beberapa keterbatasan model awal menghalangi penerimaan dan penerapannya secara luas pada obat-obatan. Sekarang, setelah sistem AI mampu menganalisis algoritma kompleks dan belajar mandiri, kita memasuki era baru dalam dunia kedokteran di mana AI dapat diterapkan pada praktik klinis melalui model penilaian risiko, meningkatkan akurasi diagnostik, dan efisiensi alur kerja (Furizal dkk., 2023; Kaul dkk., 2020; Saadatmand dkk., 2022).

1.3.2 *MACHINE LEARNING*

Machine learning adalah salah satu alat yang paling menjanjikan dalam klasifikasi (Gudiyangada Nachappa dkk., 2020; Kwekha-Rashid dkk., 2023; Niu & Huang, 2019). *Machine learning* adalah bidang dalam kecerdasan buatan yang mempelajari dan mengembangkan algoritma komputer yang dapat belajar dan meningkatkan kinerjanya secara mandiri dari data (Chauhan dkk., 2023). Disiplin ilmu ini bertujuan untuk membangun model dan metode yang memberdayakan sistem otonom untuk menghasilkan perilaku cerdas tanpa instruksi eksplisit (Febrian dkk., 2023). *Machine learning* adalah model yang bertujuan untuk menemukan fungsi, ketergantungan, atau struktur yang tidak diketahui antara variabel input dan output (Zhang dkk., 2020).

1.3.3 *EXPERT SYSTEM*

Sistem pakar yaitu aplikasi komputer yang dikembangkan untuk memecahkan masalah kompleks dalam bidang tertentu pada tingkat kecerdasan dan keahlian manusia yang luar biasa (Janjanam dkk., 2021; Samhan dkk., 2021). Karakteristik sistem pakar yaitu berkinerja tinggi, dapat dimengerti, dapat diandalkan, dan sangat responsif (Al-Masawabe & Abu-Naser, 2021). Sistem yang menggunakan pengalaman manusia mensimulasikan pemikiran melalui penerapan pengetahuan dan antarmuka. Sistem ini juga memanfaatkan pengetahuan pakar sebagai basis data dan data di dalam sistem, menangani kemampuan untuk memecahkan masalah dalam pakar manusia (Elhabib & Abu-Naser, 2021; Muhammad & Algehyne, 2021). Sistem ini digunakan untuk mengeksplorasi diagnosa medis atau sebagai alat bantu Pendidikan (Mettleq dkk., 2019).

1.3.4 *BAYES' THEOREM*

Teorema Bayes adalah metode yang ditemukan oleh Thomas Bayes (Perbawawati dkk., 2019; Trihartati & Adi, 2016). Teorema Bayes merupakan suatu metode yang didasarkan pada training data, berlandaskan pada probabilitas bersyarat. Teorema Bayes merupakan aturan yang menggunakan probabilitas untuk membuat keputusan terbaik atas informasi yang tersedia. Penggunaan metode ini memiliki keuntungan utama yaitu menyerderhanakan metode klasik yang mungkin sulit untuk dipahami (Manalu, 2021). Teorema Bayes sebagai rumus matematika guna membantu menghitung nilai probabilitas dari bukti-bukti yang diberikan untuk menghasilkan nilai hipotesis (Mondal, 2020). Persamaan Bayes dinyatakan sebagai berikut (Setyaputri dkk., 2018).

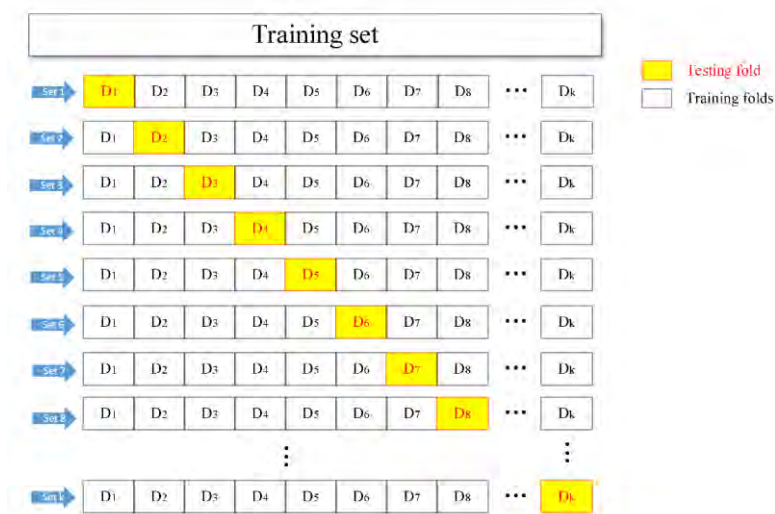
$$P(H_k|E) = \frac{P(E|H_k)P(H_k)}{\sum_{k=1}^n P(E|H_k)P(H_k)} \quad (1.1)$$

$P(H_k|E)$ mewakili probabilitas dari hipotesis H_k bila diberikan bukti E , menggambarkan tingkat keyakinan atas kebenaran H_k setelah mempertimbangkan bukti. Sementara itu, $P(E|H_k)$ mencerminkan probabilitas munculnya bukti E jika diketahui bahwa hipotesis H_k adalah benar, memperlihatkan sejauh mana bukti mendukung validitas H_k . Selain itu, $P(H_k)$ menunjukkan probabilitas dari hipotesis H_k tanpa mempertimbangkan bukti apa pun, memberikan gambaran tentang tingkat keyakinan sebelum bukti diperhitungkan. Parameter n melambangkan jumlah hipotesis yang ada.

1.3.5 K-FOLD CROSS VALIDATION

Cross validation adalah pengukuran untuk menilai kinerja model prediktif dan analisis statistik akan menggeneralisasi ke kumpulan data independen. Cross validation sering digunakan untuk pelatihan dan pengujian algoritma *machine learning* (Casal-Guisande dkk., 2022; King dkk., 2021). Ada banyak jenis cross validation, salah satunya yaitu K-Fold Cross Validation (Rohani dkk., 2018).

K-Fold Cross Validation berfungsi untuk menilai kinerja proses sebuah metode algoritma dengan membagi sampel data secara acak dan mengelompokkan data tersebut sebanyak nilai K k-fold (Ahmed dkk., 2018; Febrian dkk., 2023; Kaliappan dkk., 2023; Shehzad dkk., 2022; Wieczorek dkk., 2022). Gambar 1.1 dengan jelas mengilustrasikan konsep validasi silang K-fold, di mana data awal dibagi secara acak ke dalam K fold (kelompok). Istilah-istilah teknis akan dijelaskan pada saat pertama kali digunakan. Format dan kutipan yang konsisten akan diterapkan, dan kesalahan tata bahasa serta istilah-istilah yang ambigu akan dihindari. Dalam setiap iterasi, satu kelompok ditetapkan sebagai dataset pengujian, sedangkan $K-1$ kelompok lainnya merupakan set pelatihan. Metodologi ini mempertahankan formalitas, objektivitas, dan keseimbangan. Eksperimen ini tetap menggunakan teknik validasi silang K-fold, di mana satu fold dicadangkan sebagai dataset pengujian, sementara $K-1$ fold yang tersisa berfungsi sebagai dataset pelatihan untuk melatih dan menilai model yang dipilih dengan data pengujian yang telah ditentukan (Barile dkk., 2022; Yan dkk., 2022). Metode ini menjamin penggunaan semua data yang tersedia untuk pengujian dan pelatihan model, menjadikannya strategi evaluasi yang andal dan tahan lama (Gupta dkk., 2021; Lyu dkk., 2022; Soper, 2021).



Gambar 1.1 *K-fold cross validation*

Nilai K dalam K-Fold Cross Validation adalah parameter yang ditentukan pengguna yang menentukan berapa banyak fold dataset yang akan dibagi. Biasanya, nilai K dipilih antara 5 dan 10, tetapi juga dapat diatur ke nilai yang lebih tinggi jika kumpulan data cukup besar untuk menampungnya (Roy & Saha, 2022).

1.4 METODOLOGI

Gambar 1.2 adalah representasi visual dari kerangka penelitian yang dijalankan dalam studi ini. Kerangka penelitian ini menguraikan langkah-langkah utama yang diambil dalam penelitian, dimulai dari tahap awal hingga hasil akhir yang diharapkan.

Tahap pertama dalam penelitian ini adalah melakukan studi pustaka yang mendalam mengenai penyakit bayi. Tujuannya adalah untuk menggali pengetahuan yang telah ada sebelumnya mengenai berbagai penyakit yang mungkin dialami oleh bayi. Dengan pemahaman yang kuat tentang penyakit-penyakit ini, penelitian dapat berbasis pada dasar yang kokoh.

Selanjutnya, penelitian melibatkan pengumpulan data dari Puskesmas Sorong. Data ini akan digunakan untuk membentuk dataset yang akan menjadi dasar dari penelitian. Data yang terkumpul kemudian dibagi menjadi beberapa bagian menggunakan metode K-Fold, di mana dataset akan terbagi menjadi sejumlah bagian (K) untuk digunakan dalam proses pengujian.

Setelah pembagian dataset, dilakukan proses klasifikasi dengan menerapkan metode Teorema Bayes untuk membangun model yang dapat mengklasifikasikan penyakit pada bayi berdasarkan gejala yang diamati. Model yang telah dibangun kemudian diuji menggunakan teknik K-Fold Cross Validation. Tujuannya adalah untuk memastikan bahwa model yang dikembangkan efektif dan memiliki tingkat akurasi yang tinggi dalam mengidentifikasi penyakit bayi.

Hasil akhir dari penelitian ini adalah evaluasi performa model klasifikasi. Evaluasi ini mencakup kemampuan model dalam mengidentifikasi penyakit bayi berdasarkan gejala yang diamati menggunakan metode Teorema Bayes dengan bantuan Teknik K-Fold Cross Validation. Hasil ini memberikan wawasan yang penting tentang sejauh mana metode ini

efektif dalam mendiagnosis penyakit pada bayi. Dengan kata lain, penelitian ini bertujuan untuk menyediakan informasi yang berharga dalam pengembangan sistem diagnosis penyakit bayi yang akurat dan efektif.

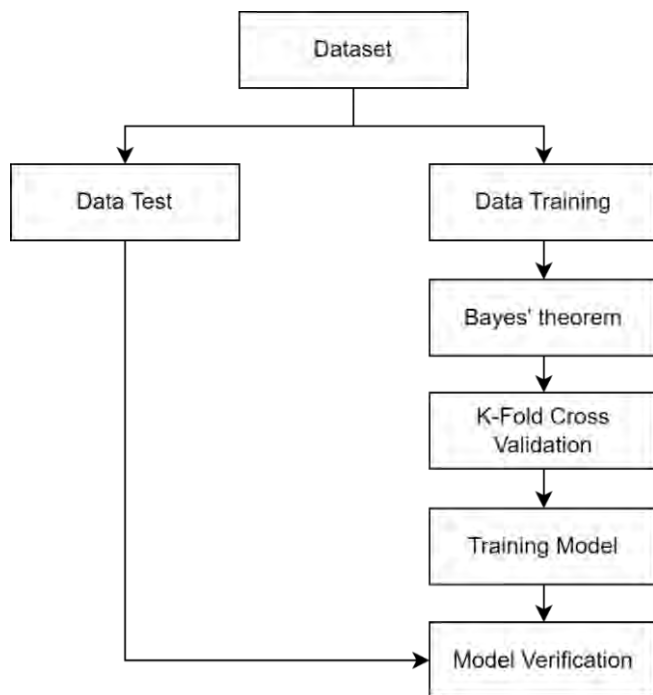


Gambar 1.2 Kerangka Penelitian

Gambar 1.3 adalah representasi visual yang menjelaskan alur kerja dataset ketika diterapkan dalam konteks Teorema Bayes yang telah dioptimalkan melalui proses pengujian K-Fold Cross Validation. Diagram alir ini memaparkan serangkaian langkah yang dilakukan dalam proses analisis data. Pertama, dataset awal dibagi menjadi dua bagian utama: data training (pelatihan) dan data testing (pengujian). Data training digunakan untuk melatih model menggunakan Teorema Bayes, di mana model akan memanfaatkan pengetahuan yang terkandung dalam data ini untuk membuat prediksi.

Setelah model pelatihan selesai, langkah selanjutnya adalah melakukan pengujian menggunakan K-Fold Cross Validation. Teknik ini melibatkan pembagian data training menjadi beberapa sub-kluster yang disebut "fold" dan melakukan pengujian berulang dengan menggunakan kombinasi data training dan data uji dari masing-masing fold. Tujuannya adalah untuk menghasilkan model pelatihan yang konsisten dan kuat dalam menghadapi berbagai situasi data uji yang berbeda.

Hasil dari proses K-Fold Cross Validation adalah model pelatihan yang telah diverifikasi dan diuji dengan berbagai data uji. Model ini diharapkan memiliki kemampuan yang tinggi untuk menghasilkan prediksi yang akurat. Dalam konteks ini, akurasi model adalah salah satu metrik yang digunakan untuk mengukur sejauh mana model tersebut mampu melakukan prediksi yang benar. Dengan demikian, Gambar 1.3 memberikan pandangan visual tentang bagaimana dataset mengalir melalui serangkaian langkah ini, yang akhirnya menghasilkan model yang dapat memberikan prediksi dengan tingkat akurasi yang diharapkan.



Gambar 1.3 Diagram alir teorema bayes yang dioptimalkan dengan k-fold cross validation

1.5 HASIL DAN PEMBAHASAN

Bagian ini akan menguraikan paparan analisis Teorema Bayes terkait diagnosis penyakit bayi yang diuji menggunakan K-Fold Cross Validation.

1.5.1 DATA ACQUISITION

Dataset yang digunakan merupakan data pasien bayi bulan September 2021 hingga Desember 2022 pada Puskesmas Sorong. Kumpulan data yang diperoleh sebanyak 120 data. Deskripsi dataset dapat dilihat pada Tabel 1.1.

Tabel 1.1 Deskripsi Dataset

<i>ID Atribut</i>	<i>Nama Atribut</i>	<i>Deskripsi Atribut</i>
1	ID pasien	ID pasien
2	Usia	Usia pasien [tahun, bulan]
3	G01	Batuk pilek [0: no, 1: yes].
4	G02	Dehidrasi [0: no, 1: yes]
5	G03	Hidung tersumbat [0: no, 1: yes]
6	G04	Batuk [0: no, 1: yes]
7	G05	Radang tenggorokan [0: no, 1: yes]
8	G06	Batuk berlendir [0: no, 1: yes]
9	G07	Batuk Kering [0: no, 1: yes]
10	G08	Bunyi stridor [0: no, 1: yes]
11	G09	Bersin [0: no, 1: yes]
12	G10	Flu [0: no, 1: yes]

<i>ID</i> <i>Atribut</i>	<i>Nama</i> <i>Atribut</i>	<i>Deskripsi Atribut</i>
13	G11	BAB encer yang lebih dari empat kali [0: no, 1: yes]
14	G12	Ingus kental [0: no, 1: yes]
15	G13	Mulut teras pahit [0: no, 1: yes]
16	G14	Gemetar [0: no, 1: yes]
17	G15	Mual muntah [0: no, 1: yes]
18	G16	Timbul bentol atau ruang di sela jari, sekitar pusar, anus, perut, dan pelipatan [0: no, 1: yes]
19	G17	Blas disekitar lipatan [0: no, 1: yes]
20	G18	Bisul [0: no, 1: yes]
21	G19	Luka bernanah [0: no, 1: yes]
22	G20	Leher terasa sakit [0: no, 1: yes]
23	G21	Feses berampas[0: no, 1: yes]
24	G22	Feses berair[0: no, 1: yes]
25	G23	Nafas sesak [0: no, 1: yes]
26	G24	Gatal yang terasa tidur [0: no, 1: yes]
27	G25	Perut kembung [0: no, 1: yes]
28	G26	Luti luti air [0: no, 1: yes]
29	G27	Gatal sampai luka [0: no, 1: yes]
30	G28	Demam [0: no, 1: yes]
31	G29	Ruam [0: no, 1: yes]
32	G30	Pilek [0: no, 1: yes]
33	Penyakit	Penyakit pasien [0: Infeksi Saluran Pernapasan Akut, 1: Faringitis Akut, 2: Dermatitis Kontak Alergi, 3: Diare, 4: Skabies]

Tabel 1.1 yang disajikan adalah deksripsi dari atribut-atribut yang digunakan dalam suatu dataset. Atribut-atribut ini mencakup informasi terkait pasien, gejala klinis, dan diagnosis penyakit. Setiap atribut memiliki penjelasan mendalam tentang makna dan tipe informasi yang diwakili. Misalnya, atribut usia menyajikan informasi tentang usia pasien dalam tahun dan bulan, sedangkan atribut penyakit mengidentifikasi jenis penyakit yang diderita oleh pasien dengan menggunakan kode khusus. Terdapat juga atribut yang merepresentasikan gejala-gejala seperti batuk, hidung tersumbat, dan demam dengan nilai biner (0: tidak, 1:ya), yang memberikan gambaran keberadaan atau ketiadaan gejala pada pasien. Atribut-atribut ini penting dalam proses identifikasi penyakit dan diagnosis, memungkinkan analisis yang lebih mendalam terhadap hubungan antara gejala dan jenis penyakit yang mungkin diderita oleh pasien. Dengan memahami setiap atribut ini, data dapat diinterpretasikan secara lebih efektif untuk mendukung pengambilan keputusan klinis yang tepat.

Dataset ini mencakup beragam informasi medis terkait kondisi kesehatan yang sering terjadi pada bayi meliputi usia bayi, gejala yang dialami bayi, dan jenis penyakit yang menjadi landasan untuk penelitian ini. Tabel 1.2 menggambarkan isi dari sebagian dataset yang akan digunakan dalam penelitian ini. Dataset ini masih dalam kondisi mentah dan belum mengalami tahap pemrosesan.

Tabel 1.2 Dataset Asli

<i>ID</i> <i>pasien</i>	<i>Usia</i>	<i>G0</i> <i>1</i>	<i>G0</i> <i>2</i>	<i>G0</i> <i>3</i>	<i>G0</i> <i>4</i>	<i>G0</i> <i>5</i>	...	<i>G2</i> <i>6</i>	<i>G2</i> <i>7</i>	<i>G2</i> <i>8</i>	<i>G2</i> <i>9</i>	<i>G3</i> <i>0</i>	<i>Penyakit</i>
8	1 bulan	yes	no	no	no	no	...	no	no	yes	no	no	Infeksi Saluran Pernapasan Akut
67	1 bulan	no	no	no	no	no	...	no	no	yes	no	no	Dermatitis Kontak Alergi
115	1 bulan	no	no	no	no	no	...	yes	no	no	yes	no	Skabies

<i>ID pasien</i>	<i>Usia</i>	<i>G0 1</i>	<i>G0 2</i>	<i>G0 3</i>	<i>G0 4</i>	<i>G0 5</i>	...	<i>G2 6</i>	<i>G2 7</i>	<i>G2 8</i>	<i>G2 9</i>	<i>G3 0</i>	<i>Penyakit</i>
120	1 bulan	no	no	no	no	no	...	no	no	no	no	yes	Skabies
83	1 bulan	no	no	no	no	no	...	no	no	yes	no	no	Diare
106	1 bulan	no	no	no	no	no	...	no	yes	no	no	no	Skabies
32	1 bulan	yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
7	2 bulan	yes	no	yes	no	no	...	no	no	yes	no	no	Infeksi Saluran Pernapasan Akut
74	2 bulan	yes	no	no	no	no	...	no	no	no	yes	no	Dermatitis Kontak Alergi
33	2 bulan	yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
...
47	4 tahun	yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
53	4 tahun	no	no	no	no	no	...	no	yes	no	no	no	Dermatitis Kontak Alergi
59	4 tahun	no	no	no	no	no	...	no	no	yes	no	yes	Dermatitis Kontak Alergi
64	4 tahun	no	no	no	no	no	...	no	yes	no	no	no	Dermatitis Kontak Alergi
65	4 tahun	no	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
105	4 tahun	no	no	no	no	no	...	no	no	no	no	no	Skabies
108	4 tahun	no	no	no	no	no	...	yes	yes	no	no	no	Skabies
36	4,5 tahun	no	no	no	yes	yes	...	no	no	yes	no	no	Faringitis Akut
55	4,6 tahun	no	no	no	no	no	...	no	yes	no	yes	no	Dermatitis Kontak Alergi
60	4,8 tahun	no	no	no	no	no	...	no	yes	yes	no	no	Dermatitis Kontak Alergi

Tabel 1.2 berisi data pasien dengan kolom-kolom yang mencantumkan informasi mengenai pasien, gejala-gejala yang mereka alami (dinyatakan dalam kolom G01 hingga G30), usia pasien, dan penyakit yang didiagnosis. Setiap baris dalam tabel mewakili seorang pasien dengan ID uniknya. Informasi usia pasien mulai dari 1 bulan hingga 4,8 tahun dicatat. Kemudian, dalam kolom G01 hingga G30, ada informasi mengenai gejala yang dialami pasien, di mana "yes" menunjukkan adanya gejala tertentu dan "no" menunjukkan ketiadaan gejala tersebut. Terakhir, kolom "Penyakit" mencantumkan jenis penyakit yang didiagnosis pada pasien tertentu, seperti Infeksi Saluran Pernapasan Akut, Dermatitis Kontak Alergi, Skabies, Faringitis Akut, dan lainnya.

Dengan menggunakan tabel ini, para profesional medis atau peneliti dapat menganalisis gejala pasien untuk membuat diagnosis penyakit. Data usia dan gejala-gejala yang ada pada setiap pasien dapat digunakan sebagai dasar untuk menentukan jenis penyakit yang diderita oleh pasien tersebut. Tabel ini dapat menjadi alat penting dalam penelitian dan diagnosis medis, serta membantu dalam mengidentifikasi pola gejala yang terkait dengan penyakit tertentu pada berbagai kelompok usia.

1.5.2 PREPROCESSING

Preprocessing adalah langkah penting dalam pemodelan yang dapat membantu meningkatkan akurasi, kehandalan, dan efisiensi model. Beberapa teknik yang digunakan dalam *preprocessing* pada penelitian ini yaitu:

1. *Data Cleaning*

Tahap ini dilakukan untuk memastikan bahwa data yang digunakan untuk melatih model adalah data yang berkualitas dan konsisten (Badriyah dkk., 2020). Data awal yang dikumpulkan berisi ID pasien, usia, G01 hingga G30, dan penyakit. Data yang dikumpulkan berisi ID pasien dan usia tidak diperlukan untuk melakukan training data. Dataset yang telah dilakukan *cleaning data* dapat dilihat pada Tabel 1.3.

Tabel 1.3 Cleaning Data

G01	G02	G03	G04	G05	...	G26	G27	G28	G29	G30	Penyakit
yes	no	no	no	no	...	no	no	yes	no	no	Infeksi Saluran Pernapasan Akut
no	no	no	no	no	...	no	no	yes	no	no	Dermatitis Kontak Alergi
no	no	no	no	no	...	yes	no	no	yes	no	Skabies
no	no	no	no	no	...	no	no	no	no	yes	Skabies
no	no	no	no	no	...	no	no	yes	no	no	Diare
no	no	no	no	no	...	no	yes	no	no	no	Skabies
yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
yes	no	yes	no	no	...	no	no	yes	no	no	Infeksi Saluran Pernapasan Akut
yes	no	no	no	no	...	no	no	no	yes	no	Dermatitis Kontak Alergi
yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
...
yes	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
no	no	no	no	no	...	no	yes	no	no	no	Dermatitis Kontak Alergi
no	no	no	no	no	...	no	no	yes	no	yes	Dermatitis Kontak Alergi
no	no	no	no	no	...	no	yes	no	no	no	Dermatitis Kontak Alergi
no	no	no	no	no	...	no	no	yes	no	no	Faringitis Akut
no	no	no	no	no	...	no	no	no	no	no	Skabies
no	no	no	no	no	...	yes	yes	no	no	no	Skabies
no	no	no	yes	yes	...	no	no	yes	no	no	Faringitis Akut
no	no	no	no	no	...	no	yes	no	yes	no	Dermatitis Kontak Alergi
no	no	no	no	no	...	no	yes	yes	no	no	Dermatitis Kontak Alergi

Tabel 1.3 merupakan hasil dari proses pembersihan data yang mencakup gejala-gejala pasien dan diagnosis penyakit yang didiagnosis pada mereka. Kolom-kolom tersebut mulai dari G01 hingga G30 mewakili gejala yang dialami oleh pasien, dengan "yes" menandakan kehadiran gejala tersebut dan "no" menandakan ketiadaan gejala tersebut. Setiap baris dalam tabel mewakili data untuk satu pasien tertentu. Di samping gejala, ada juga kolom "Penyakit" yang mencantumkan jenis penyakit yang didiagnosis pada pasien tersebut, seperti Infeksi Saluran Pernapasan Akut, Dermatitis Kontak Alergi, Skabies, dan Faringitis Akut.

Namun, kolom "ID Pasien" dan "Usia" sepertinya tidak diperlukan dalam tabel ini karena tidak ada informasi yang relevan dengan gejala dan diagnosis penyakit. Oleh karena itu, kolom-kolom tersebut bisa dihapus atau tidak digunakan dalam analisis data lebih lanjut. Fokus utama dari tabel ini adalah pada gejala-gejala dan diagnosis penyakit, yang akan digunakan untuk menganalisis dan memahami hubungan antara gejala dan jenis penyakit yang dialami oleh pasien. Dengan menghilangkan kolom yang tidak relevan, data akan menjadi lebih sederhana dan mudah diinterpretasikan untuk tujuan analisis medis.

2. Transformation

Tahap ini dilakukan proses mengubah data input ke dalam format yang dapat digunakan oleh algoritma Teorema Bayes (Hasan dkk., 2021). Hasil Transformasi data dapat dilihat pada Tabel 1.4.

Tabel 1.4 Transformasi Data

<i>G01</i>	<i>G02</i>	<i>G03</i>	<i>G04</i>	<i>G05</i>	...	<i>G26</i>	<i>G27</i>	<i>G28</i>	<i>G29</i>	<i>G30</i>	<i>Penyakit</i>
1	0	0	0	0	...	0	0	1	0	0	Infeksi Saluran Pernapasan Akut
0	0	0	0	0	...	0	0	1	0	0	Dermatitis Kontak Alergi
0	0	0	0	0	...	1	0	0	1	0	Skabies
0	0	0	0	0	...	0	0	0	0	1	Skabies
0	0	0	0	0	...	0	0	1	0	0	Diare
0	0	0	0	0	...	0	1	0	0	0	Skabies
1	0	0	0	0	...	0	0	1	0	0	Faringitis Akut
1	0	1	0	0	...	0	0	1	0	0	Infeksi Saluran Pernapasan Akut
1	0	0	0	0	...	0	0	0	1	0	Dermatitis Kontak Alergi
1	0	0	0	0	...	0	0	1	0	0	Faringitis Akut
...
1	0	0	0	0	...	0	0	1	0	0	Faringitis Akut
0	0	0	0	0	...	0	1	0	0	0	Dermatitis Kontak Alergi
0	0	0	0	0	...	0	0	1	0	1	Dermatitis Kontak Alergi
0	0	0	0	0	...	0	1	0	0	0	Dermatitis Kontak Alergi
0	0	0	0	0	...	0	0	1	0	0	Faringitis Akut
0	0	0	0	0	...	0	0	0	0	0	Skabies
0	0	0	0	0	...	1	1	0	0	0	Skabies
0	0	0	1	1	...	0	0	1	0	0	Faringitis Akut
0	0	0	0	0	...	0	1	0	1	0	Dermatitis Kontak Alergi
0	0	0	0	0	...	0	1	1	0	0	Dermatitis Kontak Alergi

Tabel 1.4 adalah hasil dari proses transformasi data yang mengubah gejala-gejala pasien dan diagnosis penyakit menjadi format yang lebih sederhana untuk analisis. Kolom-kolom ini, mulai dari G01 hingga G30, awalnya berisi "yes" atau "no" untuk mengindikasikan kehadiran atau ketiadaan gejala pada pasien. Dalam tabel ini, gejala "yes" diubah menjadi angka 1, sedangkan gejala "no" diubah menjadi angka 0. Ini membantu dalam mengubah data kualitatif menjadi data kuantitatif yang lebih mudah digunakan untuk analisis statistik.

Kolom "Penyakit" tetap tidak berubah dan mencantumkan jenis penyakit yang didiagnosis pada pasien. Dengan transformasi ini, data gejala pasien sekarang dapat digunakan untuk analisis statistik lebih lanjut. Data ini lebih mudah digunakan dalam berbagai algoritma pemodelan dan analisis data untuk mengidentifikasi pola gejala yang berkaitan dengan jenis penyakit yang didiagnosis. Dengan adanya data ini yang sudah diubah menjadi format angka, analisis data lebih lanjut dapat dilakukan untuk memahami hubungan antara gejala dan diagnosis penyakit pada pasien dengan lebih mudah dan akurat.

1.5.3 ANALISIS TEOREMA BAYES MENGGUNAKAN K-FOLD CROSS VALIDATION

Dataset yang telah melewati proses *preprocessing* akan diklasifikasikan menggunakan algoritma Teorema Bayes. Kombinasi yang sinergi antara Teorema Bayes dan K-Fold Cross Validation membantu dalam menganalisis dengan lebih baik, memperbaiki keyakinan awal mengenai kinerja model berdasarkan bukti empiris yang terakumulasi dari pengujian model pada berbagai set data. Proses evaluasi klasifikasi dilakukan melalui K-Fold Cross Validation dengan 10-fold, dimana dataset dibagi menjadi 10 bagian. Sebanyak 90% digunakan sebagai data latih dan 10% sisanya sebagai data uji.

Setiap segmen data latih dianalisis dengan menggunakan metode Teorema Bayes. Selanjutnya, hasil perhitungan Teorema Bayes pada tiap segmen data latih diuji dengan bagian data uji yang sesuai. Pengujian ini diulang sepuluh kali dengan konfigurasi pengujian yang berbeda pada setiap iterasi fold. Hasil evaluasi dataset pada fold pertama dapat dilihat pada Tabel 1.5.

Tabel 1.5 Hasil Testing Dataset Fold 1


<i>ID pasien</i>	<i>Label</i>	<i>Prediksi</i>	<i>Akurasi</i>
118	Skabies	Faringitis Akut	Tidak Akurat
9	Infeksi Saluran Pernapasan Akut	Diare	Tidak Akurat
87	Diare	Diare	Akurat
90	Diare	Diare	Akurat
70	Dermatitis Kontak Alergi	Dermatitis Kontak Alergi	Akurat
36	Faringitis Akut	Faringitis Akut	Akurat
115	Skabies	Skabies	Akurat
62	Dermatitis Kontak Alergi	Dermatitis Kontak Alergi	Akurat
4	Infeksi Saluran Pernapasan Akut	Infeksi Saluran Pernapasan Akut	Akurat
3	Infeksi Saluran Pernapasan Akut	Infeksi Saluran Pernapasan Akut	Akurat
34	Faringitis Akut	Dermatitis Kontak Alergi	Tidak Akurat
106	Skabies	Dermatitis Kontak Alergi	Tidak Akurat

Tabel 1.5 memuat data mengenai pasien-pasien beserta penyakit yang diderita, prediksi penyakit berdasarkan Teorema Bayes pada fold-1, dan akurasi prediksi untuk setiap kasus. Pasien dengan ID 118 didiagnosa menderita Skabies dengan prediksi Faringitis Akut, namun prediksinya dianggap tidak akurat. Pasien dengan ID 9 mengalami Infeksi Saluran

Pernapasan Akut dengan prediksi Diare, yang juga dianggap tidak akurat. Disisi lain, pasien-pasien seperti ID 87, 90, 70, dan lainnya memiliki prediksi yang akurat sesuai dengan penyakit yang mereka derita seperti Diare atau Dermatitis Kontak Alergi. Dalam kasus-kasus di mana prediksi berbeda dengan penyakit yang sebenarnya, seperti ID 34 dan 106, hasilnya dianggap tidak akurat. Penilaian akurasi prediksi berdasarkan Teorema Bayes adalah penting dalam konteks perawatan kesehatan, memastikan bahwa diagnosis yang tepat diberikan kepada pasien untuk penanganan yang sesuai dan efektif.

1.5.4 EVALUASI


Hasil evaluasi model Teorema Bayes dengan menggunakan metode K-Fold Cross Validation menunjukkan konsistensi yang baik dalam kinerja model. Rata-rata akurasi dari seluruh iterasi K-Fold Cross Validation mencapai 92%. Hal ini menunjukkan tingkat keandalan dan konsistensi model dalam memprediksi penyakit bayi dengan tepat pada berbagai subset data uji.



Gambar 1.4 Perbandingan estimasi performance setiap fold pada 10-fold cross validation

Gambar 1.4 merupakan hasil evaluasi performa model Teorema Bayes yang dilakukan dengan menggunakan teknik K-Fold Cross Validation dengan 10-fold. Evaluasi ini dilakukan dengan mengukur sejumlah metrik performa, seperti akurasi, *precision*, *recall*, dan *F1-Score*, pada setiap fold. Akurasi, yang mengindikasikan seberapa baik model dalam mengklasifikasikan data dengan benar, berkisar antara 87% hingga 97% pada setiap fold. Ini berarti model mampu membuat prediksi yang benar secara signifikan dalam rentang nilai tersebut.

Precision, yang menunjukkan proporsi dari hasil positif yang diprediksi dengan benar oleh model, juga menunjukkan variasi antara 0.60 hingga 0.92 di berbagai fold. *Recall*, yang mengukur proporsi kasus positif yang diidentifikasi dengan benar oleh model, bervariasi antara 0.55 hingga 0.90. Ini menunjukkan sejauh mana model dapat mengenali sebagian besar kasus positif yang ada dalam data. Nilai *F1-Score*, yang mencerminkan rata-rata harmonik antara *precision* dan *recall*, memberikan perspektif yang seimbang tentang performa model dalam setiap fold. Rata-rata performa model Teorema Bayes dapat dilihat pada Gambar 1.5.



Gambar 1.5 Representasi hasil rata-rata pemodelan teorema bayes dengan 10-fold cross validation

Gambar 1.5 merupakan hasil rata-rata dari penggunaan 10-fold cross validation pada model Teorema Bayes untuk mendiagnosis penyakit bayi, dan hasil tersebut bisa diuraikan sebagai berikut. Pertama, tingkat akurasi model mencapai 92%, yang mencerminkan seberapa tepat model dalam mengklasifikasikan penyakit bayi secara keseluruhan. Angka ini menunjukkan seberapa besar persentase prediksi yang benar dari total prediksi yang dibuat oleh model. *Precision*, yang mencapai 78%, mengindikasikan kemampuan model dalam mengidentifikasi penyakit bayi secara spesifik dari total kasus yang diprediksi positif. Ini artinya model cenderung membuat lebih sedikit kesalahan dalam memprediksi kasus positif. Selanjutnya, *recall* sekitar 75%, mencerminkan sejauh mana model mampu mendeteksi keseluruhan kasus penyakit bayi yang sebenarnya positif. Dengan kata lain, seberapa baik model dapat mengenali semua kasus penyakit bayi yang seharusnya dideteksi. *F1-Score* sekitar 73%, yang mencerminkan keseimbangan antara *precision* dan *recall*, yang penting untuk memastikan bahwa model tidak hanya akurat dalam mengidentifikasi kasus positif, tetapi juga mampu mencakup sebagian besar kasus yang seharusnya terdeteksi.

Hasil evaluasi ini menggambarkan model Teorema Bayes dengan K-Fold Cross Validation sebagai alat yang efektif untuk mendiagnosis penyakit bayi berdasarkan gejala yang diamati. Performa yang kuat ini memberikan keyakinan bahwa model ini dapat digunakan untuk membantu praktisi medis dalam melakukan diagnosis penyakit bayi dengan lebih tepat dan efisien, yang pada gilirannya dapat meningkatkan perawatan kesehatan bayi secara keseluruhan.

1.6 DISKUSI

Pada bagian ini, kami mengevaluasi model Teorema Bayes yang digunakan untuk mendiagnosis penyakit bayi dengan menggunakan metode K-Fold Cross Validation. K-Fold Cross Validation adalah teknik yang membagi dataset menjadi 10 bagian yang setara, di

mana satu bagian digunakan sebagai data uji sementara sembilan bagian lainnya digunakan sebagai data latih. Evaluasi model dilakukan sepuluh kali, di mana setiap fold digunakan sebagai data uji secara bergantian.

Hasil pengujian menggunakan K-Fold Cross Validation menunjukkan variasi dalam akurasi model pada setiap fold. Grafik Gambar 1.4 menunjukkan perbedaan akurasi pada masing-masing fold, memberikan gambaran tentang sejauh mana model stabil dalam berkinerja pada berbagai data uji yang berbeda. Gambar 1.5 menggambarkan hasil evaluasi kinerja model dengan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-Score*. Hasil evaluasi menunjukkan bahwa rata-rata kinerja model selama sepuluh kali pengujian 10-fold adalah sekitar 92% untuk akurasi, 78% untuk *precision*, 75% untuk *recall*, dan 73% untuk *F1-Score*.

Secara keseluruhan, hasil evaluasi ini menyiratkan bahwa model mampu menghasilkan prediksi yang cukup akurat, terutama ketika data dibagi dengan baik dan perhitungan probabilitas dilakukan secara teliti. Konsistensi dalam hasil evaluasi ini meningkatkan keyakinan bahwa model ini efektif dalam mendiagnosis penyakit bayi. Dengan kemampuan model ini dalam menghasilkan prediksi yang akurat, dapat membantu tenaga medis dalam diagnosis yang lebih tepat dan efisien bagi pasien bayi.

1.7 KESIMPULAN

Evaluasi pemodelan dengan menggunakan teknik pengujian K-Fold Cross Validation pada Teorema Bayes dalam konteks diagnosis penyakit bayi memberikan pemahaman yang sangat berharga tentang bagaimana model tersebut berkinerja. K-Fold Cross Validation melibatkan pembagian dataset menjadi beberapa bagian (fold), pelatihan model pada sebagian data, dan mengujinya pada bagian yang tersisa secara bergantian. Hasil evaluasi ini mengungkapkan sejauh mana model dapat beradaptasi dengan beragamnya data uji, serta kemampuan umumnya untuk membuat diagnosis yang akurat.

Ketika hasil evaluasi menunjukkan bahwa model memiliki kinerja yang tinggi secara konsisten di setiap fold, ini memberikan keyakinan bahwa model dapat diandalkan dalam mendiagnosis penyakit bayi. Penggunaan K-Fold Cross Validation telah terbukti efektif dalam proses pelatihan dan pengujian model, dan ini penting karena memberikan gambaran yang konsisten tentang seberapa baik model berkinerja pada berbagai dataset uji.

Kesimpulan utama dari rangkaian evaluasi ini adalah bahwa model Teorema Bayes yang diuji menggunakan K-Fold Cross Validation adalah alat yang efektif untuk mendiagnosis penyakit bayi. Evaluasi yang cermat dan analisis performa yang terperinci membantu memvalidasi dan meningkatkan keyakinan dalam keandalan model, hal ini sangat penting dalam konteks perawatan kesehatan bayi. Dengan demikian, model ini dapat menjadi alat yang berharga dalam membantu tenaga medis dalam membuat diagnosis yang akurat dan efisien bagi pasien bayi.

1.8 DAFTAR PUSTAKA

- Ahmed, F. Y. H., Ali, Y. H., & Shamsuddin, S. M. (2018). Using K-Fold Cross Validation Proposed Models for Spikeprop Learning Enhancements. *International Journal of Engineering & Technology*, 7(4.11), 145. <https://doi.org/10.14419/ijet.v7i4.11.20790>
- Al-Issa, Y., Alqudah, A. M., Alquran, H., & Al Issa, A. (2022). Pulmonary Diseases Decision Support System Using Deep Learning Approach. *Computers, Materials & Continua*, 73(1), 311–326. <https://doi.org/10.32604/cmc.2022.025750>

- Al-Masawabe, M. M., & Abu-Naser, S. S. (2021). Expert System for Short-term Abdominal Pain (Stomach Pain) Diagnosis and Treatment. *International Journal of Academic Information Systems Research (IJASIR)*, 5(5), 37–56.
- Badriyah, T., Savitri, N. A., Sa'adah, U., & Syarif, I. (2020). Application of Naive Bayes Method for IUGR (Intra Uterine Growth Restriction) Diagnosis on The Pregnancy. *2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, June, 1–4. <https://doi.org/10.1109/ICECCE49384.2020.9179256>
- Barile, C., Casavola, C., Pappalettera, G., & Kannan, V. P. (2022). Damage Progress Classification in AlSi10Mg SLM Specimens by Convolutional Neural Network and k-Fold Cross Validation. *Materials*, 15(13), 4428. <https://doi.org/10.3390/ma15134428>
- Bentley, P. M. (2021). Error rates in SARS-CoV-2 testing examined with Bayes' theorem. *Heliyon*, 7(4), e06905. <https://doi.org/10.1016/j.heliyon.2021.e06905>
- Casal-Guisande, M., Comesaña-Campos, A., Dutra, I., Cerqueiro-Pequeño, J., & Bouza-Rodríguez, J.-B. (2022). Design and Development of an Intelligent Clinical Decision Support System Applied to the Evaluation of Breast Cancer Risk. *Journal of Personalized Medicine*, 12(2), 169. <https://doi.org/10.3390/jpm12020169>
- Chang, C.-S., Yeh, Y.-T., Chien, T.-W., Lin, J.-C. J., Cheng, B.-W., & Kuo, S.-C. (2020). The computation of case fatality rate for novel coronavirus (COVID-19) based on Bayes theorem. *Medicine*, 99(21), e19925. <https://doi.org/10.1097/MD.00000000000019925>
- Chauhan, A. S., Lilhore, U. K., Gupta, A. K., Manoharan, P., Garg, R. R., Hajje, F., Keshta, I., & Raahemifar, K. (2023). Comparative Analysis of Supervised Machine and Deep Learning Algorithms for Kyphosis Disease Detection. *Applied Sciences*, 13(8), 5012. <https://doi.org/10.3390/app13085012>
- Desiani, A., Primartha, R., Arhami, M., & Orsalan, O. (2019). Naive Bayes Classifier for Infant Weight Prediction of Hypertension Mother. *Journal of Physics: Conference Series*, 1282, 1–9. <https://doi.org/10.1088/1742-6596/1282/1/012005>
- Diagnostic and Statistical Manual of Mental Disorders (DSM-5-TR)*. (n.d.). American Psychiatric Association. <https://www.psychiatry.org/psychiatrists/practice/dsm>
- Elhabib, B. Y., & Abu-Naser, S. S. (2021). An Expert System for Ankle Problems. *International Journal of Engineering and Information Systems (IJEAIS)*, 5(4), 57–66. www.ijeais.org/ijeais
- Febrian, M. E., Ferdinan, F. X., Sendani, G. P., Suryanigrum, K. M., & Yunanda, R. (2023). Diabetes prediction using supervised machine learning. *Procedia Computer Science*, 216(2022), 21–30. <https://doi.org/10.1016/j.procs.2022.12.107>
- Furizal, F., Ma'arif, A., & Rifaldi, D. (2023). Application of Machine Learning in Healthcare and Medicine: A Review. *Journal of Robotics and Control (JRC)*, 4(5), 621–631. <https://doi.org/10.18196/jrc.v4i5.19640>
- Gudiyangada Nachappa, T., Tavakkoli Piralilou, S., Gholamnia, K., Ghorbanzadeh, O., Rahmati, O., & Blaschke, T. (2020). Flood Susceptibility Mapping with Machine Learning, Multi-Criteria Decision Analysis and Ensemble Using Dempster Shafer Theory. *Journal of Hydrology*, 590, 125275. <https://doi.org/10.1016/j.jhydrol.2020.125275>
- Gupta, S., Verma, H. K., & Bhardwaj, D. (2021). Classification of Diabetes using Naïve Bayes and Support Vector Machine as a Technique. In *Operations Management and Systems Engineering* (hal. 365–376). https://doi.org/10.1007/978-981-15-6017-0_24
- Hasan, M., Faruk, O., Biki, B. B., Riajuliislam, R., Alam, K., & Shetu, S. F. (2021). Prediction of Pneumonia Disease of Newborn Baby Based on Statistical Analysis of Maternal Condition Using Machine Learning Approach. *2021 11th International*

- Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 919–924. <https://doi.org/10.1109/Confluence51648.2021.9377169>
- Hersh, A. L., Jackson, M. A., Hicks, L. A., Brady, M. T., Byington, C. L., Davies, H. D., Edwards, K. M., Maldonado, Y. A., Murray, D. L., Orenstein, W. A., Rathore, M., Sawyer, M., Schutze, G. E., Willoughby, R. E., & Zaoutis, T. E. (2013). Principles of Judicious Antibiotic Prescribing for Upper Respiratory Tract Infections in Pediatrics. *Pediatrics*, *132*(6), 1146–1154. <https://doi.org/10.1542/peds.2013-3260>
- International Statistical Classification of Diseases and Related Health Problems (ICD)*. (n.d.). World Health Organization. <https://www.who.int/standards/classifications/classification-of-diseases>
- Janjanam, D., Ganesh, B., & Manjunatha, L. (2021). Design of an expert system architecture: An overview. *Journal of Physics: Conference Series*, *1767*(1). <https://doi.org/10.1088/1742-6596/1767/1/012036>
- Jiang, Y., Li, X., Luo, H., Yin, S., & Kaynak, O. (2022). Quo vadis artificial intelligence? *Discover Artificial Intelligence*, *2*(1), 4. <https://doi.org/10.1007/s44163-022-00022-8>
- Kaliappan, J., Bagepalli, A. R., Almal, S., Mishra, R., Hu, Y. C., & Srinivasan, K. (2023). Impact of Cross-Validation on Machine Learning Models for Early Detection of Intrauterine Fetal Demise. *Diagnostics*, *13*(10), 1–22. <https://doi.org/10.3390/diagnostics13101692>
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of Artificial Intelligence in Medicine. *Gastrointestinal Endoscopy*, *92*(4), 807–812. <https://doi.org/10.1016/j.gie.2020.06.040>
- King, R. D., Orhobor, O. I., & Taylor, C. C. (2021). Cross-validation is safe to use. *Nature Machine Intelligence*, *3*(4), 276. <https://doi.org/10.1038/s42256-021-00332-z>
- Kwekha-Rashid, A. S., Abduljabbar, H. N., & Alhayani, B. (2023). Coronavirus Disease (COVID-19) Cases Analysis using Machine-Learning Applications. *Applied Nanoscience*, *13*(3), 2013–2025. <https://doi.org/10.1007/s13204-021-01868-7>
- Lyu, Z., Yu, Y., Samali, B., Rashidi, M., Mohammadi, M., Nguyen, T. N., & Nguyen, A. (2022). Back-Propagation Neural Network Optimized by K-Fold Cross-Validation for Prediction of Torsional Strength of Reinforced Concrete Beam. *Materials*, *15*(4). <https://doi.org/10.3390/ma15041477>
- Manalu, S. (2021). Expert System for Identification of Diseases of Toddlers using Bayes' Theorem Method. *International Journal of Basic and Applied Science*, *10*(1), 9–16. <https://ijobas.pelnu.ac.id/index.php/ijobas/article/view/9%0Ahttps://ijobas.pelnu.ac.id/index.php/ijobas/article/download/9/9>
- Mettleq, A. S. A., Dheir, I. M., Elsharif, A. A., & Abu-Naser, S. S. (2019). Expert System for the Diagnosis of Seventh Nerve Inflammation (Bell's palsy) Disease. *International Journal of Academic Information Systems Research (IJAIRS)*, *3*(4), 27–35.
- Mondal, B. (2020). Artificial Intelligence: State of the Art. In *Intelligent Systems Reference Library* (Vol. 172, hal. 389–425). https://doi.org/10.1007/978-3-030-32644-9_32
- Muhammad, L. J., & Algehyne, E. A. (2021). Fuzzy Based Expert System for Diagnosis of Coronary Artery Disease in Nigeria. *Health and Technology*, *11*(2), 319–329. <https://doi.org/10.1007/s12553-021-00531-z>
- Niu, B., & Huang, Y. (2019). An Improved Method for Web Text Affective Cognition Computing Based on Knowledge Graph. *Computers, Materials & Continua*, *59*(1), 1–14. <https://doi.org/10.32604/cmc.2019.06032>
- Nti, I. K., Nyarko-Boateng, O., & Aning, J. (2021). Performance of Machine Learning Algorithms with Different K Values in K-fold CrossValidation. *International Journal of Information Technology and Computer Science*, *13*(6), 61–71. <https://doi.org/10.5815/ijitcs.2021.06.05>
- Perbawawati, A. A., Sugiharti, E., & Muslim, M. A. (2019). Bayes Theorem and Forward

- Chaining Method On Expert System for Determine Hypercholesterolemia Drugs. *Scientific Journal of Informatics*, 6(1), 116–124. <https://doi.org/10.15294/sji.v6i1.14149>
- Putri, R. A., Sendari, S., & Widiyaningtyas, T. (2018). Classification of Toddler Nutrition Status with Anthropometry Calculation using Naïve Bayes Algorithm. *2018 International Conference on Sustainable Information Engineering and Technology (SIET)*, 66–70. <https://doi.org/10.1109/SIET.2018.8693169>
- Reddy, S., Fox, J., & Purohit, M. P. (2019). Artificial Intelligence-Enabled Healthcare Delivery. *Journal of the Royal Society of Medicine*, 112(1), 22–28. <https://doi.org/10.1177/0141076818815510>
- Rohani, A., Taki, M., & Abdollahpour, M. (2018). A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy*, 115, 411–422. <https://doi.org/10.1016/j.renene.2017.08.061>
- Roy, J., & Saha, S. (2022). Ensemble hybrid machine learning methods for gully erosion susceptibility mapping: K-fold cross validation approach. *Artificial Intelligence in Geosciences*, 3(July), 28–45. <https://doi.org/10.1016/j.aiig.2022.07.001>
- Saadatmand, S., Salimifard, K., Mohammadi, R., Marzban, M., & Naghibzadeh-Tahami, A. (2022). Predicting the Necessity of Oxygen Therapy in the Early Stage of COVID-19 using Machine Learning. *Medical & Biological Engineering & Computing*, 60(4), 957–968. <https://doi.org/10.1007/s11517-022-02519-x>
- Samhan, L. F., Alfarra, A. H., & Abu-Naser, S. S. (2021). An Expert System for Knee Problems Diagnosis. *International Journal of Academic Information Systems Research*, 5(4), 59–66. www.ijeais.org/ijaisr
- Setyaputri, K. E., Fadlil, A., & Sunardi, S. (2018). Comparative Analysis of Certainty Factor Method and Bayes Probability Method on ENT Disease Expert System. *Scientific Journal of Informatics*, 5(2), 205–212. <https://doi.org/10.15294/sji.v5i2.16151>
- Shehzad, F., Islam, M., Omar, M., Shah, S. I. H., Ahmed, R., & Sohail, N. (2022). Optimizations of Modified Machine Learning Algorithms Using K-Fold Cross Validations for Wheat Productivity: A Hyper Parametric Approach. *Sarhad Journal of Agriculture*, 38(5), 271–278. <https://doi.org/10.17582/journal.sja/2022/38.5.271.278>
- Soper, D. S. (2021). Greed Is Good: Rapid Hyperparameter Optimization and Model Selection Using Greedy k-Fold Cross Validation. *Electronics*, 10(16), 1973. <https://doi.org/10.3390/electronics10161973>
- Trihartati, A., & Adi, C. K. (2016). An Identification of Tuberculosis (TB) Disease in Humans using Naïve Bayesian Method. *Scientific Journal of Informatics*, 3(2), 99–108. <https://doi.org/10.15294/sji.v3i2.7918>
- Ureel, Y., Dobbelaere, M. R., Ouyang, Y., De Ras, K., Sabbe, M. K., Marin, G. B., & Van Geem, K. M. (2023). Active Machine Learning for Chemical Engineers: A Bright Future Lies Ahead! *Engineering*, xxx. <https://doi.org/10.1016/j.eng.2023.02.019>
- Wieczorek, J., Guerin, C., & McMahon, T. (2022). K -fold cross-validation for complex sample surveys. *Stat*, 11(1), 1–10. <https://doi.org/10.1002/sta4.454>
- Yan, T., Shen, S.-L., Zhou, A., & Chen, X. (2022). Prediction of geological characteristics from shield operational parameters by integrating grid search and K-fold cross validation into stacking classification algorithm. *Journal of Rock Mechanics and Geotechnical Engineering*, 14(4), 1292–1303. <https://doi.org/10.1016/j.jrmge.2022.03.002>
- Zhang, C., Yao, J., Hu, G., & Schött, T. (2020). Applying Feature-Weighted Gradient Decent K-Nearest Neighbor to Select Promising Projects for Scientific Funding. *Computers, Materials & Continua*, 64(3), 1741–1753.

<https://doi.org/10.32604/cmc.2020.010306>

BAB 2

Analisis Kinerja *Distance Algorithms* pada Pemodelan Klasifikasi *K-Nearest Neighbors* dalam Mendeteksi Stunting

Syahrani Lonang, Anton Yudhana, Muhammad Kunta Biddinika

1.1. PENDAHULUAN

Stunting adalah masalah kesehatan utama yang mempengaruhi anak-anak di bawah usia lima tahun. Prevalensi global stunting pada anak adalah sekitar 21,9%, dengan mayoritas kasus terkonsentrasi di kawasan Asia (Gani dkk., 2021). Menurut data UNICEF World Bank, prevalensi stunting Indonesia pada tahun 2020 menduduki peringkat ke-115 di antara 151 negara di seluruh dunia. Namun demikian, menurut klasifikasi yang diberikan oleh World Health Organization (WHO), Indonesia terus dikategorikan dalam kelompok yang memiliki prevalensi stunting tinggi. Indonesia menempati urutan ketiga dalam prevalensi balita stunting tertinggi di kawasan Asia Tenggara, hanya di belakang Timor-Leste (50,5%) dan India (38,4%), sebesar 36,4% (Sudigyo dkk., 2023), (Kemenkes, 2018). Stunting adalah suatu kondisi di mana balita gagal berkembang karena kekurangan gizi kronis, yang mengakibatkan balita menjadi sangat pendek untuk usia mereka (Tim Nasional Percepatan Penanggulangan Kemiskinan, 2017). Stunting menyebabkan gangguan kognitif, pertumbuhan fisik terhambat, kerentanan terhadap penyakit lebih banyak, bahkan peningkatan risiko kematian pada balita (Perdue dkk., 2019).

Di sektor kesehatan, *machine learning* telah dimanfaatkan serta digunakan untuk mendeteksi penyakit (Prasad dkk., 2016), (Gaurav dkk., 2023) termasuk stunting, menggunakan metode klasifikasi. *K-Nearest Neighbors* (KNN) adalah *machine learning algorithm* yang populer digunakan untuk mengklasifikasi sebuah penyakit. Mendeteksi *polycystic syndrome* di ovarium (Alagarsamy dkk., 2023), memprediksi risiko penyakit kardiovaskular (Garg dkk., 2023), mendiagnosis osteoporosis (Patil dkk., 2021), dan mengidentifikasi demensia (Mathkunti & Rangaswamy, 2020) merupakan contoh penerapan metode KNN di bidang kesehatan.

Tidak hanya di bidang kesehatan, KNN juga digunakan untuk hal-hal lain seperti mengklasifikasikan prestasi akademik mahasiswa, mengidentifikasi kesegaran ikan, prediksi tunggakan pembayaran SPP, prediksi perbaikan kebijakan manufaktur, dan prediksi kesalahan *software* (Suguna dkk., 2019), (Yudhana dkk., 2022), (Kusrini dkk., 2019), (Akhbari dkk., 2014), (Hammad dkk., 2019).

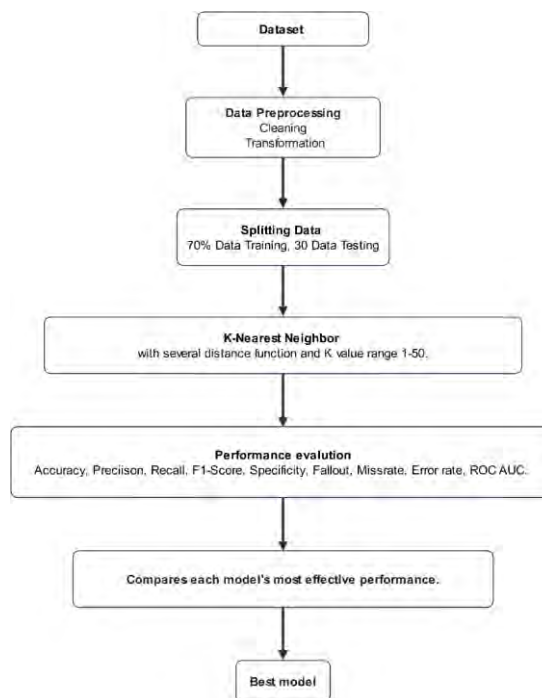
Tinjauan literatur berikut akan menyoroti KNN, dan berbagai algoritma *machine learning* yang digunakan dalam penelitian yang berbeda untuk mendeteksi penyakit. Algoritma KNN telah diakui sebagai algoritma *machine learning* populer yang digunakan untuk deteksi penyakit dan diagnosis (Uddin dkk., 2022).

KNN digunakan dalam penelitian (Sendari dkk., 2019) untuk mengklasifikasikan status gizi balita menggunakan antropometri, dataset yang digunakan adalah 210 *record* Pos Layanan Terpadu. Nilai k yang digunakan adalah 3, 5, 7, 9, dan 15. Pada nilai k 3, 5, 7, dan 9, akurasi tertinggi yang dicapai adalah 85,24% dengan tingkat kesalahan 14,76%. Berbagai algoritma pembelajaran mesin digunakan dalam penelitian lain untuk memprediksi stunting di Rwanda. *Logistic regression*, *random forest*, *naive bayes*, *extreme gradient boosting*, dan *graded boosting* adalah lima algoritma yang digunakan. *Gradient boosting* menghasilkan hasil terbaik, dengan akurasi 79,33%, presisi (72,51%), recall (94,49%), dan f1-score (82,05%) (Ndagijimana dkk., 2023). Penelitian lain oleh (Mansur dkk., 2021) mengklasifikasikan stunting menggunakan *machine learning techniques* seperti *logistic regression* dan *classification tree*. Data *Bangladesh Demographic and Health Survey* (BDHS) 2014 digunakan. Akurasi 67,1% dan 68,9% adalah hasil yang tertinggi setelah dilakukan pengujian untuk kedua algoritma tersebut. Penelitian serupa dilakukan oleh (Chilyabanyama dkk., 2022) melakukan analisis kinerja algoritma *machine learning* dalam mengklasifikasikan stunting pada anak. Dari hasil penelitian ini, *random forest* merupakan algoritma yang paling akurat, dengan akurasi 79%. Penelitian lain menggunakan berbagai pengklasifikasi untuk menilai dan membandingkan kemampuan prediksi optimal untuk

diabetes. Hasil eksperimen menunjukkan bahwa algoritma KNN mengungguli pengklasifikasi SVM, mencapai tingkat akurasi 83,15% (Kaur, 2019). Menggunakan *metric accuracy, specificity, precision, recall, f-measure* dan, MCC studi KNN lain mengevaluasi kinerjanya dalam memprediksi penyakit jantung. Hasil analisis KNN mampu memberikan kinerja prediktif dengan tingkat presisi tinggi dan utilitas potensial tinggi (Ali dkk., 2021).

Tujuan dari penelitian ini adalah untuk menganalisis efektivitas algoritma KNN menggunakan empat *distance function*, yaitu *Euclidean, Manhattan, Minkowski, dan Canberra*, dengan nilai *k* mulai dari 1 hingga 50. *Dataset* yang digunakan dalam penelitian ini adalah data Elektronik Pencatatan dan Pelaporan Gizi Balita Berbasis Masyarakat (EPPGBM) . Temuan penelitian kami menunjukkan bahwa kinerja KNN dapat diandalkan untuk mengklasifikasikan balita stunting. *Euclidean distance function* dengan $K = 6$ dan *Manhattan* $K = 12$ menghasilkan kinerja yang sangat baik dan merupakan nilai *k* yang paling efektif dari masing-masing fungsi jarak. Penelitian ini menjelaskan metodologi KNN yang terbaik dalam hal *accuracy, precision, recall*, dan lain-lain dalam mendeteksi stunting. Metode ini cepat dan efektif. Oleh karena itu, metode ini memberikan pendekatan baru untuk mengklasifikasikan balita dengan stunting menggunakan KNN dengan menggunakan empat fungsi jarak dengan nilai *K* mulai dari satu hingga 50.

1.2 METODOLOGI PENELITIAN

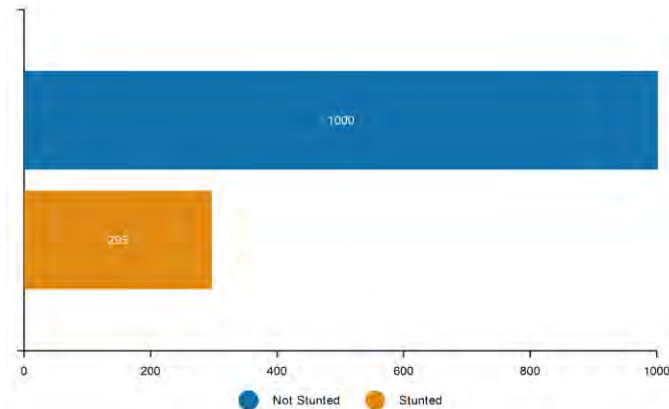


Gambar 1.1 Flowchart metodologi yang diusulkan

Metodologi yang diusulkan dalam makalah ini dapat dilihat pada Gambar 1.1 Kumpulan data yang digunakan akan melalui *preprocessing, data preprocessing* mengacu pada transformasi data yang belum diproses menjadi dataset yang bersih. Dataset diproses sebelumnya untuk memeriksa nilai yang hilang, data dengan *noise*, dan inkonsistensi lainnya sebelum algoritma dijalankan. *Noise data* dapat menyebabkan kesalahan dalam proses *data mining*, sehingga harus dihilangkan (Hamidi & Daraei, 2016) dan data harus dalam format yang *machine learning* kompatibel (Thajeel dkk., 2023). Dalam hal ini, jika algoritma hanya memproses data numerik, kelas berlabel "tidak stunting" atau "stunting" harus diganti


dengan "0" atau "1". Dua *subset* akan dibuat dari *dataset*: data testing dan *data training*. Distribusi *subset* ini akan menjadi 30 persen data pengujian dan 70 persen data pelatihan, sebagaimana ditentukan oleh model yang digunakan dalam penelitian ini. Empat fungsi jarak KNN digunakan dalam penelitian ini untuk membangun model klasifikasi stunting, dan kemudian beberapa kinerja metrik digunakan untuk mengevaluasi efektivitas KNN dalam mengklasifikasikan balita stunting.

1.2.1 DATASET



Gambar 1.2 Diagram batang yang disajikan menggambarkan distribusi data di berbagai kelas.

Penelitian ini menggunakan dataset yang berasal dari data Elektronik Pencatatan dan Pelaporan Gizi Balita Berbasis Masyarakat (EPPGBM), yang dikumpulkan dari Puskesmas Jonggat, Kabupaten Lombok Tengah, Indonesia. Seperti yang ditunjukkan pada Gambar 1.2, *dataset* berisi total 1259 *record* dengan dua kelas. Status balita dibagi menjadi dua kategori berdasarkan hasil diagnostik. Kategori 01: 1000 balita tidak diidentifikasi mengalami stunting. Kategori 02: 295 balita diidentifikasi mengalami stunting. Dua kelas dibagi sebagai berikut: Stunting mempengaruhi 23% balita dan tidak mempengaruhi 77% balita. *Dataset* ini memiliki empat kolom atribut dan satu kolom kelas. Ada 101 balita perempuan dan 194 balita laki-laki di antara 295 balita dengan tanda-tanda stunting. Gambar. 1.3 mewakili distribusi setiap atribut dalam *dataset*.



Gambar 1.3 Distribusi dataset untuk (a) jenis kelamin, (b) usia, (c) berat badan, (d) tinggi balita.

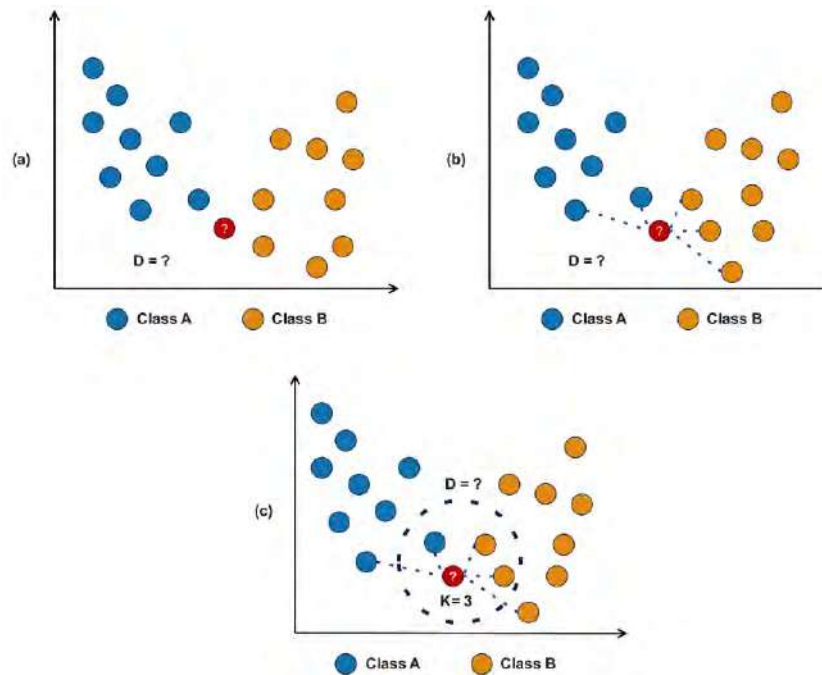
Kumpulan data yang digunakan tidak berisi nilai yang hilang, dan Tabel 1.1 memberikan deskripsi terperinci tentang fitur tersebut.

Tabel 1.1 Deskripsi *dataset*

Atribut	Fitur	Deskripsi
1	Jenis kelamin	Jenis kelamin balita (0: laki-laki, 1: perempuan)
2	Umur	Usia balita, 1-60 (bulan)
3	Berat	Berat balita (kilogram)
4	Tinggi	Tinggi balita dalam sentimeter (cm)
5	Kelas	0 'Tidak Stunting' dan 1 'Stunting'

1.2.2 K-NEAREST NEIGHBORS

K-Nearest Neighbor (KNN) adalah salah satu algoritma pembelajaran mesin yang diawasi yang paling banyak digunakan karena kemampuannya untuk memecahkan masalah yang kompleks (Abbad Ur Rehman dkk., 2021), (Yudhana dkk., 2022). Prinsip kerja dasar KNN adalah menentukan kelas berdasarkan kelas tetangga terdekatnya. Algoritma KNN relatif mudah diterapkan, tetapi sering disebut sebagai algoritma pembelajaran malas. Karena KNN menunda generalisasi data pelatihan sampai tugas diterima oleh model (Cunningham & Delany, 2022), (Maillo dkk., 2017).



Gambar 1.4 Prinsip kerja KNN, (a) data asli, (b) menghitung jarak, (c) mengidentifikasi tetangga terdekat dan menetapkan label yang paling sering di antara k

Efektivitas algoritma KNN dipengaruhi oleh dua faktor kunci: fungsi jarak dan nilai K (Mushtaq dkk., 2020). Jumlah tetangga yang dipilih ditentukan oleh parameter K dalam algoritma KNN. Pilihan parameter K secara signifikan mempengaruhi akurasi klasifikasi algoritma KNN (Barakat dkk., 2023). Gambar 1.4 menggambarkan prinsip kerja KNN. Lingkaran biru mewakili kelas A, dan lingkaran oranye milik kelas B. Lingkaran merah adalah titik data yang algoritma akan coba klasifikasikan sebagai kelas A atau kelas B. Pada Gambar 1.4, simbol 'D' menunjukkan fungsi jarak, dan garis putus-putus menargetkan titik data dari setiap kelas yang paling dekat dengan lingkaran kuning. Lingkaran merah akan diidentifikasi sebagai milik kelas A oleh KNN jika lingkaran merah kita dekat dengan

sejumlah besar objek atau lingkaran di kelas A; jika tidak, lingkaran merah akan diidentifikasi oleh algoritma sebagai milik kelas B.

Ada beberapa fungsi jarak dalam KNN yang dapat digunakan untuk mengukur jarak. Fungsi jarak berikut digunakan dalam penelitian ini: jarak *Euclidean*, *Manhattan*, *Minkowski*, dan *Canberra*. Biarkan x dan y menjadi vektor fitur $x = (x_1, x_2, \dots, x_n)$, dan $y = (y_1, y_2, \dots, y_n)$. Fungsi jarak dibahas sebagai berikut:

$$Euclidean_{d(x,y)} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1.1) \quad Manhattan_{d(x,y)} =$$

$$\sum_{i=1}^n |x_i - y_i| \quad (1.2) \quad Minkowski_{d(x,y)} = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}}$$

$$(1.3) \quad Canberra_{d(x,y)} = \sum_{i=1}^n \left(\frac{|x_i - y_i|}{|x_i| + |y_i|} \right) \quad (1.4)$$

1.2.3 PERFORMANCE EVALUATION

Kinerja model klasifikasi akan dinilai dengan memanfaatkan confusion matrix. Penerapan *confusion matrix* memberikan analisis komprehensif kinerja model melalui penyelidikan berbagai indikator kinerja. Klasifikasi yang dilakukan oleh model, baik aktual maupun prediksi, umumnya direpresentasikan dan divisualisasikan menggunakan *confusion matrix* (Islam dkk., 2017), (Sahu dkk., 2019). Klasifikasi aktual dan prediksi yang dilakukan oleh model biasanya dihasilkan dan digambarkan oleh matriks kebingungan. Tabel yang disebut sebagai *confusion matrix* sering digunakan untuk menggambarkan kinerja model klasifikasi pada satu set data uji dengan nilai sebenarnya yang diketahui (Awujoola dkk., 2022).

Penelitian ini tidak menyeimbangkan data untuk mengevaluasi kinerja KNN pada dataset yang tidak seimbang. Metrik akurasi digunakan, tetapi kelemahannya adalah tidak dapat mendeteksi kinerja model yang buruk ketika data tidak seimbang. Akibatnya, beberapa indikator metrik kinerja, seperti *precision*, *recall*, *f1-score*, *specificity*, *fall-out*, *miss-rate*, *error-rate*, dan AUC digunakan untuk mendapatkan data kinerja model yang komprehensif. Menggunakan kumpulan metrik ini memungkinkan kami mengevaluasi model sambil mengatasi batasan masing-masing metrik. Contoh *confusion matrix* untuk klasifikasi biner ditunjukkan pada Gambar 1.5.

Confusion Matrix

Predicted Class	0	True Negative (TN)	False Negative (FN)
	1	False Positive (FP)	True Positive (TP)
		0	1
		Actual Class	

Gambar 1.5 Confusion matrix visualization

True negative, dilambangkan sebagai TN pada Gambar 1.5 menunjukkan jumlah titik data kelas negatif aktual yang diprediksi oleh model sebagai negatif aktual. Istilah FN mengacu pada jumlah data yang diprediksi memiliki kelas negatif tetapi positif. *True positive* disingkat TP, adalah jumlah data positif yang diklasifikasikan dengan benar oleh model berdasarkan kelasnya. Jumlah data dalam kelas yang negatif tetapi diprediksi positif oleh model disebut sebagai positif palsu (FP) (Sharma dkk., 2022), (Luque dkk., 2019), (Vanacore dkk., 2022).

Setelah *confusion matrix* dihasilkan untuk setiap model, kinerja klasifikasi akan dinilai menggunakan berbagai metrik, termasuk *error rate*, *precision*, *accuracy*, *recall*, *f1-score*, *specificity*, *fallout*, dan *miss rate*. Metrik ini akan dihitung berdasarkan rumus yang disediakan di bawah ini.

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100\%, \quad (1.5)$$

$$Error\ rate = \frac{FP+FN}{TP+FP+TN+FN} \times 100\%, \quad (1.6)$$

$$Precision = \frac{TP}{TP+FP} \times 100\%, \quad (1.7)$$

$$Recall\ (TPR) = \frac{TP}{TP+FN} \times 100\% \quad (1.8)$$

$$F1\ -\ Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \times 100\%, \quad (1.9)$$

$$Specificity\ (TNR) = \frac{TN}{TN+FP} \times 100\% \quad (1.10)$$

$$Fallout\ (FPR) = \frac{FP}{FP+TN} \times 100\%, \quad (1.11)$$


$$Missrate (FNR) = \frac{FN}{FN+TP} \times 100\% \quad (1.12)$$

Metrik ini menjadi dasar untuk mengevaluasi kinerja pengklasifikasi, yang akan diperkenalkan selanjutnya. *Accuracy* adalah persentase prediksi yang benar. Ini mengukur seberapa baik model memprediksi suatu kondisi. *Precision* adalah metrik yang digunakan untuk mengevaluasi relevansi instans yang diambil. Ini dihitung sebagai rasio prediksi positif sejati dengan himpunan semua nilai positif sejati (Ho dkk., 2019). Recall atau sering disebut *true positive rate* adalah persentase *true positive* yang diprediksi dengan benar. *Specificity* adalah proporsi kasus negatif yang diprediksi secara akurat terhadap jumlah keseluruhan kasus negatif yang sebenarnya (Tharwat, 2021). *F1-score* adalah presisi antara rata-rata harmonik *recall* (Shaban dkk., 2020).

Area under the ROC Curve (AUC) digunakan sebagai metrik signifikan tambahan untuk mengevaluasi kemampuan dan ketahanan model klasifikasi ketika nilai ambang batas diubah. AUC ditentukan dengan memplot kurva karakteristik operasi penerima (ROC) dengan tingkat positif palsu pada sumbu horizontal dan tingkat positif sebenarnya pada sumbu vertikal. Area di bawah kurva (AUC) menunjukkan ketepatan tes yang membedakan antara kelas yang diprediksi dan kelompok kelas yang sebenarnya. Nilai AUC berkisar dari 0 (semua kelas salah diprediksi) hingga 1 (semua kelas diprediksi dengan benar) (Valero-Carreras dkk., 2023), (Polat dkk., 2017).

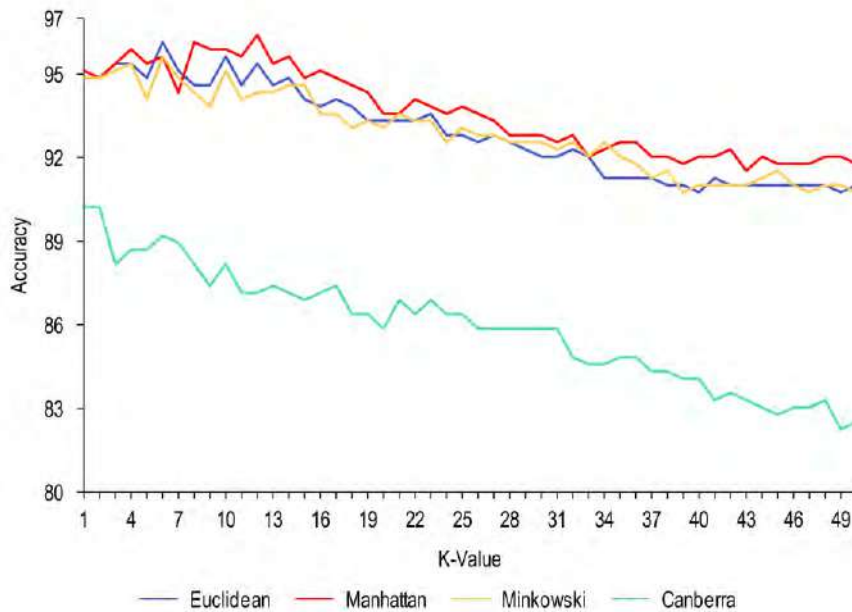
1.3 HASIL DAN PEMBAHASAN

Pekerjaan eksperimental penelitian ini dilakukan pada Intel (R) Core (TM) i5-1240P Generasi ke-12 @ 2,10 GHz, dengan RAM 16 GB dan SSD 512 GB. Model klasifikasi KNN dibuat menggunakan bahasa pemrograman Python di Jupyter Lab. Untuk memilih nilai k yang sesuai dan efektif, 1 hingga 50 adalah rentang nilai k yang dipertimbangkan dengan empat fungsi jarak yang berbeda, dan masing-masing kinerja model kemudian dievaluasi.



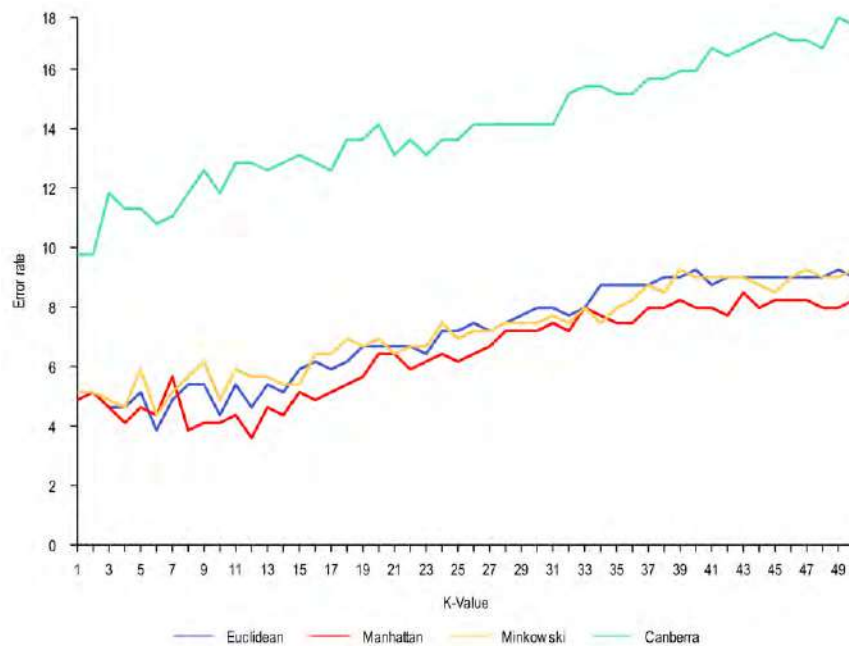
Gambar 1.6 Confusion matrix (a) Euclidean K = 6, (b) Manhattan K = 12, (c) Minkowski K = 6, (d) Canberra K = 1.

Gambar. 1.6 menunjukkan *confusion matrix* pada K terbaik untuk setiap fungsi jarak. Hasil *confusion matrix* oleh fungsi jarak *Euclidean* pada K = 6 ditunjukkan pada Gambar. 13 (a), menghasilkan nilai TN 276, TP = 97, FN = 0, dan FP = 16. *Manhattan* pada K = 12 menghasilkan TP = 89, TN = 286, FP = 6, dan FN = 8, seperti yang ditunjukkan pada Gambar 12 (b). *Confusion matrix Minkowski* dan *Canberra* pada K = 6 dan K = 1 dengan TN dan FP yang sama ditampilkan dalam Gambar. 13 (c) dan (d). TN = 218, FP = 11. Minkowski memiliki TP = 91 dan FN = 6, sedangkan *Canberra* memiliki TP = 70 dan TN = 27.



Gambar 1.7 Akurasi setiap *distance function*

Gambar 1.7 menunjukkan tingkat akurasi yang dicapai oleh algoritma KNN dengan nilai K yang berkisar dari 1 hingga 50 untuk empat *distance function*. Dalam percobaan ini, akurasi tertinggi yang dicapai oleh *Manhattan distance function* adalah 96,40% pada K = 12, yang juga merupakan akurasi tertinggi di antara fungsi jarak lainnya. 90,75% adalah akurasi terendah yang diperoleh dengan K = 49. Keakuratan setiap fungsi jarak menurun seiring dengan meningkatnya nilai k. *Euclidean* dan *Minkowski distance functions* memperoleh akurasi tertinggi pada K = 6 masing-masing 96,14% dan 95,63%. *Canberra distance function* memiliki akurasi terendah dibandingkan dengan yang lain pada 82,26% pada K = 49 dan akurasi tertinggi pada K = 1 dan K = 2 pada 90,23%.



Gambar 1.8 Error rate setiap *distance function*

Berdasarkan hasil pengamatan yang dilakukan pada Gambar 1.8, terlihat bahwa *error rate* cenderung meningkat seiring dengan pertambahan nilai K. Pada *Euclidean distance*, tercatat bahwa *error rate* tertinggi terjadi saat K = 41 dengan nilai 9,25%, sedangkan *error rate* terendah diperoleh saat K = 6 dengan nilai 3,86%. Pada *Manhattan distance*, nilai *error rate* tertinggi terjadi saat K = 43 dengan nilai 8,48%, sementara nilai terendah terdapat pada K = 12 dengan *error rate* 3,60%. Selanjutnya, pada *Minkowski distance*, *error rate* tertinggi tercatat pada K = 50 dengan nilai 9,25%, sedangkan terendah pada k = 6 dengan *error rate* 4,37%. Namun, pada *Canberra distance*, terjadi peningkatan yang signifikan pada *error rate*, dengan nilai tertinggi mencapai 17,74% pada K = 49 dan nilai terendah pada k = 1 dengan 9.77%. Secara rata-rata, *error rate* pada *Euclidean*, *Manhattan*, dan *Minkowski distance* berada pada kisaran 5-9%, sementara pada *Canberra distance*, rata-rata *error rate* lebih tinggi, berkisar antara 10-17%. Hasil ini menunjukkan bahwa keempat *distance function* memiliki pola yang berbeda dalam mengatasi masalah *error rate*, dengan *Manhattan distance* menunjukkan kinerja terbaik dalam mengurangi *error rate* pada kisaran nilai k yang beragam. Berikut adalah performa lengkap setiap *metric* dihasilkan setiap *distance function* untuk dianalisis kinerjanya.

Tabel 1.2 Performa model klasifikasi menggunakan *Euclidean distance*

K	Accuracy	Precision	Recall	F1-Score	Specificity	Fall out	Miss rate	Error rate
1	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
2	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
3	95,37	88,35	93,81	91,00	95,89	4,11	6,19	4,63
4	95,37	87,62	94,85	91,09	95,55	4,45	5,15	4,63
5	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
6	96,14	90,20	94,85	92,46	96,58	3,42	5,15	3,86
7	95,12	89,80	90,72	90,26	96,58	3,42	9,28	4,88
8	94,60	90,43	87,63	89,01	96,92	3,08	12,37	5,40
9	94,60	88,78	89,69	89,23	96,23	3,77	10,31	5,40
10	95,63	90,82	91,75	91,28	96,92	3,08	8,25	4,37
...
41	91,26	89,87	73,20	80,68	97,26	2,74	26,80	8,74
42	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
43	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
44	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
45	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
46	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
47	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
48	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
49	90,75	89,61	71,13	79,31	97,26	2,74	28,87	9,25
50	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00

Berdasarkan Tabel 1.2, dapat dilihat bahwa performa model klasifikasi menggunakan algoritma *K-Nearest Neighbors* (KNN) dengan *euclidean distance* dalam mendeteksi

stunting sangat dipengaruhi oleh nilai K. Pada nilai K=1 hingga K=2, model menunjukkan performa yang stabil dengan tingkat akurasi sebesar 94,86%, *precision* 87,38%, *recall* 92,78%, *F1-score* 90,00%, *specificity* 95,55%, *fall out* 4,45%, *miss rate* 7,22%, dan *error rate* 5,14%. Namun, seiring dengan peningkatan nilai K, terjadi fluktuasi pada performa model. Pada K=6, model mencapai performa terbaiknya dengan tingkat akurasi sebesar 96,14%, *precision* 90,20%, *recall* 94,85%, *F1-score* 92,46%, *specificity* 96,58%, *fall out* 3,42%, *miss rate* 5,15%, dan *error rate* terendah yaitu 3,86%. Namun, setelah K=6, performa model secara umum menurun. Pada K=50, model menunjukkan tingkat akurasi sebesar 91,00%, *precision* 90,79%, *recall* 71,13%, *F1-score* 79,77%, *specificity* 97,60%, *fall out* 2,40%, *miss rate* 28,87%, dan *error rate* 9,00% yang merupakan *error rate* tertinggi. Hasil ini menunjukkan bahwa penggunaan *euclidean distance* dalam algoritma KNN dapat memberikan hasil yang memuaskan dalam mendeteksi stunting pada balita, dengan nilai *error rate* yang relatif rendah, terutama pada nilai k yang optimal.

Dari Tabel 1.2, dapat dilihat juga bahwa *recall* cenderung menurun seiring dengan peningkatan nilai K. Ini menunjukkan bahwa model menjadi kurang sensitif dalam mendeteksi stunting seiring dengan peningkatan jumlah tetangga yang dipertimbangkan. Pada K=1, model mencapai *recall* sebesar 92,78%, namun pada K=50, *recall* menurun menjadi 71,13%. Hal ini dapat terjadi dikarenakan data yang tidak seimbang dapat mempengaruhi performa model klasifikasi dan biasanya mengarah pada prediksi yang bias terhadap kelas mayoritas.

Tabel 1.3 Performa model klasifikasi menggunakan *Manhattan distance*

K	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Specificity</i>	<i>Fall out</i>	<i>Miss rate</i>	<i>Error rate</i>
1	95,12	87,50	93,81	90,55	95,55	4,45	6,19	4,88
2	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
3	95,37	88,35	93,81	91,00	95,89	4,11	6,19	4,63
4	95,89	90,10	93,81	91,92	96,58	3,42	6,19	4,11
5	95,37	87,62	94,85	91,09	95,55	4,45	5,15	4,63
6	95,63	89,22	93,81	91,46	96,23	3,77	6,19	4,37
7	94,34	87,88	89,69	88,78	95,89	4,11	10,31	5,66
8	96,14	91,84	92,78	92,31	97,26	2,74	7,22	3,86
9	95,89	92,63	90,72	91,67	97,60	2,40	9,28	4,11
10	95,89	91,75	91,75	91,75	97,26	2,74	8,25	4,11
11	95,63	92,55	89,69	91,10	97,60	2,40	10,31	4,37
12	96,40	93,68	91,75	92,71	97,95	2,05	8,25	3,60
...
41	92,03	93,42	73,20	82,08	98,29	1,71	26,80	7,97
42	92,29	93,51	74,23	82,76	98,29	1,71	25,77	7,71
43	91,52	93,24	71,13	80,70	98,29	1,71	28,87	8,48
44	92,03	94,59	72,16	81,87	98,63	1,37	27,84	7,97
45	91,77	94,52	71,13	81,18	98,63	1,37	28,87	8,23
46	91,77	94,52	71,13	81,18	98,63	1,37	28,87	8,23
47	91,77	94,52	71,13	81,18	98,63	1,37	28,87	8,23
48	92,03	95,83	71,13	81,66	98,97	1,03	28,87	7,97

49	92,03	95,83	71,13	81,66	98,97	1,03	28,87	7,97
50	91,77	95,77	70,10	80,95	98,97	1,03	29,90	8,23

Berdasarkan Tabel 1.3, dapat dilihat bahwa performa model klasifikasi KNN dengan *Manhattan distance function* pada nilai $K = 1$ model menunjukkan performa yang baik dengan tingkat akurasi sebesar 95,12%, presisi 87,50%, recall 93,81%, F1-Score 90,55%, spesifisitas 95,55%, fall out 4,45%, miss rate 6,19%, dan error rate 4,88%. Namun, seiring dengan peningkatan nilai K , terjadi fluktuasi pada performa model. Pada $K=12$, model mencapai performa terbaiknya dengan tingkat akurasi sebesar 96,40%, presisi 93,68%, recall 91,75%, F1-Score 92,71%, spesifisitas 97,95%, fall out 2,05%, miss rate 8,25%, dan error rate terendah yaitu 3,60%. Ini menunjukkan bahwa $K=12$ adalah nilai K yang paling optimal untuk *Manhattan distance*. Namun, setelah $K=12$, performa model secara umum menurun. Pada $K=50$, model menunjukkan tingkat akurasi sebesar 91,77%, presisi 95,77%, recall 70,10%, F1-Score 80,95%, spesifisitas 98,97%, fall out 1,03%, miss rate 29,90%, dan error rate 8,23% yang merupakan error rate tertinggi. Tingkat kesalahan pada model juga akan dianalisis karena sangat penting untuk menunjukkan kesalahan yang dibuat oleh model. Nilai miss rate yang tinggi menunjukkan bahwa model melewatkan banyak kasus stunting, sedangkan nilai fall out yang tinggi menunjukkan bahwa model salah mengklasifikasikan banyak kasus non-stunting sebagai stunting. Dari Tabel 1.3, dapat dilihat bahwa miss rate dan fall out cenderung meningkat seiring dengan peningkatan nilai K . Ini menunjukkan bahwa peningkatan nilai K dapat meningkatkan kesalahan yang dibuat oleh model dalam mendeteksi stunting. Pada $K=8$, model mencapai miss rate terendah yaitu 7,22% dan fall out terendah yaitu 2,05% pada $K=12$. Namun, pada $K=50$, miss rate meningkat menjadi 29,90% dan fall out menurun menjadi 1,03%. Ini menunjukkan bahwa meskipun model memiliki akurasi yang tinggi, model masih membuat kesalahan dalam mendeteksi stunting, khususnya pada nilai K yang tinggi. Oleh karena itu, dalam penggunaan model ini untuk mendeteksi stunting, perlu dilakukan penyesuaian nilai K untuk meminimalkan kesalahan yang dibuat oleh model.

Tabel 1.4 Performa model klasifikasi menggunakan *Minkowski distance*

K	Accuracy	Precision	Recall	F1-Score	Specificity	Fall out	Miss rate	Error rate
1	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
2	94,86	87,38	92,78	90,00	95,55	4,45	7,22	5,14
3	95,12	87,50	93,81	90,55	95,55	4,45	6,19	4,88
4	95,37	87,62	94,85	91,09	95,55	4,45	5,15	4,63
5	94,09	85,58	91,75	88,56	94,86	5,14	8,25	5,91
6	95,63	89,22	93,81	91,46	96,23	3,77	6,19	4,37
7	94,86	89,69	89,69	89,69	96,58	3,42	10,31	5,14
8	94,34	88,66	88,66	88,66	96,23	3,77	11,34	5,66
9	93,83	87,63	87,63	87,63	95,89	4,11	12,37	6,17
10	95,12	89,80	90,72	90,26	96,58	3,42	9,28	4,88
...
39	90,75	88,61	72,16	79,55	96,92	3,08	27,84	9,25
40	91,00	88,75	73,20	80,23	96,92	3,08	26,80	9,00
41	91,00	89,74	72,16	80,00	97,26	2,74	27,84	9,00

42	91,00	88,75	73,20	80,23	96,92	3,08	26,80	9,00
43	91,00	89,74	72,16	80,00	97,26	2,74	27,84	9,00
44	91,26	90,91	72,16	80,46	97,60	2,40	27,84	8,74
45	91,52	91,03	73,20	81,14	97,60	2,40	26,80	8,48
46	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
47	90,75	89,61	71,13	79,31	97,26	2,74	28,87	9,25
48	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
49	91,00	90,79	71,13	79,77	97,60	2,40	28,87	9,00
50	90,75	89,61	71,13	79,31	97,26	2,74	28,87	9,25

Tabel 1.4 menunjukkan performa model klasifikasi yang menggunakan *Minkowski distance*. Dalam tabel ini, kita dapat melihat bagaimana nilai K mempengaruhi performa model. Pada K=4, model mencapai nilai *recall* tertinggi yaitu 94,85%. Nilai *recall* yang tinggi menunjukkan bahwa model sangat efektif dalam mengidentifikasi kasus stunting. Pada K=44, model mencapai nilai *precision* tertinggi yaitu 91,03%. Nilai *precision* yang tinggi menunjukkan bahwa model sangat akurat dalam prediksinya dan memiliki sedikit *false positive*. Pada K=44, model mencapai nilai *specificity* tertinggi yaitu 97,69%. Nilai *specificity* yang tinggi menunjukkan bahwa model sangat efektif dalam mengidentifikasi kasus non-stunting. Akan tetapi, nilai K yang paling optimal adalah K=6, di mana model mencapai akurasi tertinggi 95,63%, *precision* 89,22%, *recall* 93,81%, *f1-score* 91,46%, *specificity* 96,23%, *fall out* 3,77%, *miss rate* 6,19% dan *error rate* sebesar 4,37%.

Tabel 1.5 Performa model klasifikasi menggunakan *Canberra distance*

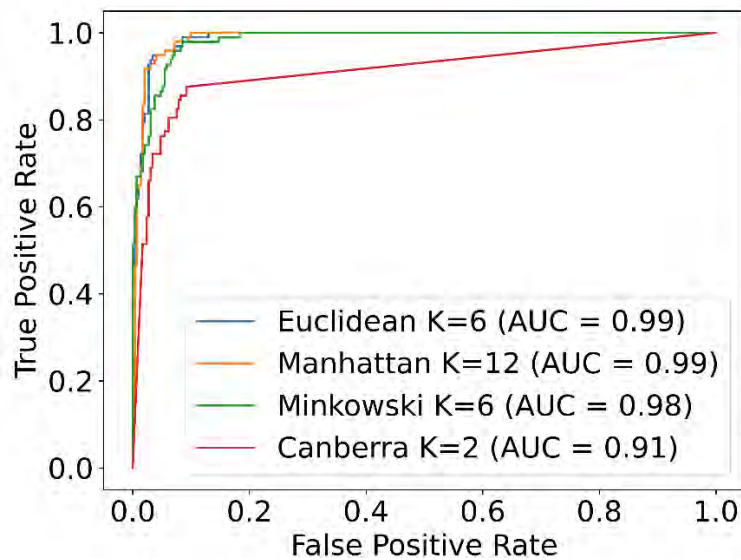
K	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Specificity</i>	<i>Fall out</i>	<i>Miss rate</i>	<i>Error rate</i>
1	90,23	86,42	72,16	78,65	96,23	3,77	27,84	9,77
2	90,23	86,42	72,16	78,65	96,23	3,77	27,84	9,77
3	88,18	84,93	63,92	72,94	96,23	3,77	36,08	11,83
4	88,69	85,33	65,98	74,42	96,23	3,77	34,02	11,31
5	88,69	86,30	64,95	74,12	96,58	3,42	35,05	11,31
6	89,20	87,67	65,98	75,29	96,92	3,08	34,02	10,80
7	88,95	87,50	64,95	74,56	96,92	3,08	35,05	11,05
8	88,18	86,96	61,86	72,29	96,92	3,08	38,14	11,83
9	87,40	86,36	58,76	69,94	96,92	3,08	41,24	12,60
10	88,18	89,23	59,79	71,60	97,60	2,40	40,21	11,83
...
39	84,06	94,87	38,14	54,41	99,32	0,68	61,86	15,94
40	84,06	94,87	38,14	54,41	99,32	0,68	61,86	15,94
41	83,29	94,44	35,05	51,13	99,32	0,68	64,95	16,71
42	83,55	94,59	36,08	52,24	99,32	0,68	63,92	16,45
43	83,29	94,44	35,05	51,13	99,32	0,68	64,95	16,71
44	83,03	94,29	34,02	50,00	99,32	0,68	65,98	16,97
45	82,78	94,12	32,99	48,85	99,32	0,68	67,01	17,22
46	83,03	94,29	34,02	50,00	99,32	0,68	65,98	16,97

47	83,03	94,29	34,02	50,00	99,32	0,68	65,98	16,97
48	83,29	94,44	35,05	51,13	99,32	0,68	64,95	16,71
49	82,26	93,75	30,93	46,51	99,32	0,68	69,07	17,74
50	82,52	93,94	31,96	47,69	99,32	0,68	68,04	17,48


Berdasarkan Tabel 1.5, performa klasifikasi menggunakan *Canberra distance* memberikan gambaran yang mendalam tentang efektivitas model dalam mendeteksi stunting pada balita. Terdapat beberapa metrik evaluasi yang relevan untuk Secara keseluruhan, model menunjukkan tingkat akurasi yang baik, dengan nilai tertinggi sebesar 90,23% pada $k = 1$ dan 2. Namun, perlu diperhatikan bahwa akurasi cenderung menurun seiring dengan peningkatan nilai k , mencapai nilai terendah sebesar 82,26% pada $k = 49$. Hal ini menunjukkan bahwa model cenderung memiliki kinerja yang lebih baik dalam mengidentifikasi stunting pada balita ketika nilai k -nya rendah.

Selanjutnya, *precision* dan *recall* memberikan wawasan yang lebih spesifik tentang kinerja model dalam mengklasifikasikan data stunting. Meskipun terdapat fluktuasi dalam nilai-nilai ini, terdapat kecenderungan bahwa *precision* cenderung lebih tinggi daripada *recall*. Hal ini menunjukkan bahwa model cenderung lebih baik dalam mengklasifikasikan data non-stunting dengan tepat daripada mengidentifikasi data stunting secara keseluruhan. Meskipun fluktuasi terjadi seiring dengan perubahan nilai k , terdapat kecenderungan umum bahwa *F1-Score* cenderung menurun seiring dengan peningkatan nilai k . Model menunjukkan tingkat *specificity* yang tinggi, dengan nilai tertinggi sebesar 99,32% pada beberapa nilai k . Namun, *error rate*, *miss rate*, dan *fall out* cenderung meningkat seiring dengan peningkatan nilai k , menunjukkan bahwa model mungkin mengalami kesulitan dalam mengklasifikasikan beberapa sampel dengan tepat pada nilai k yang lebih tinggi. Hasil ini menunjukkan bahwa meskipun *Canberra distance* memberikan akurasi yang baik dalam mendeteksi stunting pada balita, perlu diperhatikan bahwa kinerja model ini masih lebih rendah dibandingkan ketiga *distance function* yang telah diuji.

Kurva karakteristik operasi penerima (ROC), bersama dengan area di bawah kurva (AUC), adalah metrik signifikan yang digunakan untuk menilai efektivitas pengklasifikasi KNN untuk deteksi stunting. Skor AUC berkisar dari 0 hingga 1, dengan nilai yang lebih tinggi menunjukkan kinerja pengklasifikasi yang lebih baik. Gambar 1.9 menggambarkan skor AUC untuk masing-masing nilai k terbaik untuk empat fungsi jarak yang ada. Fungsi jarak *Manhattan* dan *Euclidean* mencapai nilai AUC tertinggi '0,99'. *Manhattan* dengan $K = 12$, bagaimanapun, adalah model yang paling efektif untuk mengklasifikasikan balita pertumbuhan terhambat.



Gambar 1.9 ROC AUC Score



Gambar 1.10 Perbandingan penelitian ini dengan penelitian lain yang relevan

Gambar. 13 menggambarkan perbandingan pendekatan yang digunakan dalam penelitian ini dengan penelitian yang ada pada topik yang sama. Hasilnya menunjukkan bahwa model kami telah mencapai tingkat akurasi yang luar biasa dengan menggunakan algoritma KNN sederhana dengan fungsi jarak optimal dan nilai K. Klasifikasi yang sangat baik dicapai oleh model kami dengan kinerja akurasi 94,60%. Mengalahkan kinerja model penelitian relevan yang ada, penelitian (Sendari dkk., 2019) mencapai akurasi tertinggi 85,24% dengan jarak Euclidean untuk mengklasifikasikan status gizi pada balita. Keakuratan algoritma peningkatan gradien (Ndagijimana dkk., 2023), pohon klasifikasi (Mansur dkk., 2021), dan hutan acak (Chilyabanyama dkk., 2022) Untuk klasifikasi balita stunting kurang dari 80%, menandakan bahwa model tersebut belum dapat diandalkan untuk mengklasifikasikan balita stunting secara akurat.

1.6 KESIMPULAN

Penerapan algoritma pembelajaran mesin dalam deteksi penyakit telah mendapatkan popularitas yang signifikan di bidang medis karena efektivitas dan kegunaannya. Tulisan ini berpusat pada implementasi klasifikasi *K-Nearest Neighbors* (KNN) yang terkenal untuk klasifikasi stunting. Empat fungsi jarak yang berbeda digunakan pada dataset gizi balita, masing-masing dengan rentang nilai K optimal mulai dari 1 hingga 50. Empat fungsi jarak dibandingkan sambil mempertimbangkan berbagai metrik evaluasi kinerja, seperti *accuracy*, *precision*, *recall*, *f1-score*, *error rate*, *specificity*, *fall out* dan *miss rate*. Setelah menganalisis kinerja empat fungsi jarak KNN, fungsi jarak Manhattan mencapai akurasi 96,40%, presisi 93,68%, tingkat penarikan 91,75%, skor f1 92,71%, tingkat kesalahan 3,60%, spesifisitas 97,95%, kejatuhan 2,05%, dan tingkat kesalahan 8,25% pada nilai k 12. Nilai AUC untuk fungsi jarak Manhattan K = 12 berdasarkan ROC adalah 0,99. Temuan kami menunjukkan bahwa fungsi jarak Manhattan atau Euclidean dengan kisaran nilai K 1 hingga 15 adalah teknik klasifikasi yang efektif untuk mendeteksi balita stunting. Di antara banyak pengklasifikasi, keuntungan dari KNN adalah rentang fungsi jarak yang jelas digunakan dengan faktor-faktor tetangga mereka, juga dikenal sebagai nilai k.

Penelitian ini memberikan rekomendasi untuk penelitian ke depan untuk menyeimbangkan dataset menggunakan metode under sampling dan oversampling untuk hasil yang lebih tepat, serta penambahan variabel yang berdampak pada stunting balita, seperti indeks kekayaan rumah tangga dan tingkat pendidikan orang tua.

DAFTAR PUSTAKA

- Abbad Ur Rehman, H., Lin, C. Y., & Mushtaq, Z. (2021). Effective K-Nearest Neighbor Algorithms Performance Analysis of Thyroid Disease. *Journal of the Chinese Institute of Engineers, Transactions of the Chinese Institute of Engineers, Series A*, 44(1), 77–87. <https://doi.org/10.1080/02533839.2020.1831967>
- Akhbari, M., Zare Mehrjerdi, Y., Khademi Zare, H., & Makui, A. (2014). A novel continuous KNN prediction algorithm to improve manufacturing policies in a VMI Supply Chain. *International Journal of Engineering, Transactions B: Applications*, 27(11), 1681–1690. <https://doi.org/10.5829/idosi.ije.2014.27.11b.05>
- Alagarsamy, M., Shanmugam, N., Mani, D. P., Thayumanavan, M., Sundari, K. K., & Suriyan, K. (2023). Detection of Polycystic Syndrome in Ovary Using Machine Learning Algorithm. *International Journal of Intelligent Systems and Applications in Engineering*, 11(1), 246–253.
- Ali, M. M., Paul, B. K., Ahmed, K., Bui, F. M., Quinn, J. M. W., & Moni, M. A. (2021). Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison. *Computers in Biology and Medicine*, 136, 104672. <https://doi.org/10.1016/j.compbiomed.2021.104672>
- Awujoola, O. J., Ogwueleka, F. N., Odion, P. O., Awujoola, A. E., & Adelegan, O. R. (2022). Genomic data science systems of Prediction and prevention of pneumonia from chest X-ray images using a two-channel dual-stream convolutional neural network. *Data Science for Genomics*, 217–228. <https://doi.org/10.1016/B978-0-323-98352-5.00013-6>
- Barakat, M. E., Chin, C. G., & Ee, L. I. (2023). Performance Analysis of Chronic Kidney Disease Detection Based on K-Nearest Neighbors Data Mining. *International Journal*

- of Intelligent Systems and Applications in Engineering*, 11(8s), 393–400.
- Chilyabanyama, O. N., Chilengi, R., Simuyandi, M., Chisenga, C. C., Chirwa, M., Hamusonde, K., Saroj, R. K., Iqbal, N. T., Ngaruye, I., & Bosomprah, S. (2022). Performance of Machine Learning Classifiers in Classifying Stunting among Under-Five Children in Zambia. *Children*, 9(7), 1082. <https://doi.org/10.3390/children9071082>
- Cunningham, P., & Delany, S. J. (2022). k-Nearest Neighbour Classifiers - A Tutorial. *ACM Computing Surveys*, 54(6), 1–25. <https://doi.org/10.1145/3459665>
- Gani, A. A., Hadju, V., Syahrudin, A. N., Otuluwa, A. S., Palutturi, S., & Thaha, A. R. (2021). The effect of convergent action on reducing stunting prevalence in under-five children in Banggai District, Central Sulawesi, Indonesia. *Gaceta Sanitaria*, 35, S421–S424. <https://doi.org/10.1016/j.gaceta.2021.10.066>
- Garg, P., Sharma, N., & Shukla, B. (2023). Predicting the Risk of Cardiovascular Diseases using Machine Learning Techniques. *International Journal of Intelligent Systems and Applications in Engineering*, 11(1), 165–173.
- Gaurav, K., Kumar, A., Singh, P., Kumari, A., Kasar, M., & Suryawanshi, T. (2023). Human Disease Prediction using Machine Learning Techniques and Real-life Parameters. *International Journal of Engineering*, 36(6), 1092–1098. <https://doi.org/10.5829/IJE.2023.36.06C.07>
- Hamidi, H., & Daraei, A. (2016). Analysis of Pre-processing and Post-processing Methods and Using Data Mining to Diagnose Heart Diseases. *International Journal of Engineering*, 29(7), 921–930. <https://doi.org/10.5829/idosi.ije.2016.29.07a.06>
- Hammad, M., Alqaddoumi, A., Al-Obaidy, H., & Almseidein, K. (2019). Predicting software faults based on k-nearest neighbors classification. *International Journal of Computing and Digital Systems*, 8(5), 461–467. <https://doi.org/10.12785/ijcds/080503>
- Ho, J. Y., Afan, H. A., El-Shafie, A. H., Koting, S. B., Mohd, N. S., Jaafar, W. Z. B., Hin, L. S., Malek, M. A., Ahmed, A. N., Mohtar, W. H. M. W., Elshorbagy, A., & El-Shafie, A. (2019). Towards a time and cost effective approach to water quality index class prediction. *Journal of Hydrology*, 575, 148–165. <https://doi.org/10.1016/j.jhydrol.2019.05.016>
- Islam, M. M., Iqbal, H., Haque, M. R., & Hasan, M. K. (2017). Prediction of breast cancer using support vector machine and K-Nearest neighbors. *2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*, 226–229. <https://doi.org/10.1109/R10-HTC.2017.8288944>
- Kaur, R. (2019). Predicting diabetes by adopting classification approach in data mining. *International Journal on Informatics Visualization*, 3(2–2), 218–221. <https://doi.org/10.30630/joiv.3.2-2.229>
- Kemenkes. (2018). Buletin Jendela Data dan Informasi Kesehatan: Situasi Balita Pendek di Indonesia. *Kementerian Kesehatan RI*, 20.
- Kusrini, K., Luthfi, E. T., Muqorobin, M., & Abdullah, R. W. (2019). Comparison of naive bayes and K-NN method on tuition fee payment overdue prediction. *2019 4th International Conference on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2019*, 6, 125–130. <https://doi.org/10.1109/ICITISEE48480.2019.9003782>
- Luque, A., Carrasco, A., Martín, A., & de las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Maillo, J., Ramírez, S., Triguero, I., & Herrera, F. (2017). kNN-IS: An Iterative Spark-based design of the k-Nearest Neighbors classifier for big data. *Knowledge-Based Systems*, 117, 3–15. <https://doi.org/10.1016/j.knosys.2016.06.012>

- Mansur, M., Afiaz, A., & Hossain, M. S. (2021). Sociodemographic risk factors of under-five stunting in Bangladesh: Assessing the role of interactions using a machine learning method. *PLOS ONE*, *16*(8), e0256729. <https://doi.org/10.1371/journal.pone.0256729>
- Mathkunti, N. M., & Rangaswamy, S. (2020). Machine Learning Techniques to Identify Dementia. *SN Computer Science*, *1*(3), 118. <https://doi.org/10.1007/s42979-020-0099-4>
- Mushtaq, Z., Yaqub, A., Sani, S., & Khalid, A. (2020). Effective K-nearest neighbor classifications for Wisconsin breast cancer data sets. *Journal of the Chinese Institute of Engineers*, *43*(1), 80–92. <https://doi.org/10.1080/02533839.2019.1676658>
- Ndagijimana, S., Kabano, I. H., Masabo, E., & Ntaganda, J. M. (2023). Prediction of Stunting among Under-5 Children in Rwanda Using Machine Learning Techniques. *Journal of Preventive Medicine and Public Health*, *56*(1), 41–49. <https://doi.org/10.3961/jpmp.22.388>
- Patil, K. A., Prashanth, K. V. M., & Ramalingaiah, A. (2021). Texture feature extraction of Lumbar spine trabecular bone radiograph image using Laplacian of Gaussian filter with KNN classification to diagnose osteoporosis. *Journal of Physics: Conference Series*, *2070*(1). <https://doi.org/10.1088/1742-6596/2070/1/012137>
- Perdue, K. L., Jensen, S. K. G., Kumar, S., Richards, J. E., Kakon, S. H., Haque, R., Petri, W. A., Lloyd-Fox, S., Elwell, C., & Nelson, C. A. (2019). Using functional near-infrared spectroscopy to assess social information processing in poor urban Bangladeshi infants and toddlers. *Developmental Science*, *22*(5), e12839. <https://doi.org/10.1111/desc.12839>
- Polat, H., Danaei Mehr, H., & Cetin, A. (2017). Diagnosis of Chronic Kidney Disease Based on Support Vector Machine by Feature Selection Methods. *Journal of Medical Systems*, *41*(4). <https://doi.org/10.1007/s10916-017-0703-x>
- Prasad, V., Rao, T. S., & Babu, M. S. P. (2016). Thyroid disease diagnosis via hybrid architecture composing rough data sets theory and machine learning algorithms. *Soft Computing*, *20*(3), 1179–1189. <https://doi.org/10.1007/s00500-014-1581-5>
- Sahu, B., Mohanty, S. N., & Rout, S. K. (2019). A Hybrid Approach for Breast Cancer Classification and Diagnosis. *EAI Endorsed Transactions on Scalable Information Systems*, *6*(20), e2. <https://doi.org/10.4108/eai.19-12-2018.156086>
- Sendari, S., Widyaningtyas, T., & Maulidia, N. A. (2019). Classification of Toddler Nutrition Status with Anthropometry using the K-Nearest Neighbor Method. *2019 International Conference on Electrical, Electronics and Information Engineering (ICEEIE)*, 1–5. <https://doi.org/10.1109/ICEEIE47180.2019.8981408>
- Shaban, W. M., Rabie, A. H., Saleh, A. I., & Abo-Elsoud, M. A. (2020). A new COVID-19 Patients Detection Strategy (CPDS) based on hybrid feature selection and enhanced KNN classifier. *Knowledge-Based Systems*, *205*, 106270. <https://doi.org/10.1016/j.knsys.2020.106270>
- Sharma, D. K., Chatterjee, M., Kaur, G., & Vavilala, S. (2022). Deep learning applications for disease diagnosis. In *Deep Learning for Medical Applications with Unique Data* (pp. 31–51). Elsevier. <https://doi.org/10.1016/B978-0-12-824145-5.00005-8>
- Sudigyo, D., Hidayat, A. A., Nirwantono, R., Rahutomo, R., Trinugroho, J. P., & Pardamean, B. (2023). Literature study of stunting supplementation in Indonesian utilizing text mining approach. *Procedia Computer Science*, *216*, 722–729. <https://doi.org/10.1016/j.procs.2022.12.189>
- Suguna, R., Shyamala Devi, M., Bagate, R. A., & Joshi, A. S. (2019). Assessment of feature selection for student academic performance through machine learning classification. *Journal of Statistics and Management Systems*, *22*(4), 729–739.

- <https://doi.org/10.1080/09720510.2019.1609729>
- Thajeel, I. K., Samsudin, K., Hashim, S. J., & Hashim, F. (2023). Machine and Deep Learning-based XSS Detection Approaches: A Systematic Literature Review. *Journal of King Saud University - Computer and Information Sciences*, 35(7), 101628. <https://doi.org/10.1016/j.jksuci.2023.101628>
- Tharwat, A. (2021). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168–192. <https://doi.org/10.1016/j.aci.2018.08.003>
- Tim Nasional Percepatan Penanggulangan Kemiskinan. (2017). 100 Kabupaten/Kota Prioritas untuk Intervensi Anak Kerdil (Stunting): Tim Nasional Percepatan Penanggulangan Kemiskinan. *Jakarta*, 2(c), 287.
- Uddin, S., Haque, I., Lu, H., Moni, M. A., & Gide, E. (2022). Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction. *Scientific Reports*, 12(1), 1–11. <https://doi.org/10.1038/s41598-022-10358-x>
- Valero-Carreras, D., Alcaraz, J., & Landete, M. (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers & Operations Research*, 152, 106131. <https://doi.org/10.1016/j.cor.2022.106131>
- Vanacore, A., Pellegrino, M. S., & Ciardiello, A. (2022). Fair evaluation of classifier predictive performance based on binary confusion matrix. *Computational Statistics*. <https://doi.org/10.1007/s00180-022-01301-9>
- Yudhana, A., Umar, R., & Saputra, S. (2022). Fish Freshness Identification Using Machine Learning: Performance Comparison of k-NN and Naïve Bayes Classifier. *Journal of Computing Science and Engineering*, 16(3), 153–164. <https://doi.org/10.5626/JCSE.2022.16.3.153>

BAB 3
Klasifikasi Citra Medis Menggunakan
Segmentasi *Active Contour* dengan Algoritma
Support Vector Machine

Syifa'ah Setya Mawarni, Murinto, Sunardi

1.1. PENDAHULUAN

Proses segmentasi telah digunakan pada beragam pengolahan citra yang berguna bagi kehidupan manusia (Theodoridis & Koutroumbas, 2006). Segmentasi akan mempartisi citra menjadi beberapa segmen. Hal ini sangat membantu dalam memberikan perbedaan pada objek-objek yang ada didalam citra dan memudahkan pemberian analisis tambahan serta memberikan kemudahan dalam identifikasi objek yang ada di dalam citra (Khairil & Jumadi, 2022). Segmentasi telah banyak digunakan pada bidang medis yang salah satunya adalah untuk menganalisis citra luka luar. Luka adalah kerusakan pada fungsi perlindungan kulit disertai hilangnya kontinuitas jaringan epitel dengan atau tanpa adanya kerusakan pada jaringan lainnya seperti otot, tulang, dan nervus. Luka bisa disebabkan oleh beberapa hal, seperti tekanan, sayatan, dan luka karena operasi (Ryan, 2014). *Active contour* adalah salah satu metode segmentasi yang dapat digunakan untuk mendeteksi objek luka.

Penelitian menggunakan metode segmentasi untuk mendeteksi objek pada citra medis telah dilakukan oleh (Trisnawati & Hakim, 2018) dalam diagnosis penyakit paru-paru. Segmentasi citra paru-paru menggunakan metode Sobel dengan DRLSE sebagai pembantu dalam proses membaca hasil *CT-Scan* paru-paru agar segmentasi berjalan lebih cepat. Metode ini menghasilkan akurasi 95,08% serta AUC pada ROC menghasilkan 90,66%. Penelitian lain menggunakan algoritma K-Means untuk segmentasinya seperti yang digunakan oleh (Hadianti & Riana, 2021) untuk analisis citra sel pap smear dan J48 untuk klasifikasinya dan mendapatkan hasil akurasi 91,6%, presisi 92,5%, dan sensitivitas 91,7%. Penelitian (Fakhrurrozi & Adi, 2014) menggunakan metode segmentasi active contour untuk membedakan kanker dan tumor. Penelitian ini mendapatkan hasil *functionality* 0,9375, *stress testing* 100%, *expert validation* 77,5%, dan *usability* 75,8%. Selain dapat membedakan kanker dan tumor, segmentasi dapat meningkatkan akurasi pada identifikasi tumor yang diteliti oleh (Emadi, Dehkordi, & Mobarakeh, 2023) menggunakan segmentasi model active contour dan algoritma super-pixel dan fast primal dual sebagai klasifiernya dengan menghasilkan akurasi 86.59, sensitifitas 88.57, dan *F1-measure*. Penelitian yang dilakukan oleh (Nouri & Damavandi, 2022) mencoba menggunakan segmentasi tekstur baru metode parametric active contour model berdasarkan jensen-tsallis divergence pada objek *synthetic* dan citra natural. Penelitian ini mendapatkan hasil yang lebih memuaskan dibanding menggunakan metode lainnya.

Segmentasi active contour tidak akan bekerja maksimal jika tidak menggunakan tahap *preprocessing*. Tahap ini merupakan penyesuaian ukuran citra untuk mendapat RoI dan peningkatan kualitas citra, penyesuaian ukuran citra bertujuan untuk mencari RoI dengan mempersempit area citra, hal ini untuk mengurangi beban komputasi yang tidak diperlukan dalam mengolah bagian citra yang tidak ada kaitannya dengan objek (Widyantara, Kusuma, & Wirastuti, 2015). Pentingnya penerapan *preprocessing* diterangkan pada penelitian yang dilakukan oleh (Widyantara, Kusuma, & Wirastuti, 2015) tentang segmentasi paru-paru menggunakan metode anisotropic diffusion filter pada tahap *preprocessing* dengan tingkat akurasi, sensitifitas, dan spesifisitas lebih baik jika menggunakan anisotropic diffusion filter. Penelitian yang dilakukan oleh (Ramadhan, Wara, & Reja, 2023) untuk memperbaiki kualitas citra digital dengan menggunakan contrast stretching dengan hasil nilai MSE sebesar 0,010607 dan PSNR sebesar 19,744.

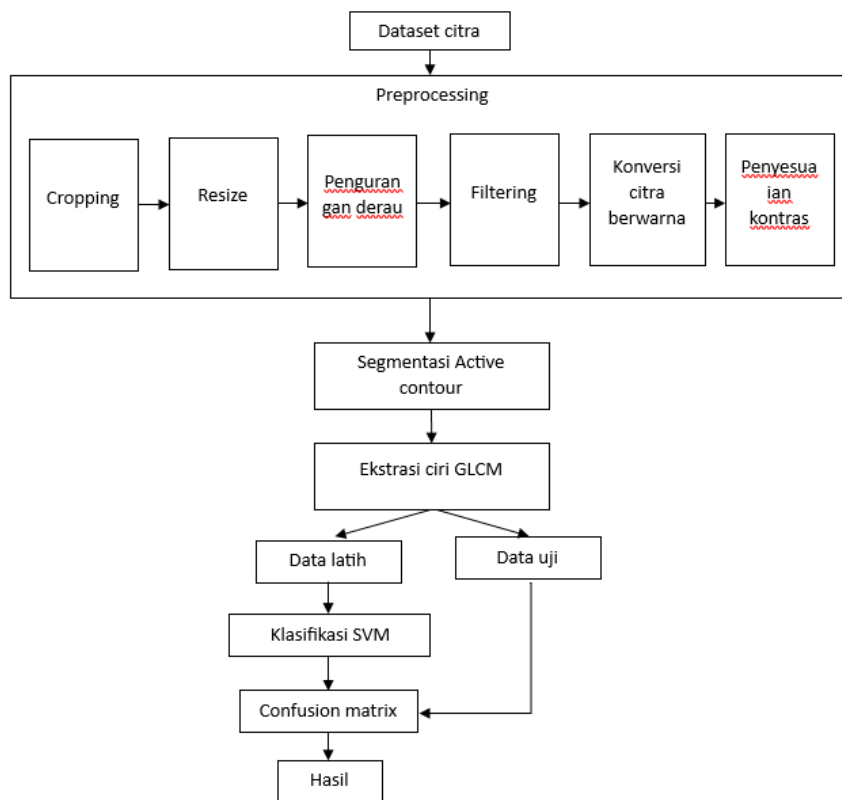
Banyak jenis luka luar seperti luka bakar, luka tusuk, luka laserasi, dan luka abrasi. Meski segmentasi menggunakan teknik active contour dapat dikatakan mampu dalam mendeteksi luka, namun belum tentu luka dapat didiagnosa. Pengukuran akurasi diagnosa citra luka dapat menggunakan algoritma support vector machine. Algoritma ini SVM bekerja dengan mendefinisikan batas antara dua kelas dengan jarak maksimum dari data terdekat. Jarak

maksimum diperoleh dengan menemukan *hyperplane* terbaik di input ruang yang diperoleh dengan mengukur *margin hyperplane* (Peryanto, Yudhana, & Umar, 2021).

Penelitian pada bidang medis menggunakan support vector machine untuk klasifikasinya pernah dilakukan oleh (Assaghir, Janbain, Makki, Kurdi, & Karam, 2017) untuk mendeteksi hipertensi dengan nilai SBP 7,61% dan DBP 9,36%. Penelitian dengan objek kanker lung pernah dilakukan oleh (Mishra & Gangwar, 2023) dengan membandingkan beberapa algoritma salah satunya adalah support vector machine. Hasil akurasi, presisi, *recall*, dan *F1-score* tertinggi mencapai 100% menggunakan algoritma decision tree.

1.2. METODE PENELITIAN

Penelitian ini diawali dengan pengumpulan dataset citra luka. Dataset yang didapatkan kemudian diolah pada tahap *data preprocessing* yang meliputi *cropping*, *resize*, perbaikan derau (*noise*), dan konversi citra berwarna ke citra keabuan. Setelah *preprocessing* selesai maka dilanjutkan dengan tahap segmentasi dengan metode *active contour* untuk mendeteksi bentuk kerusakan pada kulit. Citra hasil segmentasi kemudian diklasifikasi untuk mengetahui jenis lukanya. Alur penelitian ini dapat dilihat pada Gambar 1.



Gambar 1.1 Alur Penelitian

1.2.1 DATASET PENELITIAN

Penelitian ini menggunakan dataset citra yang berupa citra luka luar saja. Dataset citra luka luar merupakan dataset yang cukup sulit didapatkan. Terutama untuk mengakuisisi data citra luka dari rumah sakit. Penelitian ini menggunakan dataset yang didapat dari data repositori

Kaggle dengan jumlah data sebanyak 140 citra yang terdiri dari dua kelas yaitu luka lecet dan luka bakar. Setiap kelas memiliki 70 data citra. Contoh luka luar untuk dua kelas tersebut dapat dilihat pada Gambar 2.



Gambar 1.2.1 Luka Luar

1.2.2 DATA PREPROCESSING

Ada enam tahapan *preprocessing* yang digunakan pada penelitian ini, yaitu *cropping*, *resize*, pengurangan derau, *filtering*, konversi citra, dan penyesuaian kontras.

Citra yang lukanya tidak berada tepat ditengah gambar akan melalui tahap *cropping* terlebih dahulu sehingga luka dapat berada ditengah gambar. Tahap ini memudahkan citra diberi *masking*. Jika citra yang dikerjakan hanya 10 sampai 20 citra, *masking* bisa diberikan secara manual menyesuaikan letak objek namun karena data berjumlah lebih dari 100 maka *masking* dilakukan secara otomatis dengan meletakkan *masking* tepat ditengah citra. Alasan tersebutlah yang mendasari adanya *cropping* citra agar luka dapat tepat ditengah citra sehingga *masking* bisa bekerja secara optimal.

Proses *cropping* jelas merubah jumlah piksel menjadi lebih sedikit dari pada piksel asli. Hal ini mempengaruhi hasil segmentasi jika citra satu dengan citra yang lain tidak sama. Citra dengan jumlah lebih sedikit akan kehilangan strukturnya, sedangkan citra dengan jumlah piksel yang lebih banyak akan memakan waktu yang lebih lama sehingga diperlukan proses *resize* citra untuk membuat dataset citra mempunyai ukuran yang sama namun masih bisa disegmentasi tanpa menghilangkan struktur dan dalam waktu yang sesingkat mungkin.

Citra asli biasanya terkontaminasi dengan derau (*noise*), baik itu pada saat pengambilan gambar, pengiriman gambar, pengunduhan gambar (Furizal, Mawarni, Akbar, Yudhana, & Murinto, 2023). Derau merupakan gangguan yang disebabkan oleh penyimpanan data digital yang diterima oleh penerima data gambar sehingga dapat mengganggu kualitas gambar (Simangunsong, 2017). Penggunaan noise dan filter didasarkan pada pengukuran nilai kualitas gambar. Ada empat pengukuran kualitas gambar yaitu Mean Square Error (MSE) (Sara, Akter, & Uddin, 2019) (Badriyah, Sakinah, Syarif, & Syarif, 2019). Peak Singal Noise Ratio (PSNR) (Putri, Yudhana, & Sunardi, 2022) (Huang, Li, & Wen, 2021) (Jia, et al., 2019). Semakin kecil nilai MSE maka semakin baik pula nilai pemulihan dari efek noise, dan pada PSNR semakin tinggi nilainya maka semakin baik karena dianggap mendekati citra aslinya. Persamaan MSE dan PSNR dapat dilihat pada persamaan (1.1) dan (1.2).

$$MSE = \frac{1}{m \times n} \sum_{i=0}^m \sum_{j=0}^n [f'(i, j) - f(i, j)]^2 \quad (1.1)$$

$$PSNR = 10 \log_{10} \left(\frac{Max}{\sqrt{MSE}} \right) \quad (1.2)$$

Dimana m dan n adalah ukuran kolom dan baris dari gambar, $f(I,j)$ adalah gambar asli dan $f'(I,j)$ adalah gambar yang dipulihkan. Max adalah nilai piksel maksimum, jika 8 bit berarti $2^8 - 1 = 255$.

Citra asli mempunyai dasar warna merah, hijau, dan biru yang sering juga disebut gambar RGB. Gambar RGB mempunyai nilai intensitas piksel total sebesar 24-bit, setiap saluran warna mempunyai nilai intensitas piksel 8-bit yang berarti mempunyai variasi warna $2^8 = 256$ derajat warna (0 hingga 255). Citra skala abu-abu (*grayscale image*) adalah citra berskala keabuan dengan nilai intensitas paling banyak 255 berwarna putih hingga hitam dengan nilai intensitas minimal 0 (Wahyudi, Triyanto, & Ruslianto, 2015). Konversi citra dari citra RGB ke citra keabuan bertujuan untuk menyederhanakan citra sehingga proses segmentasi menjadi lebih efisien.

Konversi citra dari berwarna menjadi keabuan berfungsi agar citra menjadi lebih sederhana serta proses segmentasi menjadi lebih efisien. Sedangkan penyesuaian kontras atau *contrast adjustment* berfungsi agar citra keabuan menjadi lebih pekat lagi.

1.2.3 SEGMENTASI ACTIVE CONTOUR

Segmentasi citra bertujuan untuk memisahkan objek dengan *background* pada objek luka, pemisahan yang dimaksud adalah pemisahan objek luka dengan kulit (*background*) dengan tetap mempertahankan tepi kulit (Mawarni, Murinto, & Sunardi, Segmentasi Citra Luka Luar Berbasis Warna Menggunakan Teknik Active Contour, 2023). *Active contour* merupakan salah satu dari sekian banyak teknik segmentasi dimana prosesnya berupa minimalisasi energi dengan nilai minimum berupa batas objek. Fungsi energi tersebut tidak hanya terdiri dari informasi mengenai *edge*, melainkan juga berisi properti yang mengontrol pergerakan dari kurva itu sendiri (Ickhsan, 2020). *Active contour* pertama kali diperkenalkan oleh Kass (1988) dengan persamaan (1.3) (Muliriasari & Murinto, 2013).

$$E_{Snake} = \int_{s=0}^1 E_{int}(v(s)) + E_{img} + E_{con}(V(s)) ds \quad (1.3)$$

Dimana :

- E_{Snake} = Merupakan fungsi energi dari active contour, dari fungsi tersebut akan dicari objek yang memenuhi fungsi energi tersebut.
- $v(s)$ = Merupakan kumpulan dari x dan y koordinat dari kurva active contour.
- E_{int} = Merupakan energi internal dari active contour, energi ini mempengaruhi pergerakan dari kurva active contour.
- E_{img} = Merupakan energi dari gambar digital yang menjadi inputan (low level features seperti edge points).
- E_{con} = high level information yang mempengaruhi pergerakan dari kurva active contour.

1.2.4 EKSTRAKSI CIRI GLCM

Fitur-fitur yang digunakan dalam penelitian ini diambil dari hasil segmentasi citra. Fitur ini dinormalisasi dalam rentang normal $[0,1]$ dan kemudian digunakan sebagai data masukan

pengklasifikasi SVM. Fitur-fitur tersebut adalah rata-rata, varians, deviasi standar, dan skewness. Ekstraksi fitur digunakan untuk mengubah data citra dari matriks menjadi vektor (Mawarni, Murinto, & Sunardi, Medical External Wound Image Classification Using Support Vector Machine Technique, 2023).

Ekstraksi fitur yang digunakan dalam penelitian ini adalah ekstraksi fitur GLCM atau Gray Level Co-occurrence Matrix dimana GLCM merupakan teknik analisis tekstur citra yang merepresentasikan hubungan antara dua piksel yang berdekatan dengan intensitas, jarak, dan sudut skala abu-abu (Punithavathi & Devakumari, 2019). GLCM memiliki delapan sudut 0° , 45° , 90° , 135° , 180° , 225° , 270° , 315° . GLCM memiliki perhitungan parameter jarak berdasarkan jumlah piksel antara piksel referensi dan piksel tetangga (Farhan & Kamil, 2020). Empat fitur yang digunakan GLCM adalah homogenitas, kontras, korelasi, dan energi.

Entropi memberikan informasi tentang ukuran acak gambar. Homogenitas merupakan nilai pengukuran jarak elemen sebaran GLCM dengan nilai 0 dan 1. Nilai 1 berarti homogenitas diagonal GLCM dan nilai 0 berarti homogenitas vertikal GLCM. Kontrasnya akan menyesuaikan tinggi rendahnya warna gambar. Nilai keseluruhan tersebut memberikan informasi sebagai bahan analisis dalam menentukan jenis tumor atau kanker (Putri, Yudhana, & Sunardi, 2022).

1.2.5 SUPPORT VECTOR MACHINE

Kumpulan data yang terdiri dari dua kelas yang dapat dipisahkan secara linier dengan garis lurus disebut data linier, sedangkan data yang tidak dapat dipisahkan secara linier disebut data nonlinier. Data non-linier biasanya dipisahkan menggunakan kurva tidak beraturan (Mawarni, Murinto, & Sunardi, Medical External Wound Image Classification Using Support Vector Machine Technique, 2023). Algoritma SVM sulit memisahkan data non-linier sehingga memerlukan trik kernel untuk memetakan data non-linier berdimensi rendah ke dimensi lebih tinggi agar dapat dipisahkan menjadi data linier. Ada 3 macam trik kernel.

1. Kernel Linier

Kernel linier digunakan untuk memisahkan data linier atau data yang hanya terdiri dari dua kelas dengan garis lurus. Rumus kernel linier ada pada persamaan 1.4.

$$K(x, xi) = \text{sum}(x * xi) \quad (1.4)$$

2. Kernel RBF

Kernel RBF digunakan untuk data non-linier yang dipisahkan menggunakan kurva tidak beraturan. Hasil pelatihan kernel RBF memiliki error yang lebih sedikit dibandingkan kernel lain yang menggunakan parameter gamma. Persamaan 1.5 menunjukkan rumus kernel RBF.

$$K(x, xi) = \exp(-\text{gamma} * \text{sum}(x - xi^2)) \quad (1.5)$$

3. Kernel Polynomial

Kernel polinomial juga digunakan untuk data non-linier dimana derajat pada kernel polinomial mengontrol fleksibilitas hasil klasifikasi, semakin tinggi nilai derajat pada kernel polinomial memungkinkan batas keputusan yang lebih fleksibel (Ben-Hur & Weston, 2010). Rumus kernel polinomial ada pada persamaan 1.6.

$$K(x, x_i) = \exp(-\text{gamma} * \text{sum}(x - x_i^2)) \quad (1.6)$$

SVM menggunakan algoritma supervised learning dimana machine learning dilatih untuk mempelajari data berlabel. Klasifikasi membagi data menjadi data latih dan data uji. Data latih diberi label prediksi, data uji diberi label target. Klasifikasi SVM menggunakan data latih. Sebelum data diklasifikasi menggunakan SVM, dataset dibagi menjadi data latih dan data uji. Dataset citra kemudian dibagi menjadi 70% data latih dan 30% data uji. Tabel 1 menunjukkan hasil pembagian dataset gambar luka.

Tabel 1. Distribusi Data

Kategori	Total Dataset	Data Uji	Data Latih
Laserasi	70	49	21
Bakar	70	49	21

Algoritma SVM hanya diterapkan pada data latih, hal ini bertujuan untuk mengidentifikasi *hyperplane* yang memisahkan data antar kelas, sedangkan data uji dilakukan dengan menguji model SVM pada data yang belum pernah dilihat. Data uji tidak digunakan saat pelatihan, begitu juga dengan data latih yang tidak digunakan selama pengujian agar dapat mengevaluasi seberapa baik kinerja model mengenali pola dari data yang belum pernah dilihat dengan menginput data uji pada model SVM yang telah dilatih. Hasilnya dapat dibandingkan dengan label sebenarnya dari data uji.

1.2.6 ANALISIS CONFUSION MATRIX

Confusion matrix merupakan matriks yang berfungsi untuk menganalisis hasil klasifikasi atau prediksi dengan nilai yang sebenarnya pada data uji. Selain itu *confusion matrix* membantu menilai apakah program termasuk berhasil atau gagal dalam klasifikasi ataupun prediksi pada masing-masing kelas.

Confusion matrix mempunyai empat istilah representasi dari hasil proses klasifikasi maupun prediksi yaitu TP (*True Positive*) data yang benar dan diprediksi benar, TN (*True Negative*) data yang benar namun diprediksi salah, FP (*False Positive*) data yang salah namun diprediksi benar, dan terakhir adalah FN (*False Negative*) data yang salah dan diprediksi salah. Matriks dari pada *confusion matrix* dapat dilihat pada Table 2.

Tabel 2. *Confusion Matrix*

		Prediksi	
		Benar	Salah
True data	Positif	TP	FP
	Negatif	TN	FN

Confusion matrix menggunakan akurasi, presisi, *recall*, dan *F1-score* (Peryanto, Yudhana, & Umar, 2021). Akurasi digunakan untuk melihat seberapa besar persentase hasil dataset yang diklasifikasikan dengan benar oleh sistem [29]. Persamaan 1.7 menghitung akurasi.

$$Accuracy = \frac{\sum TP}{Total\ Data} \times 100\% \quad (1.7)$$

Derajat kesesuaian informasi yang diberikan sistem dengan informasi yang dibutuhkan pengguna disebut presisi, sedangkan tingkat keberhasilan sistem dalam menemukan informasi disebut *recall* (Saputra & Rosiyadi, 2019). Persamaan 1.8 dan persamaan 1.9 digunakan untuk menghitung presisi dan *recall*.

$$precision = \frac{TP}{TP+FP} \times 100 \quad (1.8)$$

$$recall = \frac{TP}{TP+FN} \times 100 \quad (1.9)$$

F1-score merupakan rumus rata-rata nilai *recall* yang benar dan nilai presisi (Hackeling, 2014). Persamaan 1.10 menghitung *F1-score*.

$$F1 = 2 \frac{precision \times recall}{precision + recall} \quad (1.10)$$

1.3 HASIL PENELITIAN

1.3.1 HASIL PREPROCESSING DAN SEGMENTASI

















Perbedaan piksel dan sudut pengambilan citra sangat mempengaruhi proses segmentasi dimana jika citra memiliki piksel yang berbeda maka proses segmentasi tiap citra akan berbeda. Semakin tinggi piksel semakin jelas segmentasinya namun hal tersebut juga mempengaruhi proses segmentasi menjadi lebih lama. Dibutuhkan jumlah piksel yang sesuai, tidak tinggi namun juga tidak rendah sehingga segmentasi masih bisa berjalan dengan baik namun tidak memerlukan waktu yang lama.

Segmentasi citra menggunakan metode *active contour* memiliki kelemahan dimana *masking* agar bisa lebih optimal akan ditempatkan ditengah-tengah citra, sedangkan sudut pengambilan citra luka tidak selalu ditengah sehingga citra perlu di-*crop* agar luka dapat berada ditengah.

Tahap pertama analisis *preprocessing* dapat berpengaruh pada proses segmentasi, mulai dari tepat tidaknya segmentasi sampai waktu yang digunakan pada tahap segmentasi. *Cropping* berpengaruh pada tahap *masking* dan *resize* berpengaruh pada waktu yang digunakan untuk segmentasi. Tabel 3 merupakan hasil perbandingan segmentasi citra yang belum di-*cropping* dan yang sudah di-*cropping* dengan ukuran 150x150 pixel dan 250x250 pixel.

Tabel 3. Hasil segmentasi perbandingan *resize* dan *cropping*

Ukuran citra	Ketertarikan	Citra asli		Citra hasil segmentasi	
		Abrasi	Bakar	Abrasi	Bakar

150x150 pixel	Citra sebelum cropping				
	Citra sesudah cropping				
250x250 pixel	Citra sebelum cropping				
	Citra sesudah cropping				

Tabel 3 memaparkan perbandingan hasil citra segmentasi jika menggunakan *cropping* dan tanpa *cropping* pada ukuran citra 150x150 piksel dan 250x250 piksel. Citra tanpa *cropping* menghasilkan segmentasi yang *overfitting* sedangkan citra *cropping* cenderung *underfitting* namun masih mirip dengan citra asli. Ukuran citra 150x150 masih bisa menghasilkan segmentasi yang baik namun tidak sedetail ukuran 250x250 piksel.

1.3.2 HASIL EKSTRASI CIRI

Identifikasi atribut atau ciri dari sebuah citra untuk digunakan lebih lanjut merupakan fungsi dari ekstraksi ciri. Ekstraksi ciri sendiri dapat meliputi warna, tekstur, dan bentuk. Ekstraksi ciri tekstur bisa menggunakan teknik GLCM.

Penelitian ini menggunakan ekstraksi ciri GLCM dengan empat parameter yaitu *contrast*, *correlation*, *energy*, dan *homogeneity* serta melihat dari empat sudut yaitu 0°, 45°, 90°, dan 135° secara dua arah sehingga menghasilkan total delapan fitur GLCM. Tabel 4 memperlihatkan hasil dari perhitungan GLCM pada data latih dan data uji citra ukuran 150x150 piksel dan Tabel 5 hasil perhitungan GLCM pada citra ukuran 250x250 piksel.

Tabel 4. GLCM 150x150 piksel

No.	GLCM	Luka Abrasi	Luka Bakar
-----	------	-------------	------------

		<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>	<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>
1	0°	0,4684	0,9706	0,6657	0,9916	0,2722	0,9860	0,5986	0,0995
2	45°	0,8538	0,9465	0,6571	0,9847	0,4739	0,9756	0,5936	0,9915
3	90°	0,5847	0,9633	0,6631	0,9895	0,2562	0,9896	0,5987	0,9954
4	135°	0,8321	0,9479	0,6575	0,9851	0,4790	0,9754	0,5935	0,9914

Tabel 5. GLCM 250x250 piksel

No.	GLCM	Luka Abrasi				Luka Bakar			
		<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>	<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>
1	0°	0,3665	0,9843	0,5173	0,9934	0,4713	0,9713	0,6546	0,9915
2	45°	0,5774	0,9752	0,5127	0,9896	0,6906	0,9581	0,6495	0,9876
3	90°	0,3375	0,9855	0,5178	0,9939	0,4260	0,9741	0,6554	0,9923
4	135°	0,6012	0,9742	0,5122	0,9892	0,6955	0,9578	0,6495	0,9875

1.3.3 HASIL PROSES KLASIFIKASI

Hasil segmentasi yang telah didapat kemudian akan dimasukkan ke dalam proses klasifikasi menggunakan algoritma *support vector machine* (SVM) untuk mengetahui seberapa cocok algoritma SVM mengklasifikasikan jenis luka yang telah disegmentasi oleh model *active contour*. Proses klasifikasi SVM, data latih yang telah mendapatkan nilai parameter GLCM diberi label terlebih dahulu. Citra yang telah melalui tahap pembagian data diekstraksi ciri dengan fitur GLCM untuk mengetahui tekstur dari masing-masing kelas.

Klasifikasi SVM menggunakan *optimization process*, namun untuk jumlah iterasi tidak ditentukan oleh pengguna sehingga klasifikasi SVM langsung mendapatkan hasil akurasi.

Algoritma SVM hanya diterapkan pada data latih, hal ini bertujuan untuk mengidentifikasi *hyperplane* yang memisahkan data antar kelas, sedangkan data uji dilakukan dengan menguji model SVM pada data yang belum pernah dilihat. Data uji tidak digunakan saat pelatihan, begitu juga dengan data latih yang tidak digunakan selama pengujian agar dapat mengevaluasi seberapa baik kinerja model mengenali pola dari data yang belum pernah dilihat dengan menginput data uji pada model SVM yang telah dilatih. Hasilnya dapat dibandingkan dengan label sebenarnya dari data uji.

Tabel 6 menampilkan hasil dari klasifikasi citra berukuran 150x150 piksel dengan citra berukuran 250x250 pada empat sudut GLCM menggunakan pengujian *confusion matrix*.

Tabel 6. Hasil *Confusion Matrix*

No.	GLCM	Citra 150x150				Citra 250x250			
		Akurasi	Presisi	Recall	F1-score	Akurasi	Presisi	Recall	F1-score
1	0°	71.4286	76.4706	61.9048	68.4211	88.0952	94.4444	80.9524	87.1795
2	45°	76.1905	78.9474	71.4286	75	88.0952	94.4444	80.9524	87.1795
3	90°	71.4286	71.4286	71.4286	71.4286	92.8571	100	85.7143	92.3077
4	135°	71.4286	71.4286	71.4286	71.4286	85.7143	94.1176	76.1905	84.2105

Tabel 6 memperlihatkan bahwa GLCM sudut 90° memperoleh hasil akurasi tertinggi dengan akurasi 92,8571% presisi 100%, *recall* 85,7143%, dan F1-Score 92,3077% sehingga pada klasifikasi citra luka menggunakan algoritma SVM lebih cocok menggunakan GLCM sudut 90°.

1.4 KESIMPULAN

Berdasarkan penelitian yang telah dilaksanakan maka dapat disimpulkan bahwa penelitian berhasil melakukan segmentasi citra luka luar menggunakan metode *active contour* serta berhasil melakukan klasifikasi jenis luka menggunakan algoritma *support vector machine*. Penelitian telah berhasil menguji tingkat akurasi klasifikasi menggunakan algoritma *support vector machine* dengan keberhasilan 92,8571% pada GLCM sudut 90°.

DAFTAR PUSTAKA

- A. Shahini Shamsabadi, B. S. (2009). Applying inherent capabilities of quantum-dot cellular automata to design: D flip-flop case study. *J. Syst*, 55(Archit), 180-187.
- A. Vetteth, K. W. (2003). Ram design using quantum-dot cellular automata. *NanoTechnology Conference and Trade Show*, 2, 160-163.
- Aditya, K. J., Kanedi, I., & Sudarsono, A. (2022). Segmentasi Deteksi Tepi pada Citra Digital Patah Tulang Orang Dewasa Menggunakan Metode Sobel dan Metode Prewitt. *Djtechno: Journal of Information Technology Research*, 3(2), 224-233.
- Assaghir, Z., Janbain, A., Makki, S., Kurdi, M., & Karam, R. (2017). Support Vector Machine to Detect Hypertension. *International Journal on Recent and Innovation Trends in Computing and Communication*, 5(2), 6-9.
- Badriyah, T., Sakinah, N., Syarif, I., & Syarif, D. R. (2019). Segmentation Stroke Objects based on CT Scan Image using Thresholding Method. *First International Conference on Smart Technology & Urban Development (STUD), IEEE*, 1-6.
- Ben-Hur, A., & Weston, J. (2010). A User's Guide to Support Vector Machines. *Method's in molecular biology*, 609, 223-239.
- C.S. Lent, M. L. (2006). Bennett clocking of quantum-dot cellular automata. *IOP*, 17(Nanotechnology), 4240-4251.

- Emadi, M., Dehkordi, Z. J., & Mobarakeh, M. I. (2023). Improving the Accuracy of Brain Tumor Identification in Magnetic Resonance Imaging. *International Journal of Engineering*, 36(3), 506-512.
- Fakhrurrozi, & Adi, K. (2014). Segmentasi Citra Medis Untuk Pengenalan Objek Kanker Menggunakan Metode Active Contour. *Youngster Physics Journal*, III, 209-216.
- Farhan, A. H., & Kamil, M. Y. (2020). Texture Analysis of Breast Cancer via LBP, HOG, and GLCM techniques. *IOP Conference Series: Materials Science and Engineering*, 1-10.
- Furizal, Mawarni, S. S., Akbar, S. A., Yudhana, A., & Murinto. (2023). Analysis of the Influence of Number of Segments on Similarity Level in Wound Image Segmentation Using K-Means Clustering Algorithm. *Control System and Optimization Letters*, 1(3), 132-138.
- Hackeling, G. (2014). *Mastering Machine Learning with scikit-learn*. Packt Publishing.
- Hadianti, S., & Riana, D. (2021). Segmentasi dan Pengorakan Citra Mikroskopik PAP Smear Menggunakan Algoritme K-Means dan J48. *Jurnal Teknologi dan Sistem Komputer*, 9(2), 113-119.
- Huang, C., Li, X., & Wen, Y. (2021). AN OTSU image segmentation based on fruitfly optimization algorithm. *Alexandria Engineering Journal*, 60(1), 183-188.
- Ickhsan, M. (2020). Implementasi Metode Segmentasi Active Contour Untuk Memperjelas Tepi Pada Citra Penyakit Paru-paru, VIII, 357-360.
- J. Huang, M. M. (2007). Design of sequential circuits by quantum-dot cellular automata. *Microelectr.J*, 38, 525-537.
- Jia, H., Peng, X., Song, W., Lang, C., Xing, Z., & Sun, K. (2019). Multiverse Optimization Algorithm Based on Lévy Flight Improvement for Multithreshold Color Image Segmentation. *IEEE Access*, 7, 32805-32844.
- K. Walus, T. D. (2004). QCA designer: a rapid design and simulation tool for quantum-dot cellular automata. *IEEE Trans.*, 3(Nanotechnol), 26-31.
- Khairil, E. F., & Jumadi, J. (2022). Implementasi Metode K-Means Clustering pada Segmentasi Citra Digital. *Jurnal Media Infotama*, 18(2), 291-301.
- Khurasia, P. G. (2006). *Quantum Cellular Automata*.
- Kyosun Kim, K. W. (2006). Quantum-dot cellular automata design guideline. *IEICE Trans*, 6(Fund), 1607-1614.
- Mawarni, S. S., Murinto, & Sunardi. (2023). Medical External Wound Image Classification Using Support Vector Machine Technique. *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, 9(2), 98-103.
- Mawarni, S. S., Murinto, & Sunardi. (2023). Segmentasi Citra Luka Luar Berbasis Warna Menggunakan Teknik Active Contour. *KESATRIA*, 4(2), 392-398.
- Mishra, A., & Gangwar, S. (2023). Lung Cancer Detection and Classification using Machine Learning Algorithms. *International Journal on Recent and Innovation in Computing and Communication*, 11(6), 277-282.
- Muliriasari, R., & Murinto. (2013). Analisis Perbandingan Metode Li dan Chan-Vese Pada Proses Segmentasi Citra Digital, I, 666-679.
- Niemir, M. (2004). *Deigning Digital Systems in Quantum Cellular Automata*, M.Sc.Thesis. Indiana: Department of Computer Science and Engineering Notre Dame.
- Nouri, M., & Damavandi, B. Y. (2022). A New Texture Segmentation Method with Energy-driven Parametric Active Contour Model Based on Jensen-Tsallis Divergence. *International Journal of Engineering*, 35(5), 1257-1267.
- P.D. Tougaw, C. L. (1994). Logical devices implemented using quantum cellular. *Appl*, 75(Phys), 1818-1824.

- Peryanto, A., Yudhana, A., & Umar, R. (2021). Convolutional Neural Network and Support Vector Machine in Classification of Flower Images. *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, 8(1), 1-7.
- Punithavathi, V., & Devakumari, D. (2019). Detection of Breast Lesion Using Improved GLCM Feature Based Extraction in Mammogram Images. *Institute of Scholars (InSc)*, 1040-1047.
- Putri, A. R., Yudhana, A., & Sunardi. (2022, Desember). Klasifikasi Kanker Payudara Menggunakan Metode Digital Mammogram. *Kinetik*, IX(4), 2752-2761.
- Rahman, M., Darmawidjadja, M., & Alamsah, D. (2017). Klasifikasi untuk Diagnosa Diabetes Menggunakan Metode Bayesian Regularization Neural Network (RBNN). *Jurnal Informatika*, 11(1), 36-45.
- Ramadhan, T., Wara, F. A., & Reja, I. D. (2023). Analisis Perbaikan Citra Digital Menggunakan Metode Contrast Streching. *Jurnal In Create: Inovasi dan Kreasi dalam Teknologi Informasi*, 9(1), 66-76.
- Ryan, K. (2014). *Wound Care: Nursing and Health Survival Guides*. New York: Roulledge.
- Saputra, I., & Rosiyadi, D. (2019). Perbandingan Kinerja Algoritma K-Nearest Neighbor, Naïve Bayes Classifier dan Support Vector Machine dalam Klasifikasi Tingkah Laku Bully pada Aplikasi Whatsapp. *Faktor Exacta*, 12(2), 101.
- Sara Hashemi, K. N. (2012). New robust QCA D flip flop and memory structures. *Microelectronics Journal*, 43, 929-940.
- Sara, U., Akter, M., & Uddin, M. S. (2019). Image Quality Assessment through FSIM, SSIM, MSE and PSNR-A Comparative Study. *Journal of Computer and Communications*, 7(3), 8-18.
- Simangunsong, P. B. (2017). Reduksi Noise Pada Citra Digital Menggunakan Metode Arithmetic Mean Filter. *JTIUST*, 2(2), 60-63.
- Theodoridis, S., & Koutroumbas, K. (2006). *Pattern Recognition*. USA: Academic Press.
- Trisnawati, L., & Hakim, L. (2018). Segmentasi Citra CT Scan Lung Menggunakan Deteksi Tepi Sobel dan Metode Distance Regularized Level Set Evolution (DRLSE). *Jurnal Keilmuan & Aplikasi Teknik Informatika*, 10(1), 1-13.
- V. Vankamamidi, M. O. (2008). Two-dimensional schemes for clocking/timing of QCA circuits. *IEEE Trans*, 27(Comput.-Aided Des. Integrated Circuits Syst), 34-44.
- Wahyudi, E., Triyanto, D., & Ruslianto, I. (2015). Identifikasi Teks Dokumen Menggunakan Metode Profile Projection dan Template Matching. *Jurnal Coding, Sistem Komputer Untan*, 3(2), 1-10.
- Widyantara, I. M., Kusuma, A. T., & Wirastuti, N. M. (2015). Preprocessing pada Segmentasi Citra Paru-paru dan Jantung Menggunakan Anisotropic Diffusion Filter. *Teknologi Elektro*, 14(2), 6-10.
- Zhang, R. e. (2004). A method of majority logic reduction for quantum cellular automata. *IEEE Transactions on Nanotechnology*, 3.4, 443-450.

BAB 4
Evaluasi Algoritma *Apriori* dan
Equivalence Class Transformation untuk Mendapatkan *Association Rule*:
Studi Kasus *Café & Bakery*

Fitriah, Imam Riadi, Herman

1.1 PENDAHULUAN

Di era di mana data terus menerus dihasilkan oleh berbagai sumber dalam jumlah yang sangat besar, menjadi semakin penting untuk mengubahnya menjadi pengetahuan berharga yang dapat digunakan untuk pengambilan keputusan. Proses mengubah data mentah menjadi pengetahuan memainkan peran yang sangat signifikan, terutama bagi perusahaan besar yang berusaha memahami perilaku pelanggan mereka *sekomprehensif* mungkin dan mendapatkan keunggulan kompetitif dengan menawarkan pengalaman yang lebih terarah dan personal (Y. Chen et al., 2022; X. Li, 2023; S. Mythili & R. Mohamed Shanavas, 2013). Proses mengubahnya menjadi pengetahuan adalah bagian dari teknik data mining, yang mengarah pada identifikasi pola yang paling sering terjadi dalam *Dataset* besar dan menciptakan gambaran umum yang dapat digeneralisasi dan dipahami dari realitas bisnis (Saefudin & DN, 2019; Riadi, Herman, Fitriah, & Suprihatin, 2023).

Salah satu aspek yang relevan terkait dengan *Dataset* transaksional dan memerlukan identifikasi set item yang sering muncul, sering disebut sebagai masalah Analisis *Market Basket Analysis* atau masalah Pembelajaran *Association Rule* (L. Wang et al., 2019; Zhang et al., 2019). Jenis masalah terakhir bertujuan untuk menemukan item yang sering muncul bersama dalam *Dataset* transaksi, dengan tujuan utama untuk menemukan hubungan paling umum antara item-item tersebut, memungkinkan penjual untuk menganalisis dan mengekstrak informasi berharga dari data, seperti pola pembelian konsumen, preferensi, dan kebiasaan (Sarumi et al., 2018; J. Yang et al., 2017; Krisnanto et al., 2022). Dengan menggunakan teknik *machine learning*, kita dapat mengembangkan model yang lebih canggih untuk mengidentifikasi pola, tren, dan asosiasi kompleks dalam data besar (Herman et al., 2023; Fadlil et al., 2023; Yudhana et al., 2023; Y. Wang et al., 2023).

Data mining telah menghasilkan teknik untuk mengidentifikasi pola dan tren dari *dataset* besar. Data mining menggabungkan berbagai algoritma seperti *clustering*, klasifikasi, *association rule* mining, dan *sequence discovery* untuk mengekstrak pengetahuan berharga dan bermakna dari *Dataset* yang besar (Agapito, Giuseppe M, Marianna G & Cannataro, 2019; S. Wang et al., o. J., K. Chen et al., 2023). Ini melibatkan metode dan teknik untuk mengidentifikasi pola, hubungan, dan informasi penting lainnya, dan dianggap sebagai subbidang yang signifikan dalam pengelolaan pengetahuan yang berguna dan bermakna dari *Dataset* besar (X. Yang et al., 2018; Kenmogne et al., 2022; Z. Li et al., 2021). Tujuan utama dari data mining adalah mengungkap pengetahuan berharga dari data yang ada dan menerapkannya pada pengambilan Keputusan (Istrat & Lalić, 2017; Osman et al., 2021; Lee et al., 2021).

Penelitian ini bertujuan untuk menganalisis asosiasi di antara item menggunakan dua algoritma, Apriori dan Eclat. Fokusnya adalah menganalisis pola penjualan roti dengan total data penjualan produk sebanyak 20.507 untuk menemukan aturan asosiasi yang signifikan menggunakan algoritma data mining (Jia et al., 2023; Bashkari et al., 2021; Kim et al., 2023). Informasi ini dapat memberikan wawasan berharga bagi pemilik toko roti dalam mengembangkan strategi penjualan yang lebih efektif, mengoptimalkan persediaan, dan meningkatkan kepuasan pelanggan untuk meningkatkan pengalaman berbelanja secara keseluruhan dengan menawarkan promosi yang relevan, meningkatkan rekomendasi produk, dan memastikan pendekatan yang lebih personal (Gao, 2022; Islamiyah et al., 2019).

1.1.1 ALGORITMA APRIORI

Agrawal & Srikant, pada tahun 1994, memperkenalkan algoritma Apriori dengan tujuan mengidentifikasi set item yang sering muncul untuk aturan asosiasi Boolean. Algoritma

Apriori banyak digunakan dalam konteks penemuan aturan asosiasi (Nafie Ali & Mohamed Hamed, 2018; Pan, 2021). Algoritma ini melakukan pemindaian tambahan dari urutan data untuk menghitung dukungan bagi kandidat.

Langkah ini dilakukan menggunakan fungsi *subset* untuk mengidentifikasi semua set item kandidat dalam setiap transaksi. Selanjutnya, algoritma menghitung total *Support* untuk set item kandidat ini dan mengeliminasi set item kandidat dengan *Support* lebih rendah dari ambang batas minimum (Riadi, Herman, Fitriah, Muis, et al., 2023). Jika tidak ditemukan set item yang sering muncul dalam proses ini, maka set item dengan *Support* ditentukan, dan nilai *Confidence* dihitung untuk menentukan aturan asosiasi, dan algoritma dihentikan (Mohamed & Jofri, 2022; Samuel et al., 2022).

1.1.2 ALGORITMA ECLAT

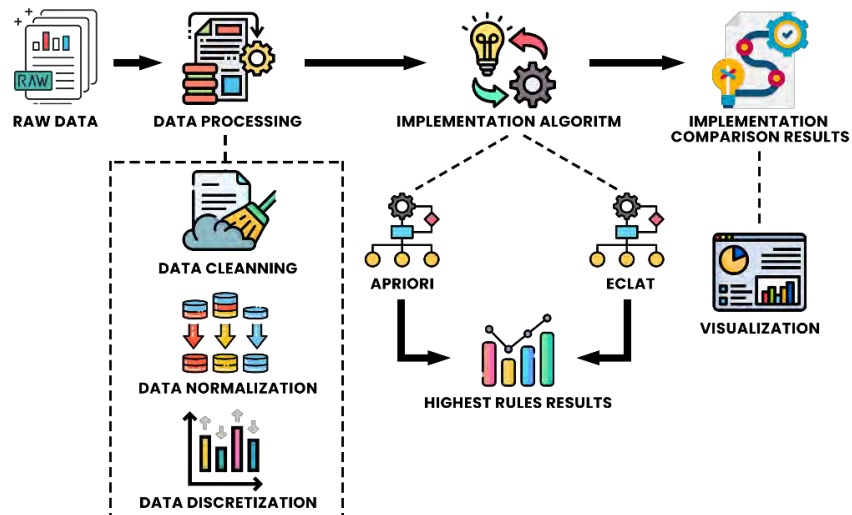
Algoritma *Equivalence Class Transformation* (Eclat) adalah algoritma penambangan pola yang efisien. Algoritma ini mencari pola yang sering muncul dengan menjelajahi struktur data dari bawah ke atas, sering dijelaskan sebagai mendaki tangga dari bawah ke atas. Untuk melakukan ini, algoritma Eclat perlu diterapkan pada jenis data yang disebut data vertikal. Konsep kunci di balik Eclat adalah mengelompokkan semua transaksi yang mengandung serangkaian item tertentu ke dalam kelompok yang sama (Khalid & Wade, 2022; Man et al., 2023).

Kemudian, dengan membandingkan set item ukuran k dengan set item ukuran $k+1$ yang sering muncul, kita dapat menghasilkan set item yang sering muncul dengan ukuran $k+1$. Proses ini terus berlanjut sampai tidak dapat ditemukan lagi set item yang sering muncul dengan ukuran yang lebih besar. Yang membuat Eclat efisien adalah bahwa ia tidak perlu memindai database beberapa kali untuk mengidentifikasi set item yang sering muncul dengan ukuran $k+1$. Setelah pemindaian awal database, set item ukuran $k+1$ dapat ditemukan dengan menggabungkan set item yang telah ditemukan sebelumnya dengan ukuran k .

Proses ini, setiap transaksi dievaluasi berdasarkan "dukungan," yang mewakili seberapa sering set item muncul dalam transaksi. Jika dukungan dari suatu transaksi sama atau lebih besar dari ambang batas dukungan minimum yang telah ditentukan sebelumnya, itu dianggap penting untuk analisis. Namun, kelemahan Eclat adalah bahwa ia hanya mempertimbangkan dukungan sebagai ukuran penting dalam menemukan aturan dan tidak memperhitungkan "*Confidence*" dari aturan-aturannya (Bao et al., 2021; Arcos et al., 1993).

1.2 ALUR PENELITIAN

Metode yang digunakan dalam penelitian ini meliputi alur kerja penelitian seperti yang digambarkan pada Gambar 1.1.



Gambar 1. 1 Alur penelitian membandingkan algoritma Apriori dan Eclat

Pengumpulan Data: Data transaksi dari toko roti yang digunakan dalam penelitian ini terdiri dari 9.684 transaksi, menghasilkan total 20.507 transaksi produk dengan 105 set item. *Dataset* ini mencakup informasi tentang barang yang dibeli oleh pelanggan. *Dataset* produk transaksi penjualan disajikan dalam Tabel 1.1

Tabel 1. 1 *Dataset* Transaksi Produk

Member_number	Date	Item Description
1	30-10-2016 09:58	Bread
2	30-10-2016 10:05	Scandinavian
2	30-10-2016 10:05	Scandinavian
3	30-10-2016 10:07	Hot chocolate
3	30-10-2016 10:07	Jam
.....
9682	04-09-2017 14:32	Coffee
9682	04-09-2017 14:32	Tea
9683	04-09-2017 14:57	Coffee
9683	04-09-2017 14:57	Pastry
9684	04-09-2017 15:04	Smoothies

Langkah berikutnya adalah melakukan pra-pemrosesan data pada Tabel 1.1 Hanya atribut *Member_number* dan *ItemDescription* yang digunakan, sementara atribut Tanggal dihapus. Transaksi dengan *Member_number* yang sama digabungkan menjadi daftar item tunggal untuk menyederhanakan data. Data yang telah diproses akan diimplementasikan dalam teknik aturan asosiasi menggunakan algoritma Apriori dan Eclat. Ini melibatkan menetapkan ambang batas dukungan minimum untuk menentukan signifikansi aturan asosiasi. Hasil analisis asosiasi akan dievaluasi. Aturan asosiasi yang signifikan dan tingkat *Confidence* asosiasi antara item dalam *Dataset* transaksi akan dianalisis. Berdasarkan hasil analisis, kesimpulan akan diambil, dan rekomendasi akan diberikan kepada pemilik toko roti. Rekomendasi ini mencakup strategi penjualan, optimalisasi persediaan, peningkatan kepuasan pelanggan, promosi, rekomendasi produk, dan pengalaman berbelanja yang lebih personal.

2.1.1 ASSOCIATION RULES: MARKET BASKET ANALYSIS

Algoritma sangat penting dalam analisis data, terutama dalam analisis keranjang belanja pasar. Tujuannya adalah untuk mengidentifikasi kombinasi item yang sering muncul bersama dalam transaksi (Hu et al., 2021; Rana & Mondal, 2021; Abdelaal et al., 2021; Nasreen et al., 2014). Teknik ini membantu mengungkap aturan menarik, pola yang sering muncul, korelasi item, dan struktur data yang mungkin terjadi secara kebetulan dalam transaksi. Dalam analisis data, kita bekerja dengan transaksi yang berisi berbagai item, yang dapat dikelompokkan menjadi "*itemset*." Konsep kunci dalam analisis ini adalah "*Support*" dan "*association rule*". *Support* mengukur seberapa sering suatu *itemset* tertentu muncul dalam transaksi, sementara aturan asosiasi adalah implikasi logis antara dua *itemset* yang menunjukkan hubungan di antara mereka (Xu et al., 2022; Liang et al., 2021).

Aturan asosiasi, yang diperkenalkan oleh Rabesh dan rekan-rekan dari IBM Almaden pada tahun 1993, adalah konsep penting dalam analisis data (Zahrotun et al., o. J.; Siying Dong, Meiqin Liu, 2019; Angulakshmi et al., 2020; Hossain et al., 2019; Yasir et al., 2020; Das et al., 2018). Aturan ini digunakan untuk mengidentifikasi pola yang sering muncul, korelasi item, dan hubungan sebab-akibat dalam data transaksi. Metode analisis ini mengungkapkan hubungan signifikan dalam *Dataset* besar dan menyatakan hasilnya dalam bentuk aturan asosiasi atau *itemset* yang sering muncul. Proses dimulai dengan pembuatan *itemset* yang sering muncul, terdiri dari item atau objek dengan *Support* di atas ambang batas minimum yang ditentukan oleh pengguna. Fokus utamanya adalah pada *itemset* yang lebih besar dan sering muncul, membentuk dasar untuk aturan asosiasi (L. Wang et al., 2023).

1.3 MEASUREMENT METRIC

Metodologi dasar analisis asosiasi adalah sebagai berikut:

1.3.1 ANALISIS KUMPULAN DATA

Analisis *Dataset* dilakukan untuk menentukan set item yang muncul paling sering dengan nilai *Support* minimum yang telah ditentukan sebelumnya. Dalam hal ini, peneliti menetapkan nilai *Support* minimum sebesar 0,02 atau 2% karena, setelah meninjau dan menganalisis volume data transaksi, nilai ini terlihat relatif kecil. Hasil pencarian untuk *itemset* yang paling sering muncul diperoleh menggunakan persamaan berikut. Nilai *Support* dari *itemset* yang paling sering muncul diperoleh menggunakan persamaan (Das et al., 2018)(1.1):

$$Support(A) = \frac{\sum Contain A}{\sum Total Transactions} \times 100\% \quad (1.1)$$

1.3.2 PEMBENTUKAN PERATURAN ASOSIASI DENGAN *SUPPORT* MINIMUM

Fase pembentukan aturan asosiasi melibatkan pemilihan data yang memenuhi *Support* dari *itemset* yang sering muncul untuk digabung, sementara *itemset* yang tidak memenuhi kriteria ini dihapus. Mereka yang memenuhi akan digunakan dalam proses selanjutnya. Nilai dari *itemset* 2-item diperoleh menggunakan persamaan (1.2):

(1.2)

$$Support (A \cap B) = \frac{\sum \text{Contain } A \text{ and } B}{\sum \text{Total Transactions}} \times 100\%$$

Nilai yang mengandung keduanya A dan B mewakili nilai dua item dalam suatu transaksi (Hassan et al., 2023) (H. Bin Wang & Gao, 2021). Mereka harus memenuhi nilai *Support* yang ditetapkan untuk *1-itemset* (0,02%), dan yang tidak memenuhi kriteria ini akan dieliminasi dan tidak melanjutkan ke langkah berikutnya. Untuk mendapatkan nilai *Support* dari *2-itemset*, Anda membagi nilai yang mengandung keduanya A dan B oleh total jumlah semua transaksi. Mendapatkan nilai *persentase*, hasil dari pembagian tersebut dikalikan dengan 100%. Nilai *Support* dari *3-itemset* diperoleh menggunakan Persamaan (1.3):

$$Support (A \cap B \cap C) = \frac{\sum \text{Contain } A, B \text{ and } C}{\sum \text{Total Transactions}} \times 100\%$$

Nilai yang mengandung A, B, dan C mewakili nilai tiga item dalam suatu transaksi. Mereka harus memenuhi nilai *Support* yang ditetapkan untuk *2-itemset* (0,02%), dan yang tidak memenuhi kriteria ini akan dieliminasi dan tidak melanjutkan ke langkah berikutnya. Untuk mendapatkan nilai *Support* dari *3-itemset*, Anda membagi nilai yang mengandung A, B, dan C oleh total jumlah semua transaksi yang mengandung A. Untuk mendapatkan nilai *persentase*, hasil dari pembagian tersebut dikalikan dengan 100%. Untuk menentukan nilai *Confidence*, peneliti menetapkan nilai *Confidence* sebesar 0,01% dengan tujuan membentuk aturan.

1.3.3 CONFIDENCE

Keyakinan adalah probabilitas bersyarat yang menunjukkan seberapa sering suatu aturan terbukti benar. Sederhananya, *Confidence* diri dapat dihitung dengan menggunakan rumus di bawah ini (1.4):

$$Confidence ((A \cap B)) = \frac{\text{Number of transactions with both } A \text{ and } B}{\sum \text{Total Transactions with } A} \times 100\% \quad (1.4)$$

1.3.4 LIFT RASIO

Lift adalah metrik penting dalam analisis asosiasi yang menggambarkan sejauh mana aturan asosiasi memiliki ketergantungan antara item dalam *Dataset*. Nilai *Lift* yang lebih tinggi menunjukkan hubungan yang lebih kuat daripada yang diharapkan oleh kebetulan, baik dalam konteks memprediksi hasil dalam *Dataset* di masa depan maupun dalam mengukur korelasi antara kelompok item A dan B. Dalam kedua hal ini, formula *Lift* diterapkan untuk membandingkan probabilitas item muncul bersama dengan probabilitas muncul secara terpisah. Secara keseluruhan, *Lift* membantu mengidentifikasi pola pembelian atau hubungan antara item dalam analisis data dan memiliki implikasi strategis dalam pengambilan keputusan bisnis.

Rumus untuk menghitung rasio *Lift* adalah sebagai berikut (1.5):

$$Lift = \frac{Support (A \text{ dan } B)}{Support (A) \times Support (B)} \quad (1.5)$$

Lift dapat diinterpretasikan sebagai ukuran seberapa kuat hubungan antara dua hal dalam data. Ini mengukur sejauh mana hubungan antara item atau elemen ketika mereka muncul bersama dalam situasi tertentu berbeda dari harapan acak. Jika nilai *Lift* lebih besar dari 1, itu menunjukkan hubungan yang signifikan antara hal-hal tersebut. Ini mirip dengan mendapatkan *Support* dari kedua pihak pemerintah; semakin tinggi *Support* ($Lift \geq 1$), semakin kuat hubungannya. Dengan kata lain, *Lift* membantu kita menemukan pola menarik dalam data, seperti memiliki insentif untuk mengeksplorasi hubungan yang menarik perhatian.

1.4 HASIL DAN PEMBAHASAN

Penelitian ini dilakukan untuk menemukan pola pembelian item umum berdasarkan data laporan pembelian harian. Data laporan penjualan harian, awalnya informasi biasa, dapat diproses menjadi informasi yang sangat berguna untuk kemajuan dan peningkatan bisnis. Oleh karena itu, penelitian ini menguji hasil penggunaan Apriori dan Eclat untuk menentukan hubungan antara pola pembelian. Dalam proses penelitian ini, data penjualan roti dengan total penjualan produk sebanyak 20.507, 9.684 transaksi, dan 105 *itemset* digunakan. *Dataset* kemudian diproses sehingga item yang dibeli pada waktu yang sama dikelompokkan ke dalam nomor transaksi yang sama. Data yang telah mengalami pra-pemrosesan dapat dilihat di Tabel 1.2

Tabel 1. 2 Pemrosesan Hasil

Transaction	item
1	Bread
2	Scandinavian, Scandinavian
3	Hot chocolate, Jam, Cookies
4	Muffin
5	Coffee, Pastry, Bread
....
9462	Bread
9463	Truffles, Tea, Spanish Brunch, Christmas common
9464	Muffin, Tacos/Fajita, Coffee, Tea
9465	Coffee, Pastry
9466	Smoothies

Nilai ambang batas yang ditetapkan dalam penelitian ini untuk memperoleh Association Rules adalah sebesar 0,02.

1.4.1 ALGORITMA APRIORI

Setelah pemrosesan data, algoritma Apriori diterapkan dengan nilai *Support* ambang batas sebesar 0,02 dan nilai *Confidence* sebesar 0,01, menghasilkan 28 aturan dengan 2 *itemset* memiliki nilai *Support* tertinggi sebesar 0,090 dan nilai *Confidence* sebesar 0,275. Salah satu aturan adalah 'jika Anda membeli Roti, maka Anda akan membeli Kopi.' Aturan Asosiasi final yang diperoleh melalui algoritma Apriori dapat dilihat di Tabel 1.3.

Tabel 1. 3 Kumpulan data aturan asosiasi apriori 20507

No	Barang Transaksi	Sup	Conf	Lift
1	{Cake} => {Tea}	0,024	0,229	1,606
2	{Tea} => {Cake}	0,024	0,167	1,606
3	{Coffee} => {Toast}	0,024	0,049	1,473
4	{Toast} => {Coffee}	0,024	0,704	1,473
5	{Medialuna} => {Coffee}	0,035	0,568	1,189
...
25	{Tea} => {Bread}	0,028	0,197	0,603
26	{Bread} => {Tea}	0,028	0,086	0,603
27	{Bread} => {Coffee}	0,090	0,275	0,576
28	{Coffee} => {Bread}	0,090	0,188	0,576

Selanjutnya data diolah menggunakan data penjualan roti dengan total *Dataset* sebanyak 8.144 yang terdiri dari 3.988 transaksi dan 78 *itemset*. *Dataset* transaksi berbentuk tabel seperti terlihat pada Tabel 1.4.

Tabel 1. 4 Kumpulan data aturan asosiasi apriori 8144

No	Barang Transaksi	Sup	Conf	Lift
1	{Medialuna} => {Coffee}	0,050	0,572	1,215
2	{Coffee} => {Medialuna}	0,050	0,106	1,215
3	{Alfajores} => {Coffee}	0,023	0,532	1,131
4	{Coffee} => {Alfajores}	0,023	0,048	1,103
5	{Coffee} => {Hot chocolate}	0,033	0,069	1,060
...
25	{Tea} => {Bread}	0,028	0,196	0,217
26	{Bread} => {Tea}	0,028	0,084	0,175
27	{Bread} => {Coffee}	0,087	0,266	0,133
28	{Coffee} => {Bread}	0,087	0,185	0,091

1.4.2 ALGORITMA ECLAT

Aturan asosiasi final menggunakan ambang batas *Support* sebesar 0,02 dan ambang batas *Confidence* sebesar 0,01 dihasilkan menggunakan algoritma Eclat, seperti yang terlihat di Tabel 1.5.

Tabel 1. 5 Kumpulan data aturan asosiasi Eclat 20507

No	Barang Transaksi	Sup	Conf	Lift
1	{Toast} => {Coffee}	0,024	0,704	1,473
2	{Coffee} => {Toast}	0,024	0,049	1,473
3	{Juice} => {Coffee}	0,021	0,536	1,120
4	{Coffee} => {Juice}	0,021	0,043	1,120
5	{Cookies} => {Coffee}	0,028	0,519	1,086
...
25	{Tea} => {Bread}	0,028	0,197	0,603
26	{Bread} => {Tea}	0,028	0,086	0,603
27	{Coffee} => {Bread}	0,090	0,188	0,576

28	{Bread} \Rightarrow {Coffee}	0,090	0,275	0,576
----	--------------------------------	-------	-------	-------

Berdasarkan Tabel 1.5, aturan yang dihasilkan menggunakan algoritma Eclat dengan 20.507 transaksi data menghasilkan 28 aturan dengan nilai *Support* tertinggi sebesar 0,090, nilai *Confidence* sebesar 0,704, dan nilai *Lift* tertinggi sebesar 1,473. Selanjutnya, perhitungan akan dilakukan dengan reduksi data menjadi 8.144, dan hasilnya dapat dilihat di Tabel 1.6.

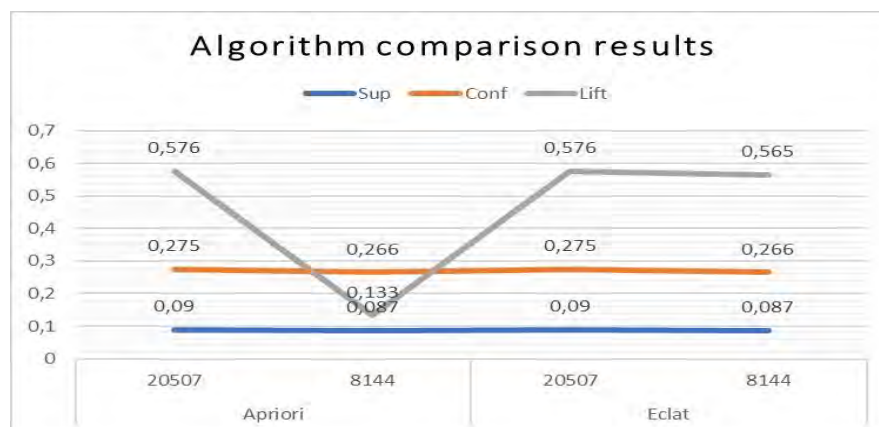
Tabel 1. 6 Kumpulan data aturan asosiasi Eclat 8144

No	Barang Transaksi	Sup	Conf	Lift
1	{Cookies} \Rightarrow {Coffee}	0,021	0,513	1,089
2	{Coffee} \Rightarrow {Cookies}	0,021	0,044	1,089
3	{Coffee} \Rightarrow {Alfajores}	0,023	0,048	1,131
4	{Alfajores} \Rightarrow {Coffee}	0,023	0,532	1,131
5	{Muffin} \Rightarrow {Coffee}	0,023	0,482	1,024
25	{Tea} \Rightarrow {Bread}	0,028	0,196	0,600
...
26	{Bread} \Rightarrow {Tea}	0,028	0,084	0,600
27	{Coffee} \Rightarrow {Bread}	0,087	0,185	0,565
28	{Bread} \Rightarrow {Coffee}	0,087	0,266	0,565

Berdasarkan Tabel 1.6, aturan yang dihasilkan menggunakan algoritma Eclat dengan 8.144 transaksi data menghasilkan 28 aturan dengan nilai *Support* tertinggi sebesar 0,087, nilai *Confidence* sebesar 0,266, dan nilai *Lift* sebesar 0,565.

1.5 HASIL PEERBANDINGAN ALGORITMA

Hasil perhitungan menggunakan algoritma Apriori dan Eclat di RStudio memungkinkan untuk mengidentifikasi perbedaan dan kesamaan antara kedua algoritma tersebut. Berikut adalah tabel yang menunjukkan perbandingan hasil dari kedua algoritma, seperti yang ditunjukkan pada Gambar 1.2.



Gambar 1. 2 Hasil perbandingan algoritma Eclat dan Apriori

Pada Gambar 1.2, hasil perbandingan antara algoritma Apriori dan Eclat disajikan, dan data telah dibagi menjadi dua set terpisah untuk setiap algoritma. Hasil yang diperoleh menunjukkan bahwa Apriori dan Eclat memberikan hasil yang serupa untuk kedua set data. Keduanya menunjukkan tingkat *Support* yang hampir identik, yang mengindikasikan seberapa sering *itemset* atau aturan asosiasi muncul dalam data. Demikian pula, tingkat

Confidence, yang mengukur kekuatan aturan asosiasi yang dihasilkan, juga menunjukkan perbedaan yang tidak signifikan antara keduanya. *Lift*, yang mengukur hubungan antara *itemset* atau aturan asosiasi, juga menunjukkan variasi yang kecil.

Penelitian ini, selain membandingkan dua algoritma data mining aturan asosiasi seperti yang telah dijelaskan sebelumnya pada Gambar 1.2 para peneliti juga memberikan penjelasan mengenai perbedaan dan kontribusi baru berdasarkan penelitian sebelumnya dalam konteks metode asosiasi. Tabel yang menggambarkan kebaruan penelitian disajikan dalam Tabel 1.7.

Tabel 1. 7 Perbandingan penelitian terdahulu dengan penelitian yang telah dilakukan

Penulis	Judul	Tools/algoritma	Results
Ardiantoro L, Sunarmi N (2020)	Badminton player scouting analysis using Frequent Pattern growth (FP-growth) algorithm	Algoritma FP-Growth PHP dan MySQL	Algoritma FP Growth mampu menggambarkan pola permainan seorang atlet bulutangkis
Hu S, Song Liang (2021)	Frequent-pattern growth algorithmbased association rule mining method of public transport travel stability	Algoritma FP-Growth	d mengembangkan model konseptual untuk memahami peralihan moda ke Tingkat Angkutan Umum (TS) yang lebih tinggi di kalangan komuter
Çakır E, Fişkin R, Sevgili C (2021)	Investigation of tugboat accidents severity: An application of association rule mining algorithms	Algoritma Apriori, Predictive Apriori dan FP-Growth	Riset data mining menunjukkan bahwa faktor yang mempengaruhi empat dari lima kecelakaan serius berkaitan dengan kerusakan lambung/mesin.
Riadi et al, (2023)	Exploring Algorithm Performance: A Comparative Study of Apriori and Eclat in Frequent Pattern Mining and Association Rule Discovery	Algoritma Apriori, Eclat	Penelitian ini berfokus pada perbandingan dua algoritma pembatasan aturan asosiasi, Apriori dan Eclat, dalam konteks domain penjualan toko roti atau bisnis toko roti

1.6 KESIMPULAN

Penelitian ini, penggunaan algoritma Apriori dan Eclat menghasilkan nilai yang sama untuk *Support* dan *Confidence*, yaitu 0,090 dan 0,275, serta *Lift* sebesar 0,576, dengan total 20.507 transaksi data. Namun, ketika data dikurangi menjadi 8.144 transaksi, nilai *Support* dan *Confidence* tetap sama masing-masing sebesar 0,087 dan 0,266. Namun, perbedaan muncul pada nilai *Lift*, dengan algoritma Apriori menghasilkan nilai 0,133, sedangkan algoritma Eclat menghasilkan nilai 0,565. Studi ini menunjukkan bahwa algoritma Eclat memberikan hasil yang lebih baik dalam menentukan aturan asosiasi. Penelitian lebih lanjut dapat fokus

pada memahami faktor-faktor yang memengaruhi perbedaan kinerja kedua algoritma ini dan bagaimana memaksimalkan manfaat dari setiap algoritma sesuai dengan kebutuhan analisis dan konteks data.

DAFTAR PUSTAKA

- Abdelaal, A. A., Abed, S., Al-Shayegi, M., & Allaho, M. (2021). Customized frequent patterns mining algorithms for enhanced Top-Rank-K frequent pattern mining. *Expert Systems with Applications*, *169*, 114530. <https://doi.org/10.1016/j.eswa.2020.114530>
- Agapito, Giuseppe Milano, Marianna Guzzi, P. H., & Cannataro, M. (2019). Mining Association Rules from Disease Ontology. *Proceedings - 2019 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2019*, 2239–2243. <https://doi.org/10.1109/BIBM47256.2019.8983022>
- Angulakshmi, M., Deepa, M., Sudha, S., & Brindha, K. (2020). Association Rule Modeling using UML and Apriori Algorithm. *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, 1–5. <https://doi.org/10.1109/ic-ETITE47903.2020.124>
- Arcos, J. R. D., Ri, R., Gxfdwlrq, Q., Hernandez, A. A., & Mining, A. A. R. (1993). *Efficient Apriori Algorithm using Enhanced Transaction Reduction Approach*. 97–101.
- Bao, G., Mei, Y., Li, G., & Wang, G. (2021). Analysis of Students Behavior Characteristics Based on K-medoids + Eclat. *Proceedings of the 2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design, CSCWD 2021*, 1239–1244. <https://doi.org/10.1109/CSCWD49262.2021.9437638>
- Bashkari, M. S., Sami, A., & Rastegar, M. (2021). Outage Cause Detection in Power Distribution Systems Based on Data Mining. *IEEE Transactions on Industrial Informatics*, *17*(1), 640–649. <https://doi.org/10.1109/TII.2020.2966505>
- Chen, K., Abtahi, F., Carrero, J. J., Fernandez-Llatas, C., & Seoane, F. (2023). Process mining and data mining applications in the domain of chronic diseases: A systematic review. *Artificial Intelligence in Medicine*, *144*(August), 102645. <https://doi.org/10.1016/j.artmed.2023.102645>
- Chen, Y., Mo, D., & Zhang, F. (2022). Stock market prediction using weighted inter-transaction class association rule mining and evolutionary algorithm. *Economic Research-Ekonomika Istrazivanja*, *35*(1), 5971–5996. <https://doi.org/10.1080/1331677X.2022.2043762>
- Das, S., Dutta, A., Jalayer, M., Bibeka, A., & Wu, L. (2018). Factors influencing the patterns of wrong-way driving crashes on freeway exit ramps and median crossovers: Exploration using ‘Eclat’ association rules to promote safety. *International Journal of Transportation Science and Technology*, *7*(2), 114–123. <https://doi.org/10.1016/j.ijtst.2018.02.001>
- Fadlil, A., Riadi, I., & Purwadi Putra, I. J. D. E. (2023). Comparison of Machine Learning Performance Using Naive Bayes and Random Forest Methods to Classify Batik Fabric Patterns. *Revue d'Intelligence Artificielle*, *37*(2), 379–385. <https://doi.org/10.18280/ria.370214>
- Gao, P. (2022). Research on Analysis of Students Using Mobile Phones in Ideological and Political Classrooms by Apriori Algorithm of Association Rules. *Procedia Computer Science*, *208*, 12–17. <https://doi.org/10.1016/j.procs.2022.10.003>
- Hassan, M. M., Karim, A., Mollick, S., Azam, S., Ignatious, E., & Farhan Al Haque, A. S. M. (2023). An Apriori Algorithm-Based Association Rule Analysis to detect Human Suicidal Behaviour. *Procedia Computer Science*, *219*, 1279–1288.

- <https://doi.org/10.1016/j.procs.2023.01.412>
- Herman, H., Riadi, I., & Kurniawan, Y. (2023). Vulnerability Detection With K-Nearest Neighbor and Naïve Bayes Method using Machine Learning. *International Journal of Artificial Intelligence Research*, 7(1), 10. <https://doi.org/10.29099/ijair.v7i1.795>
- Hossain, M., Sattar, A. H. M. S., & Paul, M. K. (2019). Market basket analysis using apriori and FP growth algorithm. *2019 22nd International Conference on Computer and Information Technology, ICCIT 2019*, 18–20. <https://doi.org/10.1109/ICCIT48885.2019.9038197>
- Hu, S., Liang, Q., Qian, H., Weng, J., Zhou, W., & Lin, P. (2021). Frequent-pattern growth algorithm based association rule mining method of public transport travel stability. *International Journal of Sustainable Transportation*, 15(11), 879–892. <https://doi.org/10.1080/15568318.2020.1827318>
- Islamiyah, Ginting, P. L., Dengen, N., & Taruk, M. (2019). Comparison of Priori and FP-Growth Algorithms in Determining Association Rules. *ICEEIE 2019 - International Conference on Electrical, Electronics and Information Engineering: Emerging Innovative Technology for Sustainable Future*, 320–323. <https://doi.org/10.1109/ICEEIE47180.2019.8981438>
- Istrat, V., & Lalić, N. (2017). Creating a Decision-Making Model Using Association Rules. *Applied Artificial Intelligence*, 31(5–6), 538–553. <https://doi.org/10.1080/08839514.2017.1378301>
- Jia, P., Zhang, J., Zhao, B., Li, H., & Liu, X. (2023). Privacy-preserving association rule mining via multi-key fully homomorphic encryption. *Journal of King Saud University - Computer and Information Sciences*, 35(2), 641–650. <https://doi.org/10.1016/j.jksuci.2023.01.007>
- Kenmogne, E. B., Tayou Djamegni, C., Nkambou, R., Tabueu Fotso, L. C., & Tadmon, C. (2022). Efficient mining of intra-periodic frequent sequences. *Array*, 16(February 2021), 100263. <https://doi.org/10.1016/j.array.2022.100263>
- Khalid, H., & Wade, V. (2022). *Comparative Analysis of Existing and a Novel Approach to Topic Detection on Conversational Dialogue Data*. 11(4), 1–18.
- Kim, B., Lim, B. T. H., Oo, B. L., & Ahn, Y. H. (2023). Data-mining-based identification of post-handover defect association rules in apartment housings. *Journal of Computational Design and Engineering*, 10(4), 1838–1855. <https://doi.org/10.1093/jcde/qwad080>
- Krisnanto, U., Juharsah, J., Putra, P., Achmad, A. D., & Timotius, E. (2022). Utilizing Apriori Data Mining Techniques on Sales Transactions. *Webology*, 19(1), 5581–5590. <https://doi.org/10.14704/web/v19i1/web19376>
- Lee, A. S. H., Yap, L. S., Chua, H. N., Low, Y. C., & Ismail, M. A. (2021). A Data Mining Approach To Analyse Crash Injury Severity Level. *Journal of Engineering Science and Technology*, 16, 1–14.
- Li, X. (2023). Optimization of the College Basketball Teaching Mode Based on the Applied Explainable Association Rule Algorithm and Cluster Analysis in Mobile Computing Environments. *Applied Artificial Intelligence*, 37(1). <https://doi.org/10.1080/08839514.2023.2214768>
- Li, Z., Li, X., Tang, R., & Zhang, L. (2021). Apriori Algorithm for the Data Mining of Global Cyberspace Security Issues for Human Participatory Based on Association Rules. *Frontiers in Psychology*, 11(February). <https://doi.org/10.3389/fpsyg.2020.582480>
- Liang, B., Li, X., Zhang, Z., Wu, C., Liu, X., & Zheng, Y. (2021). Multidrug resistance analysis method for pathogens of cow mastitis based on weighted-association rule mining and similarity comparison. *Computers and Electronics in Agriculture*, 190(August), 106411. <https://doi.org/10.1016/j.compag.2021.106411>

- Man, M., Ruslan, N. A., Jusoh, J. A., & Bakar, W. A. W. A. (2023). IR-Eclat: A new algorithm of incremental R-Eclat for infrequent itemset mining. *AIP Conference Proceedings*, 2484(11), 3545–3551. <https://doi.org/10.1063/5.0116718>
- Mohamed, J., & Jofri, M. H. (2022). *Associating User 's Preference and Satisfaction into Quality of Experience : A Shoulder-surfing Resistant Authentication Scheme by Visual Perception*. 13(10), 92–98.
- Nafie Ali, F. M., & Mohamed Hamed, A. A. (2018). Usage Apriori and clustering algorithms in WEKA tools to mining dataset of traffic accidents. *Journal of Information and Telecommunication*, 2(3), 231–245. <https://doi.org/10.1080/24751839.2018.1448205>
- Nasreen, S., Azam, M. A., Shehzad, K., Naeem, U., & Ghazanfar, M. A. (2014). Frequent pattern mining algorithms for finding associated frequent patterns for data streams: A survey. *Procedia Computer Science*, 37, 109–116. <https://doi.org/10.1016/j.procs.2014.08.019>
- Osman, M. T., Yuli, C., Li, T., & Senin, S. F. (2021). Association rule mining for identification of port state control patterns in Malaysian ports. *Maritime Policy and Management*, 48(8), 1082–1095. <https://doi.org/10.1080/03088839.2020.1825854>
- Pan, T. (2021). An Improved Apriori Algorithm for Association Mining Between Physical Fitness Indices of College Students. *International Journal of Emerging Technologies in Learning*, 16(9), 235–246. <https://doi.org/10.3991/ijet.v16i09.22747>
- Rana, S., & Mondal, M. N. I. (2021). *A Seasonal and Multilevel Association Based Approach for Market Basket Analysis in Retail Supermarket*. 1(4), 9–15.
- Riadi, I., Herman, Fitriah, Muis, A., & Yunus, M. (2023). *Implementation of association rule using apriori algorithm and frequent pattern growth for inventory control*. 15(4), 369–378. <https://doi.org/10.20895/infotel.v15i4.980>
- Riadi, I., Herman, H., Fitriah, F., & Suprihatin, S. (2023). Optimizing Inventory with Frequent Pattern Growth Algorithm for Small and Medium Enterprises. *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 23(1), 169–182. <https://doi.org/10.30812/matrik.v23i1.3363>
- S.Mythili, M., & R. Mohamed Shanavas, A. (2013). Performance Evaluation of Apriori and FP-Growth Algorithms. *International Journal of Computer Applications*, 79(10), 34–37. <https://doi.org/10.5120/13779-1650>
- Saefudin, S., & DN, S. (2019). Penerapan Data Mining Dengan Metode Algoritma Apriori Untuk Menentukan Pola Pembelian Ikan. *JSiI (Jurnal Sistem Informasi)*, 6(2), 36. <https://doi.org/10.30656/jsii.v6i2.1587>
- Samuel, S., Sani, A., Budiyantra, A., Ivone, M., & Frieyadie, F. (2022). Sales Level Analysis Using the Association Method With the Apriori Algorithm. *Jurnal Riset Informatika*, 4(4), 331–340. <https://doi.org/10.34288/jri.v4i4.422>
- Sarumi, O. A., Leung, C. K., & Adetunmbi, A. O. (2018). Spark-based data analytics of sequence motifs in large omics data. *Procedia Computer Science*, 126, 596–605. <https://doi.org/10.1016/j.procs.2018.07.294>
- Siyang Dong, Meiqin Liu, S. Z. (2019). *Association Rule Mining of Silk Relics Database with the RCFP-Growth Algorithm*. 7804–7809.
- Wang, H. Bin, & Gao, Y. J. (2021). Research on parallelization of Apriori algorithm in association rule mining. *Procedia Computer Science*, 183, 641–647. <https://doi.org/10.1016/j.procs.2021.02.109>
- Wang, L., Guo, Y., Guo, Y., Xia, X., Zhang, Z., & Cao, J. (2023). An Improved Eclat Algorithm based Association Rules Mining Method for Failure Status Information and Remanufacturing Machining Schemes of Retired Products. *Procedia CIRP*, 118, 572–577. <https://doi.org/10.1016/j.procir.2023.06.098>
- Wang, L., Ma, Q., & Meng, J. (2019). Incremental Fuzzy Association Rule Mining for

- Classification and Regression. *IEEE Access*, 7, 121095–121110. <https://doi.org/10.1109/ACCESS.2019.2933361>
- Wang, S., Cao, J., & Yu, P. S. (o. J.). *Deep Learning for Spatio-Temporal Data Mining : A Survey*. 1–21.
- Wang, Y., Jiang, J., & Wang, Y. (2023). High-Performance Computing and Artificial Intelligence for Geosciences. *Applied Sciences (Switzerland)*, 13(13), 1–4. <https://doi.org/10.3390/app13137952>
- Xu, J., Bai, D., He, H., Luo, J., & Lu, G. (2022). Disaster Precursor Identification and Early Warning of the Lishanyuan Landslide Based on Association Rule Mining. *Applied Sciences (Switzerland)*, 12(24). <https://doi.org/10.3390/app122412836>
- Yang, J., Zhang, Y., & Wei, Y. (2017). An Improved Vertical Algorithm for Frequent Itemset Mining from Uncertain Database. *2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, 355–358. <https://doi.org/10.1109/IHMSC.2017.87>
- Yang, X., Yang-Wang, F., You-Li, W., Dan-Xu, Z., & Chen, H. (2018). Association Rule Mining for the Infrared Countermeasure by the PF-Growth Algorithm. *Chinese Control Conference, CCC, 2018-July*, 8043–8048. <https://doi.org/10.23919/ChiCC.2018.8483222>
- Yasir, M., Habib, M. A., Ashraf, M., Sarwar, S., Chaudhry, M. U., Shahwani, H., Ahmad, M., Muhammad, C. H., & Faisal, N. (2020). *D-GENE : Deferring the GENERation of Power Sets for Discovering Frequent Itemsets in Sparse Big Data*. 27375–27392.
- Yudhana, A., Riadi, I., & Djou, M. R. (2023). Determining Eligible Villages for Mobile Services using K-NN Algorithm. *ILKOM Jurnal Ilmiah*, 15(1), 11–20. <https://doi.org/10.33096/ilkom.v15i1.1546.11-20>
- Zahrotun, L., Soyusiawaty, D., & Sara Pattihua, R. (o. J.). *The Implementation of Data Mining for Association Patterns Determination Using Temporal Association Methods in Medicine Data*.
- Zhang, C., Tian, P., Zhang, X., Jiang, Z. L., Yao, L., & Wang, X. (2019). Fast eclat algorithms based on minwise hashing for large scale transactions. *IEEE Internet of Things Journal*, 6(2), 3948–3961. <https://doi.org/10.1109/JIOT.2018.2885851>



Fitriah merupakan Mahasiswa Magister Informatika Universitas Ahmad Dahlan Yogyakarta tahun 2022. Sejak memperoleh gelar Sarjana dari Jurusan Informatika Fakultas Teknik Universitas Muhammadiyah Bengkulu, ia mulai tertarik dan mempelajari ilmu bidang *machine learning* dan kecerdasan buatan.



Imam Riadi merupakan Guru Besar dalam Bidang Ilmu Sistem Informasi sejak Tahun 2023. Peminatan bidang keahlian yang ditekuni: Keamanan Informasi, Keamanan Siber, Forensik Digital, dan Jaringan Komputer. Gelar Doktor didapatkan dari Program Studi Ilmu Komputer, Universitas Gadjah Mada pada tahun 2014. Gelar Magister didapatkan pada Program Studi Ilmu Komputer, Universitas Gadjah Mada pada tahun 2004. Gelar Sarjana didapatkan dari Program Studi Pendidikan Teknik Elektro, Universitas Negeri Yogyakarta (UNY) pada tahun 2001. Mulai Tahun 2002 sampai sekarang menjadi Dosen Tetap pada Program Studi Informatika Program Magister Universitas Ahmad Dahlan, Yogyakarta.



Herman Merupakan Dosen Universitas Ahmad Dahlan Yogyakarta. Meraih Gelar Ph.D. dari Universiti Teknologi Malaysia pada bidang Ilmu Komputer. Bidang keahlian yang ditekuni: Rekayasa Perangkat Lunak, Keamanan dan Keandalan Komputer, dan Komunikasi Komputer (Jaringan).

BAB 5
Perbandingan Algoritma Pengukuran Jarak *Manhattan* dan
Euclidean pada Model Klasifikasi *K-Nearest Neighbors* Pendeteksi
Gagal Jantung

Muhammad Kunta Biddinika, Herman, Alya Masitha

1.1 PENDAHULUAN

Jantung merupakan salah satu organ vital dalam sistem peredaran darah (Chethana, 2021; Khateeb & Usman, 2017). Penyakit jantung khususnya gagal tetap menjadi topik keprihatinan mendalam di kalangan peneliti dan salah satu tantangan utama dalam bidang ini adalah deteksi yang akurat dan lokalisasi yang tepat dari kejadiannya di dalam tubuh manusia (Agrawal et al., 2021). Secara historis, teknik deteksi dini telah menunjukkan efisiensi yang terbatas dalam mengidentifikasi penyakit jantung. Bahkan, profesional medis berpengalaman tetap menghadapi tantangan dalam memprediksi terjadinya gagal jantung secara akurat. Meskipun terdapat perangkat medis tertentu yang dapat digunakan untuk memprediksi penyakit jantung, penerapannya secara luas terhambat oleh biayanya yang tinggi, dan akurasi prediksi yang belum bisa diandalkan. (Choudhary & Narayan Singh, 2020).

Gagal jantung adalah kondisi medis yang ditandai dengan ketidakmampuan jantung memompa cukup darah untuk memenuhi kebutuhan tubuh (Ozcan & Peker, 2023). Penyakit ini dapat disebabkan oleh berbagai faktor, seperti: tekanan darah tinggi, penyakit jantung bawaan, diabetes, faktor gaya hidup, obesitas dan keturunan (Chicco & Jurman, 2020). Diagnosis gagal jantung yang akurat memerlukan penilaian komprehensif yang mencakup pengawasan manifestasi klinis yang rumit, eksplorasi yang cermat terhadap latar belakang medis pasien dan analisis yang cerdas tentang hasil yang berasal dari serangkaian pemeriksaan diagnostik yang ekstensif (Rahman et al., 2021). Mengingat kemajuan teknologi dan kapasitas sistem otomatis untuk mengurai dan menghitung data, teknik machine learning telah muncul sebagai alat yang layak untuk menambah aspek diagnostik dan prognostik yang berkaitan dengan penyakit ini (Latha & Jeeva, 2019). Salah satu teknik mesin yang dapat digunakan adalah klasifikasi (Assegie et al., 2021). Teknik klasifikasi dalam machine learning memiliki banyak algoritma yang dapat digunakan dalam memecahkan masalah, seperti: K-NN, naïve bayes, neural network, random forest, dll (Peirlinck et al., 2019; Srinivasa Rao et al., 2021). Namun demikian, penting untuk dicatat bahwa penyelidikan ini secara eksklusif menggunakan metodologi klasifikasi tunggal, khususnya algoritma K-Nearest Neighbor (K-NN) (Upadhyay et al., 2020).

K-NN adalah metode klasifikasi yang berfungsi untuk mengklasifikasikan data baru berdasarkan data pelatihan yang memiliki karakteristik atau fitur tertentu yang mirip dengan data baru (Anggoro & Kurnia, 2020). Teknik K-Nearest Neighbor (K-NN) ditandai dengan kesederhanaan relatifnya, menikmati pemanfaatan luas untuk implementasi dan kemampuan beradaptasi dalam berbagai penelitian dan aplikasi praktis (Uddin et al., 2022). Algoritma ini menggunakan beberapa parameter yang bekerja dengan matriks jarak dan nilai k (Abu Alfeilat et al., 2019). Tujuan utama dari metode K-Nearest Neighbor (K-NN) adalah untuk mengidentifikasi titik data terdekat atau tetangga dalam dataset yang diberikan. Algoritma ini selanjutnya berusaha untuk mengkategorikan objek berdasarkan atribut tertentu dan referensi sampel data pelatihan. Namun, K-NN menunjukkan keterbatasan, terutama dalam konteks menentukan nilai yang sesuai untuk parameter 'k' yang seharusnya tidak menjadi kelipatan dari jumlah total kelas untuk mencegah hasil yang tidak diinginkan (Fadlil et al., 2022). Metode K-NN dapat digunakan untuk memprediksi kemungkinan seseorang mengalami penyakit gagal jantung berdasarkan data medis yang telah dikumpulkan, seperti: jenis kelamin, usia, kadar gula darah, kolesterol, tekanan darah, dll (Sowmiya & Sumitra, 2018). Prediksi menggunakan metode K-NN dapat dilakukan upaya pencegahan dan pengobatan dini. Sehingga dapat meminimalisir risiko penyakit gagal jantung pada pasien. Klasifikasi K-NN menggunakan matriks pengukuran jarak yang berdampak signifikan terhadap kinerja algoritma ini. Pengukuran jarak yang paling umum digunakan dalam K-NN

adalah metode *Euclidean*. Namun, penelitian ini mengukur fungsi kinerja algoritma K-NN menggunakan dua metode pengukuran jarak, yaitu: *Euclidean* dan *Manhattan*.

Prediksi penyakit jantung adalah tugas paling penting bagi banyak profesional medis dan memerlukan analisis yang tepat dari data klinis dan patologi pasien. Sistem prediksi penyakit jantung yang terkomputerisasi dapat membantu dalam kasus seperti itu. Penelitian ini bertujuan untuk menentukan metode pengukuran jarak terbaik yang akan digunakan dalam pengklasifikasi algoritma K-NN agar mendapatkan hasil akurasi terbaik, menyajikan pembelajaran tentang teknik pengumpulan data yang digunakan untuk membangun sistem prediksi penyakit gagal jantung terkomputerisasi dan diharapkan akan memberikan kontribusi yang berharga dalam mendukung diagnosis dini dan perencanaan manajemen yang lebih baik bagi pasien yang berisiko gagal jantung.

1.2 TINJAUAN PUSTAKA

Banyak penelitian yang telah dilakukan oleh peneliti sebelumnya terkait dengan pengukuran jarak, perbandingan jarak dan membahas berbagai metode pengukuran jarak menggunakan beberapa teknik pengukuran jarak. Tinjauan literatur singkat akan dijelaskan di sini.

Penelitian yang dilakukan oleh (Hidayati & Hermawan, 2021) merupakan analisis yang membandingkan dua metode pengukuran jarak, yaitu *Euclidean* dan *Manhattan*, untuk mengevaluasi kinerja algoritma *K-Nearest Neighbors* (K-NN) dalam mengklasifikasikan kelulusan siswa. Tujuan utama dari penelitian ini adalah untuk menggunakan algoritma *K-Nearest Neighbor* (K-NN), menggabungkan metode pengukuran jarak yang beragam, untuk klasifikasi yang tepat dari hasil kelulusan siswa. Dalam penelitian ini, sejumlah variabel digunakan untuk mengukur dan menentukan akurasi kelulusan siswa, baik yang lulus tepat waktu maupun yang tidak. Variabel-variabel tersebut meliputi jenis kelamin, jurusan, jumlah sks yang ditempuh pada semester pertama, semester kedua, dan semester III, indeks prestasi kumulatif setiap semester, dan usia mahasiswa. Semua variabel ini memainkan peran penting dalam memahami faktor-faktor yang berkontribusi terhadap kelulusan siswa. Hasil tersebut diperoleh setelah melakukan serangkaian pengujian menggunakan sampel data yang terdiri dari 380 data pelatihan dan 163 data uji. Temuan menunjukkan bahwa sistem mencapai akurasi tertinggi pada nilai $K=7$, menunjukkan jumlah tetangga terdekat yang digunakan dalam algoritma *K-Nearest Neighbor* (K-NN), dengan tingkat akurasi 85,28%. Dalam analisis yang lebih mendalam, ditemukan bahwa kedua pendekatan algoritmik, yaitu *Euclidean* dan *Manhattan*, memberikan hasil akurasi yang serupa. Peningkatan nilai K tidak berpengaruh signifikan terhadap akurasi keseluruhan.

Klasifikasi menggunakan algoritma *K-Nearest Neighbors* (K-NN) sering menjadi subjek persaingan dengan algoritma klasifikasi machine learning yang jauh lebih kompleks. Ini mencerminkan relevansi yang signifikan dalam penelitian yang berfokus pada efek penggunaan berbagai metrik jarak ketika membandingkan data biomedis. Penelitian yang dilakukan oleh (Ehsani & Drabløs, 2020). Memeriksa perbandingan antara metrik jarak yang umum digunakan dengan beberapa pendekatan yang lebih inovatif, termasuk ukuran jarak menggunakan Sobolev, Fisher, Manhattan, euclidean, chebysev, dan lain-lain. Metrik pengukuran jarak tertentu, seperti: Hassanat, Sobolev dan Manhattan telah menunjukkan kinerja yang kuat dalam konteks algoritma *K-Nearest Neighbor* (K-NN) di berbagai dataset. Sebaliknya, beberapa metrik jarak alternatif menunjukkan hasil yang menguntungkan pada kumpulan data tertentu tetapi menampilkan sensitivitas yang tinggi terhadap karakteristik yang melekat pada data klasifikasi. Oleh karena itu, menjadi penting untuk menilai kesesuaian metrik jarak pada dataset analog sebelum memulai proses klasifikasi untuk memastikan metrik yang paling pas untuk setiap kasus yang berbeda.

Penerapan sistem penanggulangan banjir di negara Bangladesh juga dapat dilaksanakan dengan menggunakan algoritma K-NN (Gauhar et al., 2021). Bangladesh adalah salah satu negara yang rawan banjir. Penerapan algoritma K-NN menggunakan korelasi yang berbeda dalam pemilihan fitur digunakan untuk memprediksi terjadinya banjir. Penelitian ini menggunakan dua metode perbandingan jarak yang berbeda, yaitu: euclidean dan Manhattan. Dataset yang digunakan dalam penelitian ini berasal dari Kaggle. Data pelatihan yang digunakan adalah 80% dan pengujian adalah 20%. Analisis hasil menunjukkan bahwa akurasi pengujian tinggi dengan rata-rata 94,91%. presisi 92,00% dan rata-rata recall 91,00% menggunakan model machine learning k-NN.

Algoritma K-NN merupakan pendekatan yang relevan dan berguna dalam implementasinya untuk menganalisis kasus-kasus medis seperti kanker usus besar atau kanker kolorektal (Pratiwi et al., 2019). Di Indonesia, kanker usus besar menempati urutan ketiga sebagai jenis kanker yang paling umum pada wanita dan kedua pada pria. Faktor risiko yang berkontribusi terhadap tingginya angka kasus kanker usus besar antara lain gaya hidup yang tidak sehat, seperti konsumsi serat yang rendah, kurangnya aktivitas fisik dan kurangnya kesadaran dalam melakukan deteksi dini. Penelitian yang dilakukan di bidang ini menggunakan desain sistem untuk menganalisis data patologi jaringan kanker usus besar, yang terdiri dari 198 data, dengan masing-masing jenis kanker seperti Kanker Limfoma, kanker karsinoma, dan kondisi usus besar yang sehat. Hasil dari penelitian ini adalah sistem pengolahan citra yang mampu mendeteksi dan mengklasifikasikan jenis kanker usus besar dengan tingkat akurasi yang tinggi, dengan tetap meminimalkan waktu komputasi. Penelitian ini juga mempertimbangkan penggunaan dua metode pengukuran jarak, yaitu Euclidean dan Minkowski untuk membandingkan hasil akurasi dalam berbagai skenario. Hasil penelitian menunjukkan bahwa penggunaan metrik jarak Minkowski menghasilkan akurasi tertinggi sebesar 68,52% ketika nilai parameter $K=1$ dan nilai $q=3$.

Perbandingan metode pengukuran jarak euclidean, minkowski, Manhattan, dan Chebyshev untuk mendapatkan hasil yang optimal menggunakan algoritma klasifikasi K-NN. Dataset yang digunakan dalam penelitian ini berasal dari repositori Kaggle. Dataset yang digunakan adalah dataset stroke yang berjumlah 5.110 data dengan dua kelas 0 (pasien yang menderita stroke) dan 1 (tidak menderita stroke). Langkah awal dalam penyelidikan ini melibatkan penggantian data yang hilang dan karakter dengan nilai "0" untuk memfasilitasi perhitungan jarak berikutnya. Setelah preprocessing data ini, dataset dipartisi menjadi dua subset, yaitu set pelatihan (terdiri dari 80% data) dan set pengujian (terdiri dari 20% sisanya). Perhitungan jarak kemudian dilakukan untuk mengukur kedekatan data pengujian dengan data pelatihan, menggunakan berbagai metrik jarak. Ini memfasilitasi penugasan label kelas baru ke data pengujian berdasarkan nilai K yang dipilih dalam model K-Nearest Neighbor (K-NN). Eksperimen dilakukan menggunakan bahasa pemrograman Python dalam lingkungan Google Colaboratory. Hasilnya menggarisbawahi pengaruh pemilihan metrik jarak pada akurasi model K-NN dalam mendeteksi penyakit stroke, dengan tingkat akurasi menunjukkan tren yang meningkat dengan nilai K yang lebih tinggi. Khususnya, metode pengukuran jarak Chebyshev muncul sebagai yang paling akurat, mencapai akurasi klasifikasi 96,03% pada nilai K 10 (Iswanto et al., 2021).

Dilakukan perbandingan pengukuran jarak menggunakan euclidean dan Manhattan untuk mencapai hasil optimasi atau nilai optimal dalam mencari jarak tetangga terdekat dengan (Lubis et al., 2020). Hasil penelitian ini menunjukkan perbedaan yang signifikan antara kedua metode pengukuran jarak tersebut. Jarak Euclidean, dengan tingkat kesamaan 80%, membutuhkan waktu 17 menit dan 45 detik dan menghasilkan 8 nilai kedekatan data. Di sisi lain, jarak Manhattan menghasilkan nilai kesamaan 81,3% dengan waktu komputasi 16 menit 11 detik, dan jumlah nilai kedekatan yang sama dengan jarak Hamming, yaitu 29. Hasil yang lebih tinggi dalam kesamaan data dicapai dengan metrik Hamming, meskipun

dengan waktu komputasi yang lebih singkat. Di sisi lain, jarak Euclidean menghasilkan nilai yang lebih rendah dalam hal kesamaan, sementara jarak Manhattan menghasilkan hasil yang berada di suatu tempat di tengah.

Penelitian ini bertujuan untuk menemukan dan mengevaluasi metode pengukuran jarak yang paling optimal dan efektif dalam konteks klasifikasi algoritma K-NN (K-Nearest Neighbors). Pengembangan dan pemilihan metode pengukuran jarak yang sesuai memiliki dampak signifikan terhadap hasil akurasi algoritma K-NN. Penelitian ini berdiri sebagai kontribusi yang signifikan terhadap kemajuan sistem komputerisasi untuk memprediksi penyakit gagal jantung, dengan fokus khusus pada peningkatan kualitas dan akurasi mereka. Temuan dan metodologi yang dieksplorasi dalam penelitian ini memiliki potensi untuk meningkatkan efektivitas model prediktif di bidang diagnosis penyakit jantung, sehingga berpotensi mengarah pada peningkatan perawatan pasien dan hasil klinis. Hasil penelitian ini diharapkan dapat memberikan kontribusi yang berharga dalam mendukung diagnosis dini penyakit gagal jantung, yang merupakan langkah penting dalam perawatan kesehatan. Diagnosis yang lebih cepat dan lebih akurat dapat memungkinkan intervensi dini dan perencanaan manajemen yang lebih baik untuk pasien yang berisiko gagal jantung. Ini tidak hanya berpotensi mengurangi dampak negatif penyakit, tetapi juga dapat secara signifikan meningkatkan kualitas hidup pasien.

1.2.1 DATASET DAN PELATIHAN DATA

Dataset yang bersumber dari Kaggle ini adalah kombinasi dari berbagai sumber data yang sudah tersedia. Dataset ini menggabungkan 5 sumber terbesar data penyakit jantung yang tersedia untuk tujuan penelitian ini bersumber dari: Cleveland (303 pengamatan), Hongaria (294 pengamatan), Swiss (123 pengamatan), Long Beach VA (200 pengamatan), dan Stalog (270 pengamatan). Berdasarkan 1190 dataset, 918 data pengamatan diselesaikan oleh kaggle. Dataset yang digunakan dalam penelitian ini diperoleh dari penyimpanan data online Kaggle dan dataset ini akan digunakan untuk mengembangkan model klasifikasi dengan algoritma K-NN. Dataset yang dipertimbangkan telah banyak digunakan dalam upaya penelitian sebelumnya. Ini terdiri dari total 918 contoh data, masing-masing ditandai dengan 12 atribut. Khususnya, himpunan data ini mencakup kombinasi atribut kategoris dan numerik. Atribut dalam dataset ini akan dijelaskan pada Tabel 1. Dalam studi ini, dataset akan dipartisi menjadi dua subset yang berbeda: set pelatihan yang terdiri dari 90% data dan set pengujian yang terdiri dari 10% sisanya. Subset data pelatihan dan pengujian mencakup atribut sampel dan label kelas yang sesuai. Himpunan data pelatihan, yang merupakan 90% dari total data, terdiri dari 826 instans, sedangkan himpunan data pengujian, yang merupakan 10% dari total, mencakup 92 instans.

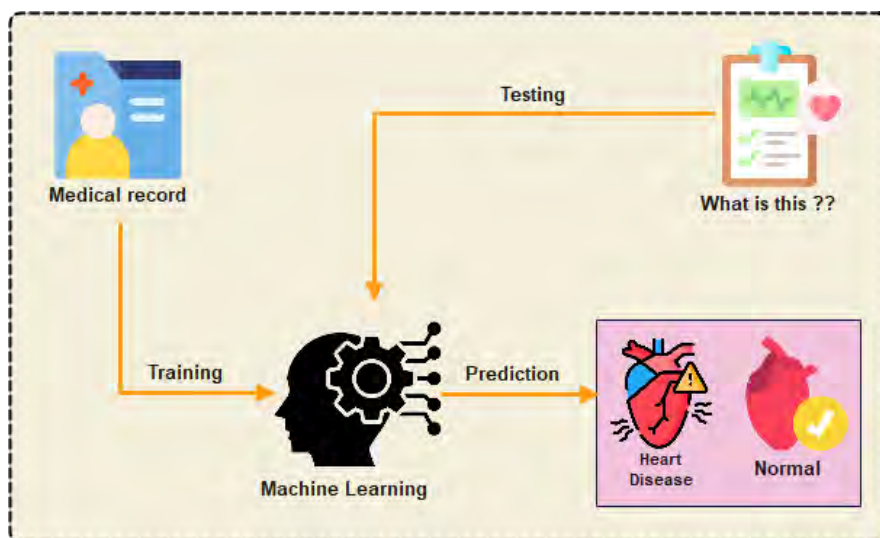
Tabel 1.1 Atribut dataset pada penelitian

<i>ID</i>	<i>Atribut</i>	<i>Deskripsi</i>
1	Age	Usia
2	Sex	M: Laki-laki. F: Perempuan
3	ChestPainType	TA: Angina khas. ATA: Angina atipikal. NAP: Nyeri non-angina. ASY: Tanpa gejala
4	RestingBP	mm/hg
5	Cholesterol	mm/dl
6	FastingBS	1: jika FastingBS > 120 mg / dl. 0: jika tidak
7	RestingECG	Normal: Normal. ST: memiliki kelainan gelombang ST-T (inversi gelombang T dan / atau elevasi ST atau depresi > 0,05 mV). LVH: menunjukkan hipertrofi

ventrikel kiri yang mungkin atau pasti menurut kriteria Estes

8	MaxHR	Nilai numerik antara 60 dan 202
9	ExerciseAngina	Y: Iya. N: Tidak
10	Oldpeak	ST [Nilai numerik diukur dalam depresi]
11	ST_Slope	Naik: naik. Datar: datar. Bawah: downsloping
12	HeartDisease	1: penyakit jantung. 0: Normal

Tabel 1 berisi informasi medis yang berkaitan dengan penyakit jantung. Data tersebut meliputi atribut seperti usia, jenis kelamin, jenis nyeri dada yang dialami pasien, tekanan darah istirahat, kadar kolesterol, gula darah puasa, hasil elektrokardiogram, denyut jantung maksimal, adanya angina saat berolahraga, nilai depresi segmen ST, kemiringan segmen ST, dan status penyakit jantung. Misalnya, atribut "Jenis Nyeri Dada" menggambarkan jenis nyeri dada yang mungkin dirasakan pasien, sedangkan "Gula Darah Puasa" menunjukkan apakah pasien memiliki gula darah puasa tinggi atau tidak. Tabel ini memainkan peran penting dalam analisis data kesehatan, membantu para peneliti untuk memahami korelasi antara faktor-faktor ini dan penyakit jantung, serta dalam pengembangan model prediktif untuk diagnosis dan manajemen penyakit jantung. Data ini penting dalam upaya perawatan kesehatan dan penelitian kardiologi.

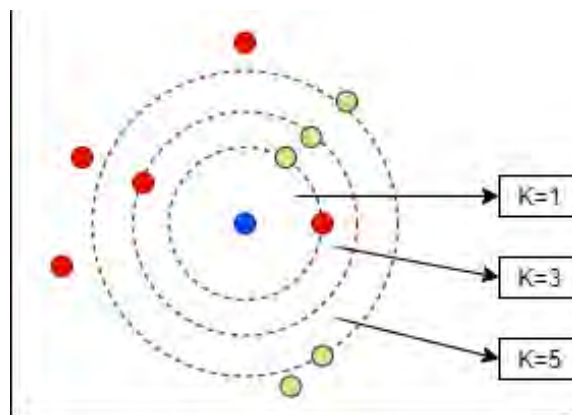


Gambar 1.1 Proses Pelatihan dan Pengujian Dataset

Pada Gambar 1, adalah representasi visual dari proses pelatihan dan pengujian dalam konteks machine learning. Proses ini adalah tahap kunci dalam pengembangan model machine learning yang efektif. Gambar 1 mengilustrasikan langkah-langkah kompleks yang dimulai dengan pengumpulan data pelatihan. Data pelatihan ini akan digunakan untuk melatih model machine learning, yang mempelajari pola dan informasi dari data. Setelah proses pelatihan, model diuji menggunakan data pengujian yang berbeda. Tujuan dari tahap pengujian ini adalah untuk mengukur sejauh mana model mampu membuat prediksi akurat pada data yang belum pernah terlihat sebelumnya. Gambar 1 memberikan visual yang berguna tentang bagaimana machine learning beroperasi. Proses ini memainkan peran penting dalam berbagai aplikasi machine learning, mulai dari pengenalan pola hingga klasifikasi. Penelitian ini menggunakan 90% data pelatihan dan 10% data pengujian.

1.2.2 K-NEAREST NEIGHBORS

Algoritma klasifikasi ini digunakan untuk mengklasifikasikan kategori atau target data berdasarkan tetangga terdekatnya (Abu Alfeilat et al., 2019). K-NN adalah algoritma yang dapat mengklasifikasikan data baru berdasarkan kesamaan antara tetangga terdekatnya. Tetangga terdekat adalah anggota kelas yang telah ditentukan oleh label. Jarak Euclidean sering digunakan untuk pengukuran sebagai matriks jarak (Patel & Upadhyay, 2020). Gambar 2 menggambarkan proses klasifikasi yang dilakukan dengan menggunakan algoritma K-NN. Ketika nilai $k = 1$, objek akan diprediksi masuk ke kelas merah karena hanya memiliki satu tetangga terdekat yang berada di kelas merah. Kemudian, dengan nilai $k = 3$, objek diprediksi akan masuk ke kelas merah. Perhitungan ini dilakukan dengan melihat tiga tetangga terdekat dari objek tersebut. Dan dari tiga tetangga, ada dua yang berada di kelas merah, sementara satu di kelas hijau. Selanjutnya, ketika nilai $k = 5$, objek diprediksi berada di kelas hijau. Dalam perhitungan ini, lima tetangga terdekat dari objek diambil. Dan dari lima tetangga, ada tiga yang berada di kelas hijau, sedangkan dua tetangga berada di kelas merah. Metode K-NN mempertimbangkan jumlah tetangga terdekat yang akan digunakan dalam proses klasifikasi. Dengan mengubah nilai k , kita dapat mengamati perbedaan prediksi kelas untuk objek tertentu berdasarkan mayoritas tetangga yang termasuk dalam kelas tertentu.



Gambar 1.2 Ilustrasi K-NN

Fungsi jarak dalam algoritma K-NN sering disebut sebagai matriks jarak atau fungsi jarak. Ini mengacu pada bagaimana mengukur jarak antara titik data di ruang fitur yang merupakan kunci awal dalam menentukan algoritma tetangga terdekat.

1.2.3 JARAK PENGUKURAN

Mengukur jarak antara X dan Y didalam ruang menggunakan berbagai macam fungsi pengukuran jarak. namun euclidean lebih sering digunakan pada penelitian (Abu Alfeilat et al., 2019). Jarak Euclidean merupakan perhitungan antara dua buah titik. Euclidean berkaitan dengan rumus Teorema Phytagoras. yaitu dengan perhitungan akar kuadrat. Euclidean berhubungan dengan Teorema Phytagoras yang biasanya diterapkan pada dimensi yang lebih tinggi (Tabaghi et al., 2020). Euclidean adalah fungsi heuristik yang diperoleh dari jarak langsung seperti untuk mendapatkan nilai dari panjang garis diagonal pada segitiga (Zubaedah et al., 2020). Misalnya x dan y diwakili oleh vektor fitur $x = (x_1, x_2, \dots, x_n)$ dan

$y = (y_1, y_2, \dots, y_n)$. dimana n merupakan dimensi ruang fitur. Untuk menghitung jarak x dan y menggunakan pengukuran jarak euclidean dapat dilihat pada persamaan (1.1)

$$\text{Euclidean } (x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1.1)$$

Fungsi jarak yang lain adalah Manhattan. Jarak Manhattan biasanya disebut juga sebagai city-block dimana jarak dari suatu titik ke titik yang lain pada suatu sistem koordinat kartesius yang menyusuri bagian vertical dan horizontal tanpa pernah kembali (Haviluddin et al., 2020). Sederhananya, perhitungan jarak dilakukan dengan mengambil nilai absolut atau nilai mutlak (Lubis et al., 2020). Penamaan jarak ini berasal dari tata letak jalan dipulau Manhattan yang berbentuk segi empat. Untuk menghitung jarak x dan y menggunakan pengukuran jarak manhattan dapat dilihat pada persamaan (1.2)

$$\text{Manhattan } (x, y) = \sum |x_i - y_i| \quad (1.2)$$

1.2.4 CONFUSION MATRIX

Confusion matrix berfungsi untuk mengevaluasi performa model klasifikasi dalam machine learning. Matriks ini memberikan gambaran tentang sejauh mana model mampu mengklasifikasikan data dengan benar dan seberapa baik dapat mengidentifikasi kelas positif atau negatif (SAPUTRA et al., 2020).

Akurasi adalah salah satu metrik evaluasi yang penting dalam pemodelan klasifikasi dalam machine learning. Metrik ini mengukur sejauh mana model klasifikasi dapat memprediksi kelas dengan benar dari keseluruhan data yang diuji. Akurasi menggambarkan persentase prediksi yang benar atau tepat dari seluruh data uji yang digunakan untuk menguji model. Dalam rumus matematisnya, akurasi dihitung dengan membagi jumlah prediksi benar (True Positives dan True Negatives) dengan total jumlah data uji. Meskipun akurasi memberikan pandangan yang kasar tentang kinerja model, terutama ketika kelas positif dan negatif seimbang, ini bukanlah satu-satunya metrik yang relevan. Persamaan dari accuracy dapat dilihat pada persamaan rumus (1.3)

$$\text{Accuracy} = \frac{TP+TN}{TP+FN+FP+TN} \quad (1.3)$$

Precision adalah metrik evaluasi yang sangat relevan dalam penilaian kinerja model klasifikasi dalam machine learning. Metrik ini fokus pada sejauh mana model mampu memberikan prediksi yang benar untuk kelas positif atau hasil yang positif. Presisi dihitung dengan membagi jumlah True Positives (prediksi benar untuk kelas positif) dengan jumlah data yang diprediksi sebagai positif, yang mencakup True Positives dan False Positives (prediksi salah untuk kelas positif). Presisi memberikan gambaran tentang seberapa akurat model dalam mengklasifikasikan data sebagai kelas positif. Metrik ini sangat penting dalam situasi di mana konsekuensi dari kesalahan positif (False Positives) tinggi, seperti dalam deteksi penyakit atau ancaman keamanan. Persamaan dari precision dapat dilihat pada persamaan rumus (1.4)

$$\text{Precision} = \frac{TP}{TP+FP} \quad (1.4)$$

Recall disebut juga dengan True Positive Rate atau sensitivitas penting yang digunakan dalam analisis confusion matrix dalam konteks klasifikasi dalam machine

learning. Recall mengukur sejauh mana model klasifikasi mampu mengidentifikasi dan memprediksi dengan benar data yang sebenarnya masuk ke dalam kelas positif. Metrik ini dihitung dengan membagi jumlah True Positives (prediksi yang benar untuk kelas positif) dengan jumlah data sebenarnya yang masuk ke dalam kelas positif, yang mencakup True Positives dan False Negatives (data yang salah diprediksi sebagai kelas negatif). Recall sangat relevan dalam situasi penting untuk menghindari kesalahan klasifikasi yang berpotensi fatal, seperti dalam diagnosis medis. Persamaan rumus dari recall dapat dilihat pada persamaan (1.5)

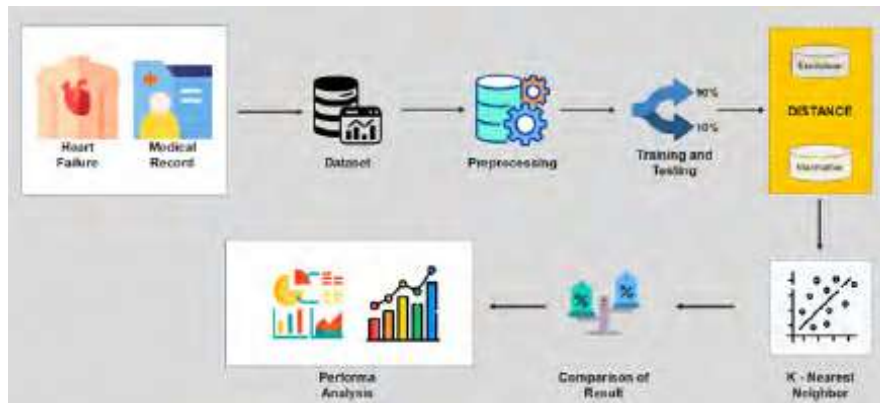
$$Recall = \frac{TP}{TP+FN} \quad (1.5)$$

F1-Score adalah metrik evaluasi yang merupakan rata-rata dari precision dan recall dalam konteks analisis confusion matrix dalam machine learning. Metrik ini dirancang untuk memberikan gambaran yang seimbang antara kemampuan model dalam memberikan prediksi yang benar (precision) dan kemampuan model dalam mengidentifikasi seluruh data positif yang sebenarnya (recall). F1-Score sangat berguna dalam situasi di mana keseimbangan antara presisi dan recall penting, dan menghindari kesalahan yang berpotensi mahal. F1-Score dihitung dengan menggunakan rumus pada persamaan (1.6)

$$f1 - score = \frac{2(precision+recall)}{precision+recall} \quad (1.6)$$

1.3 METODOLOGI PENELITIAN

Penelitian ini memerlukan serangkaian tahapan yang terstruktur dengan cermat, dirancang secara sistematis untuk mengoptimalkan hasil akurasi dalam domain machine learning. Penelitian dimulai dengan akuisisi dan penggabungan beragam dataset dari Kaggle.com, mengkonsolidasikannya ke dalam dataset terpadu yang disesuaikan untuk tujuan penelitian. Setelah pemilihan dataset, fase prapemrosesan yang ketat dijalankan untuk meningkatkan kualitas data dan menyiapkannya untuk analisis mendalam. Data kemudian dipartisi secara ketat menjadi subset pelatihan dan pengujian, mengikuti rasio split 80/20. Sebuah pertimbangan rumit berikut, yang bertujuan untuk menentukan metodologi pengukuran jarak yang paling cocok untuk digunakan bersama dengan algoritma K-NN. Studi ini melanjutkan untuk meneliti dengan cermat hasil pengukuran jarak, yang dilakukan melalui algoritma K-NN, untuk menilai kemanjurannya. Selanjutnya, analisis komparatif yang ketat dilakukan untuk membedakan perbedaan dan manfaat dari dua metode pengukuran jarak yang berbeda. Akhirnya, penelitian ini memuncak dalam evaluasi komprehensif kinerja yang dicapai melalui perbandingan ini, memberikan wawasan berharga tentang implikasi praktis dari teknik pengukuran jarak yang dipilih. Representasi grafis terperinci dan penjelasan lebih lanjut dari tahap-tahap ini diilustrasikan pada Gambar 1.3



Gambar 1.3 Kerangka penelitian

Penjelasan Gambar 1.3 Kerangka Penelitian, yaitu: **Tahap pertama** adalah mencari dataset gagal jantung di Kaggle.com untuk penelitian. **Tahap kedua** meliputi aktivitas prapemrosesan data, khususnya: pembersihan data, transformasi data, dan normalisasi data. Dalam konteks penelitian ini, pembersihan data melibatkan pemeriksaan ada atau tidak adanya nilai yang hilang dalam dataset (Olisah et al., 2022), lalu setelah memeriksa nilai yang hilang, data diubah. Transformasi data melibatkan konversi pengukuran data dari satu skala ke skala lainnya. Dalam kasus di mana data kategoris, itu diubah menjadi data numerik (Olisah et al., 2022). Setelah melakukan proses transformasi data, proses selanjutnya adalah normalisasi data. Normalisasi data dilakukan dengan menggunakan normalisasi min-max. Normalisasi data berfungsi untuk membantu proses pelatihan tentang data (Henderi, 2021). Data yang memiliki rentang yang cukup besar antar variabel numerik akan disejajarkan menjadi rentang data yang memiliki skala kecil, misalnya rentang data menggunakan normalisasi Min-Max akan memiliki rentang data 0-1 (Henderi, 2021). **Tahap ketiga** adalah data terpisah. Pemisahan data berfungsi untuk memisahkan himpunan data menjadi dua subset yang berbeda, khususnya data pelatihan dan data pengujian. Penelitian ini menggunakan 90% data pelatihan dan 10% data pengujian. Data split menggunakan fungsi acak, di mana fungsi ini membagi data pelatihan dan data pengujian secara acak. **Tahap keempat** adalah proses perhitungan jarak yang akan digunakan dalam metode K-NN. Perhitungan jarak dalam metode K-NN dilakukan untuk mengukur seberapa dekat atau seberapa jauh titik data yang akan diprediksi dari titik data lain dalam dataset. Perhitungan jarak dilakukan dengan menggunakan dua metode, yaitu: Euclidean dan Manhattan. Penelitian ini membandingkan dua metode perhitungan jarak untuk menemukan metode mana yang menghasilkan akurasi terbaik untuk metode K-NN saat menggunakan dataset ini. **Tahap kelima** adalah proses perhitungan K-NN setelah mendapatkan hasil perhitungan jarak data yang diperoleh. **Tahap keenam** merupakan perbandingan hasil akurasi yang diperoleh setelah melalui proses perhitungan metode K-NN. **Tahap terakhir** adalah penentuan hasil akurasi terbaik dari perbandingan proses sebelumnya.

1.4 HASIL PENELITIAN

Bagian ini akan membahas hasil penelitian yang telah dilakukan. Confusion matrix digunakan untuk mengukur kinerja model klasifikasi dalam machine learning. Matriks ini berguna untuk menganalisis sejauh mana model mampu mengklasifikasikan data dengan benar dan untuk memahami kesalahan yang dibuat oleh model. Confusion matrix umumnya digunakan untuk klasifikasi biner (dua kelas) atau klasifikasi multiclass (lebih dari satu kelas).

Tabel 1.2 adalah deskripsi isi dari beberapa dataset yang akan digunakan dalam penelitian. di mana himpunan data ini belum diproses atau diproses. Penjelasan mengenai informasi yang terdapat pada atribut dapat dilihat pada Tabel 1.1

Tabel 1.2 Dataset gagal jantung

<i>Age</i>	<i>Sex</i>	<i>CP</i>	<i>RBP</i>	<i>Cho</i>	<i>FBS</i>	<i>RECG</i>	<i>MaxHR</i>	<i>ExAngina</i>	<i>Oldpeak</i>	<i>St_Slope</i>
40	M	ATA	140	289	0	Normal	172	N	0	Up
49	F	NAP	160	180	0	Normal	156	N	1	Flat
37	M	ATA	130	283	0	ST	98	N	0	Up
48	F	ASY	138	214	0	Normal	108	Y	1.5	Flat
...

1.4.1 DATA PREPROCESSING

Preprocessing adalah langkah pertama sebelum proses penelitian. Fungsi preprocessing untuk mengubah data mentah menjadi data yang siap untuk proses penelitian (Henderi, 2021; Misra & Yadav, 2019). Preprocessing dalam penelitian ini menggunakan tiga tahap. yaitu: memeriksa nilai yang hilang dalam himpunan data. transformasi data. dan akhirnya proses normalisasi pada data. Proses ini dilakukan untuk memudahkan algoritma bekerja dengan baik untuk mendapatkan hasil yang maksimal. Tabel 2 mewakili kumpulan data yang belum mengalami prapemrosesan dan dalam bentuk mentah dan tidak diproses.

1.4.2 DATA TRANSFOFMATION

Dataset masih mengandung atribut yang non-numerik seperti yang menyatakan kategori. Data dari atribut seperti ini menyulitkan proses pelatihan data sehingga harus diolah terlebih dahulu. Hal yang perlu dilakukan adalah mengubah dataset yang memiliki atribut seperti kategoris itu menjadi atribut numerik seperti terlampir pada Tabel 1.3. Model akan lebih memahami dataset yang telah dikonversi ke numerik. Tabel 1.4 adalah hasil dari dataset yang telah diubah menjadi data numerik.

Tabel 1.3 Atribut yang memerlukan transformasi data

<i>ID</i>	<i>Atribut</i>	<i>Deskripsi</i>
1	Sex	M (Male) = 0; Female (F) = 1
2	ChestPainType	ASY (Asymptomatic) = 0; ATA (Atypical Angina) = 1; NAP (Non-Anginal Pain) = 2; TA (Typical Angina) = 3
3	RestingECG	Normal = 0; ST = 1; LVH = 2
4	ExerciseAngina	No (N) = 0; Yes (Y) = 1
5	St Slope	Down = 0; Flat = 1; Up = 2

Tabel 1.4 Dataset setelah transformasi data

<i>Age</i>	<i>Sex</i>	<i>CP</i>	<i>RBP</i>	<i>Cho</i>	<i>FBS</i>	<i>RECG</i>	<i>MaxHR</i>	<i>ExAngina</i>	<i>Oldpeak</i>	<i>St_Slope</i>
40	0	1	140	289	0	0	172	0	0	2
49	1	2	160	180	0	0	156	0	1	1
37	0	1	130	283	0	1	98	0	0	2
48	1	0	138	214	0	0	108	1	1,5	1
54	1	2	150	195	0	1	122	0	0	2
...

1.4.3 DATA NORMALIZATION

Proses ini adalah mengubah skala nilai pada dataset ke dalam rentang yang seragam sehingga setiap variabel memiliki proporsi yang seimbang. Normalisasi yang dilakukan pada penelitian ini menggunakan normalisasi Min-Max. Normalisasi Min-Max berfungsi mengubah data ke dalam rentang 0 sampai dengan 1. Metode ini digunakan saat atribut memiliki jarak yang berbeda-beda dan memiliki rentang nilai cukup jauh. Persamaan metode Min-Max dapat dilihat pada persamaan (1.7)

$$x_{new} = \frac{x_{old} - x_{min}}{x_{max} - x_{min}} \quad (1.7)$$

x_{old} merupakan nilai data atribut yang akan dinormalkan. x_{min} merupakan nilai minimum atribut tersebut pada dataset dan x_{max} merupakan nilai maksimumnya. Normalisasi min-max cukup sering digunakan pada berbagai macam penelitian terutama penelitian yang berkaitan dengan pengolahan data. Teknik normalisasi pada penelitian ini berguna untuk menyetarakan atribut numerik yang ada di dataset ini agar atribut numerik tidak memiliki rentang yang jauh. Normalisasi Min-Max memiliki rentang dari 0 sampai 1. Jika pada dataset memiliki nilai yang jauh lebih kecil dibandingkan dengan nilai yang lain maka teknik normalisasi perlu dilakukan agar nilai atribut yang lebih besar tidak mendominasi atribut yang lain. Table hasil normalisasi yang dilakukan dapat dilihat pada Table 1.5.

Tabel 1.5 Hasil dari normalisasi data

Age	Sex	CP	RBP	Cho	FBS	RECG	MaxHR	ExAngina	Oldpeak	St Slope
0.244	0	0.333	0.7	0.479	0	0	0.788	0	0.295	1
0.428	1	0.667	0.8	0.298	0	0	0.6760	0	0.409	0.5
0.183	0	0.333	0.65	0.469	0	0.5	0.267	0	0.295	1
0.408	1	0	0.69	0.354	0	0	0.338	1	0.465	0.5
0.530	0	0.667	0.75	0.323	0	0	0.436	0	0.295	1
...

1.4.4 PENGUKURAN JARAK EUCLIDEAN

Jarak *euclidean* sangat umum digunakan pada penelitian termasuk digunakan dalam algoritma K-NN. Persamaan pengukuran jarak euclidean dapat dilihat pada persamaan (1.1) Berikut contoh perhitungan jarak pengukuran menggunakan *euclidean*.

$$d1 = \sqrt{(0.551 - 0.530)^2 + (1 - 1)^2 + (0 - 0)^2 + (0.575 - 0.635)^2 + (0 - 0.552)^2 + (1 - 1)^2 + (0.5 - 0.5)^2 + (0.669 - 0.661)^2 + (0 - 0)^2 + (0.306 - 0.295)^2 + (0.5 - 0.5)^2} = 0.556$$

$$d2 = \sqrt{(0.551 - 0.448)^2 + (1 - 1)^2 + (0 - 0)^2 + (0.575 - 0.8)^2 + (0 - 0)^2 + (1 - 1)^2 + (0.5 - 0)^2 + (0.669 - 0.352)^2 + (0 - 0)^2 + (0.306 - 0.295)^2 + (0.5 - 0.5)^2} = 0.641$$

$$d3 = \sqrt{(0.551 - 0.408)^2 + (1 - 1)^2 + (0 - 0.333)^2 + (0.575 - 0.6)^2 + (0 - 0.293)^2 + (1 - 1)^2 + (0.5 - 0.5)^2 + (0.669 - 0.619)^2 + (0 - 0)^2 + (0.306 - 0.295)^2 + (0.5 - 1)^2} = 0.686$$

$$d4 = \sqrt{(0.551 - 0.775)^2 + (1 - 1)^2 + (0 - 0)^2 + (0.575 - 0.775)^2 + (0 - 0)^2 + (1 - 1)^2 + (0.5 - 0)^2 + (0.669 - 0.211)^2 + (0 - 0)^2 + (0.306 - 0.295)^2 + (0.5 - 0.5)^2} = 0.741$$

$$d5 = \sqrt{(0.551 - 0.734)^2 + (1 - 1)^2 + (0 - 0)^2 + (0.575 - 0.475)^2 + (0 - 0)^2 + (1 - 1)^2 + (0.5 - 0)^2 + (0.669 - 0.598)^2 + (0 - 0)^2 + (0.306 - 0.420)^2 + (0.5 - 0)^2} = 0.749$$

Berdasarkan hasil perhitungan menggunakan pengukuran jarak euclidean, maka didapatkan hasil keseluruhan yang telah dilampirkan pada Tabel 1.6

Tabel 1.6 Perhitungan pengukuran jarak *euclidean*

Age	Sex	CP	RBP	Cho	FBS	RECG	MaxHR	ExAngina	Oldpeak	St_Slope	Heart Disease	ED
0.530	1	0	0.635	0.552	1	0.5	0.661	0	0.295	0.5	1	0.556
0.448	1	0	0.8	0	1	0	0.352	0	0.295	0.5	1	0.641
0.408	1	0.333	0.6	0.293	1	0.5	0.619	0	0.295	1	0	0.686
0.775	1	0	0.775	0	1	0	0.211	0	0.295	0.5	1	0.741
0.734	1	0	0.475	0	1	0	0.598	0	0.420	0	1	0.749
...

1.4.4 PENGUKURAN JARAK MANHATTAN

Manhattan distance merupakan perhitungan jarak yang digunakan untuk mengukur dua titik dalam ruang geometri. Metode ini juga digunakan dalam algoritma K-NN untuk mengukur jarak antara titik data dalam proses pemilihan tetangga terdekat. Persamaan pengukuran jarak manhattan dapat dilihat pada persamaan (1.2), Berikut contoh perhitungan jarak berdasarkan pengukuran menggunakan *Manhattan*.

$$d1 = |0.551 - 0.530| + |1 - 1| + |0 - 0| + |0.575 - 0.635| + |0 - 0.552| + |1 - 1| + |0.5 - 0.5| + |0.669 - 0.661| + |0 - 0| + |0.306 - 0.295| + |0.5 - 0.5| = 0.651$$

$$d2 = |0.551 - 0.448| + |1 - 1| + |0 - 0| + |0.575 - 0.8| + |0 - 0| + |1 - 1| + |0.5 - 0| + |0.669 - 0.352| + |0 - 0| + |0.306 - 0.295| + |0.5 - 0.5| = 1.155$$

$$d3 = |0.551 - 0.408| + |1 - 1| + |0 - 0.333| + |0.575 - 0.6| + |0 - 0.293| + |1 - 1| + |0.5 - 0.5| + |0.669 - 0.619| + |0 - 0| + |0.306 - 0.295| + |0.5 - 1| = 1.355$$

$$d4 = |0.551 - 0.775| + |1 - 1| + |0 - 0| + |0.575 - 0.775| + |0 - 0| + |1 - 1| + |0.5 - 0| + |0.669 - 0.211| + |0 - 0| + |0.306 - 0.295| + |0.5 - 0.5| = 1.393$$

$$d5 = |0.551 - 0.734| + |1 - 1| + |0 - 0| + |0.575 - 0.475| + |0 - 0| + |1 - 1| + |0.5 - 0| + |0.669 - 0.598| + |0 - 0| + |0.306 - 0.420| + |0.5 - 0| = 1.467$$

Hasil perhitungan jarak menggunakan *manhattan* untuk hasil keseluruhan data ditunjukkan pada Tabel 1.7

Tabel 1.7 Perhitungan pengukuran jarak *manhattan*

Age	Sex	CP	RBP	Cho	FBS	RECG	MaxHR	ExAngina	Oldpeak	St_Slope	Heart Disease	MD
0.530	1	0	0.635	0.552	1	0.5	0.661	0	0.295	0.5	1	0.651
0.448	1	0	0.8	0	1	0	0.352	0	0.295	0.5	1	1.155
0.408	1	0.333	0.6	0.293	1	0.5	0.619	0	0.295	1	0	1.355
0.775	1	0	0.775	0	1	0	0.211	0	0.295	0.5	1	1.393
0.734	1	0	0.475	0	1	0	0.598	0	0.420	0	1	1.467
...

1.4.5 HASIL PERHITUNGAN K-NEAREST NEIGHBORS

Algoritma *K-Nearest Neighbors* (K-NN) adalah metode dalam *machine learning* yang memerlukan penentuan parameter k. yaitu jumlah tetangga terdekat yang akan digunakan dalam proses klasifikasi. Proses penentuan nilai k terbaik melibatkan perhitungan jarak antara data yang akan diklasifikasikan dengan data pelatihan yang telah ada. Metode ini

memerlukan pemilihan nilai k yang optimal untuk menghasilkan hasil yang paling. Penentuan nilai k yang tepat adalah langkah kritis dalam penggunaan algoritma K-NN dan dapat mempengaruhi tingkat keakuratan serta generalisasi model tersebut. Berdasarkan Table 1.6 dan Table 1.7 hasil perhitungan jarak menggunakan pengukuran jarak *euclidean* dan *Manhattan* sudah didapatkan.

Hasil dari nilai $k=3$ didapat berdasarkan pengukuran jarak *euclidean* yang mempunyai jarak terkecil terhadap data *training* dan data *testing*. Menentukan nilai $k=3$ untuk pengukuran jarak menggunakan *euclidean* dapat dilihat pada Table 1.8

Tabel 1.8 Keterangan pengukuran jarak *euclidean*

No	Class	ED
1	1	0.556
2	1	0.641
3	0	0.686
4	1	0.741
5	1	0.749
...

Menentukan nilai $k=3$ menggunakan perhitungan jarak *Manhattan* didapatkan dari hasil tetangga terdekat berdasarkan urutan jarak yang terkecil dimana pada data ke-1 bernilai 1, data ke-2 bernilai 1 dan data ke-3 bernilai 0 maka hasil dari $k=3$ adalah 1 karena nilai *class* yang diambil merupakan *class* mayoritas. Setelah mendapatkan hasil $k=3$ adalah 0, maka seluruh data uji yang sudah diprediksi akan dihitung nilai akurasi untuk mendapatkan evaluasi performa dari model klasifikasi.

Pengujian akurasi dapat dihitung menggunakan persamaan (1.3). Berikut contoh perhitungan akurasi terhadap $k=3$. Nilai TP = 47, TN=31, FP=9, dan FN=5

$$Accuracy = \frac{47+31}{47+31+9+5} = 84.78\%$$

Selanjutnya, menghitung nilai dari precision menggunakan persamaan rumus (1.4)

$$Precision = \frac{47}{47+9} = 83.93$$

Selanjutnya, menghitung nilai dari recall menggunakan persamaan rumus (1.5)

$$Recall = \frac{47}{47+5} = 90.38$$

Tahapan terakhir, menghitung f1-score menggunakan persamaan rumus (1.6)

$$Recall = \frac{2(83.93+90.38)}{83.93+90.38} = 87.04$$

Hasil dari nilai $k=5$ didapat berdasarkan pengukuran jarak *manhattan* yang mempunyai jarak terkecil terhadap data *training* dan data *testing*. Menentukan nilai $k=5$ untuk pengukuran jarak menggunakan *manhattan* dapat dilihat pada Table 1.9

Tabel 1.9 Keterangan pengukuran jarak *manhattan*

No	Class	MD
----	-------	----

1	1	0.651
2	1	1.155
3	0	1.355
4	1	1.393
5	1	1.467
...

Menentukan nilai $k=5$ menggunakan perhitungan jarak *manhattan* didapatkan dari hasil tetangga terdekat yang ada pada data ke-1 yang bernilai 1, data ke-2 yang bernilai 1, data ke-3 yang bernilai 0, data ke-4 yang bernilai 1 dan data ke-5 bernilai 1 maka hasil dari $k=5$ adalah 1 karena nilai class yang diambil mayoritasnya adalah 1. Setelah mendapatkan hasil $k=5$ adalah 1, maka seluruh data uji yang sudah diprediksi akan dihitung nilai akurasi untuk mendapatkan evaluasi performa dari model klasifikasi.

Pengujian akurasi dapat dihitung menggunakan persamaan (1.3). Berikut contoh perhitungan akurasi terhadap $k=3$. Nilai TP = 47, TN=31, FP=9, dan FN=5

$$Accuracy = \frac{49+32}{49+32+3+8} = 88.04\%$$

Selanjutnya, menghitung nilai dari precision menggunakan persamaan rumus (1.4)

$$Precision = \frac{49}{47+8} = 87.27$$

Selanjutnya, menghitung nilai dari recall menggunakan persamaan rumus (1.5)

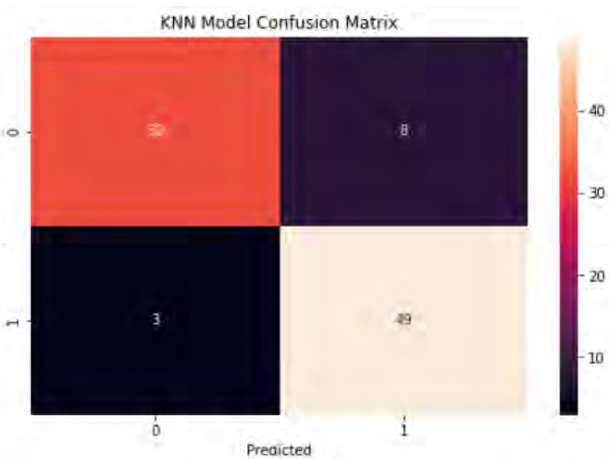
$$Recall = \frac{49}{49+3} = 92.31$$

Tahapan terakhir, menghitung f1-score menggunakan persamaan rumus (1.6)

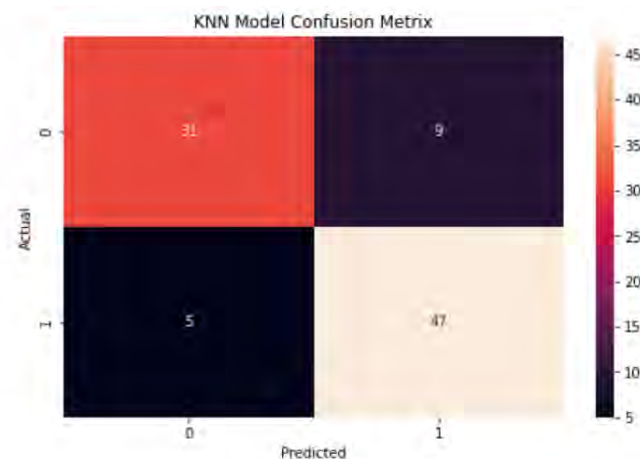
$$Recall = \frac{2(87.27+92.31)}{87.27+92.31} = 89.72$$

1.4.6 ANALISIS CONFUSION MATRIX

Confusion matrix digunakan untuk menganalisis hasil prediksi yang benar dan salah dari model K-NN. Kemudian hasil prediksi dibandingkan dengan hasil aktual. Evaluasi kinerja klasifikasi gagal jantung dilakukan melalui pemanfaatan *Confusion matrix*. Gambar 1.4 mengilustrasikan model yang mengkategorikan 92 contoh data pengujian menggunakan algoritma *K-Nearest Neighbors* (K-NN) bersama dengan metode pengukuran jarak *Manhattan*. Gambar 1.5 mewakili model yang melakukan klasifikasi 92 contoh data pengujian menggunakan algoritma *K-Nearest Neighbor* (K-NN) dengan metode pengukuran jarak *Euclidean*. *Confusion matrix* menggunakan perhitungan jarak *Manhattan* mendapatkan hasil TP [Prediksi 1, Aktual 1] = 49, TN [Prediksi 0, Aktual 0] = 32, FP [Prediksi 1, Aktual 0] = 8, dan FN [Prediksi 0, Aktual 1] = 3. *Confusion matrix* yang lebih rinci dapat dilihat pada Gambar 1.4 Sedangkan *Confusion matrix* yang menggunakan perhitungan jarak *euclidean* mendapatkan hasil TP [Prediksi 1, Aktual 1] = 47, TN [Prediksi 0, Aktual 0] = 31, FP [Prediksi 1, Aktual 0] = 9, dan FN [Prediksi 0, Aktual 1] = 5, *Confusion matrix* yang lebih rinci dapat dilihat pada Gambar 1.5

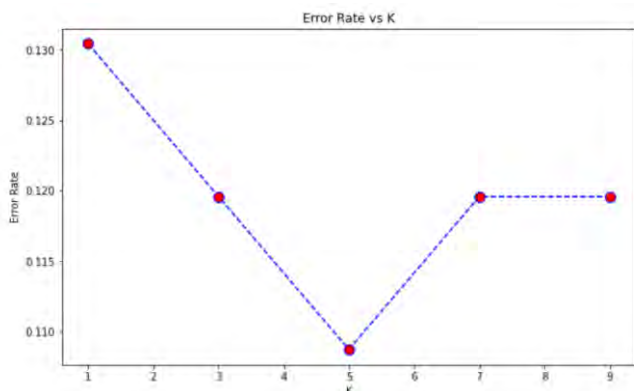


Gambar 1.4 Confusion matrix menggunakan Manhattan dengan k = 3




Gambar 1.1 Confusion matrix menggunakan Euclidean dengan k = 3

Jika dilihat dari confusion matrix yang ada pada Gambar 1.4 dan Gambar 1.5 memiliki hasil yang berbeda dari pengujiannya. Confusion matrix dengan menggunakan pengukuran jarak Manhattan mendapatkan hasil TP atau jumlah data yang benar masuk ke dalam kelas positif dan diprediksi masuk ke dalam kelas positif berjumlah 49 data, sedangkan pada confusion matrix menggunakan pengukuran jarak euclidean mendapatkan hasil TP atau kelas yang diprediksi positif dan benar masuk ke dalam kelas positif berjumlah 47. Confusion matrix dengan menggunakan pengukuran jarak Manhattan mendapatkan hasil FP atau jumlah data yang masuk ke dalam kelas negatif tetapi salah diprediksi menjadi kelas positif lebih rendah dibandingkan dengan pengukuran jarak euclidean. Confusion matrix dengan menggunakan pengukuran jarak Manhattan mendapatkan hasil TN atau jumlah data yang benar masuk ke dalam kelas negatif dan diprediksi masuk ke dalam kelas negatif berjumlah 32 data, sedangkan pada confusion matrix menggunakan pengukuran jarak euclidean mendapatkan hasil TN atau kelas yang diprediksi negatif dan benar masuk ke dalam kelas negatif berjumlah 31. Kesalahan prediksi pada model juga dapat mempengaruhi kualitas model yang digunakan. Kesalahan prediksi atau yang disebut dengan error rate merupakan ukuran seberapa sering sebuah model membuat kesalahan dalam memprediksi kelas atau hasil yang benar. Error rate dapat dihitung dengan menghitung rasio antara jumlah kesalahan (false positif dan false negative) dan jumlah total prediksi. Secara umum, semakin rendah error rate maka semakin baik pula performa model. Error rate secara garis besar adalah perbandingan banyaknya unit data yang salah dengan jumlah keseluruhan unit data. Error rate dapat dilihat pada Gambar 1.6 dan Gambar 1.7



Gambar 1.6 Error Rate menggunakan pengukuran jarak Manhattan



Gambar 1.7 Error Rate menggunakan pengukuran jarak Euclidean

Jika dianalisis lebih rinci terhadap data yang disajikan pada Gambar 1.6 dapat dilihat bahwa model yang menggunakan metode pengukuran jarak Manhattan menunjukkan perubahan signifikan dalam kualitas prediksi dengan variasi nilai k. Pada nilai k=1, model menghasilkan error rate tertinggi sebesar 13.04. Namun, saat nilai k berubah menjadi k=5 terjadi penurunan error yang cukup drastis dalam error rate menjadi 10.87. Hal ini menandakan bahwa model cenderung lebih baik dalam memprediksi hasil dengan k=5 menggunakan pengukuran jarak Manhattan. Maka, dapat disimpulkan bahwa pengukuran jarak Manhattan memberikan hasil yang lebih akurat pada k=5.

Pada Gambar 1.7, model yang menggunakan metode pengukuran jarak euclidean menunjukkan pola yang sedikit berbeda. Pada nilai k=1, error rate mencapai puncak tertinggi sebesar 16.93 yang merupakan salah satu yang tertinggi dalam variasi nilai k. Namun, ketika nilai k divariasikan menjadi k=5, k=7 dan k=9, maka error rate tetap konstan pada 11.96. Hal ini menunjukkan bahwa dalam konteks pengukuran jarak euclidean peningkatan nilai k setelah nilai k=1 tidak memberikan perubahan yang signifikan dalam kualitas prediksi. Oleh karena itu, pada pengukuran jarak euclidean memiliki nilai k yang lebih ditinggi dianggap sebagai pilihan yang lebih efisien karena memberikan hasil prediksi yang setara dengan k=5, k=7 atau k=9 tanpa meningkatkan kompleksitas model secara berlebihan. Kesimpulan dari keseluruhan analisis ini adalah pentingnya mempertimbangkan metode pengukuran jarak dan variasi nilai k yang tepat, karena memiliki dampak yang signifikan pada kualitas prediksi model.

1.4.7 HASIL PERBANDINGAN PENGUKURAN JARAK

Model yang telah diprediksi dan diuji menggunakan confusion matrix memberikan hasil akurasi prediksi penyakit gagal jantung. Hasil pengujian ini membuktikan bahwa model yang dibangun dapat memberikan performa cukup baik dalam mendeteksi kehadiran penyakit gagal jantung. Pengujian model dilakukan dengan menggunakan berbagai nilai k yang berbeda, yaitu: k=1, k=3, k=7, dan k=9.

Tabel 1.10 Hasil akurasi dari jarak *Manhattan*

<i>k-Value</i>	<i>Manhattan Distance</i>			
	<i>Accuracy (%)</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
k-1	86.96	84.48	94.23	89.09
k-3	88.04	85.96	94.23	89.91
k-5	89.13	87.5	94.23	90.74
k-7	88.04	85.96	94.23	89.91
k-9	88.04	85.96	94.23	89.91

Tabel 1.10 hasil yang menarik evaluasi Data dapat bahwa model

menyajikan sangat dalam model ini. disimpulkan mencapai

akurasi tertinggi pada k = 5 dengan akurasi 89,13%. Akurasi ini menggambarkan bahwa model ini cukup baik untuk digunakan untuk memprediksi apakah pasien mengalami gagal jantung atau tidak. Selain itu, model presisi adalah 87,5 yang menunjukkan sejauh mana model meminimalkan kesalahan dalam mengklasifikasikan pasien "didiagnosis dengan gagal jantung". Recall mencapai 94,23, menggambarkan kemampuan model untuk mengidentifikasi sebagian besar kasus positif dalam dataset. F1-score 90,74 adalah ukuran yang menggabungkan presisi dan mengingat di mana f1-score memberikan indikasi keseluruhan tentang seberapa baik model bekerja dalam mengklasifikasikan kasus penyakit gagal jantung.

Tabel 1.11 Hasil akurasi dari jarak *Euclidean*

Nilai k	Jarak Euclidean			
	Accuracy (%)	Precision	Recall	F1-Score
K-1	83,7	83,64	88,46	85,98
K-3	84,78	83,93	90,38	87,04
K-5	88,04	87,27	92,31	89,72
K-7	88,04	87,27	92,31	89,72
K-9	88,04	87,27	92,31	89,72

Tabel 1.11 menunjukkan hasil uji pengukuran jarak euclidean dengan menggunakan lima variasi nilai k, yaitu k = 1, k = 3, k = 5, k = 7 dan k = 9. Berdasarkan hasil pengujian, akurasi tertinggi diperoleh dalam mengukur jarak euclidean pada k = 5, k = 7, dan k = 9 yang masing-masing memiliki tingkat akurasi 88,04%. Hal ini menunjukkan bahwa model yang menggunakan pengukuran jarak euclidean mencapai tingkat akurasi yang sangat baik dalam mengklasifikasikan pasien gagal jantung. Hasil ini menggambarkan bahwa model tersebut memiliki kemampuan yang cukup baik untuk digunakan untuk mengklasifikasikan pasien gagal jantung. Selanjutnya hasil presisi yang diperoleh adalah 87,27 dimana model mampu menghindari kesalahan dalam mengklasifikasikan pasien sebagai positif (didiagnosis gagal jantung) ketika hasil sebenarnya negatif. Ini menekankan keakuratan model dalam meminimalkan kesalahan yang dapat berdampak negatif pada pasien. Kemudian, penarikan 92,31 menunjukkan kemampuan model untuk mengidentifikasi sebagian besar kasus positif dalam dataset dan sangat penting dalam mendeteksi kasus penyakit gagal jantung dengan benar. F1-score sebesar 89,72 merupakan ukuran yang menggabungkan presisi dan daya ingat, memberikan indikasi keseluruhan tentang seberapa baik model bekerja dalam mengklasifikasikan kasus penyakit gagal jantung. F1-score adalah ukuran yang sangat penting dalam mengevaluasi model klasifikasi, karena mencerminkan sejauh mana model dapat memberikan hasil yang baik secara keseluruhan. Nilai k = 5, k = 7 dan k = 9 menunjukkan hasil yang sama dalam pengujian, menunjukkan bahwa dalam ukuran jarak euclidean, memilih nilai k yang lebih tinggi dapat memberikan peningkatan yang signifikan dalam kinerja model. Kesimpulannya, penting untuk memilih parameter yang tepat dalam mengembangkan model yang dapat membantu dalam membuat keputusan medis yang lebih baik dalam diagnosis gagal jantung.

1.6 KESIMPULAN

Penelitian algoritma klasifikasi K-NN untuk memprediksi gagal jantung telah membandingkan metode pengukuran jarak Euclidean dan Manhattan. Penelitian ini memisahkan dataset untuk data training dan data testing. 90% dari dataset dialokasikan untuk data training, sedangkan 10% sisanya ditujukan untuk data testing. Metode normalisasi yang digunakan dalam penelitian ini adalah Min-Max. Hasil penelitian menunjukkan metode pengukuran jarak Manhattan memiliki hasil yang lebih baik daripada metode pengukuran jarak euclidean. Manhattan menghasilkan tingkat akurasi 89,13% dalam memprediksi gagal jantung sementara euclidean menghasilkan akurasi 88,04%.

DAFTAR PUSTAKA

Abu Alfeilat, H. A., Hassanat, A. B. A., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S., & Prasath, V. B. S. (2019). Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review. *Big Data*, 7(4), 221–248. <https://doi.org/10.1089/big.2018.0175>

- Agrawal, H., Chandiwala, J., Agrawal, S., & Goyal, Y. (2021). Heart Failure Prediction using Machine Learning with Exploratory Data Analysis. *2021 International Conference on Intelligent Technologies, CONIT 2021*. <https://doi.org/10.1109/CONIT51480.2021.9498561>
- Anggoro, D. A., & Kurnia, N. D. (2020). Comparison of Accuracy Level of Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) Algorithms in Predicting Heart Disease. *International Journal of Emerging Trends in Engineering Research*, 8(5), 1689–1694. <https://doi.org/10.30534/ijeter/2020/32852020>
- Assegie, T. A., Sushma, S. J., Bhavya, B. G., & Padmashree, S. (2021). Correlation Analysis for Determining Effective Data in Machine Learning: Detection of Heart Failure. *SN Computer Science*, 2(3), 1–5. <https://doi.org/10.1007/s42979-021-00617-5>
- Chethana, C. (2021). Prediction of heart disease using different KNN classifier. *Proceedings - 5th International Conference on Intelligent Computing and Control Systems, ICICCS 2021*, 1186–1194. <https://doi.org/10.1109/ICICCS51141.2021.9432178>
- Chicco, D., & Jurman, G. (2020). Machine Learning Can Predict Survival of Patients with Heart Failure from Serum Creatinine and Ejection Fraction Alone. *BMC Medical Informatics and Decision Making*, 20(1), 1–16. <https://doi.org/10.1186/s12911-020-1023-5>
- Choudhary, G., & Narayan Singh, S. (2020). Prediction of heart disease using machine learning algorithms. *Proceedings of the International Conference on Smart Technologies in Computing, Electrical and Electronics, ICSTCEE 2020*, 5(8), 197–202. <https://doi.org/10.1109/ICSTCEE49637.2020.9276802>
- Ehsani, R., & Drabløs, F. (2020). Robust Distance Measures for KNN Classification of Cancer Data. *Cancer Informatics*, 19, 1176935120965542. <https://doi.org/10.1177/1176935120965542>
- Fadlil, A., Herman, & Praseptian M, D. (2022). K Nearest Neighbor Imputation Performance on Missing Value Data Graduate User Satisfaction. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(4), 570–576. <https://doi.org/10.29207/resti.v6i4.4173>
- Gauhar, N., Das, S., & Moury, K. S. (2021). Prediction of Flood in Bangladesh using K-Nearest Neighbors Algorithm. *International Conference on Robotics, Electrical and Signal Processing Techniques*, 357–361. <https://doi.org/10.1109/ICREST51555.2021.9331199>
- Haviluddin, Iqbal, M., Putra, G. M., Puspitasari, N., Setyadi, H. J., Dwiyanto, F. A., Wibawa, A. P., & Alfred, R. (2020). A Performance Comparison of Euclidean, Manhattan and Minkowski Distances in K-Means Clustering. *2020 6th International Conference on Science in Information Technology: Embracing Industry 4.0: Towards Innovation in Disaster Management, ICSITech 2020*, 184–188. <https://doi.org/10.1109/ICSITech49800.2020.9392053>
- Henderi, H. (2021). Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (kNN) Algorithm to Test the Accuracy of Types of Breast Cancer. *IJIS: International Journal of Informatics and Information Systems*, 4(1), 13–20. <https://doi.org/10.47738/ijis.v4i1.73>
- Hidayati, N., & Hermawan, A. (2021). K-Nearest Neighbor (K-NN) Algorithm with Euclidean and Manhattan in Classification of Student Graduation. *Journal of Engineering and Applied Technology*, 2(2), 86–91. <https://doi.org/10.21831/jeatech.v2i2.42777>
- Iswanto, I., Tulus, T., & Sihombing, P. (2021). Comparison of Distance Models on K-Nearest Neighbor Algorithm in Stroke Disease Detection. *Applied Technology and Computing*

- Science Journal*, 4(1), 63–68. <https://doi.org/10.33086/atcsj.v4i1.2097>
- Khateeb, N., & Usman, M. (2017). Efficient heart disease prediction system using K-nearest neighbor classification technique. *ACM International Conference Proceeding Series*, 21–26. <https://doi.org/10.1145/3175684.3175703>
- Latha, C. B. C., & Jeeva, S. C. (2019). Improving the accuracy of prediction of heart disease risk based on ensemble classification techniques. *Informatics in Medicine Unlocked*, 16, 100203. <https://doi.org/10.1016/j.imu.2019.100203>
- Lubis, A. R., Lubis, M., & Al-Khowarizmi. (2020). Optimization of distance formula in k-nearest neighbor method. *Bulletin of Electrical Engineering and Informatics*, 9(1), 326–338. <https://doi.org/10.11591/eei.v9i1.1464>
- Misra, P., & Yadav, A. S. (2019). Impact of Preprocessing Methods on Healthcare Predictions. *SSRN Electronic Journal*, 144–150. <https://doi.org/10.2139/ssrn.3349586>
- Olisah, C. C., Smith, L., & Smith, M. (2022). Diabetes mellitus prediction and diagnosis from a data preprocessing and machine learning perspective. *Computer Methods and Programs in Biomedicine*, 220. <https://doi.org/10.1016/j.cmpb.2022.106773>
- Ozcan, M., & Peker, S. (2023). A Classification and Regression Tree Algorithm for Heart Disease Modeling and Prediction. *Healthcare Analytics*, 3, 100130. <https://doi.org/10.1016/j.health.2022.100130>
- Patel, S. P., & Upadhyay, S. H. (2020). Euclidean distance based feature ranking and subset selection for bearing fault diagnosis. *Expert Systems with Applications*, 154, 113400. <https://doi.org/10.1016/j.eswa.2020.113400>
- Peirlinck, M., Sahli Costabal, F., Sack, K. L., Choy, J. S., Kassab, G. S., Guccione, J. M., De Beule, M., Segers, P., & Kuhl, E. (2019). Using machine learning to characterize heart failure across the scales. *Biomechanics and Modeling in Mechanobiology*, 18(6), 1987–2001. <https://doi.org/10.1007/s10237-019-01190-w>
- Pratiwi, N. K. C., Magdalena, R., Fuadah, Y. N., & Saidah, S. (2019). K-Nearest Neighbor for Colon Cancer Identification. *Journal of Physics: Conference Series*, 1367, 012023. <https://doi.org/10.1088/1742-6596/1367/1/012023>
- Rahman, B., Hendric Spits Warnars, H. L., Subirosa Sabarguna, B., & Budiharto, W. (2021). Heart Disease Classification Model Using K-Nearest Neighbor Algorithm. *2021 6th International Conference on Informatics and Computing, ICIC 2021*. <https://doi.org/10.1109/ICIC54025.2021.9632918>
- SAPUTRA, D. M., SAPUTRA, D., & OSWARI, L. D. (2020). Effect of Distance Metrics in Determining K-Value in K-Means Clustering Using Elbow and Silhouette Method. *Advances in Intelligent Systems Research*. <https://doi.org/10.2991/aisr.k.200424.051>
- Sowmiya, C., & Sumitra, P. (2018). Analytical study of heart disease diagnosis using classification techniques. *Proceedings of the 2017 IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing, INCOS 2017, 2018-Febru*, 1–5. <https://doi.org/10.1109/ITCOSP.2017.8303115>
- Srinivasa Rao, M., Sekhar, C., & Bhattacharyya, D. (2021). Comparative Analysis of Machine Learning Models on Loan Risk Analysis. *Advances in Intelligent Systems and Computing*, 1280, 81–90. https://doi.org/10.1007/978-981-15-9516-5_7
- Tabaghi, P., Dokmanić, I., & Vetterli, M. (2020). Kinetic Euclidean Distance Matrices. *IEEE Transactions on Signal Processing*, 68, 452–465. <https://doi.org/10.1109/TSP.2019.2959260>
- Uddin, S., Haque, I., Lu, H., Moni, M. A., & Gide, E. (2022). Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease

prediction. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-10358-x>

Upadhyay, A., Nadar, S., & Jadhav, R. (2020). Comparative Study of SVM & KNN for Signature Verification. *Journal of Statistics and Management Systems*, 23(2), 191–198. <https://doi.org/10.1080/09720510.2020.1724619>

Zubaedah, R., Xaverius, F., Jayawardana, H., & Hidayat, S. H. (2020). Comparing Euclidean Distance and Nearest Neighbor Algorithm in an Expert System for Diagnosis of Diabetes Mellitus. *Enfermeria Clinica*, 30(S2), 374–377. <https://doi.org/10.1016/j.enfcli.2019.07.121>



Muhammad Kunta Biddinika is a lecturer at the Master of Informatics program at Ahmad Dahlan University, Yogyakarta. He studied undergraduate at Gajah Mada University Yogyakarta, then continued his master's and doctoral studies at Tokyo Institute of Technology. His areas of expertise are environmental sciences, technology and sustainability development education.



Herman Herman is a lecturer at the Master of Informatics at Ahmad Dahlan University, Yogyakarta. He studied Bachelor's degree at the Perbanas Institute of Information Engineering, Jakarta, then continued his Master's and Doctoral studies at Computer Science Universiti Teknologi Malaysia. His area of expertise is Mobile and Multimedia Technologies.



Alya Masitha is a Master's Student in Informatics at Ahmad Dahlan University, Yogyakarta. After graduating with a Bachelor's Degree in Informatics Engineering at Ahmad Dahlan University, Yogyakarta, he then continued his Master's degree in Informatics at Ahmad Dahlan University, Yogyakarta. Since 2022, Alya has been interested in the field of machine learning.

BAB 6
Pembobotan *Rank Order Centroid*
dalam Metode *Multi Attribute Utility Theory*
pada Sistem Penentuan Apoteker Terbaik

Faiz Isnan Abdurrachman, Rusydi Umar, Herman

1.1. PENDAHULUAN

Apoteker merupakan salah satu tenaga kesehatan yang memiliki keahlian di bidang obat-obatan, namun kurangnya pengenalan profesi apoteker kepada masyarakat menyebabkan banyak masyarakat yang belum memahami apa saja tugas dan peran apoteker dalam meningkatkan kualitas kesehatan masyarakat (Astutiningsih dkk., 2021). Dalam meningkatkan dan menjaga mutu pelayanan kefarmasian dan juga mengendalikan perilaku profesi apoteker, peran Ikatan Apoteker Indonesia (IAI) sangat mendasar. Apoteker diharapkan dapat melaksanakan praktik kefarmasian berdasarkan Keputusan Menteri Kesehatan tentang Standar Pelayanan Kefarmasian. Standar tersebut diupayakan sejalan dengan Standar Pelayanan Kesehatan (Novrandyka, 2015). Dengan demikian, IAI harus berusaha menjaga kualitas pelayanan kefarmasian apoteker agar kinerjanya tetap baik. Strategi yang dilakukan oleh IAI adalah dengan memberikan penghargaan kepada apoteker terbaik. Menentukan apoteker terbaik sebelumnya memiliki kendala, kendala tersebut antara lain pada saat pengolahan data calon apoteker yang membutuhkan waktu yang cukup lama dalam penyeleksiannya, rekomendasi apoteker yang masih terbilang subyektif, belum memiliki standar yang baku dalam proses penilaiannya, dan proses penilaian yang masih belum transparan. Oleh karena itu, diperlukan sebuah Sistem Pendukung Keputusan (SPK) yang dapat memberikan solusi untuk menentukan apoteker terbaik berdasarkan kriteria-kriteria yang telah ditentukan oleh IAI. Kriteria yang digunakan meliputi kedisiplinan, pelayanan kefarmasian, keaktifan, masa kerja, dan kehadiran.

SPK didefinisikan sebagai sebuah sistem yang dapat memecahkan atau menyelesaikan masalah dan berkomunikasi dalam menyelesaikan suatu masalah tertentu, baik itu terstruktur maupun tidak terstruktur (Umar dkk., 2018). Pengambilan keputusan diambil dengan cara menghitung setiap nilai alternatif. Dalam menentukan pilihan ada beberapa proses yang akan dilakukan oleh pengambil keputusan. Proses tersebut antara lain menentukan masalah, menentukan alternatif yang dipilih dan menentukan keputusan yang terbaik (Umar dkk., 2022). Dalam pengambilan suatu keputusan terdapat berbagai macam metode yang dapat digunakan, namun untuk penelitian ini metode pengambilan keputusan yang digunakan adalah metode ROC yaitu proses pemberian bobot pada kriteria berdasarkan tingkat kepentingannya. Selanjutnya bobot-bobot tersebut digunakan dalam perhitungan metode MAUT (Saputra, 2020)(Shakirov dkk., 2019).

Penelitian ini menerapkan kombinasi ROC dan MAUT tersebut pada studi kasus penentuan apoteker terbaik di Kabupaten Majalengka. Penerapan metode pembobotan ini diharapkan dapat memberikan kemudahan dalam menentukan tingkat kepentingan kriteria sehingga diperoleh hasil MAUT yang optimal, tepat dan akurat. Penelitian ini mendukung filosofi sistem pendukung keputusan yang tepat dan tidak bersifat subjektif (Toh dkk., 2021).

1.1.1 METODE PEMBOBOTAN ROC

Bobot *Rank Order Centroid* (ROC), diusulkan oleh Barron dan Barrett (1996), disebut sebagai bobot *centroid* (pusat massa) dalam upaya untuk mengidentifikasi satu set bobot yang mewakili semua kemungkinan kombinasi bobot yang dapat diterima (Liu dkk., 2020). Metode ROC didasarkan pada pemberian bobot berdasarkan tingkat kepentingan kriteria, dengan cara memberikan bobot pada setiap kriteria sesuai dengan rangking yang dinilai berdasarkan tingkat prioritasnya. Metode ini merupakan salah satu metode pembobotan yang cukup sederhana jika dibandingkan dengan metode pembobotan yang lain (Panjaitan

& Desnelita, 2021) (Lubis dkk., 2020). Biasanya memiliki pernyataan seperti "kriteria 1 adalah prioritas tertinggi dibandingkan dengan kriteria 2, begitu juga kriteria 2 adalah prioritas tertinggi dibandingkan dengan kriteria 3, kemudian langkah yang sama dilakukan sampai prioritas kriteria terendah" (Mesran dkk., 2019).

Teknik pembobotan ROC disajikan dan dibandingkan dengan teknik pembobotan konvensional (Bhowate dkk., 2018) (Esangbedo dkk., 2022). Dalam menentukan prioritas dimana nilai tertinggi merupakan nilai yang paling penting diantara nilai lainnya. Sehingga diperoleh gambaran tingkat kepentingan setiap kriteria sebagai berikut (Arini dkk., 2022) (Winfrey dkk., 2023):

$$C_1 > C_2 > C_3 > C_4 \dots C_n \quad (1.1)$$

Kemudian,

$$W_1 > W_2 > W_3 > W_4 \dots W_n \quad (1.2)$$

Sehingga nilai bobot (W), dapat dihasilkan dengan rumus sebagai berikut (Liu dkk., 2020):

$$w_n = \frac{1}{n} \sum_{i=1}^n \left(\frac{1}{n} \right) \quad (1.3)$$

1.1.2 METODE MAUT

Metode *Multi Attribute Utility Theory* (MAUT) adalah model pendukung keputusan yang akan menguraikan masalah multi-faktor atau multi-kriteria yang kompleks dengan mengubah berbagai kepentingan atau kriteria menjadi nilai numerik pada skala 0-1 dengan 0 mewakili pilihan terburuk dan 1 yang terbaik (Soni dkk., 2020) (Shash dkk., 2021). Hal ini memungkinkan perbandingan langsung yang bervariasi dalam ukuran (Siringoringo & Onella Debora Purba, 2019). Untuk perhitungannya, nilai evaluasi keseluruhan dapat didefinisikan dengan beberapa persamaan (Elviani dkk., 2022). MAUT adalah pendekatan sistematis untuk mengukur preferensi individu berdasarkan pengukuran preferensi pengambil keputusan (Nara dkk., 2019).

MAUT adalah metode perbandingan kuantitatif yang biasanya menggabungkan pengukuran biaya dan manfaat risiko yang berbeda (Yang dkk., 2019) (Kovacevic dkk., 2019). Setiap kriteria memiliki beberapa alternatif yang dapat memberikan solusi (Mihuandayani dkk., 2020). Untuk menemukan alternatif yang mendekati keinginan pengguna, untuk mengidentifikasinya dilakukan perkalian dari skala prioritas yang telah ditentukan. Sehingga hasil yang terbaik dan paling mendekati dari alternatif-alternatif tersebut yang akan diambil sebagai solusi (Courtais dkk., 2021). Untuk mendapatkan alternatif terbaik penilaian kinerja karyawan diawali dengan menentukan normalisasi matriks. Berfungsi untuk mempengaruhi penilaian kinerja dan hasil perhitungan metode MAUT dengan cara mengalikan bobot setiap kriteria yang telah ditentukan (Djasmayena dkk., 2019) (Almohassen dkk., 2023). Langkah-langkah metode MAUT adalah sebagai berikut (Siringoringo & Onella Debora Purba, 2019) (Akpan & Morimoto, 2022):

1. Menentukan alternatif, menentukan kriteria, dan bobot setiap kriteria
2. Menghitung nilai utilitas ternormalisasi dari matriks sesuai dengan atributnya untuk setiap alternatif yang dinyatakan dengan rumus (Çetinkaya dkk., 2023):

$$U(x) = \frac{(x-xi^-)}{xi^+ - xi^-} \quad (1.4)$$

Keterangan:

- U(x) : Nilai utilitas dari setiap kriteria alternatif terhadap x
- xi⁻ : Nilai terkecil dari kriteria ke-i pada semua alternatif
- xi⁺ : Nilai terbesar dari kriteria ke-i pada semua alternatif
- x : Nilai kriteria ke-i pada semua alternatif

3. Kalikan nilai utilitas dengan nilai bobot ternormalisasi untuk menemukan nilai setiap alternatif dengan rumus berikut (Rodric, 2019)(Kang dkk., 2022):

$$V(x) = \sum_{i=1}^n w_i \cdot v_i(x) \quad (1.5)$$

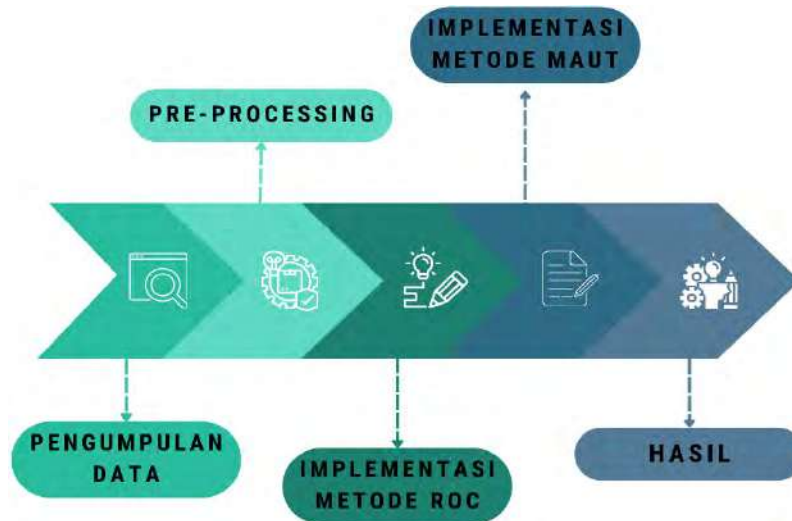
Keterangan:

- V(x) : Total evaluasi dari alternatif x
- w_i : Bobot relatif dari kriteria i
- v_i(x) : Hasil evaluasi kriteria i dari alternatif x
- i : Indeks kriteria

4. Tentukan peringkat tertinggi dengan mengurutkan nilai terbesar ke nilai terkecil.

1.2 ALUR KERJA PENELITIAN

Metode yang digunakan dalam penelitian ini mengikuti alur kerja penelitian seperti yang digambarkan pada Gambar 1.1.



Gambar 1. 1 Alur penelitian metode pembobotan ROC dengan metode perhitungan MAUT

Beberapa tahapan dalam penelitian ini, mulai dari mengumpulkan data, mengolah data, dan menganalisis data hingga memperoleh output yang diharapkan.

1.2.1 PENGUMPULAN DATA

Data set yang digunakan dalam penelitian ini adalah data kinerja apoteker. Data set tersebut memiliki kriteria kedisiplinan, pelayanan kefarmasian, keaktifan, masa kerja dan kehadiran apoteker pada bulan Februari 2023. Data rekap apoteker disajikan pada Tabel 1.1.

Tabel 1.1 Data Apoteker

<i>Alternatif</i>	<i>C1</i>	<i>C2</i>	<i>C3</i>	<i>C4</i>	<i>C5</i>
K1	Baik	Baik	2	14	90
K2	Cukup	Cukup	4	5	47
K3	Kurang	Kurang	1	6	69
K4	Baik	Baik	5	23	92
K5	Baik	Baik	6	21	90
...
K26	Cukup	Cukup	2	17	47
K27	Cukup	Cukup	5	29	80
K28	Cukup	Cukup	2	27	79
K29	Cukup	Cukup	1	23	50
K30	Baik	Baik	6	26	91

Pada Tabel 1.1. Data apoteker diperoleh dari IAI Kabupaten Majalengka. Nilai kriteria C1 sampai dengan C5 diperoleh dari ketua IAI pada bulan Februari 2023 (Amrial Khoir dkk., 2022).

Kedisiplinan (C1) merupakan informasi yang berisi laporan apoteker kepada IAI selama satu bulan. Sedangkan pelayanan kefarmasian (C2) adalah informasi yang berisi laporan *Home Care*, konseling, dan pemantauan efek samping obat selama satu bulan. Kedisiplinan dan pelayanan kefarmasian memiliki skala penilaian yang sama, seperti yang ditunjukkan pada Tabel 1.2.

Tabel 1.2. Skala Penilaian C1 dan C2

<i>Disiplin dan Layanan Farmasi</i>	<i>Nilai Kriteria</i>
Sangat baik	5
Baik	4
Cukup	3
Kurang	2
Sangat Kurang	1

Keaktifan (C3) adalah uraian yang memuat jumlah Satuan Kredit Partisipasi (SKP) selama satu bulan. SKP merupakan ukuran keikutsertaan dalam kegiatan praktik profesi, kegiatan pelayanan, kegiatan pembelajaran berkelanjutan, kegiatan pengembangan ilmu pengetahuan dan kegiatan publikasi ilmiah yang dilakukan apoteker selama masa berlaku Sertifikat Kompetensi. Ikatan Apoteker Indonesia menetapkan bahwa setiap apoteker mampu mengumpulkan SKP sebanyak 150 poin dalam lima tahun, telah dirumuskan dengan domain kegiatan kompetensi yang berimbang sebagaimana mestinya. Tabel bobot kegiatan C3 dapat dilihat pada Tabel 1.3.

Tabel 1.3. Bobot Keaktifan C3

<i>Keaktifan</i>	<i>Bobot</i>
6 kali	5
5 kali	4
4 kali	3
3 kali	2
1-2 kali	1

Masa kerja (C4) adalah informasi yang berisi periode atau lamanya apoteker bekerja di apotek. Tabel pembobotan masa kerja dapat dilihat pada Tabel 1.4.

Tabel 1.4. Bobot Masa Kerja C4

<i>Masa Kerja</i>	<i>Bobot</i>
>6 bulan	5
4-5 bulan	4
2-3 bulan	3
1-2 bulan	2
< 1 bulan	1

Kehadiran (C5) adalah keterangan yang berisi persentase kehadiran apoteker selama satu bulan. Nilai kehadiran dihitung dengan cara mengalikan jumlah kehadiran dalam satu bulan dikalikan 100%. Tabel bobot kehadiran dapat dilihat pada Tabel 1.5.

Tabel 1.5. Bobot Kehadiran C5

<i>Kehadiran</i>	<i>Bobot</i>
100%	5
80-99%	4
60-79%	3
40-59%	2
<39%	1

1.2.2 DATA PRE-PROCESSING

Pada tahap ini, peneliti mengubah data dengan nilai kategoris seperti atribut C1, C2, C3, C4, dan C5 dengan menginisialisasi data menjadi 1 sampai dengan 5. Data yang sudah di proses disajikan pada Tabel 1.6.

Tabel 1.6. Data Penilaian

<i>Alternatif</i>	<i>C1</i>	<i>C2</i>	<i>C3</i>	<i>C4</i>	<i>C5</i>
K1	4	4	1	5	4
K2	3	3	3	4	2
K3	2	2	1	5	3
K4	4	4	4	5	4
K5	4	4	5	5	4
...
K26	3	3	1	5	2
K27	3	3	4	5	4
K28	3	3	1	5	3
K29	3	3	1	5	2
K30	4	4	5	5	4

1.4 HASIL DAN PEMBAHASAN

Penelitian ini diawali dengan pengumpulan data, *pre-processing*, implementasi metode pembobotan ROC, dan perhitungan metode MAUT. Data yang digunakan dalam penelitian ini adalah dataset apoteker di Kabupaten Majalengka berdasarkan data dari IAI Kabupaten Majalengka.

1.4.1 PEMBOBOTAN ROC

Pada tahap ROC, kriteria diurutkan sesuai dengan tingkat kepentingan kriteria setelah diurutkan dari tingkat kepentingan yang paling tinggi, kemudian dilakukan pencarian nilai bobot kriteria berdasarkan jumlah kriteria yang ada dengan ketentuan rumus yang berlaku. Berikut ini adalah penyelesaian dengan menggunakan metode ROC:

$$W_{c1} = \frac{1 + \frac{1}{2} + \frac{1}{3} + \frac{1}{4} + \frac{1}{5}}{5} = 0,457$$

$$W_{c2} = \frac{0 + \frac{1}{2} + \frac{1}{3} + \frac{1}{4} + \frac{1}{5}}{5} = 0,257$$

$$W_{c3} = \frac{0 + 0 + \frac{1}{3} + \frac{1}{4} + \frac{1}{5}}{5} = 0,156$$

$$W_{c5} = \frac{0 + 0 + 0 + \frac{1}{4} + \frac{1}{5}}{5} = 0,090$$

$$W_{c4} = \frac{0 + 0 + 0 + 0 + \frac{1}{5}}{5} = 0,040$$

Sehingga hasil pembobotan dengan menggunakan metode ROC seperti pada Tabel 1.7.

Tabel 1.7. Hasil dari Metode Pembobotan ROC

<i>Kriteria</i>	<i>Nilai Bobot Metode ROC</i>
Disiplin	0,457
Layanan Farmasi	0,256667
Keaktifan	0,156667
Kehadiran	0,090
Masa Kerja	0,040

1.4.2 PROSES MAUT

Pada perhitungan ini terdapat lima kriteria dan nilai bobot yang telah ditentukan, dan dapat diganti sesuai kebutuhan. Jadi kriteria dan nilai disesuaikan dengan kebutuhan, berikut langkah-langkah perhitungannya:

Pertama, tentukan jumlah kriteria dan sub kriteria serta bobot kriteria. Bobot kriteria ditentukan berdasarkan kesepakatan dan kepentingan dalam organisasi IAI. Kriteria dan sub kriteria yang digunakan dalam penentuan apoteker terbaik, dilanjutkan dengan pembobotan kriteria dilakukan dengan memberikan nilai antara 0-100 sesuai dengan tingkat kepentingan dari masing-masing kriteria seperti yang dapat dilihat pada Tabel 1.8.

Tabel 1.8. Kriteria dan Sub-kriteria

<i>Kriteria</i>	<i>Bobot</i>	<i>Sub-Kriteria</i>
Disiplin	35	Sangat baik
		Baik
		Cukup
		Kurang
		Sangat Kurang
Layanan Farmasi	30	Sangat baik
		Baik
		Cukup
		Kurang

		Sangat Kurang
		6 kali
Keaktifan	20	5 kali
		4 kali
		3 kali
		1-2 kali
		>6 bulan
Masa Kerja	10	4-5 bulan
		2-3 bulan
		1-2 bulan
		< 1 bulan
		100%
		80-99%
Kehadiran	5	60-79%
		40-59%
		<40%

Kedua, pemberian bobot kriteria selanjutnya adalah melakukan normalisasi bobot kriteria. Hasil normalisasi bobot kriteria dapat dilihat pada Tabel 1.9.

Tabel 1.9. Normalisasi Bobot Kriteria

<i>Kriteria</i>	<i>Bobot</i>
Disiplin	0,35
Layanan	0,30
Farmasi	0,20
Keaktifan	0,20
Masa Kerja	0,10
Kehadiran	0,05
Total	1

Ketiga, menampilkan hasil normalisasi dalam sebuah tabel dan menghitung nilai akhir dengan cara menormalkan nilai bobot kriteria dikalikan dengan nilai utilitas ternormalisasi. Hasil perhitungan nilai akhir dapat dilihat pada Tabel 1.10.

Tabel 1.10. Hasil Perhitungan Metode MAUT

<i>Alternatif</i>	<i>C1</i>	<i>C2</i>	<i>C3</i>	<i>C4</i>	<i>C5</i>	<i>Nilai Akhir</i>
K1	0.233	0.150	0.000	0.100	0.038	0.521
K2	0.117	0.225	0.100	0.050	0.013	0.504
K3	0.000	0.300	0.000	0.100	0.025	0.425
K4	0.233	0.150	0.150	0.100	0.038	0.671
K5	0.233	0.225	0.200	0.100	0.038	0.796
...
K26	0.117	0.075	0.000	0.100	0.013	0.304
K27	0.117	0.075	0.150	0.100	0.038	0.479
K28	0.117	0.000	0.000	0.100	0.025	0.242
K29	0.117	0.300	0.000	0.100	0.013	0.529
K30	0.233	0.225	0.200	0.100	0.038	0.796

Keempat, tahap ini dilakukan dengan menghitung bagaimana hasil dari nilai normalisasi dikalikan dengan nilai bobot, pada penelitian ini nilai bobot ditentukan dengan menggunakan ROC sehingga hasilnya terlihat pada Tabel 1.11.

Tabel 1.11. Hasil Perhitungan Metode ROC

<i>Alternatif</i>	<i>C1</i>	<i>C2</i>	<i>C3</i>	<i>C4</i>	<i>C5</i>	<i>Nilai Akhir</i>
K1	0.304	0.128	0.000	0.040	0.068	0.540
K2	0.152	0.193	0.078	0.020	0.023	0.466
K3	0.000	0.257	0.000	0.040	0.045	0.342
K4	0.304	0.128	0.118	0.040	0.068	0.658
K5	0.304	0.193	0.157	0.040	0.068	0.761
...
K26	0.152	0.064	0.000	0.040	0.023	0.279
K27	0.152	0.064	0.118	0.040	0.068	0.441
K28	0.152	0.000	0.000	0.040	0.045	0.237
K29	0.152	0.257	0.000	0.040	0.023	0.471
K30	0.304	0.193	0.157	0.040	0.068	0.761

Selanjutnya semua nilai dijumlahkan berdasarkan alternatif kepemilikan atau dijumlahkan per baris untuk mendapatkan nilai tertinggi. Maka tabel keputusan metode MAUT dengan menggunakan metode pembobotan ROC dapat dilihat seperti pada Tabel 1.12.

Tabel 1.12. Perankingan Metode MAUT dengan Metode Pembobotan ROC

<i>Alternatif</i>	<i>Total nilai dengan ROC</i>	<i>Rank</i>
K16	1	1
K11	0.848	2
K7	0.809	3
K5	0.761	4
K30	0.761	4
K20	0.730	5

Sedangkan Metode MAUT tanpa menggunakan metode pembobotan ROC dapat dilihat pada Tabel 1.13.

Tabel 1.13. Perankingan Metode MAUT tanpa Metode Pembootan ROC

<i>Alternatif</i>	<i>Total nilai tanpa ROC</i>	<i>Rank</i>
K16	1	1
K11	0.883	2
K7	0.833	3
K5	0.796	4
K30	0.796	4
K20	0.733	5

1.5 KESIMPULAN

Penentuan apoteker terbaik menggunakan pembobotan ROC pada metode MAUT menghasilkan alternatif K16 sebagai apoteker terbaik. Demikian pula dengan metode metode MAUT tanpa ROC juga menentukan K16 sebagai apoteker terbaik. Untuk apoteker terbaik peringkat kedua sampai ke lima juga tidak ada perbedaan antara MAUT yang menggunakan pembobotan ROC dengan MAUT yang tidak menggunakan ROC. Dapat disimpulkan bahwa penggunaan pembobotan ROC pada metode MAUT tidak memiliki pengaruh yang besar terhadap sistem penentuan apoteker terbaik ketika menggunakan data IAI ini.

DAFTAR PUSTAKA

- Akpan, U., & Morimoto, R. (2022). An application of Multi-Attribute Utility Theory (MAUT) to the prioritization of rural roads to improve rural accessibility in Nigeria. *Socio-Economic Planning Sciences*, 82, 1–10. <https://doi.org/10.1016/j.seps.2022.101256>
- Almohassen, A. S., Alfozan, M., Alshamrani, O. S., & Shaawat, M. E. (2023). Evaluating construction contractors in the pre-tendering stage through an integrated based model. *Alexandria Engineering Journal*, 82(January), 437–445. <https://doi.org/10.1016/j.aej.2023.09.069>
- Amrial Khoir, S., Yudhana, A., & Sunardi. (2022). Presensi Online Menggunakan Global Positioning System untuk Penilaian Kinerja Pegawai Berdasarkan Metode Simple Additive Weighting. *Jurnal Media Informatika Budidarma*, 6(2), 858–867. <https://doi.org/10.30865/mib.v6i2.3758>
- Arini, Z. M., Sitanggang, D. J., Ali, M., & ... (2022). ... Penentuan Facial Wash Terbaik yang digunakan pada kulit berminyak dengan menggunakan Metode Multi Attribute Utility Theory (MAUT) dan Pembobotan Rank *Prosiding ...*, 317–324. <https://journals.stimsukmamedan.ac.id/index.php/senashtek/article/view/181%0Ahttps://journals.stimsukmamedan.ac.id/index.php/senashtek/article/view/181/128>
- Astutiningsih, C., Tjahjani, N. P., & Listyani, L. (2021). Pengenalan Profesi Apoteker dan Mengenali Obat Sejak Usia Dini. *Jurnal Abdidas*, 2(3), 713–719. <https://doi.org/10.31004/abdidas.v2i3.344>
- Bhowate, A., Aware, M., & Sharma, S. (2018). Rank Ordering Criteria Based Weighting Factor Evaluation in Model Predictive Torque Control of Five-phase Induction Motor Drive. *Proceedings of 2018 IEEE International Conference on Power Electronics, Drives and Energy Systems, PEDES 2018*, 1–5. <https://doi.org/10.1109/PEDES.2018.8707738>
- Çetinkaya, C., Erbaş, M., Kabak, M., & Özceylan, E. (2023). A mass vaccination site selection problem: An application of GIS and entropy-based MAUT approach. *Socio-Economic Planning Sciences*, 85(January 2022). <https://doi.org/10.1016/j.seps.2022.101376>
- Courtais, A., Lesage, F., Privat, Y., & Latifi, A. M. (2021). Determination of the optimal packing configuration of a catalytic fixed-bed reactor using geometry and multi-objective optimization methods. *Proceedings of the 2021 23rd International Conference on Process Control, PC 2021*, 102–107. <https://doi.org/10.1109/PC52310.2021.9447503>
- Djasmayena, S., Yunus, Y., & Putra, R. E. (2019). Pemilihan Supplier Obat yang Tepat Menggunakan Metode Multi Attribut Utility Theory. *Jurnal Informasi & Teknologi*, 1(4), 47–54. <https://doi.org/10.37034/jidt.v1i4.27>
- Elviani, Haerani, E., Cynthia, E. pandu, Kurnia, F., & Syafria, F. (2022). Sistem Pendukung Keputusan Penilaian Kinerja Guru Menggunakan Metode Multi Attribute Utility Theory (Maut) Di Sma Negeri 10 Kota Ternate. *Jurnal Informatika Dan Tekonologi Komputer (JITEK)*, 2(3), 237–248. <https://doi.org/10.55606/jitek.v2i3.545>
- Esangbedo, M. O., Xue, J., Bai, S., & Esangbedo, C. O. (2022). Relaxed Rank Order Centroid Weighting MCDM Method With Improved Grey Relational Analysis for Subcontractor Selection: Photothermal Power Station Construction. *IEEE Transactions on Engineering Management, PP*, 1–18. <https://doi.org/10.1109/TEM.2022.3204629>
- Kang, D., Devi, S. A., Felix, A., Narayanamoorthy, S., Kalaiselvan, S., Balaenu, D., &

- Ahmadian, A. (2022). Intuitionistic fuzzy MAUT-BW Delphi method for medication service robot selection during COVID-19. *Operations Research Perspectives*, 9(July), 100258. <https://doi.org/10.1016/j.orp.2022.100258>
- Kovacevic, M. S., Bacic, M., Stipanovic, I., & Gavin, K. (2019). Categorization of the condition of railway embankments using a multi-attribute utility theory. *Applied Sciences (Switzerland)*, 9(23), 1–17. <https://doi.org/10.3390/app9235089>
- Liu, D., Li, T., & Liang, D. (2020). An integrated approach towards modeling ranked weights. *Computers and Industrial Engineering*, 147(March 2019), 106629. <https://doi.org/10.1016/j.cie.2020.106629>
- Lubis, A. I., Sihombing, P., & Nababan, E. B. (2020). Comparison SAW and MOORA Methods with Attribute Weighting Using Rank Order Centroid in Decision Making. *MECnIT 2020 - International Conference on Mechanical, Electronics, Computer, and Industrial Technology*, 127–131. <https://doi.org/10.1109/MECnIT48290.2020.9166640>
- Mesran, M., Diansyah, T. M., & Fadlina, F. (2019). Implemententasi Metode Rank Order Cendroid (ROC) dan Operational Competitiveness Rating Analysis (OCRA) dalam Penilaian Kinerja Dosen Komputer Menerapkan (Studi Kasus: STMIK Budi Darma). *Prosiding Seminar Nasional Riset Information Science (SENARIS)*, 1(September), 822. <https://doi.org/10.30645/senaris.v1i0.89>
- Mihuandayani, M., Arundaa, R., & Tamuntuan, V. (2020). Decision Support System for Employee Recruitment of A Company Using Multi Attribute Utility Theory. *2020 2nd International Conference on Cybernetics and Intelligent System, ICORIS 2020*. <https://doi.org/10.1109/ICORIS50180.2020.9320817>
- Nara, E. O. B., Sordi, D. C., Schaefer, J. L., Schreiber, J. N. C., Baierle, I. C., Sellitto, M. A., & Furtado, J. C. (2019). Prioritization of OHS key performance indicators that affecting business competitiveness – A demonstration based on MAUT and Neural Networks. *Safety Science*, 118(November 2018), 826–834. <https://doi.org/10.1016/j.ssci.2019.06.017>
- Novrandyka, H. (2015). Jurnal Kajian Yuridis Pasal 21 Peraturan Menteri Kesehatan Nomor.889/Menkes/Per/V/2011 Tentang Registrasi, Izin Praktik Dan Izin Kerja Tenaga Kefarmasian Terkait Pemberian Rekomendasi Organisasi Profesi Apoteker. In *E-Journal Universitas Atma Jaya Yogyakarta* (Vol. 13, Issue 3). Universitas Atma Jaya Yogyakarta.
- Panjaitan, E. A., & Desnelita, Y. (2021). Implementasi Metode Rank Order Centroid dan Additive Ratio Assessment dalam Penilaian Kinerja Dosen. *Seminar Nasional Informatika (SENATIKA) Prosiding SENATIKA*.
- Rodic, B. (2019). Decision support in a telecommunications engineering e-learning platform. *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2019 - Proceedings*, 655–660. <https://doi.org/10.23919/MIPRO.2019.8757101>
- Saputra, I. M. A. B. (2020). Penentuan Lokasi Stup Menggunakan Pembobotan Rank Order Centroid (ROC) dan Simple Additive Weighting (SAW). *Jurnal Sistem Dan Informatika (JSI)*, 15(1), 48–53. <https://doi.org/10.30864/jsi.v15i1.340>
- Shakirov, V. A., Artemyev, Y. A., & Nefedov, A. S. (2019). Decision Support for the Windfarms Siting Based on Multi-Attribute Analysis and Aerodynamic Modeling. *2019 International Multi-Conference on Industrial Engineering and Modern Technologies, FarEastCon 2019*, 1–6. <https://doi.org/10.1109/FarEastCon.2019.8934159>
- Shash, A. A., Al-Salti, M., Alshibani, A., & Hadidi, L. (2021). Predicting Cost Contingency Using Analytical Hierarchy Process and Multi Attribute Utility Theory. *Journal of*

- Engineering, Project, and Production Management*, 11(3), 228–242.
<https://doi.org/10.2478/jeppm-2021-0022>
- Siringoringo, F., & Onella Debora Purba, N. (2019). Sistem Pendukung Keputusan Penilaian Kinerja Dosen dengan Metode Maut (Multi Attribute Utility Theory). *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, 406–411.
<http://prosiding.seminarid.com/index.php/sensasi/issue/archivePage%7C406>
- Soni, R., Jha, S., Patel, A., Fuse, K., & Vora, J. (2020). Notice of Removal: Multi-response Optimization of Electric Discharge Machining Using Grey Relational Analysis (GRA) and Multi-attribute Utility Theory (MAUT). *2020 IEEE 7th International Conference on Industrial Engineering and Applications, ICIEA 2020*, 65–69.
<https://doi.org/10.1109/ICIEA49774.2020.9101962>
- Toh, Y., Hagihara, A., Shiotani, M., Onozuka, D., Yamaki, C., Shimizu, N., Morita, S., & Takayama, T. (2021). Employing multiple-attribute utility technology to evaluate publicity activities for cancer information and counseling programs in Japan. *Journal of Cancer Policy*, 27, 100261. <https://doi.org/10.1016/j.jcpo.2020.100261>
- Umar, R., Fadlil, A., & Yuminah. (2018). Sistem Pendukung Keputusan dengan Metode AHP untuk Penilaian Kompetensi Soft Skill Karyawan. *Jurnal Ilmu Komputer Dan Informatika*, 27(1), 27–34.
- Umar, R., Yudhana, A., & Dernata, J. (2022). Analisis Sistem Pendukung Keputusan Seleksi Calon Anggota Organisasi IMM Menggunakan Metode SAW. *Jurnal Teknik Informatika Dan Sistem Informasi*, 9(2), 1068–1079.
<https://doi.org/https://doi.org/10.35957/jatisi.v9i2.1534>
- Winfrey, C., Meleby, P., & Miao, L. (2023). Using big data and machine learning to rank traffic signals in Tennessee. *Journal of Traffic and Transportation Engineering (English Edition)*, 10(5), 918–933. <https://doi.org/10.1016/j.jtte.2023.04.005>
- Yang, J. H., Han, M. Y., & Zuo, Q. W. (2019). Research on optimizing Model of Single-unit System Inspection Interval Based on RAMS and TOPSIS. *Proceedings of 2019 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, QR2MSE 2019, Qr2mse*, 1088–1095.
<https://doi.org/10.1109/QR2MSE46217.2019.9021268>

BAB 7
Identifikasi Citra Kupu-Kupu
Menggunakan Segmentasi *Multilevel Thresholding*
dan Klasifikasi *Convolutional Neural Network*
dengan Arsitektur Alexnet

Ainin Maftukhah, Abdul Fadlil, Sunardi

1.1. PENDAHULUAN

Kupu-kupu dalam taksonomi hewan menduduki ordo tersendiri, yaitu *lepidoptera* yang kalau diterjemahkan ke dalam bahasa Indonesia berarti 'serangga bersayap sisik'. Kupu-kupu berperan penting dalam ekosistem sehingga diperlukan pengetahuan dan pemahaman yang cukup tentang kupu-kupu supaya kelestariannya dapat terjaga. Terutama berkaitan dengan ancaman transformasi cuaca, penyakit, dan predator alaminya (Gonggoli et al., 2021; Maftukhah et al., 2023; Rajab & Asriady, 2015). Penelitian ini bertujuan untuk menemukan solusi alternatif dalam mengidentifikasi jenis kupu-kupu dari data citra diam (*still images*).

Proses pengenalan pola pada citra serta mengklasifikasikan informasi yang terkandung di dalamnya menjadi pembahasan yang berkembang dari waktu ke waktu. Pengenalan pola memberikan penyelesaian untuk permasalahan yang berkaitan dengan identifikasi dan klasifikasi pada beragam objek, seperti tulisan tangan, motif batik, citra berkaitan medis, bahkan citra dari satelit.

Pengenalan pola pada citra kupu-kupu sangat menarik karena mempunyai skema warna serta bentuk yang sangat banyak. Teknologi visi komputer (*computer vision*) telah digunakan untuk mengenali serta mengidentifikasi jenis kupu-kupu pada banyak penelitian. Pemrosesan citra digital (*digital image processing*) sebagai bagian dari *computer vision* melibatkan beberapa tahap, seperti tahap segmentasi citra, tahap ekstraksi fitur, hingga tahap klasifikasi. Tahap segmentasi citra digunakan untuk memisahkan objek serta latar belakang. Tahap ekstraksi fitur menggunakan ekstraksi ciri warna. Tahapan klasifikasi memakai algoritma *Convolutional Neural Network* (CNN) untuk membandingkan fitur yang sudah diekstrak dari data training dan data testing.

Salah Satu metode *deep learning* yang mampu mengidentifikasi objek dalam gambar adalah CNN. Fitur CNN dianggap sebagai pendekatan terbaik dalam deteksi dan pengenalan objek (Hariyani et al., 2020; Hendriyana & Maulana, 2020). CNN merupakan salah satu algoritma kecerdasan buatan yang sudah banyak digunakan untuk memproses citra serta menetapkan bobot dan bias yang bisa dipelajari pada aspek tertentu dalam citra yang dapat membedakan satu citra dengan yang lain (Manuaba & Basiroen, 2023). CNN memiliki pengaturan multi-lapisan dengan pooling lapisan-lapisan termasuk lapisan yang terhubung sepenuhnya. Lapisan CNN mengatur neuron sehingga memiliki tiga dimensi (Chaniago et al., 2022; Han et al., 2020). Ada beberapa arsitektur CNN VGG-16, VGG-19, GoogLeNet, ResNet, dan AlexNet yang telah diterapkan pada klasifikasi citra tanpa melibatkan atau menggunakan proses segmentasi (Akbar & Sandfreni, 2021).

Penelitian ini dilakukan segmentasi citra dengan Multilevel Thresholding untuk memisahkan objek dan background dalam citra kupu-kupu. Jenis kupu-kupu dapat ditentukan berdasarkan nama jenis menggunakan klasifikasi CNN. Metode segmentasi Multilevel Thresholding untuk mendapatkan pemisahan objek dengan latar belakang dan klasifikasi CNN untuk mendapatkan hasil akurasi terbaik.

1.2 TINJAUAN PUSTAKA

Pada fase awal penelitian ini telah melakukan kajian literature dan ditemukan cukup banyak penelitian sejenis yang berkaitan dengan penelitian ini. Penelitian Andrian dkk. membuat model *machine learning* untuk mengklasifikasikan citra kupu-kupu menggunakan metode *K-Nearest Neighbor*. Model tersebut dilaporkan mampu mengklasifikasikan citra kupu-kupu dengan akurasi mencapai 80% (Andrian et al., 2019). Mengimplementasikan algoritma pengoptimalan untuk citra *Multilevel Threhsolding*. Hasil menunjukkan bahwa metode yang diusulkan mengungguli algoritma lainnya. Srikanth & Bikshalu meneliti segmentasi

Multilevel Threhsolding dengan algoritma pencarian harmoni. Objek yang digunakan citra juru kamera, otak, lena, dan lain-lain. Perbandingan menjelaskan bahwa hasil metode yang diusulkan lebih ungu dari pada metode berbasis histogram (Sowjanya & Injeti, 2021).

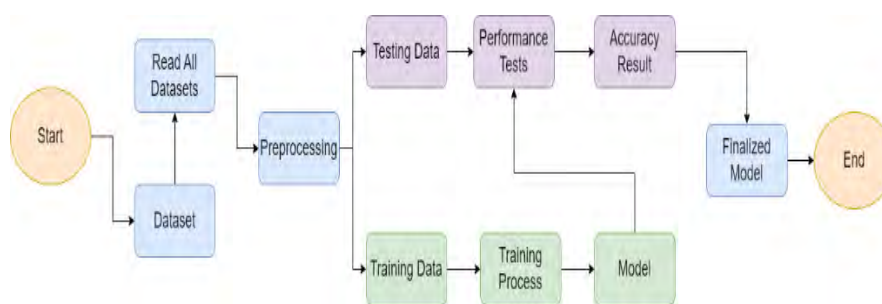
Membandingkan letak polip menggunakan CNN dengan arsitektur *RetinaNet*. Objek yang digunakan citra usus besar. Hasil model terbaik tanpa ekstensi data dengan nilai 0,8415 dan data augmentasi dengan nilai *matrix Ap25* = 0,9308 (Jonathan et al., 2022).

Melakukan klasifikasi menggunakan metode CNN dengan objek pucuk daun teh. Hasil akurasi terbaik 97,5% dengan menggunakan arsitektur VGGNET19 (Ibrahim et al., 2022).

Meneliti *human actifity recognition* berdasarkan tangkapan *webcam* menggunakan metode *Convolutional Neural Network* dengan arsitektur MobileNet. Objek yang digunakan video, *data augmentation* menggunakan *random rotation*. Hasil pengujian menghasilkan model optimal dengan *hyperparameter* dalam bentuk 20 epoch, penghentian awal dengan kesabaran 10, kecepatan pembelajaran 0,0001, ukuran tumpukan 16, dan lapisan padat 5. Model dijalankan dengan validasi silang dan matriks konfusi diuji menghasilkan kinerja hasil akhir F1 sebesar 84,52% (Hariz et al., 2022).

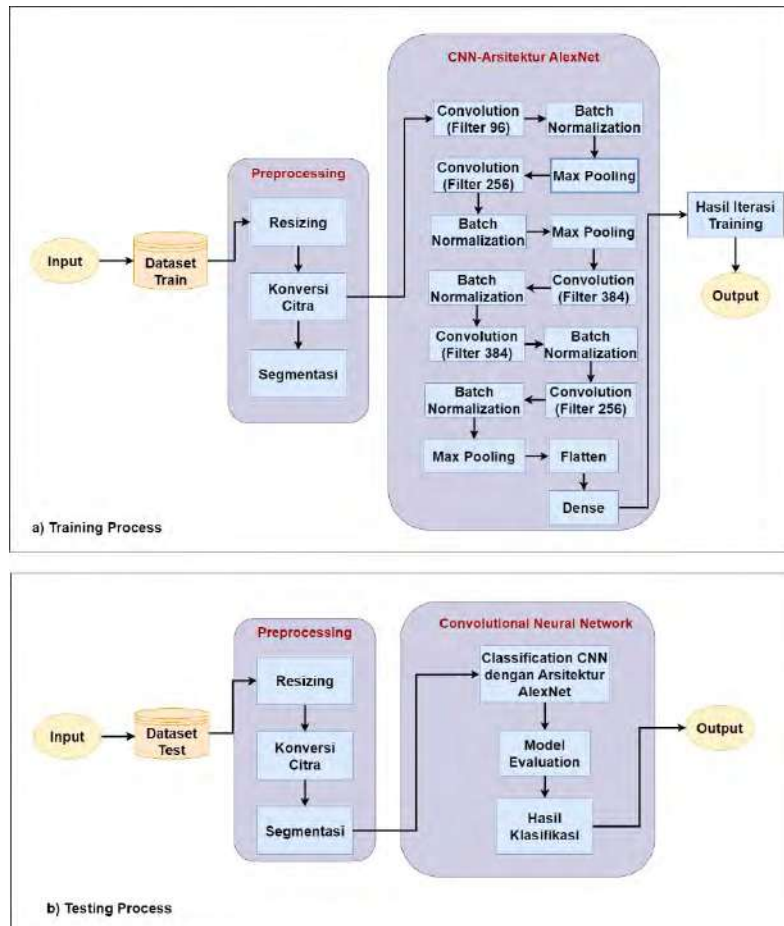
1.3 METODOLOGI PENELITIAN

Pembangunan model klasifikasi untuk mengidentifikasi jenis kupu-kupu pada penelitian ini mengikuti alur seperti ditunjukkan pada Gambar 1.1.



Gambar 1. 1 Alur Penelitian

Gambar 1.1 memperlihatkan langkah pertama adalah *input dataset* yang dilanjutkan dengan pembacaan data tersebut. Setelah itu dilakukan *preprocessing* data. Hasil *preprocessing* dataset dilakukan *training* data, kemudian dilakukan *training* proses sesuai model CNN arsitektur AlexNet. Hasil dari *training* model kemudian dilakukan *testing* data dan dilihat kinerja *testing*. Setelah kinerja *testing* mendapatkan hasil akurasi dan model selesai.



Gambar 1. 2 Proses *Training* dan *Testing*

Proses training dan testing yang ditunjukkan pada Gambar 1.2 pertama dilakukan input dataset train, output dari input data dilakukan *preprocessing* meliputi *resize*, konversi citra, dan segmentasi. Hasil *preprocessing* dilakukan *convolution* dengan filter 96. Output konvolusional dikenali *normalisasi batch*, yaitu ReLU, setelah itu *max pooling* diterapkan ke hasil *normalisasi batch*. Langkah konvolusi, *normalisasi batch*, dan *max pooling* dilakukan sebanyak 5 kali. Kemudian yang terakhir hasil *max pooling* diflatten, hasil *flatten* dilakukan *dense* sebanyak 2 kali. Hasil *dense* dibuat dengan model iterasi *training* untuk mendapatkan hasil terbaik. Hasil klasifikasi tahap terakhir.

1.3.1 DATASET

Dataset penelitian terdiri dari 419 citra kupu-kupu yang diakuisisi dari data repositori Kaggle (<https://www.kaggle.com/datasets/gposenka/butterfly-images40-species>). Data ini mencakup berbagai jenis kupu-kupu termasuk jenis umum, langka dan rentan. Spesies (jenis) merupakan sekelompok organisme yang memiliki ciri-ciri umum yang serupa dan spesies mengacu pada individu bukan kelompok atau golongan. Spesies merupakan toksom tingkatan paling rendah. Atribut kupu-kupu mengacu pada ciri fisik yang dapat diamati atau diidentifikasi pada spesies kupu-kupu, termasuk warna, pola, bentuk sayap, dan ukuran. Menggunakan dataset dengan jumlah data yang cukup besar, variasi jenis kupu-kupu yang banyak akan menghasilkan hasil yang lebih valid dalam membangun model pengenalan.



Gambar 1.3 Citra Kupu-Kupu

1.3.2 DATA PREPROCESSING

Data Preprocessing merupakan langkah awal untuk mempersiapkan data citra saat sebelum diproses lebih lanjut (Hakim et al., 2023). Metode pra-pemrosesan untuk mengurangi perbedaan ini bergantung pada peningkatan kontras dan pemfokusan data (Faria et al., 2018; Ferreira et al., 2020). Tahap *preprocessing* dimana semua ukuran gambar yang tidak sama diubah menjadi 150×150 piksel karena CNN menerima ukuran yang sama. Setelah diubah ukurannya, gambar RGB diubah menjadi skala abu-abu untuk pemrosesan dan pelatihan model (Khodier et al., 2022). Secara digital, gambar skala abu-abu dapat direpresentasikan sebagai matriks dua dimensi. Setiap elemen tabel menunjukkan intensitas (tingkat abu-abu) gambar pada titik koordinat yang sesuai. Jika suatu gambar direpresentasikan sebagai 8-bit, artinya gambar tersebut mempunyai 28 atau 256 tingkat skala abu-abu (biasanya 0 hingga 255), dengan 0 menunjukkan intensitas paling gelap dan 255 menunjukkan intensitas paling terang. Setiap elemen pada tabel di atas disebut elemen gambar atau piksel. Dengan mengubah intensitas setiap piksel, representasi keseluruhan gambar berubah. Suatu citra yang dinyatakan dalam matriks berukuran $M \times N$ mempunyai intensitas tertentu dalam piksel tertentu. Posisi (i,j) dan koordinat (x,y) elemen bayangan berbeda. Penghitungan piksel dimulai dari pojok kiri atas, sedangkan koordinat x dan y berada di pojok kiri bawah (Maria et al., 2018). Pra-pemrosesan ini digunakan untuk menormalkan gambar guna mengevaluasi dampaknya terhadap hasil klasifikasi setiap model CNN. Langkah-langkah untuk melakukan praproses data menggunakan *Tensorflow Preprocessing Library* (Soekarta et al., 2022).

1.3.3 SEGMENTASI CITRA

Segmentasi citra merupakan pembagian suatu citra menjadi beberapa wilayah tersendiri. Metode segmentasi yang berbeda bergantung pada pencarian dalam suatu wilayah atau perbatasannya. Batas wilayah dapat diketahui dengan menggunakan deteksi tepi. Bagian dalam wilayah ditentukan oleh sifat-sifat piksel yang membentuk wilayah tersebut. Metode *thresholding* berbasis wilayah merupakan algoritma segmentasi yang populer (Sundararajan, 2017).

Thresholding merupakan salah satu teknik segmentasi citra. *Thresholding* menunjukkan besarnya tingkat signifikansi tertentu. Ada beberapa variasi *thresholding* yang digunakan dalam pengolahan citra. Tipe awal merupakan dengan mengaplikasikan *thresholding* citra skala abu-abu untuk mendapatkan citra biner. *Thresholding* $T > 0$ ditetapkan dengan semua tingkat abu-abu dengan nilai kurang dari atau sama dengan T ditetapkan ke 0 dan sisanya ditetapkan ke 1 (Sundararajan, 2017). Multilevel *thresholding* merupakan metode yang menggunakan sekumpulan ambang batas untuk mengklasifikasikan piksel suatu citra ke dalam beberapa kategori (Huang et al., 2020). Citra berwarna dibedakan menjadi latar depan dan latar belakang menggunakan lebih dari 2 *threshold* (tingkat tri atau *quad*) untuk

memisahkan tiga komponen R,G,B, memberikan spesifisitas yang sangat baik (Elaziz et al., 2019). Sebagian titik threshold mengklasifikasikan citra ke dalam kelas berbeda yang memberikan opsi untuk analisis wilayah target.

$$O_1(x, y) = \{i(x, y) \in I | 0 \leq I(x, y) \leq m_1 - 1\} \quad (1.1)$$

$$O_2(x, y) = \{i(x, y) \in I | m_1 \leq I(x, y) \leq m_2 - 1\} \quad (1.2)$$

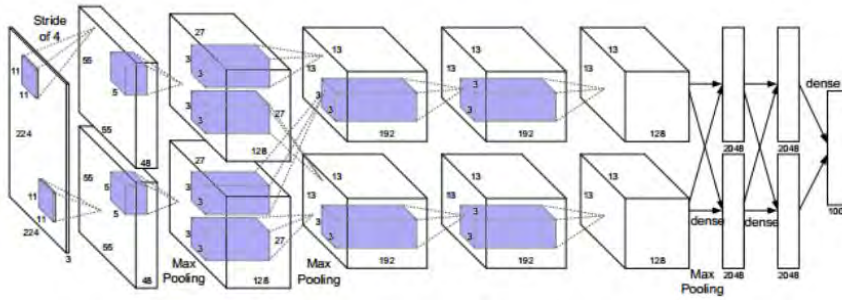
$$O_i(x, y) = \{i(x, y) \in I | m_i \leq I(x, y) \leq m_i - 1\} \quad (1.3)$$

$$O_r(x, y) = \{i(x, y) \in I | m_r \leq I(x, y) \leq L - 1\} \quad (1.4)$$

Dimana $t_1, t_2, t_3, t_4 \dots t_i, \dots t_r$ mewakili ambang batas yang berbeda. Kelompok piksel abu-abu yang berbeda ditetapkan berdasarkan nilai intensitas, dan setiap kelompok memiliki nilai piksel yang berbeda dalam rentang yang ditentukan (Kalyani et al., 2021).

1.3.5 CNN DENGAN ARSITEKTUR ALEXNET

Pemodelan CNN untuk mengklasifikasikan citra menggunakan citra yang sudah diberi label kelas terlebih dahulu. Label kelas menunjukkan kelas dari kumpulan kelas tertentu. Klasifikasi dilakukan dengan menggunakan model yang diperoleh dengan menggunakan prosedur pembelajaran prosedur. Tergantung pada jenis pembelajaran yang digunakan ada dua klasifikasi, satu menggunakan pembelajaran *supervised* dan satu lagi menggunakan *unsupervised* (Murty & Devi, 2018). Tujuan klasifikasi merupakan untuk mengidentifikasi karakteristik, pola, atau struktur suatu citra dan menggunakannya untuk menetapkan ke kelas tertentu. Terkait citra dan rangsangan visual, pengamat manusia sering kali melakukan tugas klasifikasi tertentu dengan akurasi tinggi (Solomon & Breckon, 2018). CNN merupakan metode pendidikan mendalam berlapis- lapis yang memperluas *Artificial Neural Network* (ANN). CNN diproses oleh susunan jaringan serta menciptakan output dari kelas tertentu. Tiap tingkat melaksanakan pelatihan serta *output* dari tiap tingkat yang digunakan selaku *input* buat tingkat selanjutnya. Awal mulanya, CNN menciptakan fitur simpel semacam warna, kecerahan serta tepi, sebaliknya tingkat selanjutnya menciptakan fitur yang lebih lingkungan. CNN terdiri dari tiga lapisan yang terhubung sepenuhnya dan lima lapisan konvolusional. Lapisan *AlexNet* pertama digunakan sebagai gambar filter masukan untuk bidang lebar, tinggi dan kedalaman (merah, hijau, biru) dengan dimensi $227 \times 227 \times 3$. Lapisan komposit terakhir menggabungkan sepenuhnya 1.000 lapisan komposit, dan yang lainnya. Lapisan digunakan sebagai pemisah fitur. Untuk setiap gambar masukan, *AlexNet* menghasilkan vektor fitur berdimensi 4.096 yang berisi lapisan tersembunyi yang diaktifkan tepat sebelum lapisan keluaran. *AlexNet* adalah struktur besar yang berisi 650.000 neuron dan 60 juta parameter. Model ini dilatih pada sekitar 1,2 juta gambar pelatihan dan diuji pada kumpulan data ImageNet yang terdiri dari 150.000 gambar uji. Model ini mengurangi masalah *oversampling* dengan sangat efektif dengan menghapus dan menambahkan data (Mashrur et al., 2019).



Gambar 1. 4 Arsitektur Alexnet

Gambar 1.4 menunjukkan arsitektur *AlexNet* dimulai dengan gambar masukan yang telah diproses sebelumnya dengan ukuran hasil 150x150, kemudian melakukan pemfilteran atau kernel. hasil kernel menggunakan *convolution* yang di *pooling*. *Convolution* dan *max-pooling* dilakukan sebanyak lima kali. Masing-masing dianggap memiliki karakteristik akibat *convolution*. Kemudian dilakukan proses *flatten* untuk mengubah gambar menjadi matriks satu dimensi. Kemudian terhubung sepenuhnya tiga kali. Sebagai langkah terakhir citra dapat diklasifikasikan.

1.3.6 EVALUASI MODEL

Evaluasi model Alexnet digunakan untuk mengetahui efektivitasnya. Evaluasi ini menggunakan matriks akurasi, *recall*, *precision*, dan *F1-score* yang dapat dihitung dengan rumus sebagai berikut:

$$Accuracy(\%) = \frac{TP+TN}{total\ testing\ data} \quad (1.5)$$

$$Recall = \frac{TP}{TP+FN} \quad (1.6)$$

$$Precision = \frac{TP}{TP+FP} \quad (1.7)$$


$$F1 - Score = 2 \times \frac{recall \times precision}{recall + Precision} \quad (1.8)$$

1.4 HASIL DAN PEMBAHASAN


Proses pembangunan model CNN pada penelitian ini menggunakan platform *Google Colab*. Dataset yang digunakan berupa citra kupu-kupu berjumlah 419 citra dari Kaggle. Data citra dibagi menjadi 90% data *training* dan 10% data *testing*. Proses pertama yang dilakukan sebelum klasifikasi untuk mendapatkan hasil terbaik dengan tahap *preprocessing* dan segmentasi *thresholding* yang telah diuji pada dataset citra kupu-kupu. Hasil penelitian membahas analisis tentang perbandingan klasifikasi citra kupu-kupu dengan arsitektur Alexnet menggunakan segmentasi *multilevel threshold* dan tanpa segmentasi.




Gambar 1. 5 Citra Asli Kupu-Kupu



Gambar 1. 6 Hasil *Resizing*



Gambar 1. 7 Hasil RGB ke *Grayscale*



Gambar 1. 8 (a) Citra Asli (b) Hasil Tanpa Segmentasi (c) Hasil Segmentasi *Multilevel Threshold*


Gambar 1.5 merupakan citra asli yang akan diproses untuk *preprocessing*. pada tahap *preprocessing* dilakukan teknik perubahan ukuran dan mengubah warna RGB ke *grayscale*. Hasil perubahan ukuran 150x150 dapat dilihat pada Gambar 1.6 dikarenakan alexnet hanya menerima ukuran gambar yang sama. Konversi RGB ke grayscale untuk meningkatkan efisiensi analisis dapat dilihat pada Gambar 1.7. Setelah tahap RGB to *grayscale* maka dilakukan tahap segmentasi dengan menggunakan teknik segmentasi *multilevel thresholding*. Hasil segmentasi dapat dilihat pada Gambar 1.8(c) dan tanpa segmentasi dapat dilihat pada Gambar 1.8(b). Hasil dari preprocessing digunakan dalam klasifikasi menggunakan metode CNN dengan arsitektur Alexnet.

Tabel 1. 1 Proses *Epoch Training*

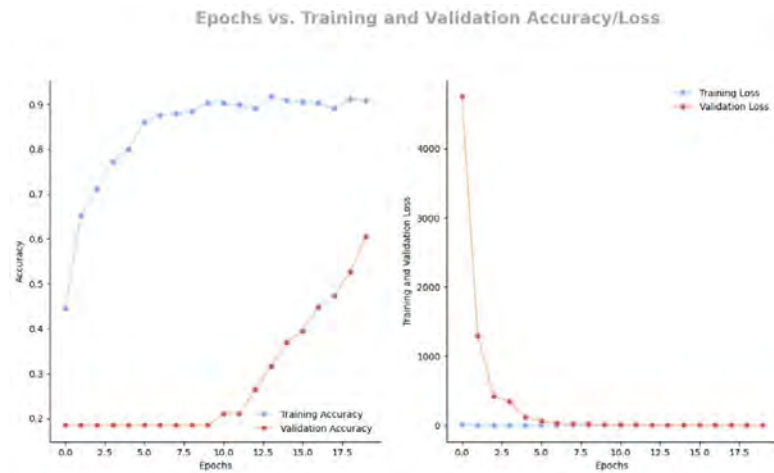
<i>Epoch</i>	<i>Tanpa Segmentasi</i>		<i>Segmentasi Multilevel Threshold</i>	
	<i>Accuracy</i>	<i>Training Loss</i>	<i>Accuracy</i>	<i>Training Loss</i>
1	0.49	9.10	0.44	14.76

2	0.73	2.36	0.65	4.37
3	0.84	1.63	0.71	2.33
4	0.89	0.65	0.77	1.25
5	0.87	0.48	0.79	0.78
6	0.89	0.37	0.86	0.48
7	0.89	0.52	0.87	0.42
8	0.89	0.64	0.87	0.33
9	0.88	0.32	0.88	0.31
10	0.91	0.27	0.90	0.27
11	0.91	0.23	0.90	0.32
12	0.91	0.28	0.89	0.26
13	0.92	0.21	0.89	0.26
14	0.94	0.19	0.91	0.24
15	0.92	0.22	0.90	0.29
16	0.94	0.19	0.90	0.28
17	0.91	0.24	0.90	0.25
18	0.94	0.16	0.89	0.28
19	0.92	0.20	0.91	0.25
20	0.94	0.14	0.90	0.25

Setelah proses 20 *epoch* dilajalakan, model dengan tanpa segmentasi dan menggunakan segmentasi *multilevel thresholding* pada data citra kupu-kupu menetapkan hasil yang cukup memuaskan untuk model simpel. Tabel 1.1 yang mencakup kolom *training* akurasi dan loss merupakan hasil dari *epoch* yang dijalankan, pelatihan model dilakukan *preprocessing* tanpa segmentasi. Meskipun hasil tersebut cukup baik, namun masih terdapat beberapa kesalahan dalam klasifikasi citra kupu-kupu, terutama pada gambar yang tingkat kompleksitas tinggi. Pelatihan model menggunakan segmentasi citra yang diproses dengan teknik *multilevel thresholding*. Teknik ini digunakan untuk memisahkan objek dari latar belakang berdasarkan tingkat kecerahan piksel, dengan segmentasi teknik *multilevel thresholding*, model tidak dapat mengklasifikasikan citra dengan akurat. Hasil proses epoch yang ditampilkan dari nilai fungsi *training loss* dan *training* akurasi membantu mengevaluasi efektivitas model dalam mengklasifikasikan data train, serta meningkatkan setiap proses *epoch* selama pelatihan.



Gambar 1.9 Grafik Akurasi dan *Loss* Tanpa Segmentasi




Gambar 1. 10 Grafik Akurasi dan *Loss* Segmentasi *Multilevel Threshold*

Gambar 9 dan Gambar 10 dapat dianalisis bahwa hasil akurasi dan *loss* grafik dihasilkan dengan pengujian menggunakan arsitektur *Alexnet* tanpa segmentasi serta menggunakan segmentasi *multilevel thresholding*. Grafik akurasi dan *loss* digunakan untuk memahami performa model dalam mengklasifikasikan citra kupu-kupu. Terlihat dari grafik akurasi, akurasi model meningkat seiring dengan banyaknya *epoch* yang dilakukan. Pada awal pelatihan, akurasi model cenderung rendah, namun seiring berjalannya waktu akurasi model meningkat secara signifikan. Hal ini menunjukkan bahwa model secara bertahap berlatih mengklasifikasikan citra dengan lebih baik. Pada saat yang sama, dalam grafik *loss*, dapat dilihat bahwa *loss* model berkurang seiring dengan bertambahnya jumlah *epoch* eksekusi. *Loss* merupakan ukuran seberapa jauh prediksi model dengan nilai sebenarnya, sehingga semakin rendah nilai *loss* maka kualitas prediksi model akan semakin baik. Penelitian ini terlihat bahwa model tersebut berhasil mengurangi *loss* secara signifikan dari waktu ke waktu. Hasil keluaran dari proses trining dapat dilihat pada Gambar 1.11.

	precision	recall	f1-score	support
0	1.00	0.45	0.62	11
1	0.78	0.47	0.58	15
2	0.35	0.88	0.50	8
3	0.88	0.88	0.88	8
accuracy			0.62	42
macro avg	0.75	0.67	0.65	42
weighted avg	0.77	0.62	0.63	42

Gambar 1. 11 Proses *Training Alexnet* dengan Segmentasi *Multilevel Threshold*




Gambar 1. 12 *Confusion Matrix Alexnet* dengan Segmentasi *Multilevel Threshold*

Gambar 1.12 menyajikan temuan tersebut. Hasil dari matriks kebingungan menunjukkan bahwa 5 gambar Adonis diprediksi secara akurat dari data asli. 5 gambar menunjukkan burung sombong Amerika, tetapi satu gambar yang menampilkan Adonis diidentifikasi sebagai burung walet raksasa Afrika. Dari data asli, 7 gambar burung walet Afrika dianggap bagus. African Snoot harus digunakan untuk 7 gambar, dan salah satu dari gambar tersebut adalah AN88. 7 gambar yang dinilai terbaik dari informasi asli burung African snoot. Yang harus dianggap dengan African giant Swallowtail adalah 7 gambar. 7 gambar AN88 telah disetujui untuk data mentah. 7 gambar akan dianggap dengan African Snoot. Hasil keluaran dari proses trining dapat dilihat pada Gambar 1.13.

	precision	recall	f1-score	support
0	0.91	0.91	0.91	11
1	0.86	0.80	0.83	15
2	0.86	0.75	0.80	8
3	0.80	1.00	0.89	8
accuracy			0.86	42
macro avg	0.86	0.86	0.86	42
weighted avg	0.86	0.86	0.86	42

Gambar 1. 13 Proses Training Alexnet tanpa Segmentasi *Multilevel Threshold*



Gambar 1. 14 *Confusion Matrix* Alexnet tanpa Segmentasi Multilevel Threshold

Hasilnya ditunjukkan pada Gambar 1.14. Hasil konfusi matriks menunjukkan bahwa 10 citra Adonis yang dinyatakan baik diprediksi dari data aslinya. 1 gambar dengan Adonis dianggap sebagai African Giant Swallowtail. 12 gambar African Giant Swallowtail yang dinilai bagus

diantara data aslinya. 1 citra harus dianggap dengan African Snoot dan 2 citra AN88. 6 gambar African Snoot yang dianggap bagus di antara informasi aslinya. 1 citra untuk dianggap bersama African Giant Swallowtail dan 1 citra Adonis. 8 gambar AN88 diterima sebagai data mentah.

Tabel 1. 2 Hasil Pengujian

Class	Amount of data	Without Segmentation		Segmentation Multilevel Threshold	
		True	False	True	False
Adonis	11	9	2	5	6
African Giant Swallowtail	15	11	4	7	8
American Snoot	8	7	1	7	1
An 88	8	8	0	7	1
Accuracy(%)		83%		62%	

Menganalisis dari Tabel 2 hasil pengujian dari data testing 10% akurasi akhir diperoleh dengan arsitektur Alexnet tanpa segmentasi dan menggunakan segmentasi *multilevel threshold*. Pada Tabel 2 terlihat bahwa model tanpa segmentasi mampu mengklasifikasikan citra dengan akurasi yang tinggi, sedangkan menggunakan segmentasi *multilevel threshold* tidak dapat mengklasifikasikan citra dengan akurasi yang tinggi. Hasil pengujian menunjukkan bahwa model tanpa segmentasi memiliki akurasi 83%, sementara model dengan segmentasi *multilevel threshold* hanya mencapai akurasi 62%.

Perbandingan akurasi ini bisa diakibatkan oleh sebagian faktor, seperti model tanpa segmentasi dapat lebih mudah mengidentifikasi dan membedakan fitur-fitur penting dalam citra, sehingga model tersebut dapat menghasilkan prediksi yang lebih akurat. Pada saat yang sama model dengan segmentasi multilevel thresholding dapat mengalami kesulitan dalam mengidentifikasi dan membedakan fitur-fitur penting, sehingga menghasilkan prediksi yang kurang akurat. Penggunaan segmentasi *multilevel threshold* bisa jadi menyebabkan hilangnya data penting pada citra, sehingga model kesusahan dalam mengklasifikasikan informasi dengan benar. Sedangkan itu, model tanpa segmentasi dapat memanfaatkan data lengkap pada citra buat menciptakan prediksi yang lebih akurat. Karena penggunaan jaringan saraf konvolusional dalam arsitektur AlexNet, keunggulannya adalah kemampuan model untuk mengekstrak fitur hierarki secara otomatis. AlexNet telah terbukti efektif dalam menyelesaikan tugas klasifikasi gambar yang kompleks. Namun, potensi kerugiannya mencakup kebutuhan data dalam jumlah besar untuk pelatihan yang optimal dan kompleksitas komputasi yang lebih tinggi dibandingkan model yang lebih sederhana.

1.5 KESIMPULAN

Penelitian ini telah membuat model klasifikasi citra menggunakan algoritma CNN untuk mengidentifikasi jenis kupu-kupu. Penelitian menggunakan segmentasi *multilevel thresholding* dan pemodelan dibuat dengan arsitektur AlexNet pada platform Google Colabs. Hasil pengujian menampilkan bahwa gabungan segmentasi *multilevel thresholding* serta arsitektur AlexNet menciptakan model klasifikasi yang kurang akurat dalam mengenali jenis kupu-kupu. Perbandingan dari hasil pengujian ini, bisa disimpulkan bahwa model tanpa segmentasi cenderung lebih baik dalam mengklasifikasikan data citra dengan mendapatkan

hasil akurasi 83%, dibanding dengan model menggunakan segmentasi *multilevel threshold* mendapatkan hasil akurasi 62%. Dengan demikian pemilihan teknik segmentasi yang sesuai sangat diperlukan untuk mengklasifikasikan objek yang berbeda-beda dengan beragam tingkat kompleksitasnya.

DAFTAR PUSTAKA

- Akbar, H., & Sandfreni, S. (2021). Klasifikasi Kanker Serviks Menggunakan Model Convolutional Neural Network Alexnet. *JIKO (Jurnal Informatika Dan Komputer)*, 4(1), 44–51. <https://doi.org/10.33387/jiko.v4i1.2606>
- Andrian, R., Anwar, S., Muhammad, M. A., & Junaidi, A. (2019). Identifikasi Kupu-Kupu Menggunakan Ekstraksi Fitur Deteksi Tepi (Edge Detection) dan Klasifikasi K-Nearest Neighbor (KNN). *Jurnal Teknik Informatika Dan Sistem Informasi*, 5(2), 234–243. <https://doi.org/10.28932/jutisi.v5i2.1744>
- Chaniago, M. D., Sugiharto, A. A., Khatulistiwa, Q. D., Sari, Z., & Eko, A. (2022). Covid-19 Detection Using Convolutional Neural Networks (CNN) Classification Algorithm. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(2), 190–197. <https://doi.org/10.29207/resti.v6i2.3823>
- Elaziz, M. A., Bhattacharyya, S., & Lu, S. (2019). Swarm selection method for multilevel thresholding image segmentation. *Expert Systems with Applications*, 138. <https://doi.org/10.1016/j.eswa.2019.07.035>
- Faria, L. C. De, Rodrigues, L. F., & Mari, F. (2018). Cell Classification using Handcrafted Features and Bag of Visual Words. *XIV Workshop de Visão Computacional (WVC), November*.
- Ferreira, L., Coelho, M., & Fernando, J. (2020). Comparing Convolutional Neural Networks and Preprocessing Techniques For Hep-2 Cell Classification In Immunofluorescence Images. *Computers in Biology and Medicine*, 116(November 2019), 103542. <https://doi.org/10.1016/j.compbiomed.2019.103542>
- Gonggoli, A. D., Sari, S., Oktofiani, H., Santika, N., Herlina, R., Agatha, T., & Gunawan, Y. E. (2021). Identifikasi Jenis Kupu-Kupu (Lepidoptera) di Universitas Palangka Raya. *Bioeksperimen*, 7(1), 16.
- Hakim, L., Rahmanto, H. R., Kristanto, S. P., & Yusuf, D. (2023). Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network. *Jurnal Teknoinfo*, 17(1), 203. <https://doi.org/10.33365/jti.v17i1.2342>
- Han, F., Yao, J., Zhu, H., & Wang, C. (2020). Marine Organism Detection and Classification from Underwater Vision Based on the Deep CNN Method. *Mathematical Problems in Engineering*, 2020. <https://doi.org/10.1155/2020/3937580>
- Hariyani, Y. S., Hadiyoso, S., & Siadari, T. S. (2020). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 8(2), 443. <https://doi.org/10.26760/elkomika.v8i2.443>
- Hariz, F. A., Yulita, I. N., & Suryana, I. (2022). Human Activity Recognition Berdasarkan Tangkapan Webcam Menggunakan Metode Convolutional Neural Network (CNN) Dengan Arsitektur MobileNet Human Activity Recognition Berdasarkan Tangkapan Webcam Menggunakan Metode Convolutional Neural Network (CNN) Dengan. *Ilmiah Teknologi Sistem Informasi*, 3(4), 103–115.
- Hendriyana, H., & Maulana, Y. H. (2020). Identification of Types of Wood using Convolutional Neural Network with Mobilenet Architecture. *Jurnal RESTI (Rekayasa*

- Sistem Dan Teknologi Informasi*), 4(1), 70–76. <https://doi.org/10.29207/resti.v4i1.1445>
- Huang, X., Shen, L., Fan, C., zhu, J., & Chen, S. (2020). *Multilevel Image Thresholding Using a Fully Informed Cuckoo Search Algorithm*. 1–12. <http://arxiv.org/abs/2006.09987>
- Ibrahim, N., Lestray, G. A., Hanafi, F. S., Saleh, K., Pratiwi, N. K. C., Haq, M. S., & Mastur, A. I. (2022). Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(1), 162–176. <https://doi.org/10.26760/elkomika.v10i1.162>
- Jonathan, R. D., Hasugian, M. J., & Sartika, E. M. (2022). *Perbandingan Deteksi Letak Polip pada Citra Colonoscopy menggunakan CNN dengan Arsitektur RetinaNet*. 10(4), 946–960. <https://doi.org/10.26760/elkomika.v10i4.945>
- Kalyani, R., Sathya, P. D., & Sakthivel, V. P. (2021). Multilevel Thresholding for Medical Image Segmentation Using Teaching-Learning Based Optimization Algorithm. *International Journal of Intelligent Engineering and Systems*, 14(2), 11–21. <https://doi.org/10.22266/ijies2021.0430.02>
- Khodier, M. M., Ahmed, S. M., & Sayed, M. S. (2022). Complex Pattern Jacquard Fabrics Defect Detection Using Convolutional Neural Networks and Multispectral Imaging. *IEEE Access*, 10, 10653–10660. <https://doi.org/10.1109/ACCESS.2022.3144843>
- Maftukhah, A., Fadlil, A., & Sunardi, S. (2023). Segmentasi Citra Kupu-Kupu Menggunakan Metode Multilevel Thresholding. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 7(2), 545–554.
- Manuaba, I. B. K., & Basiroen, V. J. (2023). Comparison Study of Image Augmentation on Modified Cnn Architecture for Indonesian Lasem-Batik'S Motifs. *ICIC Express Letters*, 17(4), 409–417. <https://doi.org/10.24507/icicel.17.04.409>
- Maria, E., Yulianto, Y., Arinda, Y. P., Jumiati, J., & Nobel, P. (2018). Segmentasi Citra Digital Bentuk Daun Pada Tanaman Di Politani Samarinda Menggunakan Metode Thresholding. *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 2(1), 37. <https://doi.org/10.30872/jurti.v2i1.1377>
- Mashrur, F. R., Dutta Roy, A., & Saha, D. K. (2019). Automatic Identification of Arrhythmia from ECG Using AlexNet Convolutional Neural Network. *International Conference on Electrical Information and Communication Technology, EICT, December*, 20–22. <https://doi.org/10.1109/EICT48899.2019.9068806>
- Murty, M. N., & Devi, D. V. S. (2018). Introduction to pattern Recognition and Machine Learning. In *Angewandte Chemie International Edition*, 6(11), 951–952. (Vol. 3, Issue 1). <https://medium.com/@arifwicaksanaa/pengertian-use-case-a7e576e1b6bf>
- Rajab, A., & Asriady, D. (2015). *Keanekaragaman Jenis Kupu-Kupu Papilionidae*. Tn-Babul.
- Soekarta, R., Nurdjan, N., & Syah, A. (2022). Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas Batanghari Jambi*, 22(2), 900. <https://doi.org/10.33087/jiubj.v22i2.2065>
- Solomon, C., & Breckon, T. (2018). *Fundamentals of Digital Image Processing A Practical Approach with Examples in Matlab*.
- Sowjanya, K., & Injeti, S. K. (2021). Investigation of butterfly Optimization and Gases Brownian Motion optimization Algorithms for Optimal Multilevel Image Thresholding. *Expert Systems with Applications*, 182, 115286. <https://doi.org/10.1016/j.eswa.2021.115286>
- Sundararajan, D. (2017). Digital image processing: A signal processing and algorithmic approach. In *Digital Image Processing: A Signal Processing and Algorithmic Approach*. <https://doi.org/10.1007/978-981-10-6113-4>



Ainin Maftukhah is a graduate of Informatics, Faculty of Industrial Technology, Universitas Ahmad Dahlan Yogyakarta. She continues her master's degree in informatics at Universitas Ahmad Dahlan Yogyakarta. She is interested in computer vision.



Abdul Fadlil is a lecturer at Ahmad Dahlan University (UAD) Yogyakarta. He earned his Doctorate degree from Universiti Teknologi in 2006, earned his Master of Engineering degree in Electrical Engineering study programme of Gadjah Mada University in 2000 and Bachelor of Physics obtained from Gadjah Mada University in 1992. He has been a permanent lecturer at Ahmad Dahlan University since January 1996. The courses he teaches are Intelligent Systems and Signal Systems.

Sunardi is a lecturer at Ahmad Dahlan University (UAD) . He received his bachelor's degree from Gadjah Mada University, Yogyakarta, in 1999, master's degree from Bandung Institute of Technology, Indonesia, in 2003, and Ph.D. degree from Universiti Teknologi Malaysia, Johor Bahru, Malaysia, in 2011, all in electrical engineering. Currently, he is a lecturer at the Department of Electrical Engineering, Ahmad Dahlan University, Yogyakarta. His research interests include data, break information, and communication.



Buku ini merupakan kompilasi beberapa laporan penelitian berkaitan dengan sistem penunjang keputusan (Decision Support System) dan kecerdasan buatan (Artificial Intelligence), terutama pemodelan Machine Learning. Praktisi pendidikan dan akademisi di bidang teknik informatika (Computer Science) tentunya memahami betapa kemajuan pemodelan machine learning dan aplikasinya yang menjadi bagian utama dari artificial intelligence bermula dari pemrograman komputer konvensional. Berangkat dari pemrograman model matematika, model statistik, sistem pakar, sistem penunjang keputusan, sehingga sampai pada pemodelan machine learning. Dimana pemrograman komputer konvensional sudah berganti menjadi pemrograman yang membuat sistem bisa belajar dan berkembang dari data yang diolah. Tujuh bab artikel dalam buku ini menyandingkan laporan penelitian decision support system bisa nampak terhubung dan selaras dengan penelitian yang sudah menggunakan pemodelan machine learning. Memang begitulah teknologi berkembang datang silih berganti sebagai sebuah evolusi.



Penerbit UAD Press

Universitas Ahmad Dahlan - Kampus 2, Jl. Pramuka No.42, Pandeyan,
Kec. Umbulharjo, Kota Yogyakarta, Daerah Istimewa Yogyakarta 55161
Telp/Fax : 0882-3949-9820