

**Jurnal
Informatika & Teknologi Cerdas**




JITC



Vol. 2 No. 1 Tahun 2026

Diterbitkan oleh:

 Program Studi Teknik Informatika
Fakultas Ilmu Rekayasa
Universitas Paramadina

Juni 2026

JURNAL INFORMATIKA & TEKNOLOGI CERDAS (JITC)

Volume 2, Nomor 1, Juni 2026

Tinjauan Literatur: Penerapan Teknologi Blockchain dalam Sistem Verifikasi Sertifikat Akademik
Wisnu Rizki Ferdiansyah, Safani Nur Awal, Muhamad Tsaqif

Applications of WDM System in US Patents
Mhnd Farhan

Prediksi Prognosis Kanker Payudara Menggunakan Hybrid Artificial Neural Network dan Gaussian Naïve Bayes
Jesika Octavia Hutagaol, Margaretha Yohanna, Harlen Gilbert Simanullang

Sistem Pendukung Keputusan Seleksi Penerima Beasiswa KIP Kuliah Menggunakan Metode SAW dengan Pembobotan Kriteria Akademik dan Kondisi Ekonomi Mahasiswa
Laura, Yaslinda Lizar

Klasifikasi Sampah Berbasis Citra Menggunakan Metode CNN: Studi Komparatif dengan Decision Tree, Random Forest, dan SVM untuk Pengelolaan Sampah Berkelanjutan
Nabila Carrissa Dewi, Gus Nanang Syaifuddin

JURNAL INFORMATIKA & TEKNOLOGI CERDAS (JITC)
Volume 2, Nomor 1, Juni 2026

Advisor

Rektor Universitas Paramadina

Editor in Chief

Dr. Diki Gita Purnama, M.Kom. : Universitas Paramadina, Indonesia

Editorial Board

Retno Hendrowati, M.T. : Universitas Paramadina, Indonesia
Wahyuningdiah Trisari H.P, M.T.I. : Universitas Paramadina, Indonesia
Deshinta Arrova Dewi, PhD. : INTI University, Malaysia
Muhammad Darwis, M.Kom. : Universitas Paramadina, Indonesia
Rahmad Syahlevi, M.T.I. : Universitas Paramadina, Indonesia

Reviewers

Dr. Harry T. Y. Achsan, M.Kom. : Universitas Paramadina, Indonesia
Dr. Harry Limantho : Institut Pertanian Bogor, Indonesia
Ir. Akbar Iskandar, S.Pd, M.Kom. : Universitas Teknologi Akba Makassar, Indonesia
Quintin Dikara Barcah, M.Sc. : Universitas Paramadina, Indonesia
Tri Basuki Kurniawan, S.Kom., M.Eng., Ph.D. : Universitas Bina Darma, Indonesia
Dr. Markani Pato, S.Kom, M.Pd. : Universitas Teknologi Akba Makassar, Indonesia
Ritna Wahyuni, S.Kom, M.Kom. : Institut Teknologi Sawit Indonesia, Indonesia

Secretariat

Shabrina Putri

Editorial Address

Program Studi Teknik Informatika
Universitas Paramadina Kampus Cipayung
Jl. Raya Mabes Hankam Kav. 9 Setu, Cipayung, Jakarta Timur – 13880

JURNAL INFORMATIKA & TEKNOLOGI CERDAS (JITC)
Volume 2, Nomor 1, Juni 2026

Daftar Isi

Tinjauan Literatur: Penerapan Teknologi Blockchain dalam Sistem Verifikasi Sertifikat Akademik	1-5
Wisnu Rizki Ferdiansyah, Safani Nur Awal, Muhamad Tsaqif	
Applications of WDM System in US Patents	6-9
Mhnd Farhan	
Prediksi Prognosis Kanker Payudara Menggunakan Hybrid Artificial Neural Network dan Gaussian Naïve Bayes	10-15
Jesika Octavia Hutagaol, Margaretha Yohanna, Harlen Gilbert Simanullang	
Sistem Pendukung Keputusan Seleksi Penerima Beasiswa KIP Kuliah Menggunakan Metode SAW dengan Pembobotan Kriteria Akademik dan Kondisi Ekonomi Mahasiswa	16-20
Laura, Yaslinda Lizar	
Klasifikasi Sampah Berbasis Citra Menggunakan Metode CNN: Studi Komparatif dengan Decision Tree, Random Forest, dan SVM untuk Pengelolaan Sampah Berkelanjutan	21-28
Nabila Carrissa Dewi, Gus Nanang Syaifuddiin	

Tinjauan Literatur: Penerapan Teknologi Blockchain dalam Sistem Verifikasi Sertifikat Akademik

Wisnu Rizki Ferdiansyah^{1*}, Safani Nur Awal², Muhamad Tsaqif³

^{1,2,3}Program Studi Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto
Email: ^{1*}wisnu.rizki.f02@gmail.com, ²safaninur0000@gmail.com, ³much.tsaqif@gmail.com

Abstrak - Penelitian ini mengevaluasi penerapan teknologi blockchain untuk mengatasi pemalsuan sertifikat akademik menggunakan metode Systematic Literature Review (SLR) berdasarkan pedoman PRISMA (2022–2025). Dari analisis terhadap tujuh studi terpilih, ditemukan bahwa arsitektur paling efektif adalah model hybrid yang menggabungkan public blockchain (Ethereum) dan penyimpanan off-chain (IPFS) dengan integrasi QR Code. Implementasi ini terbukti menjamin integritas data (immutability) dan memangkas waktu verifikasi menjadi hitungan detik. Namun, karena kendala biaya transaksi tinggi dan privasi data, penelitian selanjutnya disarankan berfokus pada solusi consortium blockchain atau teknologi Layer-2.

Kata kunci: Blockchain, Verifikasi Sertifikat Akademik, Systematic Literature Review, Ethereum, IPFS.

Abstract - This study evaluates the application of blockchain technology to address academic certificate forgery using a Systematic Literature Review (SLR) based on PRISMA guidelines (2022–2025). Analysis of seven selected studies reveals that the most effective architecture is a hybrid model combining public blockchain (Ethereum) and off-chain storage (IPFS) integrated with QR Codes. This implementation is proven to guarantee data immutability and reduce verification time to seconds. However, due to high transaction costs and privacy issues, future research is recommended to focus on consortium blockchain or Layer-2 solutions.

Keywords— Blockchain, Academic Certificate Verification, Systematic Literature Review, Ethereum, IPFS.

I. PENDAHULUAN

Pemalsuan ijazah dan kredensial akademik telah menjadi isu global signifikan yang merusak integritas pendidikan dan pasar tenaga kerja [1][2][3]. Praktik ini mencakup pemalsuan dokumen fisik hingga peretasan basis data institusi [4][5]. Sistem verifikasi konvensional yang seringkali manual, terpusat, dan berbasis kertas, terbukti tidak efisien, memakan waktu, mahal, serta rentan terhadap manipulasi dan kegagalan sistem [6][7]. Verifikasi seringkali memerlukan komunikasi langsung dengan institusi penerbit atau perantara [8]. Ketergantungan pada basis data terpusat menimbulkan risiko keamanan serta single point of failure [9][10]. Selain itu, fitur keamanan fisik pada sertifikat sulit diverifikasi secara independen oleh pihak ketiga [4]. Keterbatasan ini menuntut solusi yang lebih andal, seiring meningkatnya kebutuhan transparansi di sektor pendidikan [11].

Teknologi blockchain, sebagai buku besar digital terdistribusi yang diamankan secara kriptografis [12][13][14][15], menawarkan solusi potensial [16]. Sifat utamanya, yaitu immutability (kekekalan data) dan desentralisasi (tanpa otoritas pusat) [17][18][19], secara inheren mengatasi kelemahan sistem tradisional. Blockchain memungkinkan pembuatan catatan kredensial yang aman, transparan, dan tahan manipulasi [20][21]. Hal ini juga memfasilitasi proses verifikasi yang lebih efisien tanpa memerlukan perantara terpusat [1].

Namun, hingga kini belum terdapat studi literatur yang komprehensif mengenai implementasi teknologi blockchain dalam verifikasi kredensial akademik. Kekosongan informasi ini menunjukkan perlunya penelitian pendahuluan berbasis Systematic Literature Review (SLR) guna mengidentifikasi, memetakan, dan mensintesis hasil penelitian terdahulu di bidang ini. Pendekatan SLR, sebagaimana dikemukakan oleh Pati dan Lorusso [22], bertujuan mengumpulkan, mengevaluasi secara kritis, serta mengintegrasikan temuan-temuan penelitian untuk memperoleh pemahaman yang utuh mengenai topik yang dikaji.

Penelitian ini bertujuan memberikan gambaran menyeluruh tentang tren, manfaat, dan tantangan implementasi blockchain pada sistem verifikasi kredensial akademik. Selain itu, hasil analisis SLR diharapkan dapat menghasilkan rekomendasi praktis bagi institusi pendidikan, pengembang teknologi, dan pembuat kebijakan dalam merancang solusi berbasis blockchain yang efektif dan efisien guna menjaga integritas akademik.

Pertanyaan penelitian (RQ) pada penelitian ini sebagai berikut:

RQ1: Bagaimana konsep dan mekanisme kerja teknologi blockchain dalam konteks verifikasi sertifikat akademik?

RQ2: Bagaimana hasil implementasi blockchain pada sistem verifikasi sertifikat akademik yang telah dibahas dalam penelitian terdahulu?

RQ3: Apa tantangan dan keterbatasan yang dihadapi dalam implementasi blockchain untuk verifikasi kredensial akademik?

II. METODE PENELITIAN

Penelitian ini menggunakan metode *Systematic Literature Review* (SLR) dengan mengadopsi pedoman *Preferred Reporting Items for Systematic Review and Meta-Analyses* (PRISMA). Pendekatan ini dipilih untuk menjamin transparansi dan reproduksibilitas dalam proses pengumpulan, penyaringan, dan sintesis literatur yang relevan. Kerangka PRISMA digunakan untuk meminimalkan bias seleksi dan memastikan kualitas studi yang dianalisis dalam menjawab pertanyaan penelitian mengenai penerapan *blockchain* pada verifikasi sertifikat akademik.

A. Strategi Pencarian (Search Strategy)

Pencarian literatur dilakukan secara terstruktur melalui basis data akademik *Google Scholar*, yang dipilih karena kemampuannya menyajikan artikel terkurasi beserta konteks sitasinya. Proses pencarian dibatasi pada rentang publikasi 2022 hingga 2025 untuk memastikan relevansi dan keterkinian teknologi yang dikaji.

String pencarian (*search string*) disusun menggunakan operator Boolean dengan kombinasi kata kunci berikut: “*blockchain*”, “*blockchain technology*”, “*academic certificate verification*”, “*academic credential verification*”, “*digital academic certificates*”, dan “*blockchain-based credential system*”.

B. Kriteria Inklusi dan Eksklusi Artikel

Untuk menyeleksi artikel yang paling relevan, ditetapkan kriteria inklusi dan eksklusi (Tabel 1). Artikel disaring melalui tiga tahapan: pemeriksaan judul, abstrak, dan pembacaan teks lengkap (*full-text*).

TABEL 1. Kriteria Inklusi dan Eksklusi Artikel

Kriteria Inklusi	Kriteria Eksklusi
Artikel berbahasa Inggris atau Bahasa Indonesia	Artikel non-bahasa Inggris atau Bahasa Indonesia
Teks lengkap dapat diakses	Artikel dengan teks lengkap yang tidak dapat diakses
Artikel yang dipublikasikan dalam jurnal ilmiah atau prosiding konferensi	Publikasi selain jurnal atau prosiding konferensi
Artikel yang diterbitkan pada periode 2022–2025 serta membahas penerapan teknologi <i>blockchain</i> dalam sistem verifikasi sertifikat atau kredensial akademik	Artikel yang diterbitkan di luar rentang tahun 2022–2025 atau tidak relevan dengan topik verifikasi sertifikat akademik berbasis <i>blockchain</i>

C. Proses Seleksi dan Ekstraksi Data

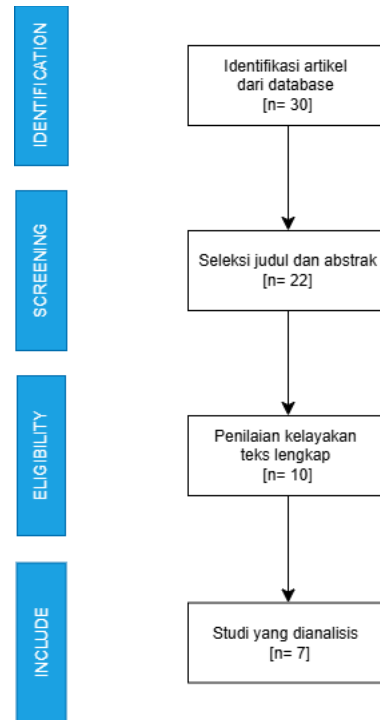
Proses seleksi mengikuti diagram alir PRISMA (Gambar 1). Dari hasil pencarian awal, dilakukan penyaringan duplikasi dan relevansi judul/abstrak. Artikel yang lolos tahap awal dievaluasi kelayakannya berdasarkan ketersediaan teks lengkap dan kesesuaian konten dengan pertanyaan penelitian.

Data dari artikel terpilih kemudian diekstraksi meliputi: (1) Identitas studi (penulis, tahun), (2) Pendekatan teknologi *blockchain* yang digunakan, (3) Mekanisme verifikasi yang

diusulkan, dan (4) Temuan utama terkait manfaat serta tantangan implementasi.

D. Analisis Data

Data dianalisis menggunakan pendekatan kualitatif tematik. Temuan dikelompokkan berdasarkan tema utama yang diturunkan dari pertanyaan penelitian, yaitu: mekanisme kerja *blockchain*, hasil implementasi sistem, serta tantangan yang dihadapi. Sintesis ini bertujuan memberikan gambaran komprehensif mengenai kontribusi teknologi *blockchain* dalam menjaga integritas sertifikat akademik.



Gambar 1. Diagram Alir PRISMA Proses Seleksi Artikel

III. HASIL DAN PEMBAHASAN

Berdasarkan proses seleksi PRISMA, diperoleh 7 artikel yang memenuhi kriteria inklusi. Tabel 2 menyajikan ringkasan studi yang dianalisis dalam tinjauan ini. Mayoritas penelitian berfokus pada pengembangan purwarupa (*prototype*) sistem verifikasi menggunakan platform *blockchain* publik (seperti *Ethereum*) maupun privat (*Hyperledger*).

TABEL 2. Daftar Artikel Terpilih Hasil SLR

No	Daftar Artikel Terpilih (Blockchain – Academic Credential Verification)		
	Penulis	Judul Artikel	Tahun
1	Taufiq Rizky Darmawan Suseno, Irawan Afrianto, Sufa Atin	Strengthening data integrity in academic document recording with blockchain and InterPlanetary file system	2024
2	Nur Khairunnisa Noorhizam a, Zubaile	Verification of Ph.D. Certificate Using QR	2023

No	Daftar Artikel Terpilih (Blockchain – Academic Credential Verification)		
	Penulis	Judul Artikel	Tahun
	Abdullah a., Shahreen Kasim a, Isredza Rahmi A Hamid a, Mohd Anuar Mat Isa	Code on Blockchain Ethereum	
3	Olaya Samuel Oluwaseyi & R.O. Akinyede	Utilizing Blockchain Technology for University Certificate Verification System	2024
4	Faton Kabashi, Halil Snopçe, Artan Luma1, Vehbi Neziri	Trustworthy Verification of Academic Credentials through Blockchain Technology	2024
5	Noshi, Yuan Xu	Development of Blockchain-Based Academic Credential Verification System	2024
6	Mariano Anthony Cardenas-Quispe & Alex Pacheco	Blockchain ensuring academic integrity with a degree verification prototype	2025
7	Ruqaya Abdelmagid, Mohamed Abdelsalam, Fahad Kamal Alsheref	A Blockchain Framework for Academic Certificates Authentication	2024

A. Mekanisme dan Arsitektur Sistem

RQ1: Bagaimana konsep dan mekanisme kerja teknologi *blockchain* dalam konteks verifikasi sertifikat akademik?

Berdasarkan analisis literatur, terdapat pola umum dalam mekanisme kerja verifikasi sertifikat akademik berbasis *blockchain*. Arsitektur sistem yang diusulkan umumnya melibatkan integrasi antara *smart contract*, penyimpanan terdesentralisasi, dan antarmuka verifikasi.

- Platform Blockchain:** Sebagian besar studi, termasuk Cardenas-Quispe & Pacheco [23] serta Noorhizam et al. [24], memanfaatkan *Ethereum* sebagai infrastruktur utama karena dukungan *smart contract* yang matang dan ekosistem yang luas. Namun, untuk kebutuhan institusi yang memprioritaskan privasi dan kontrol akses, Kabashi et al. [25] mengusulkan penggunaan *Hyperledger Fabric (blockchain privat/konsorsium)*, yang menawarkan skalabilitas lebih tinggi tanpa biaya transaksi (*gas fee*) yang fluktuatif seperti pada *public blockchain*.
- Mekanisme Penyimpanan (Off-chain Storage):** Menyimpan seluruh data dokumen di dalam blok (*on-chain*) dinilai tidak efisien dan mahal. Sebagai solusi, Suseno et al. [20] dan Noshi & Xu [6] menerapkan *InterPlanetary File System (IPFS)*. Dalam mekanisme ini, hanya kode unik (*hash*) dari dokumen yang dicatat di *blockchain*, sementara file fisik dokumen disimpan di jaringan IPFS yang terdesentralisasi. Pendekatan ini menjaga integritas data tanpa membebani jaringan *blockchain*.
- Verifikasi Berbasis QR Code:** Untuk memudahkan pengguna akhir (seperti perekrut kerja), sistem dilengkapi dengan fitur QR Code. Seperti dijelaskan

oleh Noorhizam et al. [24], pemindaian QR Code pada ijazah akan langsung mengarahkan verifikator ke data transaksi di *blockchain*, memungkinkan validasi keaslian dokumen secara real-time dan transparan.

B. Hasil Implementasi dan Manfaat

RQ2: Bagaimana hasil implementasi *blockchain* pada sistem verifikasi sertifikat akademik yang telah dibahas dalam penelitian terdahulu?

Implementasi teknologi *blockchain* terbukti memberikan solusi signifikan atas kelemahan sistem verifikasi konvensional. Temuan utama meliputi:

- Integritas Data (Immutability):** Semua studi menyepakati bahwa sifat *immutable* (kekekalan data) pada *blockchain* berhasil memitigasi risiko pemalsuan ijazah. Oluwaseyi & Akinyede [26] menekankan bahwa penggunaan algoritma *hashing* (SHA-256) memastikan setiap perubahan kecil pada dokumen akan mengubah nilai *hash*, sehingga manipulasi data dapat dideteksi seketika.
- Efisiensi Waktu:** Sistem ini memangkas birokrasi legalisir yang berbelit. Cardenas-Quispe & Pacheco [23] menunjukkan bahwa proses verifikasi yang sebelumnya memakan waktu harian hingga mingguan dapat dipersingkat menjadi hitungan detik melalui sistem otomatis.
- Desentralisasi dan Keamanan:** Suseno et al. [20] menyoroti bahwa kombinasi *blockchain* dan IPFS menghilangkan risiko titik kegagalan tunggal (*single point of failure*). Data sertifikat tetap aman dan dapat diverifikasi meskipun server lokal institusi mengalami gangguan atau peretasan.

C. Tantangan dan Keterbatasan

RQ3: Apa tantangan dan keterbatasan yang dihadapi dalam implementasi *blockchain* untuk verifikasi kredensial akademik?

Meskipun menawarkan berbagai keunggulan, penerapan teknologi ini masih menghadapi beberapa tantangan teknis dan operasional:

- Biaya Transaksi (Gas Fee):** Tantangan utama pada penggunaan *public blockchain* seperti *Ethereum* adalah biaya transaksi yang tinggi untuk setiap pencatatan sertifikat. Noshi & Xu [6] mengidentifikasi bahwa fluktuasi biaya ini dapat menjadi hambatan bagi institusi dengan anggaran terbatas.
- Skalabilitas dan Penyimpanan:** Kabashi et al. [25] mencatat bahwa seiring bertambahnya jumlah lulusan, ukuran *ledger* akan terus membesar, yang dapat mempengaruhi kinerja jaringan. Solusi *hybrid* menggunakan penyimpanan *off-chain* (IPFS) menjadi krusial untuk mengatasi masalah ini.
- Privasi Data:** Pada *blockchain* publik, data transaksi dapat dilihat oleh siapa saja. Abdelmagid et al. [27] menyarankan penggunaan mekanisme kontrol akses atau *private blockchain* untuk memastikan data sensitif mahasiswa tidak terekspos secara bebas kepada publik yang tidak berkepentingan.

IV. KESIMPULAN

Berdasarkan Tinjauan Pustaka Sistematis (SLR) terhadap tujuh studi (2022–2025), arsitektur paling efektif untuk verifikasi sertifikat akademik adalah model hybrid yang menggabungkan public blockchain (Ethereum) dan penyimpanan IPFS yang terintegrasi dengan QR Code. Implementasi ini terbukti menjamin integritas data (immutability), memitigasi risiko pemalsuan, dan memangkas waktu verifikasi secara drastis tanpa memerlukan perantara.

Namun, penerapan teknologi ini masih terkendala oleh tingginya biaya transaksi (gas fee) dan isu privasi data pada jaringan terbuka. Oleh karena itu, penelitian selanjutnya disarankan untuk berfokus pada solusi consortium blockchain atau teknologi Layer-2 guna menekan biaya, serta pengembangan mekanisme privasi yang lebih kuat untuk melindungi data lulusan.

REFERENSI

- [1] D. Chiş and M. Caramihai, "Blockchain in Higher Education: A Secure Traceability Architecture for Degree Verification," *Reimagining Educ. - Role E-Learning, Creat. Technol. Post-Pandemic Era*, pp. 1–21, 2023, doi: 10.5772/intechopen.1001997.
- [2] A. Rehman and F. Hashim, "International Journal of Social Science and Human Research Leveraging Internal Audit and Blockchain to Mitigate Academic Fraud and Enhance Institutional Sustainability: A General Strain Theory Perspective," vol. 08, no. 01, pp. 479–496, 2025, doi: 10.47191/ijsshr/v8-i1-59.
- [3] M. R. Hodgman, "Employers' Perspectives on the Performance of Higher Education Institutions in Preparing Graduates for the Workplace: A Review of the Literature," vol. 8, no. 3, pp. 92–103, 2018, doi: 10.5296/ber.v8i3.13370.
- [4] S. H. Said, M. A. Dida, E. M. Kosia, and R. S. Sinde, "A Blockchain-based Conceptual Model to Address Educational Certificate Verification Challenges in Tanzania," *Eng. Technol. Appl. Sci. Res.*, vol. 13, no. 5, pp. 11691–11704, 2023, doi: 10.48084/etasr.6170.
- [5] J. Gilbert, M. Mboma, and O. T. Tshipata, "Enhancing the Reliability of Academic Document Certification Systems with Blockchain and Large Language Models," vol. 21, pp. 419–437, 2024, doi: 10.37394/23209.2024.21.39.
- [6] Noshi and Y. Xu, "Development of Blockchain-Based Academic Credential Verification System," *OALib*, vol. 11, no. 09, pp. 1–20, 2024, doi: 10.4236/oalib.1112130.
- [7] P. M. Pondkule, "Implementation of blockchain-based document management system for higher education organizations," vol. 18, no. 1, pp. 1–11, 2025, doi: 10.2478/ijssis-2025-0001.
- [8] M. A. C. Quispe and A. Pacheco, "Blockchain ensuring academic integrity with a degree verification prototype," *Sci. Rep.*, vol. 15, no. 1, pp. 1–15, 2025, doi: 10.1038/s41598-025-93913-6.
- [9] T. M. Nasrullah et al., "Device Agent Assisted Blockchain Leveraged Framework for Internet of Things," *IEEE Access*, vol. 11, no. December 2022, pp. 1254–1268, 2023, doi: 10.1109/ACCESS.2022.3231491.
- [10] C. Li, "Enhancing CAD Data Integrity and Security in Supply Chain Networks Using Blockchain," vol. 18, no. 1, pp. 1–22, 2025, doi: 10.4018/IJISSCM.389716.
- [11] K. Saja and A. Stecyk, "Blockchain-Based Certification: Enhancing Transparency and Trust in Higher Education," *Eur. Res. Stud. J.*, vol. XXVI, no. Issue 3, pp. 363–380, 2023, doi: 10.35808/ersj/3219.
- [12] A. C. Fortune, E. J. Garba, U. Mohammed, and A. A. Kadam, "Blockchain-Enabled Conceptual Framework for Enhancing Academic Transcript Issuance and Authentication in the Nigerian Educational System," *Int. J. Dev. Math.*, vol. 1, no. 2, pp. 227–236, 2024, doi: 10.62054/ijdm/0102.19.
- [13] E. A. Tissier et al., "Time Until Proof of Credentials Significantly Decreases With the Use of Blockchain Technology and the Document Management System," vol. 15, no. 11, pp. 1–6, 2023, doi: 10.7759/cureus.48920.
- [14] M. I. Sarwar and L. A. Maghrabi, "Blockchain: A Crypto-Intensive Technology — A Comprehensive Review," *IEEE Access*, vol. 11, no. December, pp. 141926–141955, 2023, doi: 10.1109/ACCESS.2023.3342079.
- [15] S. Davidson, P. D. E. Filippi, and J. Potts, "Blockchains and the economic institutions of capitalism," pp. 1–20, 2017, doi: 10.1017/S1744137417000200.
- [16] Y. Wang, X. Cong, L. Zi, and Q. Xiang, "Blockchain for Credibility in Educational Development: Key Technology, Application Potential, and Performance Evaluation," *Secur. Commun. Networks*, vol. 2023, 2023, doi: 10.1155/2023/5614241.
- [17] J. A. Berrios Moya, J. Ayoade, and M. A. Uddin, "A Zero-Knowledge Proof-Enabled Blockchain-Based Academic Record Verification System," *Sensors*, vol. 25, no. 11, pp. 1–24, 2025, doi: 10.3390/s25113450.
- [18] O. I. Oriekhoe, B. I. Ashiwaju, and K. C. Ihemereze, "BLOCKCHAIN TECHNOLOGY IN SUPPLY CHAIN MANAGEMENT: A COMPREHENSIVE REVIEW," vol. 6, no. 1, pp. 150–166, 2024, doi: 10.51594/ijmer.v6i1.714.
- [19] J. S. M. B and V. Kale, *Blockchain Technology Based Supply Chain Management System*. Atlantis Press International BV, 2023. doi: 10.2991/978-94-6463-136-4.
- [20] T. R. D. Suseno, I. Afrianto, and S. Atin, "Strengthening data integrity in academic document recording with blockchain and InterPlanetary file system," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 2, pp. 1759–1769, 2024, doi: 10.11591/ijece.v14i2.pp1759-1769.

- [21] H. Taherdoost, "A Critical Review of Blockchain Acceptance Models — Blockchain Technology Adoption Frameworks and Applications," 2022.
- [22] D. Pati and L. N. Lorusso, "How to Write a Systematic Review of the Literature," *HERD Heal. Environ. Res. Des. J.*, vol. 11, no. 1, pp. 15–30, Jan. 2018, doi: 10.1177/1937586717747384.
- [23] M. A. Cardenas-quispe and A. Pacheco, "Blockchain ensuring academic integrity with a degree verification prototype," pp. 1–15, 2025.
- [24] N. Khairunnisa, Z. Abdullah, S. Kasim, I. Rahmi, and A. Hamid, "Verification of Ph . D . Certificate Using QR Code on Blockchain Ethereum," vol. 7, no. September, pp. 716–725, 2023.
- [25] V. N. Faton Kabashi, Halil Snopçe, Artan Luma, "Trustworthy Verification of Academic Credentials through Blockchain Technology," *Int. J. Online Biomed. Eng.*, vol. 20, no. 9, pp. 51–64, 2024, doi: 10.3991/ijoe.v20i09.48999.
- [26] O. S. Oluwaseyi, "Utilizing Blockchain Technology for University Certificate Verification System," vol. 12, no. 45, pp. 23–40, 2024.
- [27] R. Abdelmagid, M. Abdelsalam, and F. K. Alsheref, "A Blockchain Framework for Academic Certificates Authentication," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 7, pp. 297–305, 2024, doi: 10.14569/IJACSA.2024.0150729.

Applications of WDM System in US Patents

Mhnd Farhan^{1*}

^{1*} Baghdad University, Iraq
Email: ^{1*}mhndfarhan@yahoo.com

Abstract - In fiber-optical telecommunications, wavelength division multiplexing (WDM) is a multiplexing and transmission scheme in which distinct wavelengths, each emitted by multiple lasers, carry specific information. WDM filters are used to multiplex these wavelengths. Similarly, at the receiving end, they are demultiplexed or separated using coherent detection with tunable local oscillators or similar filters. This paper explains the most recent applications of the WDM System in US patents. A succinct explanation of the WDM System is also given.

Keywords: US Patents, WDM, structure and applications

I. INTRODUCTION

The technique known as wavelength-division multiplexing (WDM) in fiber-optic communications multiplexes several optical carrier signals onto a single optical fiber by employing various wavelengths of laser light [1]. Wavelength-division duplexing, another name for bidirectional communications over a single fiber strand, and capacity multiplication are made possible by this technique [1].

While frequency-division multiplexing usually refers to a radio carrier, which is more frequently described by frequency, WDM is frequently used to refer to an optical carrier, which is usually described by its wavelength [2]. Since wavelength and frequency convey the same information, this is strictly conventional. In particular, the velocity of the carrier wave is equal to the product of frequency (measured in Hertz, or cycles per second) and wavelength (the actual length of one cycle). This is the speed of light in a vacuum, and it is typically represented by the lowercase letter *c*. The velocity in glass fiber is significantly slower, typically 0–7 times *c*. In real-world systems, the carrier frequency is a fraction of the data rate.

II. WDM METHOD & STRUCTURE

In Fig. 1, a multiplexer at the transmitter joins the multiple signals together, and a demultiplexer at the receiver separates them. This is how the WDM system works. It is feasible to create a device that can serve as an optical add-drop multiplexer and do both at the same time with the correct kind of fiber. Etalons (stable solid-state single-frequency Fabry–Pérot interferometers in the form of thin-film-coated optical glass) have traditionally been employed as optical filtering devices. Since there are three distinct types of WDM, one of which is referred to as WDM, the notation xWDM is typically

used when discussing the technology in general. Only two signals were combined in the initial WDM systems. A simple 100 Gbit/s system can be expanded to over 16 Tbit/s over a single fiber pair using modern systems, which can handle 160 signals. There is also a 320-channel system.

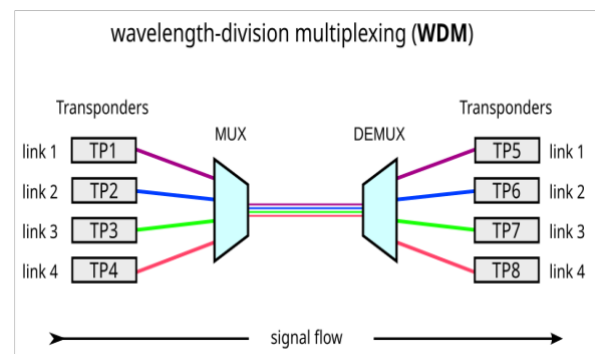


Fig. 1: WDM Structure

Telecommunications companies favor WDM systems because they enable them to increase network capacity without installing additional fiber. Without having to completely redesign the backbone network, they can integrate multiple generations of technological advancements into their optical infrastructure by utilizing WDM and optical amplifiers. Simply upgrading the multiplexers and demultiplexers at each end of a link will increase its capacity. At the very edge of the transport network, optical-to-electrical-to-optical (O/E/O) translation is frequently used to accomplish this, allowing for interoperability with already-existing equipment that has optical interfaces [3].

The majority of WDM systems use single-mode optical fiber cables with a 9 μm core diameter. Multi-mode optical fiber cables, also referred to as premises cables, with core diameters of 50 or 62.5 μm can also use specific types of WDM.

Unlike laser sources, optical receivers are typically wideband devices. Consequently, in the WDM system, the demultiplexer needs to supply the receiver's wavelength selectivity.

III. APPLICATIONS OF WDM IN US PATENTS

Receiving an optical coherence tomography (“OCT”) signal or signals, dividing them into a number of subspectra, averaging the subspectra, and then creating the image or images of the three-dimensional anatomical flow map(s) based on the averaged subspectra are examples of exemplary systems, methods, and computer-accessible media for creating an image(s) of a three-dimensional anatomical flow

map(s) in [4]. One or more OCT signals may be swept-source signals. A Hamming window can be used to divide the OCT signal or signals into subspectra. For each subspectra, the nearest side lobe can be minimized by optimizing the Hamming distance window. Before the subspectra are averaged, the position of at least one of them can be changed. Before the subspectra are averaged, the positions of all but one of them can be changed.

Wavelength splitter structures and formation techniques for a wavelength-division-multiplexing filter stage are described in [5]. The first waveguide core of the structure is made up of a first section, a second section, and a phase delay line connecting the first and second sections. In the first waveguide core, the phase delay line consists of a delay section and several longitudinally arranged segments. The second waveguide core of the structure is made up of a first section, a second section, and a phase delay line connecting the first and second sections. A first directional coupler is defined by placing the first section of the second waveguide core next to the first section of the first waveguide core, and a second directional coupler is defined by placing the second section of the second waveguide core next to the second section of the first waveguide core.

In [6], a photonics frequency comb generator consists of two integrated dies: a silicon photonics die with a microring resonator coupled to the laser and frequency modulators, and an indium phosphide die laser of a first wavelength grown on from it. The first wavelength is changed into several second wavelengths by the microring resonator. A hybrid non-linear optical wavelength generator is one kind of microring resonator that uses silicon and non-silicon materials like SiC or SiGe to produce a non-linear wavelength generation. By varying the ring's geometric size and the separation between it and the traverse waveguide, the second wavelengths are produced. A different kind of microring resonator divides the first wavelength into several second wavelengths, which are then sent to filters and modulators. Each of these devices chooses and modifies one of the second wavelengths in a one-to-one correspondence. Applications for this frequency comb generator include multi-chip modules in high-speed transceivers and WDM/CWDM.

Coherent photonic circuit architectures that optically carry out linear algebraic calculations are revealed in [7]. Coherent optical linear neurons arranged in a crossbar configuration can be used to implement individual neural network layers in neuromorphic applications of such photonic circuit architectures. Electronic circuitry is integrated at the interfaces between neural network layers to determine the neuron inputs to one layer based on the neuron outputs of the layer before it. When combined with electro-optic switches, wavelength division multiplexing can effectively implement specific network models and make a general hardware configuration programmable.

Configurable intensity-modulation direct-detection (IM-DD) optical transceivers that can switch between single-polarization (SP) and dual-polarization (DP) operation are the focus of implementations in [8].

Systems, procedures, and equipment for single-ended electro-absorption modulators (EAMs) with electrical combining are revealed here in [9]. Systems and techniques for carrying out optical encoding and multiplication operations for optical signals without the use of a sign value are specifically disclosed. It is possible to transform the optical output into a photocurrent input and then apply the sign value to the photocurrent input on an electrical layer.

A multicore optical fiber with first and second cores, a first communication device optically coupled to a first end of the multicore optical fiber's first core, a second communication device optically coupled to a second end of the multicore optical fiber's first core, a first sensing device optically coupled to a first end of the multicore optical fiber's second core, and a second sensing device optically coupled to a second end of the multicore optical fiber's second core are all components of a hybrid sensing-communication system described in [10]. The communication data is distinct from the sensing data, and the first and second communication devices only exchange communication data along the first core, while the first and second sensing devices only exchange sensing data along the second core.

An optical source is described in [11]. A semiconductor laser chip with multiple epitaxial gain layers, which function as a gain medium and provide multiple lasing wavelengths in a band of frequencies without mode hopping and/or with significantly reduced mode beating below a predetermined value, and an optical cavity with at least one mirror are two examples of this optical source. Aperiodic gratings, echelle gratings with a common arm that contains the epitaxial gain layers and multiple output arms that provide the lasing wavelengths, or a set of ring resonators that provide the lasing wavelengths are some examples of optical components that can be included in the optical source to select laser modes of the optical cavity.

Wherever radio service coverage is required, an antenna port is created by tapping an optical medium, like fiber, in [12]. A digital optical signal is received from a host unit via each antenna port, which is a bi-directional remote unit that converts the signal to a radio frequency signal for transmission. Radio frequency signals are received by the remote unit, converted to digital signals, combined with signals from other remote units, and then transformed into an optical signal that is sent to the host unit.

Using a multimode pump source, an optical fiber was set up in [13] to increase the pump conversion efficiency of an L-band fiber amplifier. An active fiber core region co-doped with both erbium and ytterbium can directly absorb multimode light, including 915 nm, and use stimulated emission to add gain to the L-band signals. Another active fiber core region doped with erbium can absorb the undesired C-band amplified spontaneous emission (ASE) light produced by this active fiber core region, adding gain to the L-band signals. It is possible to set up active regions and cladding to correspond with a specific spatial mode of the optical signal. It is possible to use signal-pump combiners with side or end coupling.

A digital baseband unit that can split a baseband signal into in-phase and quadrature components and output the in-phase and quadrature components is one example of a transmitting apparatus that complies with the current disclosure in [14]. Another is an outphasing signal generation unit that can generate first and second outphasing signals based on the in-phase and quadrature components, and a time-division combining unit that can create a time-division combined signal by combining the first and second outphasing signals in a time-division fashion.

Continuous wave signals with varying wavelengths at a channel spacing from one another are employed in an optical circuit in [15]. A photonic integrated circuit is used to implement a portion of the optical circuit. In a modulation stage, modulators create modulated signals by modulating continuous wave signals. The continuous wave or modulated signals are multiplexed to create multiplexed signals by a multiplexing stage, which may include multiplexing filters, power combiners, or power couplers. The modulation stage may come before or after the multiplexing stage. In a final step, the multiplexed signals are combined into an output signal by one or more polarization rotator and combiner (PRC) devices. A first set of distinct wavelengths at a first polarization and a second set of distinct wavelengths at a second polarization orthogonal to the first polarization are both present in the output signal.

In [16], a distributed acoustic sensor (DAS) box is connected to an optical fiber that is positioned to extend to a tree as part of an integrated system for detecting soil moisture, farm fire, and red palm weevil (RPW). In order to ascertain whether the RPW is present from the first optical signal, the temperature at a point along the optical fiber from the second optical signal, and the moisture at a point around the tree from the third optical signal, the DAS box is set up to process the first three distinct optical signals reflected from the optical fiber.

An optical device that can enhance O-band light is comprised of a Praseodymium (Pr)-doped waveguide optical amplifier in [17]. It is possible for the substrate to form the waveguide optical amplifier (e.g. either glass or silicone) and consists of cladding that borders at least one side of the core and a core that defines an optical path through the waveguide optical amplifier. The core is made of a silicon-based substance, like silicon nitride, doped with Praseodymium (Pr) in such a way that the waveguide optical amplifier amplifies the O-band signal light when pump light and O-band signal light are passed through it.

An optical source is described in [18]. A silicon-photonics chip that creates an optical cavity and a semiconductor laser chip are two possible components of this optical source. In a band of wavelengths, the semiconductor laser chip may offer gain at several lasing wavelengths. Additionally, the silicon-photonics chip has the ability to modify the size of an optical signal close to an interface between the silicon-photonics chip and the semiconductor laser chip. Additionally, a center frequency of a micro-ring resonator's passband may be matched to a non-zero integer multiple of a cavity-mode spacing by varying the phase of a

phase shifter and resonance frequencies of a micro-ring resonator in the silicon-photonics chip. By suppressing undesired lasing wavelengths and re-enforcing the lasing wavelengths, this could enable the optical source to mode-lock its lasing wavelengths. In certain configurations, the optical source's free-spectral range could fall between 100 GHz and 800 GHz.

To authenticate client devices on a communication network, a server device is offered in [19]. The server device has a processor with memory that can hold computer-executable instructions and a transceiver that can communicate with at least one client of the communication network. When the instructions are carried out by the processor, the server device receives an authentication request from a client device, generates a seed for the client device's first key if the client device authenticates, transmits the seed to the client device, receives a hash of the first key from the client device, and validates the first key using the hash of the first key.

IV. CONCLUSION

It was demonstrated that the most recent use of WDM system in US patents highlights the significance and range of services that WDM system offers. Additionally, the WDM's general structure was displayed.

REFERENCE

- [1] C. Hong, et.al., "Optofluidic wavelength division multiplexing for single-virus detection". Proceedings of the National Academy of Sciences of the United States of America. vol.112, no.42, pp. 12933–12937. 2015.
- [2] Y. Yuan, et.al., "Multipath Transmission of Marine Electromagnetic Data Based on Distributed Sensors". Journal of Coastal Research, vol.97, pp.99–102, 2019.
- [3] L. Hongqin, et.al., "Analysis and Simulation of Morphology Algorithm for Fiber Optic Hydrophone Array in Marine Seismic Exploration". Journal of Coastal Research, vol.94: pp.145–148, 2019.
- [4] P. Yingtian et al., "System, method, and computer-accessible medium for subsurface capillary flow imaging by wavelength-division-multiplexing swept-source optical doppler tomography", US-11771321B2, 2023.
- [5] B.Yusheng, " Wavelength-division-multiplexing filter stages with segmented wavelength splitters", US-11782208B1, 2023.
- [6] V Olmos et al., "Heterogeneous integration of frequency comb generators for high-speed transceivers", US-11791902B2, 2023.
- [7] P. Nikolaos et al., "Coherent photonic computing architectures", US-11817903B2, 2023.

- [8] D. Christopher R. et al., "Configurable Intensity-Modulation Direct Detection (IMDD) Optical TRANSCEIVERS", US-20230396339A1, 2023.
- [9] P. Nikolaos et al., "Single Ended Eam With Electrical Combining", US-20240013041A1, 2024.
- [10] O. Siew et al., "Hybrid sensing-communication optical system and method", US-11956016B2, 2024.
- [11] K. Ashok et al., "Broad-Bandwidth Laser With Reduced Mode Beating", US-20240291237A1, 2024.
- [12] B. Donald et al., "Distributed digital antenna system", US-RE50112E, 2024.
- [13] W. Lixian et al., "Systems and methods to increase pump conversion efficiency of an optical fiber", US-12126134B2, 2024.
- [14] K. Yuma et al., "Transmitting apparatus, receiving apparatus, communication system, and communication method", US-12155460B2, 2024.
- [15] P. Dong; et al., "Wavelength-division-multiplexing optical circuit implemented in photonic integrated circuit for optical transmitter", US-12237913B2, 2025.
- [16] O. Siew et al., "Versatile optical fiber sensor and method for detecting red palm weevil, farm fires, and soil moisture", US-12270788B2, 2025.
- [17] M. Varghese, "Optical Waveguide Amplifiers With Doped Silicon-Based Core", US-20250125577A1, 2025.
- [18] K. Ashok V. et al., "Mode-Selective and Tunable Multi-Wavelength O-Band Quantum-Dot U-Comb Laser", US-20250132539A1, 2025.
- [19] P. Massimiliano et al., "Systems and Methods for Advanced Quantum-Safe PKI Credentials for Authentications", US-20250150268A1, 2025.

Prediksi Prognosis Kanker Payudara Menggunakan Hybrid Artificial Neural Network dan Gaussian Naïve Bayes

Jesika Octavia Hutagaol^{1*}, Margaretha Yohanna², Harlen Gilbert Simanullang³

¹Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Methodist Indonesia

²Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Methodist Indonesia

³Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Methodist Indonesia

Email: ¹hutagaoljesika04@gmail.com, ²yohanna.na2@gmail.com, ³harlen.gilbert@gmail.com

Abstrak – Kanker payudara menjadi salah satu jenis kanker yang paling banyak menyebabkan kematian pada wanita di dunia. Prognosis kanker payudara diperlukan untuk membantu tenaga medis dalam memprediksi kemungkinan kekambuhan penyakit sehingga penanganan dapat dilakukan lebih cepat dan tepat. Penelitian ini bertujuan menerapkan metode hybrid Artificial Neural Network (ANN) dan Gaussian Naïve Bayes untuk prediksi prognosis kanker payudara menggunakan dataset Breast Cancer Wisconsin Prognostic (WPBC). Dataset yang digunakan terdiri dari 198 data pasien dengan 35 fitur numerik. Tahapan penelitian meliputi preprocessing data, normalisasi, pembagian data latih dan data uji menggunakan rasio 80:20, ekstraksi fitur menggunakan ANN, serta klasifikasi menggunakan Gaussian Naïve Bayes. Berbeda dengan penelitian sebelumnya yang umumnya menggunakan metode tunggal, penelitian ini memanfaatkan ANN sebagai ekstraksi fitur sebelum proses klasifikasi menggunakan Gaussian Naïve Bayes. ANN digunakan dengan satu hidden layer berisi 16 neuron untuk mempelajari hubungan non-linear antar fitur dan menghasilkan 16 fitur baru hasil dari ekstraksi. Fitur hasil ekstraksi tersebut kemudian digunakan sebagai input pada proses klasifikasi menggunakan Gaussian Naïve Bayes. Evaluasi model dilakukan menggunakan confusion matrix berdasarkan metrik accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa metode hybrid ANN-Gaussian Naïve Bayes memperoleh accuracy sebesar 90%, precision sebesar 72,73%, recall sebesar 88,89%, dan F1-score sebesar 80%. Hasil tersebut menunjukkan bahwa pendekatan hybrid mampu meningkatkan performa klasifikasi prognosis kanker payudara dibandingkan metode tunggal.

Kata kunci: Kanker Payudara, Prognosis, Artificial Neural Network, Gaussian Naïve Bayes, Hybrid

Abstract – Breast cancer is one of the types of cancer that causes the most deaths in women in the world. Breast cancer prognosis is important to assist medical personnel in predicting the possibility of recurrence so that treatment can be provided more effectively. This study aims to implement a hybrid Artificial Neural Network (ANN) and Gaussian Naïve Bayes method for breast cancer prognosis prediction using the Breast Cancer Wisconsin Prognostic (WPBC) dataset. The dataset consisted of 198 patient records with 35 numerical features. The research stages included data preprocessing, normalization, splitting the dataset into training and testing data using an 80:20 ratio, feature extraction

using ANN, and classification using Gaussian Naïve Bayes. Unlike previous studies that generally used single methods, this study utilizes ANN as a feature extractor before the classification process using Gaussian Naïve Bayes. ANN was used with one hidden layer containing 16 neurons to learn non-linear relationships among features and generate 16 new extracted features. These extracted features were then used as input for Gaussian Naïve Bayes classification process. Model evaluation was conducted using a confusion matrix with accuracy, precision, recall, and F1-score metrics. The experimental results showed that the hybrid ANN-Gaussian Naïve Bayes method achieved an accuracy of 90%, precision of 72.73%, recall of 88.89%, and an F1-score of 80%. These results indicate that the hybrid method provides better classification performance compared to single methods in breast cancer prognosis prediction.

Keywords— Breast Cancer, Prognosis, Artificial Neural Network, Gaussian Naïve Bayes, Hybrid

I. PENDAHULUAN

Salah satu penyakit dengan jumlah penderita tertinggi pada wanita di seluruh dunia adalah kanker payudara, yang juga merupakan penyebab utama kematian akibat kanker. Penyakit ini terjadi akibat pertumbuhan sel abnormal pada jaringan payudara yang berkembang secara tidak terkendali. Menurut World Health Organization (WHO), kanker payudara menjadi salah satu jenis kanker dengan jumlah kasus baru tertinggi setiap tahunnya. Tingginya jumlah penderita kanker payudara menyebabkan pentingnya proses prognosis untuk membantu tenaga medis memprediksi kemungkinan *recurrence* atau *non-recurrence* setelah pasien menjalani pengobatan [1].

Perkembangan teknologi *machine learning* telah banyak diterapkan dalam bidang kesehatan, khususnya untuk membantu proses klasifikasi dan prediksi penyakit [2]. Berbagai metode *machine learning* telah digunakan dalam klasifikasi kanker payudara, seperti Decision Tree, Support Vector Machine, Artificial Neural Network (ANN), dan Naïve Bayes [3], [4].

Artificial Neural Network (ANN) merupakan metode berbasis jaringan saraf tiruan yang memiliki kemampuan baik dalam mempelajari pola non-linear pada data [5]. ANN bekerja dengan meniru cara kerja jaringan saraf manusia melalui proses pembelajaran bobot pada setiap neuron [6]. Metode ANN mampu menghasilkan performa klasifikasi yang baik pada berbagai kasus kesehatan karena mampu mengenali pola kompleks pada dataset medis [7].

Meskipun demikian, ANN memiliki kelemahan ketika digunakan pada dataset berukuran kecil karena berpotensi mengalami overfitting [8], [9]. Overfitting menyebabkan model terlalu menyesuaikan data latih sehingga performa model menurun ketika digunakan pada data baru. Oleh sebab itu, diperlukan kombinasi dengan metode lain untuk meningkatkan stabilitas model klasifikasi.

Gaussian Naïve Bayes merupakan metode klasifikasi probabilitas yang bekerja menggunakan pendekatan Teorema Bayes dengan menganggap setiap atribut bersifat independen [10]. Metode ini dapat digunakan pada dataset berukuran kecil karena memiliki proses komputasi yang sederhana, cepat, dan efektif [11]. Meskipun datanya terbatas, Gaussian Naïve Bayes juga dapat menghasilkan hasil klasifikasi yang stabil [12].

Beberapa penelitian sebelumnya masih berfokus pada diagnosis kanker payudara menggunakan metode tunggal. Penelitian oleh Tanti et al. menggunakan metode Naïve Bayes untuk klasifikasi kanker payudara dan memperoleh hasil yang cukup baik [13]. Penelitian lain oleh Yordanus dan Senjaya menunjukkan bahwa metode *deep learning* memberikan performa yang baik pada dataset Wisconsin, namun membutuhkan proses komputasi yang lebih kompleks [14]. Namun, kedua penelitian tersebut masih menggunakan metode tunggal dan belum menerapkan kombinasi ANN sebagai feature extractor dengan Gaussian Naïve Bayes dalam prediksi prognosis kanker payudara.

Penelitian ini mengusulkan metode hybrid ANN dan Gaussian Naïve Bayes, di mana ANN digunakan sebagai metode ekstraksi fitur untuk menghasilkan representasi fitur yang lebih optimal sebelum proses klasifikasi dilakukan menggunakan Gaussian Naïve Bayes. Tujuan penelitian ini adalah menganalisis performa metode hybrid ANN dan Gaussian Naïve Bayes dalam memprediksi prognosis kanker payudara menggunakan dataset WPBC berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*.

II. METODE PENELITIAN

A. Desain Penelitian

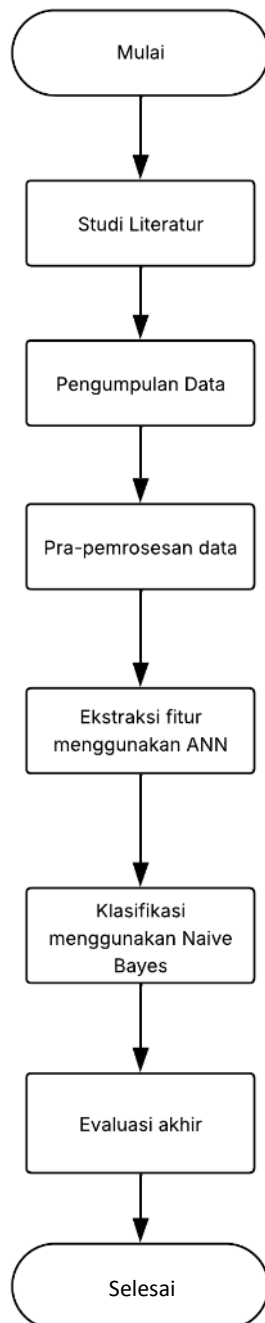
Penelitian ini menggunakan jenis penelitian eksperimen dengan pendekatan kuantitatif. Pendekatan kuantitatif

digunakan karena penelitian berfokus pada pengukuran performa model machine learning dalam memprediksi prognosis kanker payudara berdasarkan data numerik. Metode eksperimen dilakukan dengan melakukan proses pelatihan dan pengujian model hybrid Artificial Neural Network dan Gaussian Naïve Bayes menggunakan dataset Breast Cancer Wisconsin Prognostic (WPBC).

Dataset untuk penelitian ini diperoleh dari Breast Cancer Wisconsin Prognostic (WPBC) yang berisi data prognosis kanker payudara dengan dua kelas yaitu recurrence dan non-recurrence. Dataset terdiri dari 198 data pasien dengan beberapa atribut numerik yang merepresentasikan karakteristik sel tumor payudara, seperti ukuran, tumor, radius, tekstur, perimeter, area, smoothness, compactness, concavity, concave points, symmetry, fractal dimension, tumor_size, dan lymph_node_status. Pada penelitian ini atribut ID tidak digunakan dalam proses pelatihan model karena hanya berfungsi sebagai identitas data, sedangkan atribut outcome digunakan sebagai label kelas prognosis.

Instrumen penelitian yang digunakan berupa perangkat lunak Python dengan beberapa library pendukung machine learning seperti scikit-learn, NumPy, dan Pandas [15]. Library tersebut digunakan untuk preprocessing data, pelatihan model ANN, klasifikasi Gaussian Naïve Bayes, serta evaluasi model.

Tahapan penelitian dimulai dari studi literatur, pengumpulan data, preprocessing data, pelatihan model hybrid, hingga evaluasi performa model. Framework penelitian dapat dilihat pada Gambar 1.



Gambar 1. Framework Penelitian

B. Prosedur Penelitian

Penelitian dimulai dengan proses preprocessing data untuk membersihkan dan mempersiapkan dataset sebelum digunakan dalam pelatihan model *machine learning*. Tahap preprocessing meliputi pengecekan missing value, normalisasi data, dan pemisahan atribut dengan label kelas. Pada dataset ditemukan beberapa missing value pada atribut *lymph_node_status* yang ditandai dengan simbol “?”. Missing value tersebut ditangani menggunakan metode imputasi median agar tetap dapat digunakan dalam proses pelatihan model tanpa mengurangi jumlah dataset secara signifikan.

Label kelas pada dataset terdiri dari dua kategori yaitu N (Non-Recurrence) dan R (Recurrence). Pada penelitian ini

label kelas ditransformasikan ke dalam bentuk numerik, yaitu 0 untuk Non-Recurrence dan 1 untuk Recurrence agar dapat diproses oleh algoritma *machine learning*. Selanjutnya dilakukan normalisasi data menggunakan metode MinMaxScaler untuk menyamakan rentang nilai antar fitur sehingga proses pelatihan model menjadi lebih optimal. Dataset kemudian dibagi menjadi data latih sebesar 80% dan data uji sebesar 20%.

Setelah preprocessing selesai dilakukan, Artificial Neural Network (ANN) digunakan untuk mempelajari pola hubungan antar fitur pada dataset prognosis kanker payudara. ANN terdiri dari input layer, satu hidden layer berisi 16 neuron dengan fungsi aktivasi ReLU. Pada penelitian ini, ANN tidak digunakan sebagai klasifikasi akhir, melainkan sebagai proses ekstraksi fitur untuk menghasilkan representasi data yang lebih baik sebelum dilakukan klasifikasi. Hasil keluaran dari hidden layer kemudian digunakan sebagai input pada Naïve Bayes untuk proses klasifikasi prognosis kanker payudara.

Gaussian Naïve Bayes merupakan metode klasifikasi probabilitas yang menggunakan distribusi Gaussian untuk menghitung probabilitas setiap fitur terhadap kelas tertentu [16]. Metode ini dipilih karena memiliki proses komputasi dengan baik pada dataset berukuran kecil dan karena dataset yang digunakan didominasi oleh atribut kontinu sehingga lebih sesuai menggunakan distribusi Gaussian.

Namun, Gaussian Naïve Bayes memiliki kelemahan karena mengasumsikan bahwa setiap fitur tidak bergantung satu sama lain. Pada dataset medis, khususnya prognosis kanker payudara, beberapa atribut memiliki hubungan atau keterkaitan antar fitur sehingga asumsi independensi tidak terpenuhi. Oleh karena itu, pada penelitian ini ANN digunakan untuk mempelajari pola hubungan antar atribut dan menghasilkan representasi fitur yang lebih optimal sebelum dilakukan proses klasifikasi menggunakan Gaussian Naïve Bayes.

Evaluasi performa model dilakukan menggunakan confusion matrix untuk memperoleh nilai *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur tingkat ketepatan klasifikasi secara keseluruhan, *precision* digunakan untuk mengukur ketepatan prediksi positif, *recall* digunakan untuk mengukur kemampuan model untuk menemukan kelas positif, sedangkan *F1-score* digunakan untuk menyeimbangkan nilai *precision* dan *recall*. Hasil analisis tersebut digunakan untuk mengetahui kemampuan model hybrid ANN dan Gaussian Naïve Bayes dalam memprediksi prognosis kanker payudara secara akurat.

III. HASIL DAN DISKUSI

Hasil penelitian diperoleh melalui proses pelatihan dan pengujian model hybrid Artificial Neural Network (ANN) dan Gaussian Naïve Bayes menggunakan dataset Breast Cancer Wisconsin Prognostic (WPBC). Tahapan penelitian meliputi *preprocessing* data, ekstraksi fitur menggunakan ANN, proses klasifikasi menggunakan Gaussian Naïve Bayes, serta evaluasi performa model menggunakan *confusion matrix*.

Hasil preprocessing menunjukkan bahwa seluruh data berhasil dipersiapkan untuk proses pelatihan model. Dataset terdiri dari 198 data pasien dengan 33 atribut numerik yang telah dinormalisasikan ke rentang 0 sampai 1 sehingga data memiliki skala yang seragam. Data hasil preprocessing tersebut kemudian digunakan sebagai input pada proses ekstraksi fitur menggunakan ANN. Hasil preprocessing data dapat dilihat pada Tabel 1.

TABEL 1. Hasil Pra-pemrosesan Data

No	X1	X2	...	X33
1	0,2419	0,6467	...	0,1852
2	0,4839	0,6455	...	0,0741
3	0,9274	0,7753	...	0,0000
4	0,9839	0,3932	...	0,0000
5	0,2097	0,7339	...	0,0000
6	0,5565	0,0207	...	0,1481
7	0,2016	0,0077	...	0,0741
8	0,7742	0,7055	...	0,0000
9	0,3145	0,0280	...	0,0370
10	0,7258	0,5330	...	0,0000
...
198	0,0403	0,0188	...	0,0000

Artificial Neural Network digunakan untuk mempelajari pola hubungan antar atribut pada dataset prognosis kanker payudara. Pada penelitian ini, ANN digunakan sebagai proses ekstraksi fitur sebelum dilakukan klasifikasi menggunakan Gaussian Naïve Bayes. Penggunaan ANN pada tahap ekstraksi fitur bertujuan untuk menghasilkan representasi data yang lebih optimal sehingga dapat membantu meningkatkan performa klasifikasi.

Hasil ekstraksi fitur dari *hidden layer* ANN menghasilkan 16 fitur baru yang merepresentasikan pola hubungan non-linear antar atribut pada dataset prognosis kanker payudara. Fitur h1 hingga h16 merupakan hasil keluaran dari *hidden layer* pada proses ekstraksi fitur menggunakan ANN. Fitur-fitur hasil ekstraksi tersebut kemudian digunakan sebagai input pada Gaussian Naïve Bayes untuk proses klasifikasi. Contoh hasil ekstraksi fitur ANN dapat dilihat pada Tabel 2.

TABEL 2. Hasil Ekstraksi Fitur ANN

No	h1	h2	...	h16
1	6,1817	7,0391	...	6,8659
2	5,5567	5,3165	...	5,8130
3	6,9028	6,7886	...	8,1575
4	4,9642	4,9198	...	5,8549
5	5,0671	5,7334	...	5,5280

6	6,1975	6,7072	...	6,5077
7	5,0884	5,1054	...	4,7174
8	6,9139	7,5168	...	6,3324
9	4,2840	5,4390	...	5,2366
10	5,7202	6,6955	...	5,8062
...
198	4,6595	6,0358	...	6,3119

Berdasarkan Tabel 2, ANN berhasil menghasilkan representasi fitur baru dari data asli melalui proses pembelajaran pada hidden layer. Fitur-fitur tersebut digunakan sebagai input pada Gaussian Naïve Bayes sehingga proses klasifikasi dapat dilakukan menggunakan representasi data yang diharapkan lebih optimal dibandingkan menggunakan data asli secara langsung.

Setelah proses ekstraksi fitur selesai dilakukan, Gaussian Naïve Bayes digunakan untuk melakukan klasifikasi prognosis kanker payudara berdasarkan fitur hasil ekstraksi ANN. Contoh hasil klasifikasi Gaussian Naïve Bayes terhadap data uji dapat dilihat pada Tabel 3.

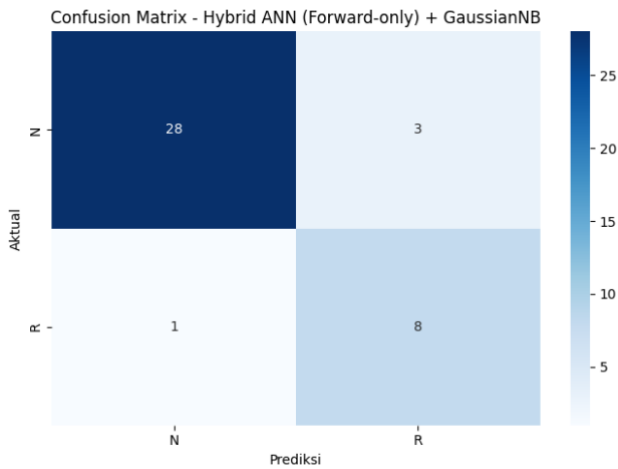
TABEL 3. Hasil Klasifikasi Gaussian Naïve Bayes

No	Data Uji	Prediksi
1	0	0
2	0	1
3	0	0
4	1	1
5	0	0
6	0	0
7	0	0
8	0	0
9	0	0
10	0	0
11	0	1
12	0	0
13	0	1
14	0	0
15	0	0
16	0	0
17	0	0
18	0	0
...
40	1	0

Hasil klasifikasi menunjukkan bahwa sebagian besar data uji berhasil diprediksi dengan benar oleh model hybrid ANN dan Gaussian Naïve Bayes. Penggunaan fitur hasil ekstraksi ANN membantu Gaussian Naïve Bayes dalam mengenali pola data prognosis kanker payudara dengan lebih baik. Hasil

pengujian model hybrid ANN dan Gaussian Naïve Bayes berdasarkan *confusion matrix* dapat dilihat pada Gambar 2.

Hasil perbandingan performa model dapat dilihat pada Tabel 4.



Gambar 2. Confusion Matrix ANN dan Gaussian Naïve Bayes

Berdasarkan *confusion matrix* pada Gambar 2, model hybrid ANN dan Gaussian Naïve Bayes berhasil mengklasifikasikan sebagian besar data secara akurat. Sebanyak 28 data kelas non-recurrence berhasil diprediksi dengan benar (*True Negative*), sedangkan 8 data kelas *recurrence* berhasil juga diklasifikasikan dengan benar (*True Positive*). Selain itu, terdapat 3 data *False positive* dan 1 data *False Negative*. Kesalahan klasifikasi tersebut menunjukkan bahwa beberapa data masih memiliki pola atribut yang mirip antar kelas sehingga model mengalami kesulitan dalam membedakan karakteristik tertentu pada data prognosis kanker payudara. Meskipun demikian, jumlah prediksi benar yang lebih dominan menunjukkan bahwa model hybrid mampu mempelajari pola prognosis kanker payudara dengan cukup baik. Adapun hasil dari evaluasi model dapat dilihat pada Gambar 3.

```

=====
EVALUASI MODEL
=====
Akurasi      : 90.00%
Presisi      : 72.73%
Recall       : 88.89%
F1-Score     : 80.00%
    
```

Gambar 3. Evaluasi Model

Berdasarkan hasil evaluasi pada Gambar 3, model hybrid ANN dan Gaussian Naïve Bayes memperoleh nilai *accuracy* sebesar 90%, *precision* sebesar 72,73%, *recall* sebesar 88,89%, dan *F1-score* sebesar 80%. Nilai-nilai ini menunjukkan bahwa model memiliki kemampuan untuk melakukan klasifikasi prognosis kanker payudara dengan performa yang cukup baik.

Selain melakukan pengujian terhadap model hybrid, penelitian ini juga melakukan pengujian terhadap metode tunggal untuk mengetahui perbandingan performa model.

TABEL 4. Perbandingan Performa Model

Model	Accuracy	Precision	Recall	F1-Score
ANN	75%	40%	22,22%	28,57%
Gaussian Naïve Bayes	47,50%	22,73%	55,56%	32,26%
Hybrid ANN-Gaussian Naïve Bayes	90%	72,73%	88,89%	80%

Berdasarkan Tabel 4, metode hybrid ANN dan Gaussian Naïve Bayes memperoleh performa terbaik dibandingkan metode tunggal. ANN sebagai metode tunggal memperoleh *accuracy* sebesar 75%, sedangkan Gaussian Naïve Bayes memperoleh *accuracy* sebesar 47,50%.

Rendahnya performa Gaussian Naïve Bayes dipengaruhi oleh asumsi independensi antar atribut yang kurang sesuai pada dataset medis. Pada dataset prognosis kanker payudara, beberapa atribut memiliki hubungan antar fitur sehingga asumsi independensi tidak sepenuhnya terpenuhi. Sementara itu, ANN sebagai metode tunggal mampu mempelajari pola data dengan lebih baik, namun masih memiliki keterbatasan dalam proses klasifikasi pada dataset berukuran kecil.

Penggabungan ANN dan Gaussian Naïve Bayes mampu menghasilkan representasi fitur yang lebih baik sebelum proses klasifikasi dilakukan. Representasi fitur tersebut membantu Gaussian Naïve Bayes dalam mengurangi pengaruh asumsi independensi antar atribut sehingga proses klasifikasi menjadi lebih optimal. Hasil penelitian ini menunjukkan bahwa kombinasi metode machine learning dapat menjadi pendekatan yang efektif dalam klasifikasi prognosis kanker payudara.

IV. KESIMPULAN

Penelitian ini berhasil menerapkan metode hybrid Artificial Neural Network (ANN) dan Gaussian Naïve Bayes untuk prediksi prognosis kanker payudara menggunakan dataset Breast Cancer Wisconsin Prognostic (WPBC). ANN digunakan sebagai proses ekstraksi fitur sebelum dilakukan klasifikasi menggunakan Gaussian Naïve Bayes. Pendekatan hybrid yang digunakan mampu meningkatkan performa klasifikasi dibandingkan metode tunggal.

Berdasarkan hasil pengujian, model hybrid ANN dan Gaussian Naïve Bayes memperoleh nilai *accuracy* sebesar 90%, *precision* sebesar 72,73%, *recall* sebesar 88,89%, dan *F1-score* sebesar 80%. Hasil tersebut menunjukkan bahwa pendekatan hybrid ANN dan Gaussian Naïve Bayes mampu menghasilkan performa klasifikasi yang lebih baik dibandingkan penggunaan metode tunggal.

Penelitian ini masih memiliki beberapa keterbatasan, di antaranya jumlah dataset yang relatif kecil dan hanya menggunakan satu arsitektur ANN dengan satu hidden layer dan belum membandingkan performa dengan metode deep learning lainnya.

Penelitian selanjutnya dapat menggunakan dataset dengan jumlah data yang lebih besar serta membandingkan performa metode hybrid dengan algoritma machine learning lainnya untuk memperoleh hasil klasifikasi yang lebih optimal, juga dapat memanfaatkan metode Explainable Artificial Intelligence (XAI) untuk mengetahui fitur yang memiliki pengaruh terbesar terhadap hasil prediksi prognosis kanker payudara.

REFERENSI

- [1] S. Z. Amanta, A. Fitri, H. S. Nasution, and D. Sitanggang, "Faktor – Faktor yang Memengaruhi Disease Free Survival 5 Tahun Pasien Kanker Payudara di RSUD Raden," vol. 6, pp. 5448–5463, 2025.
- [2] D. Z. Zurkarnain, A. Damayanti, and E. Winarko, "Hybrid Jaringan Saraf Tiruan Backpropagation dengan Firefly Algorithm dan Simulated Annealing untuk Peramalan Curah Hujan di Surabaya," vol. 3, no. 1, pp. 56–70, 2021.
- [3] Natalia et al., "Perbandingan Algoritma Naive Bayes , Logistic Regression Dan Artificial Neural Network Untuk Klasifikasi Tingkat Kesejahteraan Keluarga," pp. 1–13.
- [4] N. Cahyani, R. Irsyada, and A. Y. Kartini, "Implementasi Machine Learning Model sebagai Sistem Prediksi Penyakit Breast Cancer," vol. 4, no. 2, pp. 1112–1120, 2024.
- [5] A. B. Kurniati and W. A. Sidik, "Model Artificial Neural Networks (ANN) untuk Prediksi COVID- 19 di Indonesia," vol. 12, no. 3, pp. 833–844, 2023.
- [6] V. R. Danestiara and M. S. Abdillah, "Deep Neural Network untuk Klasifikasi Influenza," vol. 21, no. 2, pp. 288–292, 2022.
- [7] T. H. Saragih *et al.*, "Jaringan Syaraf Tiruan Backpropagation dengan Adaptive Moment Estimation untuk Klasifikasi Penyakit Covid-19 di Kalimantan Selatan," vol. 16, no. 2, pp. 162–172, 2022.
- [8] O. Shobayo, "Developments in Deep Learning Artificial Neural Network Techniques for Medical Image Analysis and Interpretation," pp. 1–31, 2025.
- [9] A. Safonova, G. Ghazaryan, S. Stiller, M. Mainknorn, C. Nendel, and M. Ryo, "International Journal of Applied Earth Observation and Geoinformation Ten deep learning techniques to address small data problems with remote sensing," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 125, no. November, p. 103569, 2023, doi: 10.1016/j.jag.2023.103569.
- [10] A. N. P. Shona Chayy Bilqisth, Khoirudin, "Mengukur Tingkat Kepuasan Mahasiswa Terhadap E-Learning Universitas Semarang Menggunakan Algoritma Naïve Bayes," *J. Tek. Elektro dan Inform.*, vol. 17, pp. 1–7, 2022.
- [11] W. A. Dewa, "Penerapan Metode Naïve Bayes untuk Menentukan Pengajuan Polis Baru pada PT. Asuransi "XYZ"," vol. 20, pp. 83–91, 2021.
- [12] A. E. Prasetya, F. M. Ishaq, I. Prasetya, and N. Purwati, "Implementasi Teknik Data Mining untuk Memprediksi Kanker Payudara dengan Algoritma Naive Bayes," vol. 1, no. 1, pp. 27–35, 2025.
- [13] L. Tanti, B. S. Riza, Y. Y. Thanri, and N. Panjaitan, "Model Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Naive Bayes," *IT J.*, vol. 12, no. 2, pp. 1–12, 2024, [Online]. Available: <https://www.doi.org/10.22303/it.1.1.2021.01-10>
- [14] M. I. Yordanus and W. F. Senjaya, "Prediksi Diagnosis dan Prognosis Breast Cancer menggunakan Machine Learning," vol. 6, no. November, pp. 284–290, 2024.
- [15] M. R. Alfarizi and M. Z. Al-farish, "Penggunaan Python sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning," vol. 2, pp. 1–6, 2023.
- [16] A. A. Permana, I. Engineering, U. M. Tangerang, and J. Perintis, "Enhancing Early Diagnosis of Heart Disease : A Comparative Study of K-NN and Naive Bayes Classifiers Using the UCI Heart Disease Dataset," vol. 5, no. 1, pp. 35–42, 2024, doi: 10.26714/jichi.v5i1.11251.

Sistem Pendukung Keputusan Seleksi Penerima Beasiswa KIP Kuliah Menggunakan Metode SAW dengan Pembobotan Kriteria Akademik dan Kondisi Ekonomi Mahasiswa

Laura^{1*}, Yaslinda Lizar²

^{1,2}Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Imam Bonjol Padang
Email: ^{1*}wawalaura813@gmail.com, ²yaslinda.lizar@uinib.ac.id

Abstrak - Proses seleksi penerima beasiswa memerlukan mekanisme penilaian yang mampu mengakomodasi berbagai kriteria secara adil dan terukur. Banyaknya jumlah pendaftar serta beragam faktor yang menjadi pertimbangan sering kali menyebabkan proses penentuan penerima beasiswa menjadi kompleks apabila dilakukan secara manual. Kondisi tersebut berpotensi menimbulkan subjektivitas dan ketidakkonsistenan dalam pengambilan keputusan. Penelitian ini bertujuan mengembangkan Sistem Pendukung Keputusan (SPK) yang dapat membantu proses pemilihan penerima beasiswa dengan menerapkan metode Simple Additive Weighting (SAW). Metode SAW dipilih karena memiliki kemampuan untuk mengolah sejumlah kriteria yang telah diberi bobot sesuai tingkat kepentingannya, sehingga menghasilkan nilai preferensi yang dapat digunakan sebagai dasar penentuan penerima beasiswa. Kriteria yang digunakan meliputi Indeks Prestasi Kumulatif (IPK), penghasilan orang tua, jumlah tanggungan orang tua, prestasi mahasiswa, dan tingkat kehadiran. Pengumpulan data dilakukan melalui penyebaran kuesioner kepada 30 responden guna memperoleh informasi terkait relevansi dan tingkat kepentingan setiap kriteria. Hasil penelitian menunjukkan bahwa penerapan metode SAW mampu menghasilkan peringkat calon penerima beasiswa secara sistematis berdasarkan nilai preferensi tertinggi. Dengan demikian, sistem yang dikembangkan dapat mendukung proses seleksi yang lebih efisien, objektif, dan akuntabel.

Kata kunci: Sistem Pendukung Keputusan, Beasiswa, Simple Additive Weighting, Pengambilan Keputusan, Seleksi Penerima Beasiswa

Abstract - The scholarship recipient selection process requires an assessment mechanism capable of accommodating multiple criteria in a fair and measurable manner. The large number of applicants and the variety of factors considered often make the selection process complex when conducted manually. Such conditions may lead to subjectivity and inconsistencies in decision-making. This study aims to develop a Decision Support System (DSS) to assist in selecting scholarship recipients by applying the Simple Additive Weighting (SAW) method. The SAW method was chosen because it can process multiple criteria that have been assigned weights according to their level of importance, thereby generating preference values that can be used as the basis for determining scholarship recipients. The criteria used in this study include Grade Point Average (GPA), parents' income, number of dependents in the family, student achievements, and attendance

records. Data were collected through the distribution of questionnaires to 30 respondents to obtain information regarding the relevance and importance of each criterion. The results indicate that the implementation of the SAW method can systematically rank scholarship candidates based on the highest preference values. Therefore, the developed system can support a more efficient, objective, and accountable scholarship selection process.

Keywords— Decision Support System, Scholarship, Simple Additive Weighting, Decision Making, Scholarship Selection

I. PENDAHULUAN

Beasiswa merupakan salah satu bentuk bantuan pendidikan yang diberikan kepada mahasiswa untuk mendukung keberlangsungan studi dan meningkatkan motivasi belajar. Pemberian beasiswa bertujuan untuk membantu mahasiswa yang memiliki keterbatasan ekonomi maupun mahasiswa berprestasi agar dapat menyelesaikan pendidikan dengan baik.

Namun, dalam proses penentuan penerima beasiswa sering ditemukan berbagai kendala, terutama ketika jumlah calon penerima cukup banyak dan kriteria penilaian yang digunakan beragam. Kondisi ini menyebabkan proses seleksi menjadi lebih kompleks dan berpotensi menimbulkan subjektivitas dalam pengambilan keputusan. Pada umumnya, proses penentuan penerima beasiswa masih dilakukan secara manual dengan mempertimbangkan beberapa aspek seperti Indeks Prestasi Kumulatif (IPK), penghasilan orang tua, jumlah tanggungan keluarga, prestasi akademik maupun non-akademik, serta tingkat kehadiran mahasiswa. Proses seleksi secara manual membutuhkan waktu yang relatif lama dan memiliki risiko kesalahan dalam pengolahan data, sehingga keputusan yang dihasilkan kurang optimal [1].

Untuk meningkatkan kualitas proses penentuan penerima beasiswa, dibutuhkan suatu mekanisme yang mampu mendukung pengambilan keputusan secara sistematis dan

berbasis data. Salah satu solusi yang dapat diterapkan adalah Sistem Pendukung Keputusan (SPK), yaitu sistem komputer yang digunakan untuk membantu pengambil keputusan dalam menganalisis berbagai alternatif pada permasalahan yang memiliki banyak pertimbangan [2]. Penerapan SPK dalam proses seleksi beasiswa memungkinkan setiap calon penerima dievaluasi berdasarkan kriteria yang telah ditetapkan, sehingga hasil penilaian menjadi lebih objektif, akurat, dan mudah dipertanggungjawabkan. Selain itu, penggunaan sistem ini dapat meningkatkan efisiensi proses seleksi serta memperkuat transparansi dalam penentuan penerima beasiswa.

Simple Additive Weighting (SAW) merupakan salah satu teknik pengambilan keputusan multikriteria yang banyak digunakan dalam Sistem Pendukung Keputusan. Metode ini memungkinkan setiap alternatif dinilai berdasarkan sejumlah kriteria yang memiliki tingkat kepentingan berbeda. Proses pengolahan data dilakukan melalui normalisasi nilai kriteria untuk memperoleh skala yang seragam, kemudian dilanjutkan dengan perhitungan nilai preferensi menggunakan bobot yang telah ditentukan. Nilai preferensi tersebut menjadi dasar dalam menentukan urutan prioritas alternatif [3]. Karena prosedur perhitungannya tidak kompleks dan mudah dipahami, metode SAW sering dipilih sebagai pendekatan yang efektif dalam menghasilkan keputusan yang terukur dan objektif.

Beberapa penelitian terdahulu menunjukkan bahwa metode SAW telah banyak diterapkan dalam berbagai proses seleksi dan pengambilan keputusan, termasuk dalam penentuan penerima beasiswa. Penelitian sebelumnya menunjukkan bahwa metode SAW mampu meningkatkan efektivitas proses seleksi dengan mempertimbangkan berbagai kriteria secara bersamaan sehingga hasil keputusan menjadi lebih akurat dan adil [4]. Namun demikian, masih terdapat kebutuhan untuk menyesuaikan penggunaan kriteria dengan kondisi dan kebutuhan pada lingkungan penelitian tertentu agar hasil keputusan lebih relevan.

Penelitian ini menawarkan pendekatan yang berbeda dibandingkan studi terdahulu yang umumnya memanfaatkan metode Simple Additive Weighting (SAW) untuk kebutuhan seleksi secara luas. Fokus penelitian diarahkan pada penentuan penerima beasiswa KIP Kuliah dengan mengintegrasikan aspek akademik dan aspek ekonomi sebagai dasar penilaian. Beberapa kriteria yang digunakan dalam proses evaluasi meliputi Indeks Prestasi Kumulatif (IPK), tingkat pendapatan orang tua, jumlah anggota keluarga yang menjadi tanggungan, prestasi yang dimiliki mahasiswa, serta tingkat kehadiran selama perkuliahan. Integrasi berbagai kriteria tersebut memungkinkan proses seleksi dilakukan secara lebih komprehensif karena tidak hanya menilai capaian akademik mahasiswa, tetapi juga mempertimbangkan kondisi ekonomi keluarga. Dengan demikian, sistem yang dikembangkan mampu menghasilkan rekomendasi penerima beasiswa yang lebih tepat sasaran, transparan, dan sesuai dengan tujuan pemberian bantuan pendidikan.

Berdasarkan permasalahan yang telah diidentifikasi, penelitian ini berfokus pada pengembangan sebuah sistem

yang dapat mendukung proses pengambilan keputusan dalam penentuan penerima beasiswa. Sistem yang dibangun dirancang untuk mengolah data calon penerima secara terstruktur sehingga menghasilkan rekomendasi yang dapat dijadikan acuan dalam proses seleksi. Melalui penerapan mekanisme penilaian yang sistematis, penelitian ini diharapkan mampu meningkatkan efisiensi proses evaluasi, mengurangi unsur subjektivitas dalam penentuan penerima, serta menghasilkan keputusan yang lebih konsisten dan dapat dipertanggungjawabkan. Selain itu, sistem diharapkan dapat membantu pihak pengelola beasiswa dalam menetapkan penerima yang paling layak berdasarkan hasil pengolahan data yang dilakukan secara terukur.

II. METODE PENELITIAN

Penelitian ini bertujuan mengembangkan sebuah Sistem Pendukung Keputusan (SPK) yang dapat digunakan untuk membantu proses seleksi penerima beasiswa melalui penerapan metode Simple Additive Weighting (SAW). Sistem yang dibangun dirancang untuk menghasilkan rekomendasi penerima beasiswa berdasarkan hasil evaluasi sejumlah kriteria yang telah ditetapkan secara terukur dan sistematis.

A. Desain Penelitian

Jenis Penelitian: Penelitian ini menggunakan metode kuantitatif deskriptif dengan fokus pada pengembangan Sistem Pendukung Keputusan. Pendekatan deskriptif digunakan untuk menggambarkan kondisi dan kebutuhan dalam proses penentuan penerima beasiswa, sedangkan pendekatan kuantitatif diterapkan untuk mengolah data numerik yang diperoleh dari responden dan digunakan dalam proses perhitungan metode SAW.

Pendekatan Penelitian: Pendekatan kuantitatif dipilih karena seluruh data yang dianalisis berbentuk angka dan dapat diukur secara statistik. Data yang diperoleh selanjutnya diolah melalui beberapa tahapan, mulai dari penentuan bobot kriteria, normalisasi data, perhitungan nilai preferensi, hingga penyusunan peringkat alternatif sebagai dasar rekomendasi penerima beasiswa. Populasi: Populasi penelitian mencakup mahasiswa yang memiliki pemahaman mengenai mekanisme seleksi beasiswa. Pengambilan sampel dilakukan menggunakan teknik purposive sampling, yaitu pemilihan responden berdasarkan karakteristik tertentu yang relevan dengan tujuan penelitian. Jumlah sampel yang digunakan sebanyak 30 responden, yang seluruhnya merupakan mahasiswa aktif. Pendapat responden dimanfaatkan untuk memperoleh informasi mengenai tingkat kepentingan setiap kriteria yang digunakan dalam proses pengambilan keputusan. Instrumen: Instrumen penelitian menggunakan kuesioner berbasis Google Form yang terdiri dari 10 pertanyaan dengan skala Likert empat tingkat, yaitu Sangat Setuju (4), Setuju (3), Kurang Setuju (2), dan Tidak Setuju (1). Instrumen penelitian disusun berdasarkan indikator yang relevan dengan kebutuhan penelitian serta disesuaikan dengan tujuan penentuan penerima beasiswa.

B. Prosedur Penelitian

Langkah-langkah Penelitian: Penelitian ini dilakukan secara bertahap dimulai dari identifikasi masalah hingga

menghasilkan keputusan penerima beasiswa. Tahapan penelitian meliputi identifikasi masalah, pengumpulan data, penyebaran kuesioner, rekapitulasi data, penentuan kriteria, pembobotan kriteria, perhitungan metode identifikasi masalah, pengumpulan data, penyebaran kuesioner, rekapitulasi data, penentuan kriteria, pembobotan kriteria, perhitungan metode SAW, perankingan, dan hasil keputusan. Tahapan tersebut dilakukan agar proses penentuan penerima beasiswa dapat berjalan secara terstruktur dan menghasilkan keputusan yang objektif. Alur penelitian yang digunakan dapat dilihat pada Gambar 1.

Pada tahap awal penelitian, dilakukan pengumpulan data melalui observasi terhadap alur seleksi penerimaan beasiswa serta kajian pustaka yang berkaitan dengan Sistem Pendukung Keputusan dan penerapan metode Simple Additive Weighting (SAW). Selain itu, data juga diperoleh melalui kuesioner yang disebar menggunakan Google Form kepada 30 responden yang merupakan mahasiswa aktif. Instrumen pengukuran dalam kuesioner tersebut menggunakan skala Likert empat pilihan, yaitu Sangat Setuju (4), Setuju (3), Kurang Setuju (2), dan Tidak Setuju (1). Hasil jawaban responden kemudian diubah ke dalam bentuk angka agar dapat diproses lebih lanjut secara kuantitatif.


Adapun kriteria yang digunakan dalam penelitian ini meliputi Indeks Prestasi Kumulatif (IPK), pendapatan orang tua, jumlah tanggungan keluarga, prestasi akademik maupun nonakademik, serta tingkat kehadiran mahasiswa. Masing-masing kriteria tersebut kemudian diberikan bobot sesuai tingkat prioritasnya untuk mendukung proses penentuan kelayakan penerima beasiswa.

Pada tahap akhir, perhitungan dilakukan dengan pendekatan metode Simple Additive Weighting (SAW) yang mencakup proses normalisasi matriks keputusan, penghitungan nilai preferensi setiap alternatif, hingga proses pemeringkatan. Hasil akhir dari tahapan ini digunakan untuk menentukan alternatif terbaik sebagai penerima beasiswa secara lebih objektif.

C. Kriteria dan Pembobotan

Penelitian ini menerapkan metode Simple Additive Weighting (SAW) untuk membantu proses penentuan penerima beasiswa dengan mempertimbangkan sejumlah kriteria yang telah ditetapkan sebelumnya. Kriteria tersebut mencakup Indeks Prestasi Kumulatif (IPK), tingkat pendapatan orang tua, jumlah tanggungan keluarga, capaian prestasi, serta tingkat kehadiran mahasiswa. Setiap kriteria kemudian diberi bobot berdasarkan tingkat prioritasnya dalam proses pengambilan keputusan.

Langkah-langkah penerapan metode SAW dalam penelitian ini disajikan pada Gambar 1.



Gambar 1. Alur Penelitian Metode Simple Additive Weighting (SAW)

Kriteria yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1:

TABEL 1. Kriteria Penentuan Penerima Beasiswa

Kode	Kriteria	Atribut
C1	Indeks Prestasi Kumulatif (IPK)	Benefit
C2	Penghasilan Orang Tua	Cost
C3	Jumlah Tanggungan Orang Tua	Benefit
C4	Prestasi	Benefit
C5	Absensi Mahasiswa	Benefit

Masing-masing kriteria diberi nilai bobot yang disesuaikan dengan tingkat prioritasnya dalam proses seleksi penerima beasiswa. Rincian bobot untuk setiap kriteria tersebut ditampilkan pada Tabel II.

TABEL II. Bobot Kriteria

Kriteria	Bobot
C1 (IPK)	30%
C2 (Penghasilan Orang Tua)	25%
C3 (Jumlah Tanggungan Orang Tua)	20%
C4 (Prestasi)	15%
C5 (Absensi Mahasiswa)	10%

Tahapan awal dalam metode Simple Additive Weighting (SAW) dimulai dengan melakukan normalisasi pada matriks keputusan agar setiap kriteria memiliki skala nilai yang dapat dibandingkan. Rumus normalisasi untuk kriteria bertipe benefit disajikan pada Persamaan (1).

$$r_{ij} = \frac{x_{ij}}{\max(x_{ij})} \quad (1)$$

Sedangkan atribut cost digunakan apabila nilai terkecil merupakan nilai terbaik. Persamaan normalisasi cost ditunjukkan pada Persamaan (2).

$$r_{ij} = \frac{\min(x_{ij})}{x_{ij}} \quad (2)$$

Selanjutnya, nilai akhir alternatif dihitung menggunakan Persamaan (3).

$$V_i = \sum_{j=1}^n w_j r_{ij} \quad (3)$$

Keterangan:

V_i = nilai akhir alternatif

w_j = bobot setiap kriteria

r_{ij} = hasil normalisasi

x_{ij} = nilai alternatif pada setiap kriteria

Mengacu pada persamaan yang digunakan, metode Simple Additive Weighting (SAW) berfungsi untuk memperoleh nilai preferensi dari setiap alternatif dengan mengombinasikan bobot serta hasil normalisasi pada tiap kriteria. Hasil perhitungan akhir yang paling besar menunjukkan alternatif yang paling sesuai, sehingga dapat dipilih sebagai calon penerima beasiswa karena dianggap paling memenuhi seluruh kriteria yang ditetapkan.

III. HASIL DAN DISKUSI

A. Hasil Kuesioner

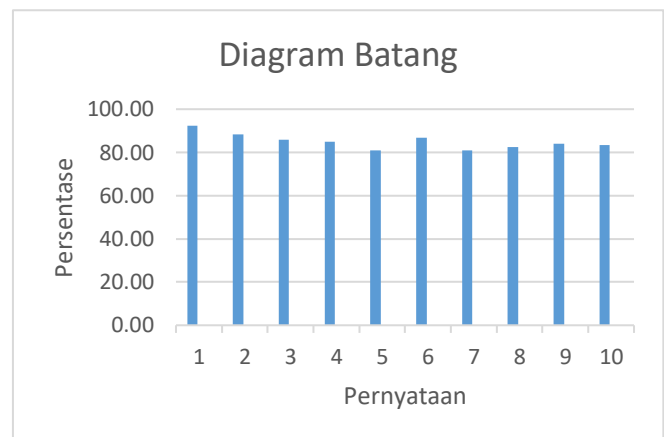
Data dalam penelitian ini diperoleh melalui penyebaran kuesioner kepada 30 responden guna menggali persepsi mereka terhadap kriteria yang digunakan dalam proses penentuan penerima beasiswa. Penyusunan kuesioner dilakukan dengan menggunakan skala Likert empat tingkat,

yaitu Sangat Setuju (4), Setuju (3), Kurang Setuju (2), dan Tidak Setuju (1). Selanjutnya, jawaban responden diolah dan direkap untuk mendapatkan total skor serta persentase pada setiap item pernyataan. Berdasarkan hasil rekapitulasi tersebut, diperoleh jumlah skor pada masing-masing indikator pertanyaan yang disajikan pada Tabel III.

TABEL III. Hasil Rekapitulasi Kuesioner

Pernyataan	Total Skor	Persentase
P1	111	92,50%
P2	106	88,33%
P3	103	85,83%
P4	102	85,00%
P5	97	80,83%
P6	104	86,67%
P7	97	80,83%
P8	99	82,50%
P9	101	84,17%
P10	100	83,33%

Dari data pada Tabel III terlihat bahwa seluruh indikator memperoleh tingkat persentase yang relatif tinggi. Persentase tertinggi dicapai oleh indikator P1 dengan nilai 92,50%, sedangkan nilai terendah berada pada indikator P5 dan P7 yang masing-masing sebesar 80,83%. Temuan ini mengindikasikan bahwa responden memberikan tanggapan positif terhadap kriteria yang diterapkan dalam proses seleksi penerima beasiswa. Ringkasan hasil persentase kuesioner tersebut ditampilkan pada Gambar 2.



Gambar 2. Diagram Persentase Hasil Kusioner

B. Penerapan Metode SAW

Setelah tahap pengumpulan data serta penetapan kriteria selesai dilakukan, proses berikutnya adalah implementasi metode Simple Additive Weighting (SAW) dalam penentuan penerima beasiswa. Langkah awal pada tahap ini adalah membentuk matriks keputusan yang berisi nilai setiap alternatif terhadap seluruh kriteria, yang kemudian

dilanjutkan dengan proses normalisasi serta penghitungan nilai preferensi.

Kriteria yang digunakan dalam penelitian ini mencakup Indeks Prestasi Kumulatif (IPK), tingkat pendapatan orang tua, jumlah tanggungan keluarga, prestasi mahasiswa, serta tingkat kehadiran. Setiap kriteria tersebut kemudian diberikan bobot sesuai dengan tingkat urgensinya dalam proses seleksi.

Selanjutnya, hasil perhitungan menggunakan metode SAW menghasilkan nilai akhir untuk masing-masing alternatif yang kemudian diurutkan dalam proses pemeringkatan. Alternatif dengan skor tertinggi dipilih sebagai kandidat utama penerima beasiswa karena dinilai paling sesuai dengan seluruh kriteria yang telah ditentukan.

C. Diskusi Hasil Penelitian

Hasil penelitian menunjukkan bahwa penerapan metode Simple Additive Weighting (SAW) dapat mendukung proses seleksi penerima beasiswa menjadi lebih sistematis dan objektif. Dengan mempertimbangkan beberapa kriteria dalam pengambilan keputusan, proses penilaian dapat dilakukan secara lebih transparan dan mengurangi subjektivitas dibandingkan metode manual.

Temuan ini juga konsisten dengan berbagai penelitian terdahulu yang menyebutkan bahwa SAW efektif digunakan dalam sistem pendukung keputusan karena mampu menghasilkan peringkat alternatif berdasarkan kombinasi bobot dan nilai tiap kriteria yang telah ditetapkan. Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan, antara lain jumlah responden yang relatif sedikit serta ruang lingkup kriteria yang masih dapat diperluas pada penelitian selanjutnya.

IV. KESIMPULAN

Berdasarkan hasil analisis yang telah dilakukan, dapat disimpulkan bahwa metode Simple Additive Weighting (SAW) dapat digunakan dalam sistem pendukung keputusan untuk membantu proses seleksi penerima beasiswa secara lebih sistematis dan objektif. Penelitian ini menetapkan beberapa kriteria penilaian, yaitu Indeks Prestasi Kumulatif (IPK), pendapatan orang tua, jumlah tanggungan keluarga, prestasi mahasiswa, serta tingkat kehadiran sebagai acuan dalam proses pemilihan.

Hasil pengolahan data menunjukkan bahwa metode SAW mampu memfasilitasi proses pengambilan keputusan melalui tahapan pemberian bobot pada setiap kriteria, normalisasi nilai, hingga proses pemeringkatan alternatif sehingga diperoleh kandidat penerima beasiswa yang paling sesuai. Selain itu, hasil kuesioner yang melibatkan 30 responden memperlihatkan bahwa kriteria yang digunakan mendapatkan respons positif, yang turut memperkuat penerapan metode ini dalam proses seleksi.

Secara keseluruhan, penelitian ini telah memenuhi tujuan yang ditetapkan, yaitu menciptakan proses penentuan penerima beasiswa yang lebih efisien, transparan, dan meminimalkan subjektivitas dalam pengambilan keputusan.

Dengan adanya sistem pendukung keputusan berbasis SAW, proses seleksi dapat dilakukan lebih cepat dengan hasil yang berbasis data terukur.

Selanjutnya, penelitian ini dapat dijadikan acuan bagi peneliti lain maupun institusi pendidikan dalam pengembangan sistem pendukung keputusan, khususnya pada bidang penentuan beasiswa. Untuk pengembangan lebih lanjut, disarankan agar jumlah responden diperbesar, kriteria penilaian diperluas, serta dilakukan perbandingan dengan metode lain dalam sistem pendukung keputusan guna memperoleh hasil yang lebih akurat dan optimal.

REFERENSI

- [1] J. G. T. Pranoto, D. Pebrianti, M. Darwis, Yaddarabullah, and E. D. Krishnasari, "Selection of Education Assistance Recipients Based on AHP and SAW," in 2022 International Seminar on Intelligent Technology and Its Applications (ISITIA), Surabaya, Indonesia, 2022, pp. 163–168, doi: 10.1109/ISITIA56226.2022.9855329.
- [2] S. Kusumadewi, *Sistem Pendukung Keputusan: Model dan Proses Pengambilan Keputusan*. Yogyakarta: Graha Ilmu, 2016.
- [3] E. Turban, R. Sharda, and D. Delen, *Decision Support and Business Intelligence Systems*, 10th ed. Boston, MA, USA: Pearson, 2015.
- [4] D. Nofriansyah and S. Defit, *Multi Criteria Decision Making (MCDM) pada Sistem Pendukung Keputusan*. Yogyakarta: Deepublish, 2017.
- [5] T. Limbong et al., *Sistem Pendukung Keputusan: Metode dan Implementasi*. Medan: Yayasan Kita Menulis, 2020.
- [6] A. S. Rosa and M. Shalahuddin, *Rekayasa Perangkat Lunak Terstruktur dan Berorientasi Objek*. Bandung: Informatika, 2018.
- [7] I. Sommerville, *Software Engineering*, 10th ed. Boston, MA, USA: Pearson, 2016.
- [8] R. S. Pressman and B. R. Maxim, *Software Engineering: A Practitioner's Approach*, 8th ed. New York, NY, USA: McGraw-Hill Education, 2019.
- [9] A. Kadir, *Pengenalan Sistem Informasi*. Yogyakarta: Andi Offset, 2017.
- [10] M. Muslihudin and Oktafianto, *Analisis dan Perancangan Sistem Informasi Menggunakan Model Terstruktur dan UML*. Yogyakarta: Andi, 2016.
- [11] F. Riandari, "Sistem Pendukung Keputusan Penerima Beasiswa Menggunakan Metode Simple Additive Weighting (SAW)," *Jurnal Teknologi Informasi*, vol. 4, no. 2, pp. 120–128, 2020.
- [12] R. Yunitarini, "Sistem Pendukung Keputusan dengan Metode Simple Additive Weighting untuk Pemilihan Penerima Beasiswa," *Jurnal Ilmiah Teknologi Informasi Asia*, vol. 13, no. 2, pp. 95–102, 2019.
- [13] M. Iqbal, A. Setiawan, and L. Pratama, "Penerapan Metode SAW pada Sistem Pendukung Keputusan Seleksi Penerima Beasiswa," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 3, pp. 512–520, 2022.
- [14] A. Nugroho and D. Prasetyo, "Implementation of Decision Support System for Scholarship Selection Using SAW Method," *Journal of Information Systems Engineering and Business Intelligence*, vol. 8, no. 1, pp. 55–63, 2023.
- [15] K. P. Fishburn, "Additive Utilities with Incomplete Product Sets: Application to Priorities and Assignments," *Operations Research*, vol. 15, no. 3, pp. 537–542, 2017.

Klasifikasi Sampah Berbasis Citra Menggunakan Metode CNN: Studi Komparatif dengan Decision Tree, Random Forest, dan SVM untuk Pengelolaan Sampah Berkelanjutan

Nabila Carrissa Dewi^{1*}, Gus Nanang Syaifuddiin²

^{1,2}Program Studi Teknologi Rekayasa Perangkat Lunak, Fakultas Teknik, Politeknik Negeri Madiun
Email: ^{1*}nabilacarrissa@gmail.com, ²gus.nanang@pnm.ac.id

Abstrak - Peningkatan volume sampah yang terus terjadi menuntut pengembangan teknologi pemilahan otomatis yang akurat dan efisien guna mendukung pengelolaan sampah berkelanjutan. Dalam beberapa tahun terakhir, Convolutional Neural Network (CNN) menjadi pendekatan dominan dalam klasifikasi citra karena kemampuannya mempelajari fitur secara otomatis. Namun, efektivitas CNN pada kondisi dataset yang terbatas masih menjadi tantangan yang belum sepenuhnya dipahami. Penelitian ini bertujuan untuk mengevaluasi kinerja CNN dibandingkan dengan algoritma machine learning klasik, yaitu Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT), pada tugas klasifikasi sampah berbasis citra.

Penelitian menggunakan Garbage Classification Dataset yang terdiri atas 4.133 citra dari tujuh kategori sampah. Tahapan penelitian meliputi preprocessing citra, ekstraksi fitur Histogram of Oriented Gradients (HOG) untuk model machine learning, pembagian data secara stratified dengan rasio 70:20:10, pelatihan model, serta evaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi 67,15%, diikuti Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%.

Temuan ini menunjukkan bahwa model deep learning tidak selalu memberikan hasil terbaik pada seluruh kondisi eksperimen. Meskipun CNN secara teoritis memiliki kemampuan representasi yang lebih tinggi, performanya menurun secara signifikan ketika dilatih dari awal menggunakan dataset yang relatif terbatas dan memiliki kemiripan visual antar kelas. Sebaliknya, pendekatan berbasis fitur HOG mampu menyediakan representasi visual yang lebih stabil sehingga meningkatkan kemampuan generalisasi algoritma machine learning klasik. Hasil penelitian memberikan bukti empiris bahwa pada skenario klasifikasi sampah dengan ketersediaan data yang terbatas, kombinasi HOG dan SVM dapat menjadi alternatif yang lebih efektif dibandingkan CNN. Temuan ini berkontribusi pada pengembangan sistem pemilahan sampah otomatis yang lebih efisien, ringan secara komputasi, dan berpotensi diterapkan pada lingkungan dengan sumber daya terbatas untuk mendukung pengelolaan sampah berkelanjutan.

Kata Kunci: Klasifikasi sampah, CNN, SVM, HOG, machine learning

Abstract - The increasing volume of municipal waste has intensified the need for accurate and efficient automated waste-sorting technologies to support sustainable waste management. Although Convolutional Neural Networks (CNNs) have become the dominant approach in image classification due to their ability to learn feature representations automatically, their effectiveness under limited-data conditions remains insufficiently explored. This study investigates the performance of CNNs in comparison with conventional machine learning algorithms, namely Support Vector Machine (SVM), Random Forest (RF), and Decision Tree (DT), for image-based waste classification.

The experiments were conducted using the Garbage Classification Dataset consisting of 4,133 images distributed across seven waste categories. The proposed framework involved image preprocessing, Histogram of Oriented Gradients (HOG) feature extraction for machine learning models, stratified data partitioning with a 70:20:10 ratio, model training, and evaluation using accuracy, precision, recall, and F1-score metrics. The results demonstrate that SVM achieved the highest accuracy of 67.15%, followed by Random Forest (65.70%), Decision Tree (39.61%), and CNN (23.67%).

A notable finding of this study is that the CNN model, despite its superior theoretical capacity for automatic feature learning, produced the lowest classification performance among the evaluated approaches. This outcome suggests that training a CNN from scratch on a relatively limited dataset with considerable inter-class visual similarity is insufficient to learn highly discriminative feature representations. In contrast, HOG-based feature engineering provided more structured and stable visual descriptors, enabling conventional machine learning algorithms to achieve better generalization performance. These findings indicate that deep learning models do not necessarily outperform traditional machine learning approaches in all scenarios and that dataset characteristics play a critical role in determining model effectiveness. This study contributes empirical evidence that, in resource-constrained environments and limited-data settings, the combination of HOG and SVM can serve as a more accurate and computationally efficient alternative to CNN-based approaches for automated waste classification. The findings provide valuable insights for the development of practical intelligent waste-sorting systems that support sustainable waste management initiatives.

Keywords: Waste Classification, CNN, SVM, HOG, Machine Learning

I. PENDAHULUAN

Peningkatan jumlah sampah merupakan salah satu permasalahan lingkungan yang semakin kompleks seiring dengan pertumbuhan populasi, urbanisasi, dan meningkatnya aktivitas konsumsi masyarakat. Pengelolaan sampah yang tidak optimal dapat menimbulkan berbagai dampak negatif, seperti pencemaran lingkungan, penurunan kualitas kesehatan masyarakat, serta meningkatnya beban pengelolaan di tempat pemrosesan akhir. Salah satu tahapan penting dalam pengelolaan sampah adalah proses pemilahan berdasarkan jenis material, karena kualitas pemilahan akan memengaruhi efektivitas proses daur ulang dan pengolahan lanjutan.

Seiring berkembangnya teknologi kecerdasan buatan, berbagai penelitian telah memanfaatkan pengolahan citra digital untuk mengotomatisasi proses klasifikasi sampah. Pendekatan ini memungkinkan sistem mengenali jenis sampah secara otomatis melalui citra yang diperoleh dari kamera sehingga dapat mengurangi ketergantungan pada proses pemilahan manual. Implementasi sistem klasifikasi berbasis citra juga menjadi salah satu solusi yang potensial untuk mendukung pengelolaan sampah yang lebih efisien dan berkelanjutan.

Dalam beberapa tahun terakhir, Convolutional Neural Network (CNN) menjadi metode yang paling banyak digunakan dalam klasifikasi citra karena kemampuannya mempelajari fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur manual. Berbagai penelitian melaporkan bahwa CNN mampu menghasilkan tingkat akurasi yang tinggi pada tugas klasifikasi objek, termasuk klasifikasi sampah. Namun, sebagian besar penelitian tersebut menggunakan dataset berukuran besar, teknik augmentasi yang intensif, atau memanfaatkan transfer learning dari model yang telah dilatih sebelumnya. Kondisi tersebut menyebabkan performa CNN pada dataset yang relatif terbatas masih belum sepenuhnya dapat digeneralisasikan.

Di sisi lain, algoritma machine learning klasik seperti Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) masih banyak digunakan karena memiliki kompleksitas yang lebih rendah dan kebutuhan komputasi yang lebih ringan. Berbeda dengan CNN yang melakukan pembelajaran fitur secara otomatis, algoritma machine learning memerlukan representasi fitur yang diekstraksi terlebih dahulu, salah satunya menggunakan Histogram of Oriented Gradients (HOG). Beberapa penelitian menunjukkan bahwa kombinasi HOG dan algoritma machine learning masih mampu memberikan

performa yang kompetitif pada dataset berukuran kecil hingga menengah.

Meskipun penelitian mengenai klasifikasi sampah telah banyak dilakukan, sebagian besar studi berfokus pada peningkatan performa CNN dan hanya sedikit yang mengevaluasi secara mendalam kondisi ketika metode machine learning klasik dapat memberikan hasil yang lebih baik dibandingkan pendekatan deep learning. Selain itu, kajian komparatif yang menganalisis perbedaan performa antara CNN dan algoritma machine learning berbasis HOG pada dataset klasifikasi sampah yang relatif terbatas masih belum banyak dilaporkan. Akibatnya, belum terdapat pemahaman yang memadai mengenai pendekatan yang paling efektif untuk diterapkan pada kondisi dengan keterbatasan data dan sumber daya komputasi.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan membandingkan performa CNN, SVM, Random Forest, dan Decision Tree dalam klasifikasi sampah berbasis citra menggunakan dataset yang terdiri atas tujuh kategori sampah. Berbeda dengan penelitian terdahulu yang umumnya berfokus pada pencapaian akurasi tertinggi, penelitian ini menitikberatkan pada analisis

efektivitas pendekatan deep learning dan machine learning klasik pada kondisi dataset yang terbatas. Dengan demikian, penelitian ini tidak hanya memberikan perbandingan performa antar model, tetapi juga menyajikan pemahaman empiris mengenai faktor-faktor yang menyebabkan perbedaan kinerja masing-masing metode.

Kontribusi utama penelitian ini terletak pada evaluasi komprehensif terhadap perbedaan paradigma pembelajaran antara CNN sebagai pendekatan end-to-end dan algoritma machine learning klasik yang memanfaatkan fitur HOG. Hasil penelitian diharapkan dapat memberikan referensi dalam pemilihan model klasifikasi yang sesuai untuk sistem pemilahan sampah otomatis, sekaligus mendukung pengembangan teknologi pengelolaan sampah yang lebih efektif, efisien, dan berkelanjutan.

II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen untuk membandingkan performa empat algoritma klasifikasi citra, yaitu Convolutional Neural Network (CNN), Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF) dalam mengklasifikasikan citra sampah. Seluruh model dilatih dan diuji menggunakan dataset yang sama sehingga perbandingan dapat dilakukan secara objektif.

A. Dataset

Penelitian ini menggunakan dataset Garbage Classification yang tersedia secara public di platform Kaggle (<https://www.kaggle.com/datasets/karansolanki01/garbage-classification>). Dataset yang terdiri atas 4.133 citra dan terbagi ke dalam tujuh kelas, yaitu Battery, Cardboard, Clothes, Glass, Metal, Paper, dan Plastic. Dataset dipilih karena memiliki variasi objek yang cukup beragam sehingga dapat digunakan untuk mengevaluasi kemampuan model dalam mengenali berbagai jenis sampah.



Gambar 1. Clothes

Untuk menjaga proporsi data pada setiap kelas, dilakukan pembagian data menggunakan metode stratified sampling dengan rasio 70% data pelatihan, 20% data validasi, dan 10% data pengujian. Proses pembagian data menggunakan nilai random seed = 42 untuk memastikan hasil eksperimen dapat direproduksi pada penelitian selanjutnya.

B. Pra-pemrosesan

Tahap pra-pemrosesan dilakukan sebelum proses pelatihan model. Seluruh citra diubah ukurannya menjadi 128×128 piksel agar memiliki dimensi yang seragam. Selanjutnya, nilai piksel dinormalisasi ke rentang 0–1 dengan membagi setiap nilai piksel dengan 255.

Pada algoritma SVM, Decision Tree, dan Random Forest dilakukan ekstraksi fitur menggunakan metode Histogram of Oriented Gradients (HOG). Parameter HOG yang digunakan meliputi orientasi gradien sebanyak 9 bin, ukuran sel 8×8 piksel, ukuran blok 2×2 sel, serta normalisasi blok menggunakan metode L2-Hys. Hasil ekstraksi fitur kemudian digunakan sebagai masukan bagi algoritma klasifikasi.

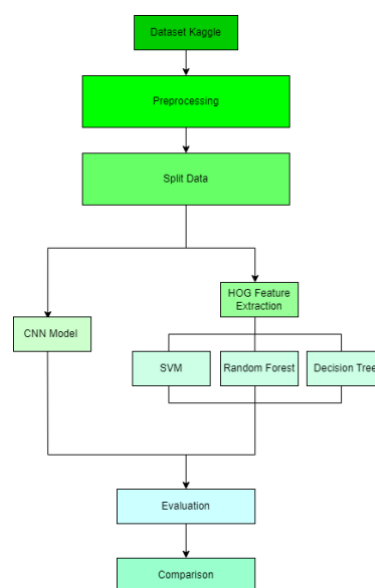
Berbeda dengan metode machine learning klasik, model CNN menerima citra yang telah dinormalisasi secara

langsung sehingga proses ekstraksi fitur dilakukan secara otomatis melalui lapisan konvolusi.

C. Tahapan Penelitian

Tahapan penelitian yang dilakukan ditunjukkan pada Gambar 2 dan terdiri atas beberapa langkah sebagai berikut:

1. Pengumpulan dataset klasifikasi sampah.
2. Pra-pemrosesan citra berupa resizing dan normalisasi.
3. Ekstraksi fitur HOG untuk model SVM, DT, dan RF.
4. Pelatihan model CNN, SVM, DT, dan RF menggunakan data pelatihan.
5. Evaluasi dan perbandingan performa model berdasarkan *metric* evaluasi.



Gambar 2. Diagram Alur

D. Konfigurasi Model

1. Convolutional Neural Network (CNN)

CNN digunakan sebagai representasi pendekatan deep learning yang mampu mempelajari fitur citra secara otomatis tanpa memerlukan ekstraksi fitur manual. Model dibangun menggunakan empat lapisan konvolusi yang diikuti oleh Batch Normalization, fungsi aktivasi ReLU, dan Max Pooling. Pada tahap klasifikasi digunakan Global Average Pooling, lapisan Dense sebanyak 256 neuron, serta Dropout sebesar 0,5 untuk mengurangi risiko overfitting. Lapisan keluaran menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi tujuh kelas sampah.

TABEL 1. Konfigurasi Model CNN

Parameter	Nilai
Input Size	$224 \times 224 \times 3$
Convolution Layers	4 Layer
Filter	32, 64, 128, 256
Kernel Size	3×3

Activation Function	ReLU
Pooling	Max Pooling 2 × 2
Dense Layer	256 Neuron
Dropout	0,5
Output Activation	Softmax
Optimizer	Adam
Learning Rate	0,0001
Loss Function	Sparse Categorical Crossentropy
Batch Size	32
Epoch	50

Model CNN dilatih menggunakan optimizer Adam dengan learning rate 0,0001 dan batch size 32 selama maksimum 50 epoch. Untuk meningkatkan stabilitas pelatihan digunakan Early Stopping dan Reduce Learning Rate on Plateau.

2. Support Vector Machine (SVM)

Support Vector Machine (SVM) digunakan sebagai salah satu model pembandingan karena memiliki kemampuan yang baik dalam menangani data berdimensi tinggi hasil ekstraksi fitur HOG. Model ini bekerja dengan mencari hyperplane optimal yang mampu memisahkan kelas secara maksimal.

TABEL 2. Konfigurasi Model SVM

Parameter	Nilai
Kernel	RBF
C	10
Gamma	Scale
Probability	True
Random State	42

Kernel Radial Basis Function (RBF) dipilih karena mampu menangani hubungan nonlinier pada ruang fitur yang dihasilkan oleh metode HOG.

3. Decision Tree

Decision Tree digunakan untuk membangun aturan klasifikasi berdasarkan struktur pohon keputusan. Setiap node merepresentasikan proses pemisahan data berdasarkan fitur tertentu hingga diperoleh keputusan akhir pada node daun.

TABEL 3. Konfigurasi Model Decision Tree

Parameter	Nilai
Criterion	Gini
Max Depth	None
Random State	42

Kriteria Gini digunakan untuk menentukan atribut terbaik pada setiap percabangan. Kedalaman pohon tidak dibatasi

sehingga struktur pohon dapat menyesuaikan karakteristik data yang digunakan.

4. Random Forest

Random Forest merupakan metode ensemble learning yang dibangun dari kumpulan pohon keputusan. Setiap pohon dilatih menggunakan subset data yang berbeda dan hasil prediksi akhir diperoleh melalui mekanisme majority voting.

TABEL 4. Konfigurasi Model Random Forest

Parameter	Nilai
n_estimators	150
Criterion	Gini
Max Depth	None
Random State	42
n_jobs	-1

Penggunaan 150 pohon keputusan bertujuan meningkatkan stabilitas model dan kemampuan generalisasi tanpa meningkatkan kompleksitas komputasi secara signifikan.

E. Lingkungan Eksperimen

Seluruh eksperimen dilakukan menggunakan bahasa pemrograman Python dengan beberapa pustaka utama yang ditunjukkan pada Tabel 5.

TABEL 5. Lingkungan Eksperimen

Komponen	Keterangan
Bahasa Pemrograman	Python
Framework CNN	TensorFlow / Keras
Machine Learning	Scikit-learn
Pengolahan Citra	OpenCV
Ekstraksi Fitur	Scikit-image (HOG)
Random Seed	42

F. Evaluasi Kerja

Evaluasi kinerja dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan citra sampah secara akurat. Seluruh model, yaitu CNN, SVM, Random Forest, dan Decision Tree, dievaluasi menggunakan data pengujian (testing set) yang tidak digunakan selama proses pelatihan.

Pengukuran performa dilakukan menggunakan confusion matrix dan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Penggunaan beberapa metrik diperlukan untuk memperoleh gambaran yang lebih komprehensif mengenai kemampuan model dalam melakukan klasifikasi pada setiap kelas sampah.

1. Accuracy

Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data pengujian.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

dengan:

- TP (True Positive) adalah jumlah data yang berhasil diklasifikasikan dengan benar sebagai kelas positif.
- TN (True Negative) adalah jumlah data yang berhasil diklasifikasikan dengan benar sebagai kelas negatif.
- FP (False Positive) adalah jumlah data yang salah diklasifikasikan sebagai kelas positif.
- FN (False Negative) adalah jumlah data positif yang salah diklasifikasikan sebagai kelas negatif.

2. Precision

Precision menunjukkan tingkat ketepatan model dalam memberikan prediksi pada suatu kelas.

$$Precision = \frac{TP}{TP + FP}$$

Nilai precision yang tinggi menunjukkan bahwa sebagian besar prediksi positif yang diberikan model merupakan prediksi yang benar.

3. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang termasuk ke dalam suatu kelas.

$$Recall = \frac{TP}{TP + FN}$$

Semakin tinggi nilai recall, semakin baik kemampuan model dalam mengenali objek pada kelas yang bersangkutan.

4. F1-Score

F1-Score merupakan rata-rata harmonik antara precision dan recall yang digunakan untuk memberikan evaluasi yang lebih seimbang.

$$F1 = \frac{Precision \times Recall}{Precision + Recall}$$

Metrik ini sangat berguna ketika distribusi data antar kelas tidak sepenuhnya seimbang.

5. Analisis Komparatif

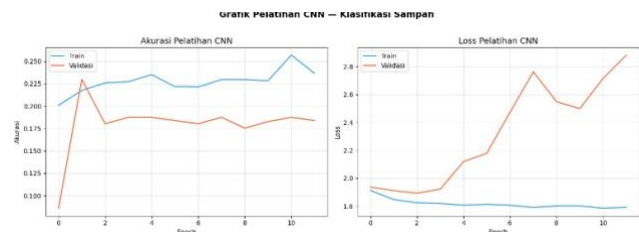
Hasil evaluasi dari setiap model kemudian dibandingkan untuk menentukan metode yang memiliki performa terbaik pada tugas klasifikasi sampah berbasis citra. Analisis dilakukan berdasarkan nilai accuracy, precision, recall, dan F1-score yang diperoleh masing-masing model. Selain membandingkan tingkat akurasi, penelitian ini juga menganalisis kemampuan generalisasi setiap model untuk memahami pengaruh karakteristik dataset terhadap efektivitas pendekatan deep learning dan machine learning klasik.

III. HASIL DAN DISKUSI

Bab ini menyajikan hasil eksperimen yang diperoleh dari penerapan metode Convolutional Neural Network (CNN), Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) pada dataset klasifikasi sampah berbasis citra. Evaluasi dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan model. Hasil eksperimen dianalisis menggunakan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Selain itu, dilakukan analisis komparatif untuk mengidentifikasi model yang memiliki performa terbaik serta mengevaluasi faktor-faktor yang memengaruhi perbedaan kinerja antar model.

A. Hasil Pelatihan Model CNN

Pada tahap pelatihan, model CNN dilatih menggunakan data pelatihan dengan konfigurasi yang telah dijelaskan pada Bab III. Untuk mengevaluasi proses pembelajaran model, digunakan grafik akurasi dan loss selama pelatihan.



Gambar 3. Grafik Akurasi dan Loss Pelatihan CNN

Gambar 3 menunjukkan perkembangan nilai akurasi dan loss pada data pelatihan dan validasi selama proses pelatihan CNN. Kurva tersebut digunakan untuk mengevaluasi kemampuan model dalam mempelajari pola data serta mengidentifikasi kemungkinan terjadinya overfitting atau underfitting. Meskipun akurasi pelatihan mengalami peningkatan selama proses pembelajaran, performa model pada data pengujian masih relatif rendah dibandingkan model machine learning yang menggunakan fitur HOG.

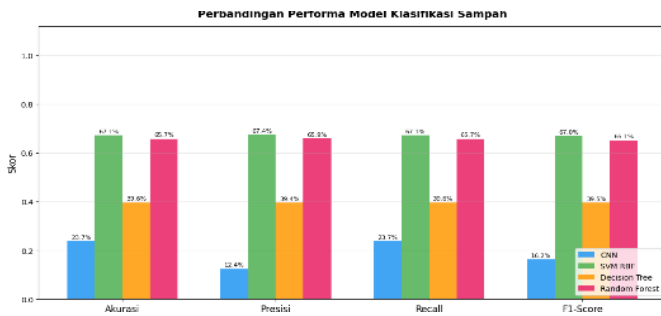
B. Hasil Evaluasi Kinerja Model

Evaluasi dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan. Kinerja model diukur menggunakan metrik accuracy, precision, recall, dan F1-score.

TABEL 6. Perbandingan Kinerja Model

MODEL	AKURASI	PRECISION	RECALL	F1-SCORE
0 CNN	23.67%	12.40%	23.67%	16.25%
1 SVM RBF	67.15%	67.39%	67.15%	66.95%
2 Decision Tree	39.61%	39.45%	39.61%	39.46%
3 Random Forest	65.70%	65.89%	65.70%	65.05%

Hasil pengujian menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi sebesar 67,15%, diikuti Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%.

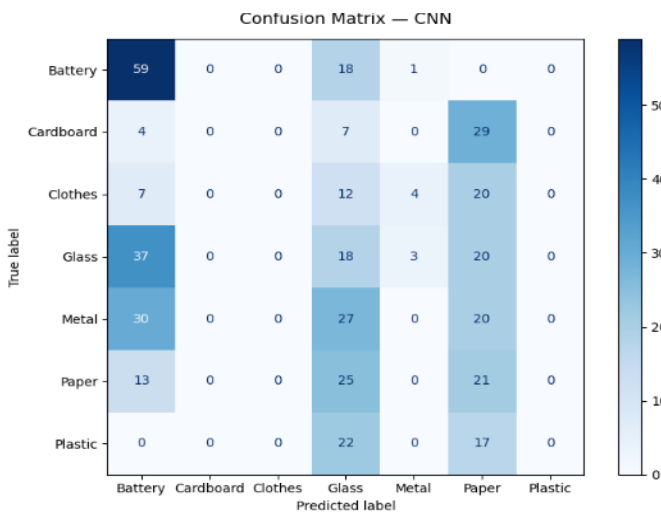


Gambar 4. Perbandingan Performa Model

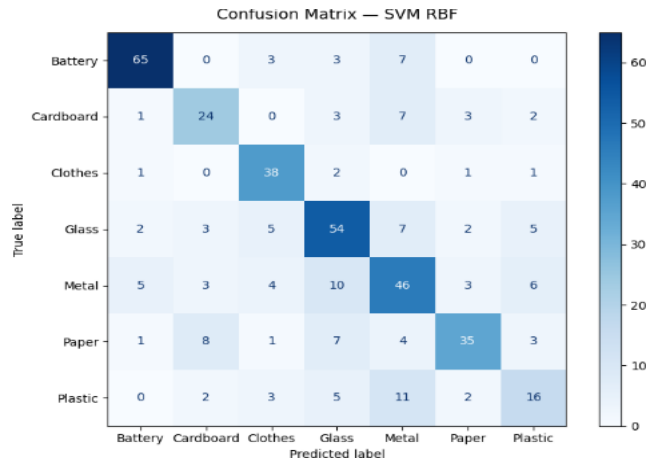
Berdasarkan Gambar 4, model SVM dan Random Forest menunjukkan performa yang lebih baik dibandingkan CNN dan Decision Tree pada hampir seluruh metrik evaluasi. Hasil ini menunjukkan bahwa representasi fitur HOG yang digunakan oleh model machine learning mampu memberikan informasi yang lebih efektif dalam membedakan karakteristik masing-masing kelas sampah.

C. Analisis Confusion Matrix

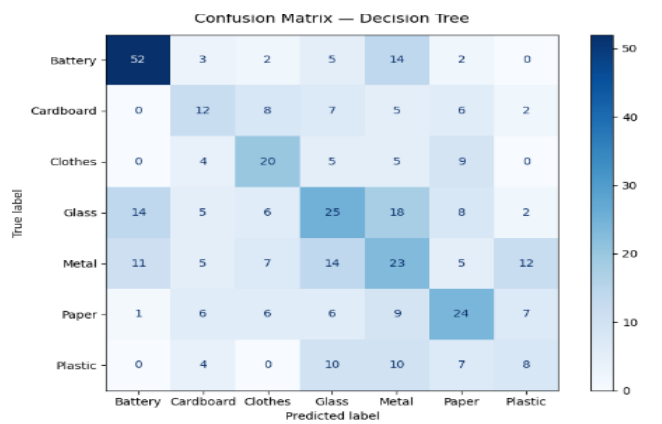
Untuk memahami pola kesalahan klasifikasi yang dilakukan model, digunakan confusion matrix pada masing-masing algoritma



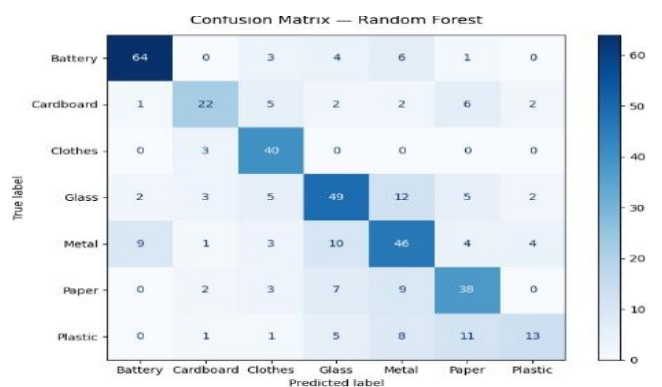
Gambar 5. Confusion Matrix CNN



Gambar 6. Confusion Matrix SVM RBF



Gambar 7. Confusion Matrix Decision Tree



Gambar 8. Confusion Matrix Random Forest

Confusion matrix menunjukkan distribusi prediksi benar dan salah pada setiap kelas. Model SVM memperlihatkan jumlah prediksi benar yang lebih tinggi dibandingkan model lainnya, sedangkan CNN menunjukkan tingkat kesalahan

klasifikasi yang lebih besar pada beberapa kelas sampah. Hal ini mengindikasikan bahwa fitur yang dipelajari CNN belum mampu membedakan karakteristik antar kelas secara optimal.

D. Diskusi

Hasil penelitian menunjukkan bahwa kombinasi HOG dan SVM menghasilkan performa terbaik dengan akurasi sebesar 67,15%. Temuan ini menunjukkan bahwa fitur berbasis gradien yang diekstraksi menggunakan HOG mampu merepresentasikan bentuk dan tekstur objek sampah secara efektif sehingga memudahkan proses klasifikasi.

Random Forest memperoleh akurasi sebesar 65,70%, hanya berbeda 1,45% dari SVM. Hal ini menunjukkan bahwa metode ensemble berbasis pohon keputusan juga mampu memanfaatkan fitur HOG dengan baik. Sebaliknya, Decision Tree menghasilkan akurasi yang lebih rendah karena model cenderung menghasilkan batas keputusan yang lebih sederhana dibandingkan Random Forest.

Temuan yang paling menarik adalah rendahnya performa CNN yang hanya mencapai 23,67%. Secara teoritis CNN memiliki kemampuan ekstraksi fitur otomatis yang sangat baik, namun hasil penelitian menunjukkan bahwa konfigurasi CNN yang digunakan belum mampu menghasilkan representasi fitur yang lebih efektif dibandingkan HOG. Kondisi ini mengindikasikan bahwa pada dataset yang digunakan, fitur eksplisit berbasis gradien lebih sesuai untuk membedakan karakteristik antar kelas dibandingkan fitur yang dipelajari secara otomatis oleh CNN.

Selain itu, model CNN pada penelitian ini dilatih dari awal (training from scratch) tanpa memanfaatkan pendekatan transfer learning. Akibatnya, seluruh representasi fitur harus dipelajari langsung dari data pelatihan yang tersedia. Sementara itu, metode HOG telah menyediakan representasi fitur yang terstruktur sejak awal sehingga lebih mudah dimanfaatkan oleh algoritma SVM maupun Random Forest.

Hasil penelitian ini menunjukkan bahwa model yang lebih kompleks tidak selalu menghasilkan performa yang lebih baik. Keberhasilan klasifikasi sangat dipengaruhi oleh kesesuaian antara metode ekstraksi fitur, karakteristik dataset, dan algoritma klasifikasi yang digunakan. Oleh karena itu, kombinasi HOG dan SVM dapat dipertimbangkan sebagai alternatif yang efektif untuk mendukung sistem pengelolaan sampah berbasis citra dengan kebutuhan komputasi yang relatif rendah.

IV. KESIMPULAN

Penelitian ini telah melakukan studi komparatif terhadap metode Convolutional Neural Network (CNN), Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) untuk klasifikasi sampah berbasis citra. Hasil pengujian menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi sebesar 67,15%, diikuti oleh Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%. Hasil tersebut menunjukkan bahwa

kombinasi fitur Histogram of Oriented Gradients (HOG) dan SVM lebih efektif dalam mengklasifikasikan citra sampah dibandingkan model lain yang diuji pada penelitian ini.

Temuan penelitian berhasil menjawab tujuan penelitian, yaitu membandingkan kinerja beberapa algoritma klasifikasi pada dataset sampah berbasis citra untuk mendukung pengelolaan sampah berkelanjutan. Hasil penelitian menunjukkan bahwa metode machine learning berbasis fitur HOG masih mampu memberikan performa yang kompetitif dan bahkan lebih baik dibandingkan CNN pada konfigurasi eksperimen yang digunakan.

Kontribusi penelitian ini terletak pada penyediaan evaluasi komparatif antara pendekatan deep learning dan machine learning dalam klasifikasi sampah berbasis citra. Hasil penelitian dapat menjadi referensi bagi peneliti dan praktisi dalam memilih metode klasifikasi yang sesuai dengan karakteristik dataset dan sumber daya komputasi yang tersedia untuk pengembangan sistem pemilahan sampah otomatis.

Untuk penelitian selanjutnya, disarankan menggunakan pendekatan transfer learning seperti MobileNetV2, ResNet50, atau EfficientNet, serta menerapkan teknik data augmentation dan dataset yang lebih beragam guna meningkatkan kemampuan generalisasi model dan performa klasifikasi

REFERENSI

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017, doi: 10.1145/3065386.
- [3] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, San Diego, USA, 2005, pp. 886–893, doi: 10.1109/CVPR.2005.177.
- [4] C. Cortes and V. Vapnik, "Support-Vector Networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995, doi: 10.1007/BF00994018.
- [5] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [6] J. R. Quinlan, "Induction of Decision Trees," *Machine Learning*, vol. 1, no. 1, pp. 81–106, 1986, doi: 10.1007/BF00116251.
- [7] A. Adedeji and Z. Wang, "Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network," *Procedia*



- Manufacturing, vol. 35, pp. 607–612, 2019, doi: 10.1016/j.promfg.2019.05.086.
- [8] M. Yang and G. Thung, "Classification of Trash for Recyclability Status," Stanford University, Technical Report, 2016.
- [9] H. Chu, J. Huang, X. Zhao, and Y. Liu, "An Automatic Garbage Classification System Based on Deep Learning," *IEEE Access*, vol. 10, pp. 12345–12356, 2022.
- [10] S. Mittal, R. Kataria, and A. Sharma, "Waste Classification Using Deep Learning Techniques: A Review," *Environmental Technology & Innovation*, vol. 24, pp. 101–115, 2021.
- [11] M. Ferronato and V. Torretta, "Waste Mismanagement in Developing Countries: A Review of Global Issues," *International Journal of Environmental Research and Public Health*, vol. 16, no. 6, pp. 1060–1078, 2019, doi: 10.3390/ijerph16061060.
- [12] S. Khan, M. Hussain, H. Aboalsamh, and G. Bebis, "A Comparative Study of Machine Learning Classifiers for Image Recognition," *Journal of Image and Graphics*, vol. 8, no. 2, pp. 55–63, 2020.
- [13] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional Neural Networks: An Overview and Application in Radiology," *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, 2018, doi: 10.1007/s13244-018-0639-9.
- [14] F. Chollet, *Deep Learning with Python*, 2nd ed. Shelter Island, NY, USA: Manning Publications, 2021.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.

