

Implementasi Algoritma Decision Tree untuk Klasifikasi Penyakit Ginjal Kronis Berbasis Machine Learning

Implementation of Decision Tree Algorithm for Chronic Kidney Disease Classification Based on Machine Learning

Affan Ar Rasyid Hasibuan^{a,1}, Nur Anzelina Hrp^{b,2}, Charles Bronson Harahap^{c,3}

^aUniversitas Potensi Utama, FTIK, Prodi Informatika, Jl. K.L Yos Sudarso Km, 6.5, Medan, 20242, Indonesia

^bUniversitas Potensi Utama, FTIK, Prodi Informatika, Jl. K.L Yos Sudarso Km, 6.5, Medan, 20242, Indonesia

Email: arrasyidd67@gmail.com¹, nuranzelinahrp22@gmail.com², charlesharahap07@gmail.com³

ABSTRAK

Penyakit Ginjal Kronis (PGK) merupakan penyakit tidak menular yang membutuhkan deteksi dini secara cepat, akurat, dan mudah diinterpretasikan. Penelitian ini bertujuan menerapkan algoritma Decision Tree berbasis machine learning untuk mengklasifikasikan PGK berdasarkan data medis pasien, mengidentifikasi fitur yang paling berpengaruh, serta mengevaluasi kinerja model melalui metrik akurasi, precision, recall, F1-score, dan confusion matrix. Data yang digunakan merupakan dataset sekunder Kidney_Disease.csv yang memuat atribut demografis, pemeriksaan klinis, pemeriksaan laboratorium, riwayat penyakit, dan kelas target CKD atau Non-CKD. Tahapan penelitian meliputi data overview, exploratory data analysis, pembersihan data, imputasi nilai hilang, label encoding, pembagian data latih dan data uji dengan proporsi 70:30, pembangunan model Decision Tree Classifier, dan evaluasi model. Hasil penelitian menunjukkan akurasi data latih sebesar 96,79% dan akurasi data uji sebesar 94,17%. Model menghasilkan nilai precision, recall, dan F1-score yang tinggi pada kedua kelas. Fitur haemoglobin, serum creatinine, specific gravity, blood glucose random, dan packed cell volume menjadi variabel penting dalam proses klasifikasi. Hasil ini menunjukkan bahwa Decision Tree dapat menjadi alat bantu skrining awal PGK yang akurat, transparan, dan mudah dipahami.

Kata Kunci : Decision Tree, machine learning, Penyakit Ginjal Kronis, klasifikasi, deteksi dini.

ABSTRACT

Chronic Kidney Disease (CKD) is a non-communicable disease that requires early detection that is fast, accurate, and interpretable. This study aims to implement a machine learning-based Decision Tree algorithm to classify CKD using patient medical data, identify the most influential features, and evaluate model performance using accuracy, precision, recall, F1-score, and confusion matrix. The study used the secondary Kidney_Disease.csv dataset, which contains demographic attributes, clinical examinations, laboratory results, medical history, and the target class of CKD or Non-CKD. The research stages included data overview, exploratory data analysis, data cleaning, missing value imputation, label encoding, 70:30 train-test split, Decision Tree Classifier model development, and model evaluation. The results showed a training accuracy of 96.79% and a testing accuracy of 94.17%. The model achieved high precision, recall, and F1-score values in both classes. Haemoglobin, serum creatinine, specific gravity, blood glucose random, and packed cell volume were identified as important variables in the classification process. These findings indicate that Decision Tree can serve as an accurate, transparent, and interpretable support tool for early CKD screening.

Keywords : Decision Tree, machine learning, Chronic Kidney Disease, classification, early detection.

Info Artikel :

Disubmit:

Direview:

Diterima :

Copyright © 2026 - Journal UPU. All rights reserved.

1. PENDAHULUAN

Penyakit Ginjal Kronis (PGK) atau Chronic Kidney Disease (CKD) merupakan gangguan fungsi ginjal yang berkembang secara progresif dan menetap. Masalah ini penting karena gejala awal PGK sering tidak jelas, sehingga banyak pasien baru terdeteksi ketika penyakit sudah berada pada tahap lanjut. Kondisi tersebut meningkatkan risiko komplikasi, kebutuhan terapi pengganti ginjal, dan beban layanan kesehatan. Dalam konteks pelayanan kesehatan, kemampuan melakukan skrining awal secara cepat menjadi kebutuhan penting agar tenaga medis dapat mengenali pasien berisiko lebih dini dan mengambil keputusan lanjutan secara lebih tepat [1], [15].

Deteksi PGK pada praktik klinis umumnya memerlukan interpretasi terhadap berbagai indikator, seperti tekanan darah, kadar kreatinin serum, hemoglobin, albumin urin, kadar urea darah, riwayat hipertensi, diabetes mellitus, edema, dan anemia. Banyaknya parameter tersebut membuat proses penilaian membutuhkan ketelitian, terutama jika fasilitas kesehatan memiliki keterbatasan sumber daya. Pada kondisi seperti ini, pendekatan komputasional berbasis machine learning dapat membantu mengolah data klinis dengan lebih konsisten, cepat, dan terukur [2], [3].

Machine learning memberi peluang untuk membangun model prediksi yang mampu mengenali pola dari data medis historis. Model klasifikasi dapat memetakan hubungan antara fitur klinis dan status penyakit sehingga hasilnya dapat digunakan sebagai dukungan awal dalam pengambilan keputusan. Pada kasus PGK, berbagai penelitian menunjukkan bahwa algoritma machine learning mampu memberikan performa prediksi yang baik, khususnya setelah dilakukan proses pembersihan data, penanganan nilai hilang, transformasi atribut, dan evaluasi model secara sistematis [3], [10], [11].

Salah satu algoritma yang relevan untuk klasifikasi data medis adalah Decision Tree. Algoritma ini membentuk struktur keputusan dalam bentuk pohon, mulai dari node akar, cabang keputusan, hingga daun sebagai kelas akhir. Keunggulan utama Decision Tree terletak pada interpretabilitasnya. Hasil klasifikasi tidak hanya menghasilkan label prediksi, tetapi juga memperlihatkan jalur keputusan yang dapat ditelusuri. Karakter ini sesuai dengan kebutuhan bidang kesehatan karena tenaga medis memerlukan model yang tidak hanya akurat, tetapi juga dapat dijelaskan [4], [6].

Dalam penelitian skripsi yang menjadi sumber artikel ini, Decision Tree digunakan untuk mengklasifikasikan pasien ke dalam dua kelas, yaitu CKD dan Non-CKD. Dataset yang digunakan berisi atribut demografis, data urin, hasil pemeriksaan darah, kondisi klinis, dan riwayat penyakit. Penelitian tersebut menempatkan Decision Tree sebagai model utama, bukan sebagai bagian dari perbandingan banyak algoritma. Fokus utamanya adalah melihat kemampuan model dalam mengklasifikasikan PGK, mengidentifikasi fitur dominan, dan menilai kinerja melalui metrik evaluasi yang relevan.

Kebutuhan penelitian ini muncul dari dua sisi. Sisi pertama adalah kebutuhan klinis, yaitu perlunya deteksi dini yang efisien dan dapat membantu proses skrining awal. Sisi kedua adalah kebutuhan teknis, yaitu perlunya model machine learning yang akurat, stabil, dan tetap mudah dipahami. Banyak algoritma memiliki akurasi tinggi, tetapi tidak semuanya mudah ditafsirkan. Decision Tree menawarkan keseimbangan antara kinerja dan keterbacaan model, sehingga cocok digunakan sebagai pendekatan awal dalam pengembangan sistem pendukung keputusan medis [7], [8].

Berdasarkan latar belakang tersebut, artikel ini menyajikan hasil konversi penelitian skripsi ke dalam bentuk naskah jurnal. Tujuan artikel ini adalah menjelaskan penerapan Decision Tree untuk klasifikasi PGK, menguraikan tahapan pengolahan data, menyajikan hasil evaluasi model, serta mendiskusikan makna fitur penting dalam proses klasifikasi. Artikel ini juga menekankan keterbatasan model dan peluang pengembangan lebih lanjut agar sistem prediksi dapat diuji secara lebih luas pada data klinis nyata.

A. Posisi Penelitian terhadap Studi Terkait

Posisi penelitian ini dapat dipahami melalui perbandingan dengan beberapa studi terkait klasifikasi PGK berbasis machine learning. Sejumlah penelitian menggunakan algoritma yang lebih kompleks, seperti ensemble learning, extra trees, stacking, dan pendekatan explainable artificial intelligence. Model tersebut sering menghasilkan akurasi tinggi, tetapi tidak selalu mudah dijelaskan dalam bentuk aturan yang sederhana. Artikel ini memilih Decision Tree sebagai model utama karena mengutamakan keseimbangan antara performa dan keterbacaan hasil.

Studi terdahulu menunjukkan bahwa klasifikasi CKD sangat dipengaruhi oleh kualitas data, metode pra-pemrosesan, pilihan fitur, serta strategi evaluasi. Oleh karena itu, kontribusi artikel ini tidak hanya terletak pada angka akurasi, tetapi juga pada penyajian alur kerja yang runtut mulai dari data overview, EDA, imputasi, encoding, pembagian data, pelatihan model, hingga evaluasi. Alur tersebut penting agar penelitian dapat direplikasi dan dikritisi secara akademik.

Tabel 2 menyajikan ringkasan posisi penelitian terhadap studi terkait. Perbandingan ini menunjukkan bahwa penelitian ini berada pada ruang penerapan Decision Tree yang fokus pada interpretasi model, bukan sekadar optimasi akurasi. Posisi ini relevan untuk konteks kesehatan karena hasil prediksi perlu dapat dijelaskan kepada pengguna, terutama ketika model diarahkan sebagai alat bantu skrining awal.

Tabel 2. Posisi Penelitian terhadap Studi Terkait

Penelitian	Fokus	Relevansi
Elshewey et al. [1]	CKD dengan explainable AI dan extra trees	Menekankan akurasi dan penjelasan model. Relevan sebagai pembanding pendekatan interpretatif.
Anqui [2]	Klasifikasi CKD dengan beberapa teknik machine learning	Menunjukkan bahwa pilihan algoritma memengaruhi performa klasifikasi.
Halder et al. [3]	Prediksi CKD dan aplikasi web cerdas	Relevan dengan pengembangan antarmuka prediksi berbasis model.
Surojudin [4]	Perbandingan Decision Tree dan Naive Bayes	Menunjukkan nilai Decision Tree pada interpretasi aturan klasifikasi.
Metherall et al. [5]	Klasifikasi CKD dan prediksi kreatinin	Menunjukkan potensi machine learning pada pengukuran terkait fungsi ginjal.
Shanmugarajeshwari dan Ilayaraja [6]	Dukungan keputusan untuk tahap CKD	Menegaskan pentingnya model klasifikasi dalam sistem pendukung keputusan.
Alshakrani et al. [7]	Klasifikasi CKD dengan beberapa classifier	Menjadi dasar bahwa evaluasi multi-metrik diperlukan dalam klasifikasi medis.
Haider et al. [8]	Analisis prediktif CKD berbasis machine learning	Mendukung relevansi pendekatan prediktif untuk deteksi dini.
Prabowo et al. [9]	Diagnosis dan prediksi CKD dengan stacked generalization	Menunjukkan arah penguatan model melalui metode ensemble.
Zuriati et al. [14]	Decision Tree dan bootstrap aggregating	Menunjukkan bahwa Decision Tree dapat ditingkatkan melalui pendekatan bagging.

2. METODE

A. Jenis Penelitian dan Sumber Data

Penelitian ini menggunakan pendekatan kuantitatif komputasional dengan metode machine learning. Objek penelitian berupa dataset sekunder yang berisi data rekam medis pasien terkait PGK. Data yang digunakan bersifat non-intervensi karena peneliti tidak melakukan pengambilan data langsung kepada pasien. Seluruh tahapan penelitian dilakukan melalui pengolahan data digital menggunakan bahasa pemrograman Python dan beberapa pustaka pendukung, seperti Pandas, NumPy, Scikit-learn, Matplotlib, dan pustaka visualisasi lain yang relevan.

Dataset yang digunakan bernama *Kidney_Disease.csv*. Dataset ini memuat data klinis pasien dalam bentuk atribut numerik dan kategorikal. Atribut numerik mencakup usia, tekanan darah, specific gravity, blood glucose random, blood urea, serum creatinine, sodium, potassium, haemoglobin, packed cell volume, white blood cell count, dan red blood cell count. Atribut kategorikal mencakup red blood cells,

pus cell, pus cell clumps, bacteria, hypertension, diabetes mellitus, coronary artery disease, appetite, pedal edema, anemia, dan classification sebagai kelas target.

Atribut classification digunakan sebagai label klasifikasi yang menunjukkan status CKD atau Non-CKD. Atribut id hanya digunakan sebagai identitas unik data dan tidak dilibatkan dalam pelatihan model. Pemisahan ini penting karena atribut identitas tidak memiliki makna prediktif terhadap status penyakit. Jika atribut identitas tetap digunakan, model berisiko mempelajari pola yang tidak relevan secara klinis.

Tabel 1. Deskripsi Fitur Dataset Penyakit Ginjal Kronis

No	Atribut	Kelompok	Keterangan
1	age	Demografis	Usia pasien dalam tahun.
2	bp	Klinis	Tekanan darah pasien dalam mmHg.
3	sg	Urinalisis	Berat jenis urin atau specific gravity.
4	al	Urinalisis	Kadar albumin dalam urin.
5	su	Urinalisis	Kadar gula dalam urin.
6	rbc	Urinalisis	Kondisi sel darah merah dalam urin.
7	pc	Urinalisis	Kondisi sel nanah atau pus cell.
8	pcc	Urinalisis	Penggumpalan sel nanah atau pus cell clumps.
9	ba	Urinalisis	Keberadaan bakteri dalam urin.
10	bgr	Biokimia darah	Kadar gula darah acak atau blood glucose random.
11	bu	Biokimia darah	Kadar urea dalam darah.
12	sc	Biokimia darah	Kadar kreatinin serum.
13	sod	Biokimia darah	Kadar natrium dalam darah.
14	pot	Biokimia darah	Kadar kalium dalam darah.
15	hemo	Hematologi	Kadar hemoglobin dalam darah.
16	pcv	Hematologi	Persentase volume sel darah merah atau packed cell volume.
17	wc	Hematologi	Jumlah sel darah putih.
18	rc	Hematologi	Jumlah sel darah merah.
19	htn	Riwayat klinis	Riwayat hipertensi.
20	dm	Riwayat klinis	Riwayat diabetes mellitus.
21	cad	Riwayat klinis	Riwayat penyakit jantung koroner.
22	appet	Kondisi klinis	Kondisi nafsu makan pasien.
23	pe	Kondisi klinis	Kondisi edema pada kaki.
24	ane	Kondisi klinis	Kondisi anemia.
25	classification	Target	Label klasifikasi CKD atau Non-CKD.

B. Tahapan Pengolahan Data

Tahap pengolahan data dimulai dari data overview. Pada tahap ini, data dimuat ke dalam lingkungan Python, kemudian diperiksa struktur kolom, tipe data, ukuran dataset, nilai unik pada atribut kategorikal, serta keberadaan nilai hilang. Pemeriksaan awal dilakukan untuk memastikan dataset dapat dipahami sebelum masuk ke tahap analisis eksploratif dan pemodelan.

Tahap berikutnya adalah exploratory data analysis (EDA). EDA dilakukan untuk memahami distribusi atribut numerik dan kategorikal, melihat perbedaan pola antara kelas CKD dan Non-CKD, serta mengidentifikasi atribut yang berpotensi berperan dalam klasifikasi. Visualisasi yang digunakan meliputi distribusi numerik, violin plot, density plot, scatter plot, dan bar chart. Hasil EDA menunjukkan beberapa fitur memiliki pemisahan yang cukup jelas antara kelas, terutama haemoglobin, packed cell volume, albumin, blood urea, red blood cell count, dan serum-related attributes.

Data pre-processing dilakukan untuk menangani nilai hilang. Atribut numerik dengan jumlah nilai hilang relatif tinggi ditangani menggunakan random sampling imputation agar distribusi data tetap

mendekati pola aslinya. Atribut kategorikal ditangani dengan mode imputation karena kategori terbanyak dianggap mewakili kecenderungan umum dalam data. Setelah proses imputasi, data diperiksa kembali untuk memastikan tidak ada nilai kosong yang tersisa.

Feature encoding dilakukan dengan Label Encoder. Proses ini mengubah nilai kategorikal menjadi nilai numerik agar dapat diproses oleh algoritma machine learning. Encoding diterapkan pada atribut seperti red blood cells, pus cell, pus cell clumps, bacteria, hypertension, diabetes mellitus, coronary artery disease, appetite, pedal edema, anemia, dan classification. Setelah encoding selesai, seluruh fitur berada dalam bentuk numerik.

Tabel 3. Ringkasan Tahapan Penelitian

No	Tahap	Uraian
1	Data loading	Membaca dataset Kidney_Disease.csv ke lingkungan Python.
2	Data overview	Memeriksa dimensi, tipe data, nilai unik, dan nilai hilang.
3	EDA	Menganalisis distribusi dan hubungan antar fitur.
4	Pre-processing	Membersihkan data dan menangani missing values.
5	Feature encoding	Mengubah atribut kategorikal menjadi numerik.
6	Model building	Memisahkan fitur dan label, lalu membagi data 70:30.
7	Decision Tree	Melatih model dengan parameter pembatas kompleksitas.
8	Evaluasi	Menghitung accuracy, precision, recall, F1-score, dan confusion matrix.



Alur komputasional penelitian klasifikasi Penyakit Ginjal Kronis berbasis Decision Tree

Gambar 1. Alur penelitian klasifikasi PGK berbasis Decision Tree

C. Pembangunan Model Decision Tree

Pembangunan model dilakukan setelah dataset siap digunakan. Seluruh atribut selain class dijadikan variabel independen, sedangkan class menjadi variabel dependen. Dataset kemudian dibagi menjadi data latih dan data uji dengan proporsi 70% untuk pelatihan dan 30% untuk pengujian. Pembagian data ini bertujuan mengukur kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya.

Model dibangun menggunakan DecisionTreeClassifier dari pustaka Scikit-learn. Untuk mengurangi risiko overfitting, penelitian menerapkan pembatasan kompleksitas model. Parameter max_depth ditetapkan sebesar 5 untuk membatasi kedalaman pohon. Parameter min_samples_leaf ditetapkan sebesar 10 agar setiap daun memiliki jumlah sampel minimum yang cukup. Parameter random_state ditetapkan sebesar 42 agar hasil pelatihan dapat direproduksi.

Decision Tree bekerja dengan memilih fitur yang paling mampu memisahkan kelas berdasarkan kriteria pemisahan tertentu. Proses ini menghasilkan struktur pohon yang memuat node keputusan dan cabang kondisi. Pada konteks PGK, struktur pohon membantu memperlihatkan fitur apa yang menjadi dasar utama model saat memisahkan pasien CKD dan Non-CKD. Dengan demikian, model tidak hanya menghasilkan prediksi, tetapi juga memberi informasi interpretatif tentang jalur keputusan.

Tabel 4. Parameter Utama Pembangunan Model

Komponen	Nilai	Fungsi
Algoritma	Decision Tree Classifier	Model supervised learning untuk klasifikasi biner CKD dan Non-CKD.
Proporsi data	70% : 30%	Data latih sebesar 70% dan data uji sebesar 30%.
max_depth	5	Membatasi kedalaman maksimum pohon untuk mengendalikan kompleksitas.
min_samples_leaf	10	Menentukan jumlah minimum sampel pada setiap leaf node.
random_state	42	Menjaga konsistensi hasil eksperimen.
Metrik evaluasi	Accuracy, precision, recall, F1-score	Menilai kinerja model dari sisi ketepatan dan keseimbangan klasifikasi.

D. Metrik Evaluasi

Evaluasi model menggunakan empat metrik utama, yaitu accuracy, precision, recall, dan F1-score. Accuracy menunjukkan persentase prediksi benar dari seluruh data uji. Precision menunjukkan proporsi prediksi positif yang benar dari seluruh prediksi positif. Recall menunjukkan kemampuan model dalam menemukan seluruh kasus positif yang sebenarnya. F1-score menggabungkan precision dan recall sehingga berguna ketika peneliti ingin melihat keseimbangan antara ketepatan prediksi dan kemampuan deteksi.

Confusion matrix digunakan untuk melihat distribusi kesalahan model secara lebih rinci. Pada konteks medis, false negative menjadi perhatian penting karena berarti pasien CKD diprediksi sebagai Non-CKD. Kesalahan jenis ini dapat membuat pasien yang sebenarnya berisiko tidak segera mendapatkan pemeriksaan lanjutan. Oleh karena itu, evaluasi tidak cukup hanya melihat accuracy. Analisis precision, recall, F1-score, dan confusion matrix tetap diperlukan agar performa model dapat dinilai secara lebih hati-hati.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (1)$$

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (2)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (3)$$

$$\text{F1-score} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (4)$$

Keterangan: TP adalah true positive, TN adalah true negative, FP adalah false positive, dan FN adalah false negative.

3. HASIL DAN PEMBAHASAN

A. Karakteristik Dataset

Dataset yang digunakan memuat 399 data pasien dengan 25 fitur prediktor dan satu kelas target. Fitur dalam dataset menunjukkan kombinasi indikator klinis yang umum digunakan dalam pemeriksaan fungsi ginjal. Kelompok fitur tersebut mencakup data umum, urinalisis, biokimia darah, hematologi, riwayat penyakit, dan kondisi klinis. Keragaman fitur ini membantu model memperoleh informasi yang cukup luas untuk membedakan pasien CKD dan Non-CKD.

Pada tahap data overview, beberapa atribut ditemukan memiliki nilai hilang. Kondisi ini wajar pada dataset medis karena tidak semua pasien memiliki hasil pemeriksaan lengkap. Namun, nilai hilang tidak dapat langsung diabaikan karena dapat mengurangi jumlah data dan mengganggu proses pelatihan. Oleh

sebab itu, penelitian melakukan imputasi berdasarkan karakter atribut. Strategi ini menjaga agar informasi penting dalam dataset tetap dapat digunakan.

Hasil EDA menunjukkan bahwa beberapa variabel memiliki perbedaan distribusi yang kuat antara kelas CKD dan Non-CKD. Pasien CKD cenderung memiliki nilai hemoglobin dan packed cell volume yang lebih rendah. Pola ini sejalan dengan karakter klinis gangguan ginjal kronis yang dapat berkaitan dengan anemia. Fitur blood urea dan serum creatinine juga menunjukkan perbedaan yang penting karena keduanya berkaitan dengan fungsi filtrasi ginjal. Selain itu, specific gravity dan albumin memberikan informasi dari aspek urinalisis yang relevan untuk klasifikasi.

B. Hasil Pra-pemrosesan dan Encoding

Pra-pemrosesan data menghasilkan dataset yang lebih lengkap dan siap digunakan. Nilai hilang pada atribut numerik diisi dengan random sampling imputation. Pendekatan ini dipilih karena dapat mempertahankan variasi nilai data, sehingga distribusi numerik tidak terlalu bergeser. Sementara itu, atribut kategorikal diisi menggunakan mode imputation. Proses ini membantu menjaga konsistensi kategori sebelum dilakukan transformasi nilai.

Setelah proses imputasi, feature encoding mengubah seluruh atribut kategorikal menjadi bentuk numerik. Transformasi ini penting karena algoritma Decision Tree pada implementasi Scikit-learn memerlukan input numerik. Label Encoder digunakan untuk memetakan kategori menjadi angka. Misalnya, kategori yes dan no, present dan notpresent, serta good dan poor dikonversi menjadi nilai numerik. Setelah seluruh atribut berada dalam bentuk numerik, model dapat dilatih tanpa kendala tipe data.

Pembersihan dan transformasi data juga membantu model menghasilkan struktur keputusan yang lebih stabil. Jika data memiliki nilai kosong atau kategori tidak konsisten, model dapat membentuk cabang keputusan yang keliru. Oleh karena itu, tahap pra-pemrosesan tidak hanya menjadi persiapan teknis, tetapi juga menjadi bagian penting dalam menjaga validitas hasil klasifikasi.

C. Interpretasi Struktur Decision Tree

Visualisasi pohon keputusan menunjukkan bahwa haemoglobin menjadi pemisah utama pada node akar. Hal ini berarti kadar hemoglobin memiliki kontribusi besar dalam proses awal pemisahan kelas CKD dan Non-CKD. Pada cabang dengan hemoglobin yang lebih rendah, model cenderung mengarah pada klasifikasi CKD. Jalur ini kemudian diperkuat oleh fitur lain, terutama serum creatinine dan ambang hemoglobin lanjutan.

Pada cabang dengan hemoglobin yang lebih tinggi, model cenderung mengarah pada klasifikasi Non-CKD. Namun, keputusan tersebut tidak langsung berhenti karena model masih menggunakan fitur specific gravity, blood glucose random, serum creatinine, dan packed cell volume untuk memperhalus klasifikasi. Struktur ini menunjukkan bahwa model tidak hanya bergantung pada satu fitur, tetapi menggabungkan beberapa indikator klinis untuk menghasilkan keputusan akhir.

Temuan fitur dominan dalam model memiliki makna penting. Haemoglobin dan packed cell volume mewakili kondisi hematologis pasien. Serum creatinine dan blood urea menggambarkan aspek biokimia darah yang berkaitan dengan fungsi ginjal. Specific gravity dan albumin menggambarkan aspek urinalisis. Dengan komposisi tersebut, jalur keputusan Decision Tree dapat dibaca sebagai gabungan indikator darah, urin, dan kondisi klinis. Hal ini membuat hasil model lebih mudah dijelaskan dibandingkan model yang bersifat black box.

Dari sisi interpretabilitas, Decision Tree memberi keuntungan karena setiap prediksi dapat ditelusuri melalui rangkaian aturan. Misalnya, prediksi CKD dapat muncul ketika hemoglobin rendah, serum creatinine tinggi, dan packed cell volume rendah. Aturan seperti ini dapat dipahami sebagai sinyal risiko yang perlu diperiksa lebih lanjut. Dalam praktik klinis, model seperti ini tidak menggantikan dokter, tetapi dapat membantu memberi peringatan awal atau mendukung proses skrining.

Tabel 5. Fitur Dominan dalam Struktur Decision Tree

Fitur	Kelompok	Interpretasi
Haemoglobin	Hematologi	Menjadi pemisah utama pada node akar dan menunjukkan kontribusi kuat dalam klasifikasi.
Serum creatinine	Biokimia darah	Berperan dalam jalur keputusan karena berkaitan dengan kemampuan ginjal menyaring zat sisa.
Specific gravity	Urinalisis	Membantu membedakan karakter urin pasien CKD dan Non-CKD.
Blood glucose random	Biokimia darah	Memberi informasi metabolik yang dapat berkaitan dengan risiko gangguan ginjal.
Packed cell volume	Hematologi	Menggambarkan konsentrasi sel darah merah dan berperan dalam pemisahan kelas.

D. Evaluasi Kinerja Model

Hasil evaluasi menunjukkan bahwa model Decision Tree memiliki performa yang tinggi. Akurasi data latih mencapai 96,79%, sedangkan akurasi data uji mencapai 94,17%. Selisih kedua nilai tersebut relatif kecil, sehingga model tidak menunjukkan indikasi overfitting yang kuat. Model mampu mempelajari pola pada data latih dan tetap mempertahankan kemampuan generalisasi pada data uji.


Pada kelas 0, model menghasilkan precision sebesar 0,93, recall sebesar 0,97, dan F1-score sebesar 0,95 dengan support sebanyak 72 data. Nilai recall yang tinggi menunjukkan bahwa model sangat baik dalam mengenali data kelas 0. Pada kelas 1, model menghasilkan precision sebesar 0,96, recall sebesar 0,90, dan F1-score sebesar 0,92 dengan support sebanyak 48 data. Hasil ini menunjukkan bahwa sebagian besar prediksi pada kelas 1 benar, meskipun masih ada sebagian kecil data kelas 1 yang salah diklasifikasikan.

Nilai macro average dan weighted average berada pada kisaran 0,94. Nilai tersebut menunjukkan kinerja yang konsisten pada kedua kelas. Weighted average mempertimbangkan proporsi jumlah data pada setiap kelas, sedangkan macro average memberi bobot yang sama pada setiap kelas. Kedua nilai yang sama-sama tinggi memperkuat kesimpulan bahwa model memiliki performa yang seimbang.

Akurasi tinggi pada data uji menunjukkan bahwa Decision Tree layak digunakan sebagai model klasifikasi awal. Namun, karena konteks penelitian berkaitan dengan kesehatan, evaluasi tidak boleh berhenti pada akurasi. False negative tetap harus diperhatikan karena dapat menyebabkan kasus CKD tidak terdeteksi. Oleh sebab itu, hasil model harus dipahami sebagai alat bantu skrining, bukan sebagai keputusan diagnosis final.

Tabel 6. Classification Report Model Decision Tree pada Data Uji

Kelas	Precision	Recall	F1-score	Support
Kelas 0	0,93	0,97	0,95	72
Kelas 1	0,96	0,90	0,92	48
Accuracy	-	-	0,94	120
Macro avg	0,94	0,94	0,94	120
Weighted avg	0,94	0,94	0,94	120



Gambar 2. Ringkasan kinerja model Decision Tree

E. Analisis Confusion Matrix

Tabel 7. Confusion Matrix Model Decision Tree

Label Aktual	Prediksi kelas 0	Prediksi kelas 1	Total
Aktual kelas 0	70	2	72
Aktual kelas 1	5	43	48
Total	75	45	120

Confusion matrix menunjukkan bahwa dari 120 data uji, model berhasil mengklasifikasikan 113 data dengan benar dan 7 data mengalami kesalahan klasifikasi. Pada kelas 0, terdapat 70 data yang diprediksi benar sebagai kelas 0 dan 2 data yang salah diprediksi sebagai kelas 1. Pada kelas 1, terdapat 43 data yang diprediksi benar sebagai kelas 1 dan 5 data yang salah diprediksi sebagai kelas 0.

Jumlah false negative sebanyak 5 data menjadi catatan penting. Dalam konteks PGK, false negative berarti pasien yang sebenarnya CKD diprediksi sebagai Non-CKD. Kesalahan ini memiliki risiko lebih tinggi dibanding false positive karena dapat menunda pemeriksaan lanjutan. Walaupun jumlahnya kecil, pengembangan model berikutnya perlu mengarah pada peningkatan recall kelas CKD agar kasus berisiko tidak mudah terlewat.

False positive sebanyak 2 data berarti pasien Non-CKD diprediksi sebagai CKD. Kesalahan ini tetap perlu dikendalikan karena dapat menimbulkan kekhawatiran dan pemeriksaan tambahan. Namun, dalam konteks skrining awal, false positive sering lebih dapat ditoleransi dibanding false negative, selama hasil model tidak dijadikan dasar diagnosis tunggal. Hasil confusion matrix menunjukkan bahwa model sudah cukup kuat, tetapi tetap memerlukan validasi klinis lebih lanjut.

F. Pembahasan

Hasil penelitian memperlihatkan bahwa Decision Tree mampu mengklasifikasikan PGK dengan akurasi tinggi dan interpretasi yang jelas. Kinerja 94,17% pada data uji menunjukkan bahwa pola yang dipelajari model tidak hanya berlaku pada data latih. Hal ini penting karena model machine learning yang baik harus mampu mengenali data baru, bukan hanya mengingat data yang digunakan saat pelatihan.

Keberhasilan model dipengaruhi oleh beberapa tahapan. Pertama, pemilihan fitur dalam dataset sudah mencakup indikator yang relevan dengan fungsi ginjal. Kedua, proses imputasi nilai hilang menjaga agar data tetap dapat digunakan tanpa menghapus terlalu banyak sampel. Ketiga, parameter

pembatas pada Decision Tree membantu mengurangi kompleksitas pohon. Kombinasi ketiga faktor tersebut membuat model lebih stabil dan tidak terlalu menyesuaikan diri dengan data latih.

Dari sudut pandang klinis, fitur yang muncul sebagai variabel penting memiliki keterkaitan yang rasional. Serum creatinine menjadi indikator penting karena berkaitan dengan fungsi ginjal dalam menyaring zat sisa. Haemoglobin dan packed cell volume berkaitan dengan kondisi hematologis yang dapat terganggu pada pasien PGK. Specific gravity dan albumin menunjukkan informasi dari pemeriksaan urin. Blood glucose random berkaitan dengan kondisi metabolik, terutama pada pasien dengan risiko diabetes mellitus. Keterkaitan ini membuat hasil model memiliki dasar interpretasi yang lebih kuat.

Hasil ini sejalan dengan beberapa penelitian terdahulu yang melaporkan bahwa machine learning efektif untuk klasifikasi CKD. Beberapa studi menunjukkan bahwa Decision Tree, Random Forest, Support Vector Machine, dan metode ensemble dapat menghasilkan akurasi tinggi pada dataset CKD [3], [8], [11], [14]. Namun, keunggulan Decision Tree dalam penelitian ini bukan hanya akurasinya, melainkan juga kemampuannya menghasilkan jalur keputusan yang mudah dibaca.

Interpretabilitas menjadi aspek penting dalam penerapan machine learning di bidang kesehatan. Model dengan akurasi tinggi tetapi sulit dijelaskan dapat menimbulkan hambatan dalam penerimaan pengguna. Tenaga medis perlu memahami alasan di balik prediksi agar dapat menilai kewajaran hasil model. Decision Tree memberi peluang tersebut melalui aturan keputusan yang eksplisit. Karena itu, model ini cocok untuk tahap awal pengembangan sistem pendukung keputusan PGK.

Walaupun demikian, hasil penelitian tidak dapat langsung dianggap sebagai bukti kelayakan klinis penuh. Dataset yang digunakan merupakan data sekunder publik. Karakteristik populasi dalam dataset belum tentu mewakili pasien pada fasilitas kesehatan tertentu. Model juga belum diuji secara prospektif dengan data pasien nyata di lapangan. Oleh karena itu, hasil ini perlu dilihat sebagai bukti komputasional awal yang perlu dilanjutkan dengan validasi eksternal.

Keterbatasan lain terletak pada tidak adanya perbandingan langsung dengan algoritma lain dalam analisis utama. Perbandingan dengan Random Forest, Gradient Boosting, Support Vector Machine, atau Logistic Regression dapat memberi gambaran lebih lengkap mengenai posisi kinerja Decision Tree. Namun, fokus tunggal pada Decision Tree tetap memiliki nilai karena artikel ini menekankan aspek interpretabilitas dan kesesuaian model untuk skrining awal.

Pengembangan lebih lanjut dapat dilakukan melalui beberapa cara. Pertama, menggunakan dataset yang lebih besar dan lebih beragam. Kedua, menerapkan cross-validation agar estimasi performa lebih stabil. Ketiga, menambahkan teknik Explainable AI seperti SHAP untuk memperkuat penjelasan kontribusi fitur. Keempat, mengembangkan sistem berbasis web atau mobile agar model dapat diuji dalam skenario penggunaan yang lebih praktis [7], [13].

Secara keseluruhan, penelitian ini menunjukkan bahwa Decision Tree memiliki potensi sebagai alat bantu klasifikasi PGK. Model menghasilkan akurasi tinggi, nilai evaluasi yang seimbang, dan struktur keputusan yang mudah dipahami. Namun, pemanfaatannya harus tetap ditempatkan sebagai pendukung skrining awal. Keputusan klinis akhir tetap perlu dilakukan oleh tenaga kesehatan dengan mempertimbangkan pemeriksaan laboratorium, kondisi pasien, dan standar praktik medis yang berlaku.

G. Implikasi Sistem Prediksi Berbasis Antarmuka

Skripsi sumber juga mengembangkan rancangan antarmuka prediksi yang memungkinkan pengguna memasukkan data pasien secara langsung. Formulir input dikelompokkan menjadi data umum pasien, pemeriksaan urinalisis, biokimia darah, hematologi, serta riwayat dan kondisi klinis. Pengelompokan ini penting karena membantu pengguna memahami data yang perlu dimasukkan dan mengurangi risiko kekeliruan input.

Sistem menampilkan hasil prediksi berupa kelas CKD atau Non-CKD, dilengkapi probabilitas prediksi. Penyajian probabilitas membuat hasil lebih informatif karena pengguna dapat melihat tingkat keyakinan model. Pada konteks sistem pendukung keputusan, informasi probabilitas lebih berguna

daripada label tunggal karena memberi ruang bagi pengguna untuk menilai apakah hasil perlu dikaji ulang atau diperiksa lebih lanjut.

Rancangan antarmuka tersebut menjadi langkah awal menuju pemanfaatan model dalam bentuk aplikasi. Namun, aplikasi klinis membutuhkan validasi lebih ketat. Sistem harus diuji dengan data baru, mendapat masukan dari tenaga kesehatan, dan mengikuti aspek keamanan data pasien. Jika dikembangkan lebih lanjut, sistem dapat diarahkan sebagai alat bantu skrining awal di fasilitas layanan kesehatan dengan sumber daya terbatas.

H. Keterbatasan dan Arah Pengembangan

Keterbatasan pertama terletak pada sumber data. Dataset yang digunakan bersifat sekunder dan berasal dari repositori publik. Data tersebut berguna untuk eksperimen komputasional, tetapi belum tentu mewakili variasi pasien pada fasilitas kesehatan tertentu. Perbedaan karakter populasi, pola pemeriksaan laboratorium, kebiasaan pencatatan, dan kualitas data dapat memengaruhi performa model ketika diterapkan pada lingkungan baru.

Keterbatasan kedua berkaitan dengan desain evaluasi. Penelitian menggunakan pembagian data latih dan data uji dengan proporsi 70:30. Strategi ini cukup untuk mengukur performa awal, tetapi belum cukup untuk memastikan stabilitas model pada berbagai skenario pembagian data. Penelitian berikutnya dapat menggunakan k-fold cross-validation agar estimasi performa lebih kuat dan tidak terlalu bergantung pada satu pembagian data.

Keterbatasan ketiga adalah belum adanya validasi klinis oleh tenaga kesehatan. Model dapat menunjukkan performa komputasional yang baik, tetapi pemanfaatan dalam praktik medis membutuhkan pengujian yang lebih ketat. Validasi klinis perlu memastikan bahwa variabel input sesuai dengan prosedur pemeriksaan, hasil prediksi dapat dibaca dengan benar, dan keluaran sistem tidak menimbulkan interpretasi yang keliru.

Keterbatasan keempat berkaitan dengan risiko *false negative*. Meskipun jumlah *false negative* relatif kecil, kesalahan ini tetap penting karena dapat membuat pasien CKD tidak terdeteksi. Penelitian lanjutan dapat mengatur threshold prediksi, memperkuat fitur klinis, atau menggunakan model ensemble untuk meningkatkan sensitivitas terhadap kelas CKD. Fokus pada recall kelas CKD menjadi penting jika model diarahkan untuk skrining awal.

Arah pengembangan berikutnya adalah integrasi model dengan Explainable AI. Walaupun *Decision Tree* sudah mudah ditafsirkan, pendekatan XAI seperti SHAP dapat menambahkan informasi kuantitatif mengenai kontribusi setiap fitur. Teknik tersebut dapat membantu pengguna memahami mengapa suatu pasien diprediksi sebagai CKD atau Non-CKD, terutama ketika jalur keputusan melibatkan banyak fitur.

Arah pengembangan lainnya adalah implementasi aplikasi berbasis web atau mobile. Aplikasi dapat dibuat dengan formulir input klinis, validasi nilai masukan, tampilan probabilitas, riwayat prediksi, dan catatan bahwa sistem hanya berfungsi sebagai alat bantu. Pengembangan aplikasi juga harus memperhatikan keamanan data, hak akses pengguna, serta dokumentasi hasil agar sesuai dengan kebutuhan fasilitas kesehatan.

Secara praktis, model dapat dimanfaatkan sebagai instrumen skrining awal pada wilayah dengan keterbatasan tenaga dan fasilitas. Namun, skenario penggunaan harus dibatasi secara jelas. Sistem dapat memberi peringatan risiko dan membantu prioritas pemeriksaan, tetapi diagnosis akhir tetap perlu mengacu pada pemeriksaan laboratorium, penilaian klinis, dan keputusan tenaga medis. Batasan ini penting agar pemanfaatan machine learning tetap aman dan bertanggung jawab.

Tabel 8. Arah Pengembangan Penelitian Lanjutan

Arah Pengembangan	Tujuan
Dataset lebih besar	Menggunakan data dari beberapa fasilitas kesehatan agar generalisasi meningkat.
Cross-validation	Mengukur stabilitas model pada berbagai pembagian data.

Perbandingan algoritma	Menguji Decision Tree terhadap Random Forest, SVM, Gradient Boosting, dan Logistic Regression.
Explainable AI	Menjelaskan kontribusi fitur dengan teknik seperti SHAP atau feature importance.
Validasi klinis	Melibatkan tenaga kesehatan untuk menilai kelayakan input, output, dan interpretasi sistem.
Aplikasi web/mobile	Mengubah model menjadi alat bantu skrining yang lebih praktis dan mudah diakses.

4. KESIMPULAN

Berdasarkan hasil penelitian, algoritma *Decision Tree* dapat diterapkan untuk mengklasifikasikan Penyakit Ginjal Kronis dengan memanfaatkan data medis pasien, seperti atribut demografis, urinalisis, biokimia darah, hematologi, riwayat penyakit, dan kondisi klinis. Model menunjukkan performa yang baik dengan akurasi data latih sebesar 96,79% dan akurasi data uji sebesar 94,17%, sehingga mampu mengenali pola data serta melakukan prediksi pada data uji secara cukup stabil. Nilai *precision*, *recall*, dan *F1-score* juga tergolong tinggi pada kedua kelas, meskipun *confusion matrix* masih menunjukkan adanya 5 *false negative* pada kelas CKD dari total 120 data uji. Hal ini menandakan bahwa peningkatan *recall* perlu menjadi perhatian agar kasus CKD tidak terlewat. Fitur yang paling berpengaruh dalam klasifikasi meliputi *haemoglobin*, *serum creatinine*, *specific gravity*, *blood glucose random*, dan *packed cell volume*. Selain akurat, *Decision Tree* juga mudah diinterpretasikan karena alur keputusannya dapat ditelusuri. Dengan demikian, model ini berpotensi digunakan sebagai alat bantu skrining awal PGK, tetapi tetap memerlukan validasi klinis dan tidak dapat menggantikan diagnosis tenaga medis.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Potensi Utama, serta seluruh pihak yang telah mendukung penyusunan penelitian dan konversi naskah skripsi menjadi artikel jurnal ini.

REFERENSI

- [1] Elshewey, A. M., Selem, E., & Abed, A. H. (2025). Improved CKD classification based on explainable artificial intelligence with extra trees and BBFS. *Scientific Reports*, 15(1), 17861.
- [2] Anqui, A. P. (2025). Classifying chronic kidney disease using selected machine learning techniques. *International Journal of Advanced and Applied Sciences*, 12(2), 72-79.
- [3] Halder, R. K., Uddin, M. N., Uddin, M. A., Aryal, S., Saha, S., Hossen, R., & Akter, M. F. (2024). ML-CKDP: Machine learning-based chronic kidney disease prediction with smart web application. *Journal of Pathology Informatics*, 15, 100371.
- [4] Surojudin, N. (2025). Perbandingan metode klasifikasi dalam memprediksi penyakit ginjal kronis. *Jurnal Informatika Ekonomi Bisnis*, 715-723.
- [5] Metherall, B., Berryman, A. K., & Brennan, G. S. (2025). Machine learning for classifying chronic kidney disease and predicting creatinine levels using at-home measurements. *Scientific Reports*, 15(1), 4364.
- [6] Shanmugarajeshwari, V., & Ilayaraja, M. (2024). Intelligent decision support for identifying chronic kidney disease stages: Machine learning algorithms. *International Journal of Intelligent Information Technologies*, 20(1), 1-22.
- [7] Alshakrani, S., Taha, R., & Hewahi, N. (2021). Chronic kidney disease classification using machine learning classifiers. 2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies, 516-519.

-
- [8] Haider, H. A., Hussain, M., & Kharisma, I. L. (2025). Predictive analysis of chronic kidney disease in machine learning. *Engineering Proceedings*, 107(1), 118.
- [9] Prabowo, A., Wardani, S., Muis, A., Gea, R., & Tarigan, N. A. B. (2024). Diagnosis and prediction of chronic kidney disease using a stacked generalization approach. *Journal of Computer Networks, Architecture and High Performance Computing*, 6(1), 467-471.
- [10] Iliyas, I. I., Boukari, S., & Gital, A. Y. U. (2025). Recent trends in prediction of chronic kidney disease using different learning approaches: A systematic literature review. *Journal of Medical Artificial Intelligence*, 8.
- [11] Phuong, N. D., Tuyen, N. T., Linh, V. T. T., Nguyen, N. N., & Nguyen, T. Q. (2025). Machine learning techniques in chronic kidney diseases: A comparative study of classification model performance. *Bioinformatics and Biology Insights*, 19, 11779322251356563.
- [12] Fatah, Z., & Atreji, R. (2025). Klasifikasi penyakit gagal jantung menggunakan metode Decision Tree. *Jurnal Ilmiah Sistem Informasi*, 4(3), 844-854.
- [13] Ikhsan, A. N., Fadilah, A. N., & Iftinani, A. D. (2023). Performance comparison of Decision Tree J48, CART, and Naive Bayes algorithms for predicting chronic kidney disease. *Indonesian Journal of Artificial Intelligence and Data Mining*, 7(1), 64-70.
- [14] Zuriati, Z., Meilantika, D., Arpan, A., Permata, R., Sriyanto, S., & Mas'ud, M. Z. (2025). Enhancing chronic kidney disease classification using Decision Tree and bootstrap aggregating: UCI dataset study with improved accuracy and AUC-ROC. *Jurnal Teknik Informatika*, 6(5), 3111-3123.
- [15] Kidney Disease: Improving Global Outcomes. (2024). KDIGO 2024 clinical practice guideline for the evaluation and management of chronic kidney disease. *Kidney International*, 105(4S), S117-S314.
- [16] Raschka, S., Liu, Y. H., & Mirjalili, V. (2022). *Machine learning with PyTorch and Scikit-Learn: Develop machine learning and deep learning models with Python*. Packt Publishing.
- [17] Pratiwi, N. I., & Prabowo, A. (2025). Analisis servicescape, hedonic lifestyle dan promotion intention terhadap keputusan pembelian konsumen pada Suara Coffee & Space. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3), 4547-4555. <https://doi.org/10.31004/riggs.v4i3.2656>
- [18] Riska, A., & Prabowo, A. (2025). Analisis social media marketing, servicescape, dan harga terhadap keputusan pembelian konsumen di Romansa Kopi. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3), 4917-4925. <https://doi.org/10.31004/riggs.v4i3.2710>
- [19] Arini, D. P., & Prabowo, A. (2025). Analisis customer experience dan customer trust terhadap keputusan pasien berkunjung kembali pada Klinik Alternatif Akupuntur Serumpun Bambu. *ANALISIS*, 15(2), 310-328. <https://doi.org/10.37478/als.v15i02.6497>
- [20] Prabowo, A., Adam, A. A., Subhan, Z. N., Tanjung, Y., Parhusip, A. A., Deviana, A., & Irwansyah. (2025). Sustainable business practices in coffee shops: The role of marketing innovation, digital marketing, and branding innovation through market development. *International Journal of Accounting and Economics Studies*, 12(6), 43-50. <https://doi.org/10.14419/p0k0pc78>
- [21] Akila, F., & Prabowo, A. (2025). Pengaruh customer experience, perceived product quality dan brand trust terhadap keputusan pembelian konsumen Dunkin Donuts Gatot Subroto. *ProBisnis: Jurnal Manajemen*, 16(5), 1157-1165. <https://ejournal.joninstitute.org/index.php/ProBisnis/article/view/1158>
- [22] Kurniawan, D., & Prabowo, A. (2025). Analisis customer relationship marketing, marketing communications dan service quality personal trainer terhadap tingkat kepuasan member pada Vizta Gym Cemara Asri Medan. *VALUE: Jurnal Ilmiah Akuntansi, Keuangan dan Bisnis*, 6(2), 392-407. <https://doi.org/10.36490/value.v6i2.2160>
- [23] Prabowo, A., Tanjung, Y., Enzelia, E. L., Bangun, R., Simarmata, H. M. P., & Wahyuni, E. S. (2025). Eksplorasi promosi berbasis social media marketing dan brand image: Identifikasi impulsive buying behaviour melalui customer engagement pada konsumen brand fashion ZARA di Kota Medan. *Jurnal Dunia Pendidikan*, 6(3), 727-747. <https://doi.org/10.55081/jurdip.v6i3.4431>
-
- DOI: <https://www.doi.org/10.22303/upu.1.1.2021.01-10>

- [24] Prabowo, A., & Tarigan, T. D. (2025). Analisis servicescape, social media marketing dan customer experience terhadap minat berkunjung kembali konsumen Fore Coffee Citraland Helvetia Medan. *Jurnal Dunia Pendidikan*, 6(3), 996–1010. <https://doi.org/10.55081/juridip.v6i3.4581>
- [25] Prabowo, A., Siburian, P., & Bangun, R. (2025). Repurchase intention among millennial coffee shop customers: Exploring key determinants. *International Journal of Accounting and Economics Studies*, 12(8), 761–769. <https://doi.org/10.14419/j7ch0q39>
- [26] Tanjung, S., & Prabowo, A. (2025). Analisis social media marketing dan customer relationship marketing terhadap kepuasan konsumen Sikologi Coffee. *Economic and Education Journal (Ecoducation)*, 7(3), 975–989. <https://doi.org/10.33503/ecoducation.v7i3.2345>
- [27] Rizki, S., Prabowo, A., & Pasaribu, E. S. (2025). Optimalisasi kinerja karyawan pada kawasan industri di Sumatera Utara: Peran work engagement dan employee experience melalui safety knowledge. *Economic and Education Journal (Ecoducation)*, 7(3), 1022–1038. <https://doi.org/10.33503/ecoducation.v7i3.2386>
- [28] Tarigan, R. R. M. T., Wahyuni, E. S., Prabowo, A., & Mauliza, P. (2026). Pengaruh pemasaran digital terhadap keputusan pembelian dengan citra merek sebagai variabel mediasi. *MARAS: Jurnal Penelitian Multidisiplin*, 4(1), 110–119. <https://doi.org/10.60126/maras.v4i1.1503>
- [29] Mahlia, M., & Prabowo, A. (2026). Analisis experiential marketing, word of mouth, dan online customer review terhadap keputusan pembelian pada PT. Alfa Scorpii. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 5(1), 14596–14606. <https://doi.org/10.31004/riggs.v5i1.8083>
- [30] Dalimunthe, S. M., & Pohan, Y. A. (2025). Pengaruh budaya digital, pengembangan sumber daya manusia (SDM) dan lingkungan kerja fisik terhadap kinerja pegawai Dinas Ketenagakerjaan Kota Medan. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3), 7004–7014. <https://doi.org/10.31004/riggs.v4i3.3050>
- [31] Tambunan, A. M., & Pohan, Y. A. (2025). Pengaruh inovasi produk, free layanan after sales dan kualitas informasi produk di website terhadap keputusan pembelian mesin Inkjet PT. Megasatria Hiticher. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3), 7412–7422. <https://doi.org/10.31004/riggs.v4i3.3107>
- [32] Delvin, S., & Pohan, Y. A. (2025). Pengaruh komitmen afektif, komitmen berkelanjutan dan komitmen normatif terhadap kinerja karyawan PT Navya Retail Indonesia. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3), 7540–7550. <https://doi.org/10.31004/riggs.v4i3.3134>
- [33] Zai, S., & Pohan, Y. A. (2025). Pengaruh sanksi keterlambatan, biaya administrasi dan tarif jasa simpan terhadap kepuasan nasabah dalam menggunakan jasa gadai pada PT. Sentral Gadai Persada. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(3). <https://doi.org/10.31004/riggs.v4i3.3284>
- [34] Devini, S. Z., & Pohan, Y. A. (2025). Pengaruh kualitas pelayanan, kualitas produk dan fasilitas terhadap kepuasan pelanggan Lazatto Chicken & Burger cabang UMSU. *Jurnal Daya Saing*, 11(3), 899–905. <https://doi.org/10.35446/dayasaing.v11i3.2504>
- [35] Zulnawati, S. E., & Pohan, Y. A. (2026). Pengaruh perceived ease of use, brand trust dan customer experience terhadap minat pengguna Maxim di Kota Medan. *Jurnal Akutansi Manajemen Ekonomi Kewirausahaan (JAMEK)*, 6(1), 112–120. <https://doi.org/10.47065/jamek.v6i1.2285>
- [36] Rezzaini, H., Kadariah, S., & Riski, B. (2025). Pengaruh pembiayaan murabahah dan literasi keuangan terhadap kesejahteraan nasabah UMKM. *Jurnal Riset Perbankan Syariah*, 4(2), 143–152. <https://doi.org/10.29313/jrps.v4i2.8726>
- [37] Nazli, P., Kadariah, S., & Sari, S. P. (2026). Model peningkatan minat menabung generasi Z di bank syariah melalui media sosial dan edukasi digital untuk penguatan ekosistem keuangan. *Journal of Science and Social Research*, 9(3), 4999–5005. <https://doi.org/10.54314/jssr.v9i3.6723>
- [38] Sipahutar, E., Asshidiq, H., Kadariah, S., Murtani, A., Nazli, P., & Trihapsari, M. (2026). Integrasi pengetahuan, religiusitas, promosi dan minat dalam keputusan menabung berbasis perilaku individu: Pendekatan multidisiplin (MSDM, psikologi, perbankan syariah, dan akuntansi). *Jurnal Ilmiah Edunomika*, 10(2). <https://doi.org/10.29040/jie.v10i2.19873>
- [39] Reza, F., & Nazli, P. (2025). SWOT analysis in the marketing strategy of IB Mudarabah Deposit products at PT. Bank Sumut KCP Syariah Karya Medan. *Digital Business: Tren Bisnis Masa Depan*, 16(4), 171–178. <https://ejournal.cria.or.id/index.php/db/article/view/357>
- [40] Andira, M. F., & Ridwan, M. (2025). The influence of service quality, transparency, and religiosity on PT Bank Mandiri employees' interest in donation to Ziswaf at The Mandiri Amal Insani Zakat (LAZ) Institution Medan Representative. *BISEI: Jurnal Bisnis dan Ekonomi Islam*, 10(2), 117–130. <https://doi.org/10.33752/bisei.v10i2.10758>
- [41] Ainayah, D., Hutagalung, M. K., Riski, B., & Arafah, S. (2025). Pengaruh perceived value dan perceived

- quality terhadap loyalitas nasabah pembiayaan KPR IB Griya pada PT Bank Sumut Syariah KCPSY Hamparan Perak. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 2015–2021. <https://doi.org/10.31004/riggs.v4i4.3561>
- [42] Daulay, Z., Riski, B., & Hutagalung, M. K. (2025). Analisis implementasi metode pemasaran direct selling pada produk talangan umroh di PT. Bank Sumut Syariah Kantor Cabang Pembantu Hamparan Perak. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 2133–2143. <https://doi.org/10.31004/riggs.v4i4.3551>
- [43] Rahman, R. J., Miko, J., & Rizki, B. (2025). The impact of mobile banking services on customer satisfaction in the digital era at PT. Bank Sumut Syariah KCP Hamparan Perak. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 5940–5946. <https://doi.org/10.31004/riggs.v4i4.4135>
- [44] Rezzaini, H., Kadariah, S., & Riski, B. (2025). Pengaruh pembiayaan murabahah dan literasi keuangan terhadap kesejahteraan nasabah UMKM. *Jurnal Riset Perbankan Syariah*, 4(2), 143–152. <https://doi.org/10.29313/jrps.v4i2.8726>
- [45] Daulay, Z., Riski, B., & Hutagalung, M. K. (2025). Analisis implementasi metode pemasaran direct selling pada produk talangan umroh di PT. Bank Sumut Syariah Kantor Cabang Pembantu Hamparan Perak. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 2133–2143. <https://doi.org/10.31004/riggs.v4i4.3551>
- [46] Alfinsyah, R., & Murtani, A. (2025). Analysis of the use of QRIS as financial technology among millennials: A case study at Warkop Kita 2 and Warkop Agam. *Digital Business: Tren Bisnis Masa Depan*, 16(4), 164–170. <https://doi.org/10.59651/digital.v16i4.355>
- [47] Eka Putra, S., Nurmala Sari, T., Simatupang, J., Murtani, A., & Tanjung, Y. (2025). Analysis of the benefits of the 7P marketing mix strategy on the brand image of Butong Tea at PT Perkebunan Nusantara IV Bah Butong. *Jurnal Ilmiah Sosio-Ekonomika Bisnis*, 28(2), 30–37. <https://doi.org/10.22437/jiseb.v28i02.41506>