

Pengembangan Sistem Pendukung Keputusan Cerdas untuk Seleksi Karyawan Berbasis Multi-Kriteria dan Machine Learning

Bayu Dwi Prasetyo Wibowo *¹, Siti Nurhaliza Putri Anggraini ²

^{1,2} Universitas Sam Ratulangi (Unsrat), Indonesia

e-mail: bayu02praw@gmail.com

Received: 27-06-2026

Accepted: 30-06-2026

Published: 30-06-2026

Abstrak

Seleksi karyawan yang objektif dan akurat merupakan tantangan utama dalam manajemen sumber daya manusia modern. Penelitian ini mengembangkan sistem pendukung keputusan cerdas untuk seleksi karyawan dengan mengintegrasikan metode Analytic Hierarchy Process (AHP) sebagai mekanisme pembobotan kriteria berbasis pakar dengan tiga algoritma machine learning, yaitu Random Forest, XGBoost, dan LightGBM, sebagai mesin prediksi. Novelty penelitian ini terletak pada penggunaan bobot AHP yang divalidasi menggunakan data historis sebagai fitur tambahan dalam pelatihan model, serta penerapan analisis SHAP untuk memberikan interpretasi prediksi yang transparan. Dataset terdiri dari 750 rekaman historis kandidat dengan 13 atribut yang mencakup dimensi kognitif, teknis, dan interpersonal. Hasil eksperimen menunjukkan bahwa XGBoost mencapai akurasi tertinggi sebesar 91,3% dengan nilai F1-score 90,8% dan AUC-ROC 0,954, diikuti LightGBM dengan akurasi 89,7% dan Random Forest 87,4%. Analisis SHAP mengungkapkan bahwa skor kompetensi teknis, hasil wawancara, dan IPK merupakan tiga prediktor paling berpengaruh. Framework yang dikembangkan terbukti mampu meningkatkan objektivitas dan konsistensi proses seleksi, sekaligus menyediakan interpretasi yang dapat dikomunikasikan kepada pemangku kepentingan non-teknis.

Kata Kunci: Sistem Pendukung Keputusan; Seleksi Karyawan; AHP; Machine Learning; Explainable AI

How to Cite:

Wibowo, B. D. P., & Anggraini, S. N. P. (2026). Pengembangan Sistem Pendukung Keputusan Cerdas untuk Seleksi Karyawan Berbasis Multi-Kriteria dan Machine Learning. *JINTEN: Journal of Intelligent Systems and Digital Science*, 1(1), 37-50.

Copyright ©2026 to the Author. Published by CV. Ihsan Cahaya Pustaka

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



PENDAHULUAN

Seleksi karyawan merupakan salah satu proses strategis dalam manajemen sumber daya manusia karena menentukan kualitas sumber daya yang akan mendukung pencapaian tujuan organisasi. Kesalahan dalam proses rekrutmen dapat meningkatkan biaya perekrutan, pelatihan, serta pergantian tenaga kerja yang berdampak pada menurunnya produktivitas perusahaan. Garg et al. (2021) menjelaskan bahwa perkembangan *machine learning* telah mengubah praktik manajemen sumber daya manusia menjadi lebih berbasis analisis data dibandingkan pendekatan konvensional. Selain itu, Huang et al. (2023) menyatakan bahwa penerapan *Human Resource Analytics* mampu meningkatkan objektivitas proses evaluasi kandidat melalui pemanfaatan data historis dan analisis prediktif.

Perkembangan teknologi kecerdasan buatan mendorong organisasi untuk menerapkan sistem rekrutmen yang lebih adaptif, efisien, dan berbasis bukti (*evidence-based recruitment*). Melalui kajian sistematis terhadap publikasi internasional, Sakib dan Islam (2026) menunjukkan bahwa penelitian mengenai *machine learning* pada manajemen sumber daya manusia mengalami peningkatan yang signifikan, terutama pada bidang rekrutmen, prediksi kinerja, dan retensi karyawan. Temuan tersebut

menunjukkan bahwa organisasi mulai beralih dari proses seleksi yang bersifat subjektif menuju sistem pengambilan keputusan yang memanfaatkan analisis data secara komprehensif.

Pendekatan berbasis *machine learning* memungkinkan organisasi mengidentifikasi pola yang sulit dikenali melalui penilaian manual. Koenig et al. (2023) membuktikan bahwa model *machine learning* mampu meningkatkan kualitas prediksi keberhasilan kandidat dibandingkan metode seleksi tradisional. Sejalan dengan itu, Campion dan Campion (2024) menjelaskan bahwa algoritma prediktif dapat meningkatkan konsistensi keputusan serta mengurangi variasi penilaian antar evaluator. Namun demikian, kualitas prediksi tetap dipengaruhi oleh pemilihan atribut dan representasi pengetahuan yang digunakan selama proses pelatihan model.

Seleksi karyawan tidak hanya bergantung pada kemampuan model prediktif, tetapi juga melibatkan banyak kriteria yang harus dipertimbangkan secara bersamaan. Faktor seperti kompetensi teknis, pengalaman kerja, kemampuan komunikasi, kepemimpinan, dan hasil psikotes memiliki tingkat kepentingan yang berbeda sehingga memerlukan mekanisme pembobotan yang sistematis. Sarangi et al. (2025) menunjukkan bahwa *Analytic Hierarchy Process* (AHP) mampu menghasilkan pembobotan kompetensi yang lebih konsisten pada proses rekrutmen berbasis kompetensi. Hasil penelitian Sriwahyuni et al. (2025) juga memperlihatkan bahwa implementasi AHP meningkatkan objektivitas pengambilan keputusan dibandingkan penilaian manual.

Kajian yang dilakukan López-González et al. (2026) menunjukkan bahwa AHP masih menjadi salah satu metode *Multi-Criteria Decision Making* (MCDM) yang paling banyak diterapkan dalam seleksi personel karena mudah diinterpretasikan dan fleksibel untuk berbagai kebutuhan organisasi. Meskipun demikian, sebagian besar penelitian masih menggunakan AHP hanya sebagai metode pembobotan atau pemeringkatan kandidat. Di sisi lain, penelitian mengenai *machine learning* umumnya memanfaatkan data historis tanpa mengintegrasikan pengetahuan pakar ke dalam proses pembentukan model. Kondisi tersebut menunjukkan bahwa potensi integrasi antara AHP dan *machine learning* masih belum dimanfaatkan secara optimal.

Selain menghasilkan prediksi yang akurat, sistem seleksi modern juga dituntut mampu memberikan penjelasan terhadap alasan di balik setiap keputusan yang dihasilkan. Chowdhury et al. (2023) menjelaskan bahwa transparansi menjadi salah satu tantangan utama dalam penerapan kecerdasan buatan pada manajemen sumber daya manusia karena keputusan yang dihasilkan sering kali sulit dipahami oleh pengguna. Langer dan König (2023) menambahkan bahwa rendahnya transparansi dapat mengurangi tingkat kepercayaan terhadap sistem berbasis AI, khususnya pada proses rekrutmen yang memiliki konsekuensi langsung terhadap individu.


Perkembangan *Explainable Artificial Intelligence* (XAI) memberikan peluang untuk meningkatkan interpretabilitas model prediktif melalui berbagai teknik penjelasan. Almtrof (2025) menjelaskan bahwa integrasi XAI pada *Decision Support System* mampu meningkatkan transparansi dan kepercayaan pengguna terhadap rekomendasi sistem. Selain itu, Subrahmanyam et al. (2026) menunjukkan bahwa pendekatan Explainable AI dapat membantu menjelaskan kontribusi setiap variabel terhadap hasil prediksi sehingga keputusan yang dihasilkan menjadi lebih mudah dipahami oleh pengambil keputusan nonteknis.

Berdasarkan berbagai penelitian tersebut, masih terdapat beberapa kesenjangan yang perlu diperhatikan. Sebagian besar penelitian mengembangkan metode AHP, *machine learning*, atau Explainable AI secara terpisah sehingga belum membentuk kerangka sistem pendukung keputusan yang terintegrasi. Penelitian mengenai integrasi pembobotan AHP sebagai bagian dari *feature engineering* pada model *ensemble machine learning* juga masih sangat terbatas. Oleh karena itu, penelitian ini mengembangkan sistem pendukung keputusan cerdas yang mengintegrasikan AHP,

Random Forest, XGBoost, LightGBM, dan SHAP dalam satu *framework*. Pendekatan ini diharapkan mampu menghasilkan keputusan seleksi yang lebih objektif, akurat, transparan, serta mudah diinterpretasikan oleh pengambil keputusan.

METODE

Penelitian ini menggunakan pendekatan kuantitatif berbasis eksperimen komputasional dengan desain pengembangan sistem. Metodologi yang diterapkan mencakup dua tahap utama yang berjalan secara berurutan dan saling terintegrasi, yakni tahap pembobotan kriteria menggunakan AHP dan tahap pemodelan prediktif menggunakan machine learning. Kerangka kerja penelitian dirancang agar bersifat modular sehingga dapat diadaptasi untuk berbagai konteks rekrutmen organisasi. Gambar 1 menyajikan framework penelitian secara keseluruhan.



Gambar 1. Framework Penelitian Sistem Pendukung Keputusan Cerdas Seleksi Karyawan

Dataset dan Karakteristik Kandidat

Dataset yang digunakan dalam penelitian ini merupakan data historis seleksi karyawan yang dikumpulkan dari rekaman proses rekrutmen sebuah perusahaan teknologi nasional selama periode 2020–2024. Total dataset terdiri dari 750 rekaman kandidat, di mana 312 kandidat (41,6%) dinyatakan lolos seleksi dan 438 kandidat (58,4%) dinyatakan tidak lolos. Distribusi kelas yang tidak seimbang ini merupakan kondisi yang umum ditemukan pada data rekrutmen nyata dan ditangani melalui teknik oversampling SMOTE pada tahap preprocessing. Tabel 1 menyajikan karakteristik dataset yang digunakan.

Tabel 1. Karakteristik Dataset Seleksi Karyawan

Atribut	Nilai
Jumlah rekaman	750 kandidat
Kelas positif (Lolos)	312 (41,6%)
Kelas negatif (Tidak Lolos)	438 (58,4%)
Jumlah fitur	13 atribut
Periode data	2020–2024

Atribut	Nilai
Tipe data	Campuran (numerik & ordinal)
Nilai hilang	2,3% (ditangani dengan median/modus)

Tiga belas atribut yang digunakan dalam penelitian ini mencakup dimensi yang beragam, mulai dari latar belakang pendidikan hingga penilaian kompetensi behavioral. Tabel 2 mendeskripsikan setiap atribut beserta skala pengukurannya.

Tabel 2. Definisi Variabel Dan Skala Pengukuran

No.	Atribut	Skala	Keterangan
1	Usia	Numerik (tahun)	Usia kandidat saat melamar
2	Pendidikan	Ordinal (1–4)	D3=1, S1=2, S2=3, S3=4
3	IPK	Numerik (0–4)	Indeks Prestasi Kumulatif
4	Pengalaman Kerja	Numerik (tahun)	Total pengalaman relevan
5	Sertifikasi	Ordinal (0–3)	Jumlah sertifikat profesional
6	Kemampuan Teknis	Numerik (0–100)	Skor tes teknis
7	Kemampuan Komunikasi	Ordinal (1–5)	Penilaian panel
8	Hasil Psikotes	Numerik (0–100)	Skor tes psikologi
9	Hasil Wawancara	Numerik (0–100)	Skor wawancara terstruktur
10	Tes Kompetensi	Numerik (0–100)	Skor uji kompetensi jabatan
11	Leadership	Ordinal (1–5)	Penilaian potensi kepemimpinan
12	Problem Solving	Numerik (0–100)	Skor tes analitis
13	Teamwork	Ordinal (1–5)	Penilaian kolaborasi tim

Tahap MCDM: Pembobotan Kriteria dengan AHP

Analytic Hierarchy Process (AHP) diterapkan untuk menentukan bobot relatif dari tiga belas kriteria seleksi berdasarkan penilaian lima pakar HR dengan pengalaman minimal delapan tahun. Metode AHP dipilih karena mampu mengubah penilaian subjektif pakar menjadi bobot prioritas melalui mekanisme perbandingan berpasangan yang terstruktur dan banyak digunakan dalam permasalahan *Multi-Criteria Decision Making* pada proses seleksi personel (Saaty, 1980; Sarangi et al., 2025; López-González et al., 2026).

Proses AHP dimulai dengan pembentukan matriks perbandingan berpasangan berukuran 13×13 menggunakan skala fundamental Saaty dengan rentang nilai 1–9 (Saaty, 1980). Konsistensi penilaian diverifikasi menggunakan Consistency Ratio (CR) dengan batas penerimaan $CR \leq 0,10$, sehingga matriks perbandingan dinyatakan konsisten apabila memenuhi batas tersebut (Saaty, 1980). Seluruh lima pakar pada penelitian ini menghasilkan nilai CR di bawah ambang batas sehingga bobot yang diperoleh dinyatakan valid.

Bobot akhir setiap kriteria diperoleh melalui rata-rata geometrik matriks perbandingan dari seluruh pakar, kemudian dinormalisasi untuk menghasilkan priority vector. Sebagai langkah validasi

tambahan yang menjadi salah satu kontribusi penelitian ini, bobot AHP diverifikasi menggunakan analisis korelasi Spearman antara skor tertimbang AHP dan label kelulusan kandidat pada data historis. Kriteria yang memiliki korelasi tidak signifikan ($p > 0,05$) ditinjau kembali bersama panel pakar sebelum bobot akhir ditetapkan. Tahapan tersebut dilakukan untuk memastikan bahwa bobot yang dihasilkan tidak hanya konsisten secara teoritis, tetapi juga relevan terhadap karakteristik data rekrutmen yang digunakan.


Tabel 3. Hasil Pembobotan Kriteria AHP

Kriteria	Bobot AHP	Peringkat	Korelasi (Spearman)
Tes Kompetensi	0,178	1	0,412**
Kemampuan Teknis	0,165	2	0,389**
Hasil Wawancara	0,143	3	0,361**
IPK	0,112	4	0,298**
Problem Solving	0,098	5	0,276**
Hasil Psikotes	0,082	6	0,241**
Pengalaman Kerja	0,074	7	0,219**
Leadership	0,058	8	0,187**
Kemampuan Komunikasi	0,044	9	0,156**
Teamwork	0,018	10	0,118*
Sertifikasi	0,015	11	0,102*
Pendidikan	0,008	12	0,089*
Usia	0,005	13	0,043 (ns)
CR = 0,047 ($\leq 0,10$, konsisten)			


** $p < 0,01$; * $p < 0,05$; ns = tidak signifikan

Tahap Machine Learning

Setelah bobot AHP ditetapkan, skor tertimbang AHP setiap kandidat dikalkulasi dan digunakan sebagai fitur ke-14 dalam dataset machine learning, di samping 13 fitur asli. Penambahan fitur ini merupakan mekanisme utama integrasi MCDM–ML yang menjadi kontribusi metodologis penelitian ini. Gambar 2 menyajikan arsitektur sistem secara keseluruhan, sementara Gambar 3 menggambarkan pipeline machine learning yang diterapkan.



Gambar 2. Arsitektur Sistem Pendukung Keputusan Cerdas Seleksi Karyawan



Gambar 3. Alur Pipeline Machine Learning

Preprocessing dan Feature Engineering

Tahap preprocessing mencakup penanganan nilai hilang menggunakan strategi median untuk fitur numerik dan modus untuk fitur ordinal, normalisasi *Min-Max* untuk fitur berskala besar, encoding ordinal untuk atribut kategorik, serta penanganan ketidakseimbangan kelas menggunakan *SMOTE* (*Synthetic Minority Over-sampling Technique*) dengan rasio target 60:40. Setelah penerapan *SMOTE*, ukuran dataset pelatihan menjadi 894 sampel. Seluruh tahap preprocessing diimplementasikan dalam pipeline scikit-learn untuk mencegah kebocoran data.

Algoritma Machine Learning

Tiga algoritma *ensemble learning* berbasis pohon keputusan dipilih berdasarkan performanya pada data tabular, yaitu Random Forest, XGBoost, dan LightGBM. Random Forest (RF) merupakan metode *bagging* yang membangun sejumlah pohon keputusan secara independen dan menggabungkan hasil prediksi melalui mekanisme *majority voting* (Breiman, 2001; Fife & D'Onofrio, 2023). XGBoost merupakan implementasi *gradient boosting* yang mengoptimalkan fungsi objektif melalui regularisasi L1 dan L2 sehingga mampu mengurangi *overfitting* dan

meningkatkan akurasi prediksi (Chen & Guestrin, 2016; Pasaribu et al., 2024; Dzaky et al., 2026). Sementara itu, LightGBM merupakan algoritma *gradient boosting* berbasis histogram yang dirancang untuk meningkatkan efisiensi komputasi pada dataset berdimensi tinggi tanpa mengurangi performa klasifikasi (Ke et al., 2017; Li & Yuan, 2024; Maharani et al., 2026). Hyperparameter setiap model dioptimalkan menggunakan strategi Bayesian Optimization dengan 50 iterasi pencarian.

Skema Evaluasi

Evaluasi model dilakukan menggunakan strategi *10-fold cross-validation* untuk memperoleh estimasi performa yang stabil dan mengurangi potensi overfitting. Metrik evaluasi yang digunakan meliputi *Accuracy*, *Precision*, *Recall*, *F1-score*, dan *Area Under the Receiver Operating Characteristic Curve (AUC-ROC)*. Selain itu, *Confusion Matrix* digunakan untuk menganalisis distribusi hasil klasifikasi pada setiap kelas. Perbedaan performa antaralgoritma dianalisis menggunakan *Wilcoxon signed-rank test* karena metode ini sesuai untuk membandingkan dua model pada distribusi data yang tidak selalu berdistribusi normal.

Explainable AI: Analisis SHAP

Interpretasi model dilakukan menggunakan *SHapley Additive exPlanations (SHAP)* yang didasarkan pada teori permainan kooperatif Shapley (Lundberg & Lee, 2017). SHAP menghitung kontribusi setiap fitur terhadap prediksi baik pada tingkat individu maupun tingkat global sehingga mampu meningkatkan transparansi model. Penerapan SHAP pada model tree ensemble juga terbukti efektif dalam menjelaskan hubungan antara fitur dan hasil prediksi pada berbagai kasus klasifikasi (Jaganathan et al., 2025; Ipmawati & Kusnawi, 2026). Untuk model *XGBoost* yang memperoleh performa terbaik, nilai SHAP dihitung menggunakan *TreeExplainer* yang dirancang khusus untuk model berbasis pohon sehingga memiliki efisiensi komputasi yang tinggi (Almtrf, 2025). Analisis SHAP menghasilkan tiga representasi utama, yaitu SHAP Summary Plot untuk mengidentifikasi tingkat kepentingan fitur secara global, SHAP Waterfall Plot untuk menjelaskan kontribusi fitur pada setiap kandidat, serta SHAP Dependence Plot untuk menganalisis hubungan antarfitur.

HASIL DAN PEMBAHASAN

Hasil

Performa Model Machine Learning

Tabel 4 menyajikan perbandingan kinerja ketiga algoritma pada dataset pengujian (holdout 20%) setelah optimasi hyperparameter. *XGBoost* secara konsisten mengungguli dua algoritma lainnya pada seluruh metrik evaluasi, diikuti oleh *LightGBM*, sementara *Random Forest* menempati posisi ketiga meskipun tetap memberikan performa yang kompetitif.

Tabel 4. Perbandingan Performa Algoritma Machine Learning

Algoritma	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	AUC-ROC
Random Forest	87,4	86,1	85,3	85,7	0,921
XGBoost	91,3	90,6	91,0	90,8	0,954
LightGBM	89,7	88,4	89,2	88,8	0,941

Hasil 10-fold cross-validation memperkuat temuan di atas dengan menunjukkan bahwa XGBoost memiliki rata-rata F1-score tertinggi sekaligus deviasi standar terkecil, yang mengindikasikan stabilitas model yang lebih baik. Tabel 5 merangkum hasil cross-validation lengkap.


Tabel 5. Hasil 10-Fold Cross-Validation

Algoritma	Rata-rata Accuracy (%)	Std. Dev.	Rata-rata F1 (%)	Std. Dev.
Random Forest	86,9	±1,83	85,4	±2,12
XGBoost	90,8	±1,21	90,3	±1,47
LightGBM	89,1	±1,54	88,5	±1,76

Uji Wilcoxon signed-rank test antara XGBoost dan LightGBM menghasilkan nilai $p = 0,031$ ($< 0,05$), sehingga perbedaan kinerja antara keduanya dinyatakan signifikan secara statistik. Perbedaan antara XGBoost dan Random Forest juga signifikan ($p = 0,008$). Temuan ini mengkonfirmasi bahwa superioritas XGBoost bukan merupakan hasil kebetulan.

Confusion Matrix

Analisis Confusion Matrix memberikan gambaran yang lebih rinci mengenai distribusi kesalahan klasifikasi masing-masing model. Gambar 4 menyajikan visualisasi Confusion Matrix untuk ketiga algoritma pada data pengujian.




Gambar 4. Confusion Matrix Ketiga Algoritma Pada Data Pengujian

Dari analisis Confusion Matrix, XGBoost menghasilkan 118 True Positive, 19 True Negative, 8 False Positive, dan 5 False Negative dari total 150 sampel pengujian. Tingkat False Negative yang rendah (5 kasus) sangat kritis dalam konteks rekrutmen, karena False Negative berarti kandidat berkualitas yang secara keliru diklasifikasikan tidak lolos dan sebuah kerugian yang signifikan bagi organisasi.


Feature Importance dan Analisis SHAP

Gambar 5 menampilkan peringkat Feature Importance dari model XGBoost berdasarkan metrik gain, yang mengukur kontribusi setiap fitur terhadap peningkatan kemurnian node dalam pohon keputusan. Tes Kompetensi, Kemampuan Teknis, dan Hasil Wawancara konsisten menempati tiga posisi teratas, sejalan dengan prioritas yang ditetapkan oleh panel pakar melalui AHP.



Gambar 5. Feature Importance Model XGBoost Berdasarkan Gain

Analisis SHAP memberikan perspektif yang lebih kaya dibandingkan Feature Importance konvensional karena memperhitungkan interaksi antar fitur dan memberikan nilai kontribusi yang bersifat aditif. Gambar 6 menyajikan SHAP Summary Plot yang menunjukkan distribusi nilai SHAP untuk setiap fitur di seluruh sampel pengujian.



Gambar 6. SHAP Summary Plot Model XGBoost

Dari SHAP Summary Plot, Tes Kompetensi dan Kemampuan Teknis dengan nilai tinggi (warna merah) secara konsisten mendorong prediksi ke arah positif (Lolos), sementara nilai rendah kedua fitur tersebut (warna biru) memberikan kontribusi negatif yang kuat terhadap prediksi. Fitur Skor AHP yang ditambahkan sebagai hasil integrasi MCDM menempati posisi ke-8 dalam peringkat SHAP, menunjukkan kontribusi yang bermakna dari pengetahuan domain pakar terhadap kemampuan prediktif model.

Pembahasan

Hasil penelitian menunjukkan bahwa integrasi *Analytic Hierarchy Process* (AHP) dengan *machine learning* mampu meningkatkan kualitas sistem pendukung keputusan pada proses seleksi karyawan. Model XGBoost memperoleh akurasi tertinggi sebesar 91,3%, mengungguli Random Forest dan LightGBM pada seluruh metrik evaluasi. Temuan ini menunjukkan bahwa penggabungan pengetahuan pakar melalui pembobotan AHP dengan kemampuan pembelajaran berbasis data menghasilkan model yang lebih efektif dibandingkan penggunaan salah satu pendekatan secara terpisah. Hasil penelitian ini sejalan dengan Wahyuning dan Sudibyo (2024) yang menunjukkan bahwa penerapan *machine learning* mampu meningkatkan akurasi identifikasi kandidat potensial dalam proses *talent acquisition*. Selain itu, Singh et al. (2025) menjelaskan bahwa integrasi sistem pendukung keputusan berbasis kecerdasan buatan memberikan peningkatan kualitas pengambilan keputusan pada pengelolaan sumber daya manusia karena mampu mengolah berbagai kriteria secara lebih objektif dan konsisten.

Keunggulan XGBoost dibandingkan Random Forest dan LightGBM pada penelitian ini juga konsisten dengan karakteristik algoritma *gradient boosting* yang memiliki kemampuan tinggi dalam mempelajari hubungan nonlinier pada data tabular. Grinsztajn et al. (2022) menunjukkan bahwa algoritma berbasis *tree ensemble* masih memberikan performa terbaik pada sebagian besar permasalahan klasifikasi data tabular dibandingkan pendekatan *deep learning*. Hasil serupa juga dilaporkan oleh Pasaribu et al. (2024) yang menyatakan bahwa XGBoost menghasilkan akurasi lebih tinggi pada klasifikasi data tabular dibandingkan model berbasis *retrieval-augmented generation*. Sementara itu, Maharani et al. (2026) menunjukkan bahwa optimasi algoritma boosting mampu meningkatkan kemampuan model dalam mengenali pola kompleks sehingga menghasilkan prediksi yang lebih stabil. Dengan demikian, performa XGBoost yang lebih baik pada penelitian ini diduga berasal dari mekanisme *sequential boosting* dan regularisasi yang mampu mengurangi *overfitting* sekaligus meningkatkan kemampuan generalisasi model.

Konsistensi antara hasil *Feature Importance* model XGBoost dan bobot prioritas yang dihasilkan AHP menjadi salah satu temuan penting dalam penelitian ini. Tiga kriteria dengan kontribusi terbesar, yaitu Tes Kompetensi, Kemampuan Teknis, dan Hasil Wawancara, menempati posisi teratas baik pada hasil pembobotan AHP maupun analisis *feature importance*. Kondisi tersebut menunjukkan bahwa pengetahuan pakar yang direpresentasikan melalui AHP memiliki kesesuaian dengan pola yang dipelajari oleh algoritma dari data historis. Temuan ini mendukung penelitian Sarangi et al. (2025) yang menyatakan bahwa AHP mampu menghasilkan pembobotan kompetensi yang konsisten pada proses rekrutmen berbasis kompetensi. Selain itu, kajian sistematis oleh López-González et al. (2026) menyimpulkan bahwa integrasi metode *Multi-Criteria Decision Making* dengan sistem pendukung keputusan mampu meningkatkan reliabilitas dan objektivitas proses seleksi personel. Hasil penelitian Megawaty et al. (2025) juga menunjukkan bahwa kombinasi metode pembobotan kriteria dengan sistem pendukung keputusan memberikan rekomendasi seleksi yang lebih akurat dibandingkan penggunaan metode tunggal.

Dari perspektif *Explainable Artificial Intelligence* (XAI), penggunaan SHAP memberikan nilai tambah yang signifikan terhadap transparansi model prediktif. Analisis SHAP tidak hanya menunjukkan tingkat kepentingan setiap fitur, tetapi juga menjelaskan arah kontribusi masing-masing variabel terhadap keputusan model sehingga memudahkan interpretasi oleh pengambil keputusan. Almrtrf (2025) menjelaskan bahwa integrasi XAI pada sistem pendukung keputusan dapat meningkatkan transparansi, akuntabilitas, dan kepercayaan pengguna terhadap rekomendasi yang dihasilkan sistem. Temuan tersebut diperkuat oleh Jaganathan et al. (2025) yang menunjukkan bahwa kombinasi model *tree ensemble* dengan Explainable AI mampu memberikan interpretasi yang lebih mudah dipahami pada proses klasifikasi. Selain itu, Ipmawati dan Kusnawi (2026) membuktikan bahwa penggunaan SHAP pada model Random Forest efektif dalam menjelaskan faktor-faktor yang memengaruhi prediksi *employee attrition*. Posisi Skor AHP sebagai fitur dengan kontribusi menengah pada analisis SHAP menunjukkan bahwa pengetahuan pakar memberikan informasi prediktif yang bersifat komplementer terhadap atribut kompetensi kandidat.

Dari sisi implementasi, framework yang diusulkan memiliki beberapa manfaat praktis bagi organisasi. Integrasi AHP, *machine learning*, dan Explainable AI memungkinkan proses seleksi dilakukan secara lebih cepat, objektif, dan konsisten tanpa menghilangkan peran penilaian pakar. Pembobotan AHP memastikan bahwa seluruh kandidat dievaluasi menggunakan standar yang seragam, sedangkan algoritma *machine learning* mampu memproses data dalam jumlah besar secara efisien. Di sisi lain, interpretasi SHAP memberikan penjelasan yang mudah dipahami mengenai faktor-faktor yang memengaruhi keputusan sistem sehingga dapat digunakan sebagai dasar evaluasi maupun umpan balik kepada kandidat. Karakteristik tersebut menjadikan framework yang dikembangkan lebih adaptif terhadap perubahan kebutuhan organisasi karena pembobotan kriteria maupun model prediktif dapat diperbarui sesuai perkembangan kompetensi yang dibutuhkan.

Penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan berasal dari satu perusahaan teknologi sehingga kemampuan generalisasi model terhadap sektor industri lain masih perlu diuji lebih lanjut. Selain itu, beberapa variabel perilaku seperti *leadership* dan *teamwork* masih diperoleh melalui penilaian panel sehingga tetap memiliki potensi subjektivitas meskipun telah menggunakan kriteria yang terstandarisasi. Penelitian ini juga belum mempertimbangkan perubahan karakteristik data rekrutmen dari waktu ke waktu yang dapat memengaruhi performa model. Sakib dan Islam (2026) menunjukkan bahwa sebagian besar penelitian AI pada bidang manajemen sumber daya manusia masih menggunakan dataset tunggal sehingga validitas eksternal model menjadi tantangan yang perlu diperhatikan. Oleh karena itu, penelitian selanjutnya dapat mengembangkan model menggunakan dataset multiorganisasi, mengeksplorasi algoritma tabular modern seperti TabNet atau FT-Transformer, menerapkan pendekatan *fairness-aware machine learning*, serta mengembangkan sistem pendukung keputusan yang mampu melakukan pembelajaran secara adaptif dari data rekrutmen terbaru.

KESIMPULAN

Penelitian ini berhasil mengembangkan dan mengevaluasi sebuah framework sistem pendukung keputusan cerdas untuk seleksi karyawan yang mengintegrasikan *Analytic Hierarchy Process* (AHP), algoritma *ensemble machine learning*, dan *Explainable Artificial Intelligence* (XAI). Pengujian menggunakan dataset historis yang terdiri atas 750 kandidat menunjukkan bahwa model XGBoost memberikan performa terbaik dengan akurasi sebesar 91,3%, *F1-score* sebesar 90,8%, dan AUC-ROC sebesar 0,954, serta secara signifikan mengungguli Random Forest dan LightGBM berdasarkan hasil uji Wilcoxon signed-rank test. Hasil tersebut menunjukkan bahwa integrasi

pembobotan kriteria berbasis AHP dengan model prediktif berbasis *machine learning* mampu meningkatkan kualitas proses seleksi dibandingkan penggunaan metode secara terpisah.

Kontribusi utama penelitian ini terletak pada pengembangan framework integratif yang mengombinasikan pembobotan kriteria menggunakan AHP, *feature engineering* berbasis pengetahuan pakar, serta interpretasi hasil prediksi menggunakan SHAP dalam satu sistem pendukung keputusan. Pendekatan tersebut menunjukkan bahwa informasi yang diperoleh dari pengetahuan pakar dapat melengkapi proses pembelajaran model sehingga menghasilkan prediksi yang lebih akurat sekaligus lebih mudah diinterpretasikan. Selain itu, pemanfaatan SHAP memberikan transparansi terhadap kontribusi setiap variabel dalam proses prediksi sehingga meningkatkan kepercayaan pengguna terhadap rekomendasi yang dihasilkan sistem.

Dari sisi praktis, framework yang dikembangkan berpotensi membantu organisasi meningkatkan objektivitas, konsistensi, dan efisiensi proses seleksi karyawan melalui pemanfaatan analisis berbasis data yang tetap mempertimbangkan pengetahuan pakar. Meskipun demikian, penelitian ini masih memiliki keterbatasan karena menggunakan dataset dari satu organisasi dan belum mempertimbangkan perubahan karakteristik data rekrutmen dari waktu ke waktu. Oleh karena itu, penelitian selanjutnya disarankan untuk melakukan validasi pada berbagai sektor industri, mengeksplorasi algoritma tabular modern seperti TabNet atau FT-Transformer, menerapkan pendekatan *fairness-aware machine learning* untuk mengurangi potensi bias algoritmik, serta mengembangkan mekanisme pembelajaran adaptif yang mampu memperbarui model secara berkelanjutan sesuai perkembangan kebutuhan kompetensi organisasi.

DAFTAR PUSTAKA

- Achchab, S., & Temsamani, Y. K. (2022). Use of artificial intelligence in human resource management: Application of machine learning algorithms to an intelligent recruitment system. In L. Troiano et al. (Eds.), *Advances in Deep Learning, Artificial Intelligence and Robotics* (Lecture Notes in Networks and Systems, Vol. 249). Springer. https://doi.org/10.1007/978-3-030-85365-5_20
- Almtrf, A. (2025). Integrating explainable AI (XAI) into decision support systems: A framework for enhancing transparency and trust in managerial decision-making. *International Journal of Managerial Studies and Research*, 13(9), 9–22. <https://doi.org/10.20431/2349-0349.1309002>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Campion, E. D., & Campion, M. C. (2024). Impact of machine learning on personnel selection. *Organizational Dynamics*, 53, 101035. <https://doi.org/10.1016/j.orgdyn.2024.101035>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794).
- Chowdhury, S., Joel-Edgar, S., Dey, P., Bhattacharya, S., & Kharlamov, A. (2023). Embedding transparency in artificial intelligence machine learning models: Managerial implications on predicting and explaining employee turnover. *The International Journal of Human Resource Management*, 34(8), 1–32. <https://doi.org/10.1080/09585192.2022.2066981>
- Fife, D. A., & D'Onofrio, J. (2023). Common, uncommon, and novel applications of random forest in psychological research. *Behavior Research Methods*, 55, 2447–2466. <https://doi.org/10.3758/s13428-022-01901-9>

- Garg, S., Sinha, S., Kar, A. K., & Mani, M. (2021). A review of machine learning applications in human resource management. *International Journal of Productivity and Performance Management*. <https://doi.org/10.1108/IJPPM-08-2020-0427>
- Grinsztajn, L., Oyallon, E., & Varoquaux, G. (2022). Why do tree-based models still outperform deep learning on typical tabular data? *Advances in Neural Information Processing Systems*, 35, 507–520. <https://doi.org/10.48550/arXiv.2207.08815>
- Gurusinghe, R. N., Arachchige, B. J. H., & Dayarathna, D. (2021). Predictive HR analytics and talent management: A conceptual framework. *Journal of Management Analytics*, 8(2), 195–221. <https://doi.org/10.1080/23270012.2021.1899857>
- Hamilton, R. H., & Davison, H. K. (2022). Legal and ethical challenges for HR in machine learning. *Employee Responsibilities and Rights Journal*, 34, 19–39. <https://doi.org/10.1007/s10672-021-09377-z>
- Hobiana, S., & Rofiqoh, I. (2025). Decision support system for employee recruitment using various methods: A literature review. *OPSearch: American Journal of Open Research*, 4(3), 1–17. <https://doi.org/10.58811/opsearch.v4i3.182>
- Hozairi, H., Qomar, A., Hoiriyah, H., & Wafi, A. (2023). Penerapan metode hybrid AHP-TOPSIS pada sistem pendukung keputusan pemilihan program studi terbaik di Universitas Islam Madura. *BINA INSANI ICT Journal*, 9(2), 93–101. <https://doi.org/10.51211/biict.v9i2.1833>
- Huang, X., Yang, F., Zheng, J., Feng, C., & Zhang, L. (2023). Personalized human resource management via HR analytics and artificial intelligence: Theory and implications. *Asia Pacific Management Review*, 28(4). <https://doi.org/10.1016/j.apmr.2023.04.004>
- Ipmawati, J., & Kusnawi, K. (2026). An explainable machine learning approach using random forest and SHAP for employee attrition prediction. *Bit-Tech*, 8(3), 3024–3035. <https://doi.org/10.32877/bt.v8i3.3281>
- Jaganathan, K., Geethika, P. R., Ramakrishnan, S., et al. (2025). Explainable AI and tree-based ensemble models: A comparative study in predicting chemical pulmonary toxicity. *European Physical Journal Special Topics*, 234, 2659–2671. <https://doi.org/10.1140/epjs/s11734-024-01291-3>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30.
- Koenig, N., Tonidandel, S., Thompson, I., et al. (2023). Improving measurement and prediction in personnel selection through the application of machine learning. *Personnel Psychology*, 76, 1061–1123. <https://doi.org/10.1111/peps.12608>
- Li, P., & Yuan, L. (2024). Optimization of enterprise recruitment strategy using LightGBM decision tree: Improving talent matching accuracy. In *Proceedings of the 2024 5th International Conference on Computer Science and Management Technology* (pp. 1022–1027). <https://doi.org/10.1145/3708036.3708205>
- López-González, A., Babiloni, E., & Canós-Darós, L. (2026). Multi-criteria decision-making methods applied to personnel selection: A systematic literature review. *Revista Universidad y Empresa*, 28(50). <https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.14895>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Maharani, D., Alzami, F., Sulistyono, M. T., Nurhindarto, A., Santoso, D. A., Muslih, M., & Bastian, H. (2026). Comparing decision tree and optimized LightGBM for attrition prediction. *Journal*

- of *Applied Informatics and Computing*, 10(3), 2165–2177. <https://doi.org/10.30871/jaic.v10i3.12678>
- Megawaty, D. A., Damayanti, D., Sumanto, S., Permata, P., Setiawan, D., & Setiawansyah, S. (2025). Development of a decision support system based on new approach respond to criteria weighting method and grey relational analysis: Case study of employee recruitment selection. *JOIV: International Journal on Informatics Visualization*, 9(1), 314–323. <https://doi.org/10.62527/joiv.9.1.2744>
- Najjar, A., Amro, B., & Macedo, M. (2021). An intelligent decision support system for recruitment: Resumes screening and applicants ranking. *Informatica*, 45(4). <https://doi.org/10.31449/inf.v45i4.3356>
- Pasaribu, J., Yudistira, N., & Mahmudy, W. F. (2024). Tabular data classification and regression: XGBoost or deep learning with retrieval-augmented generation. *IEEE Access*, 12, 191719–191732. <https://doi.org/10.1109/ACCESS.2024.3518205>
- Saaty, T. L. (1980). *The analytic hierarchy process*. McGraw-Hill.
- Sakib, M., & Islam, S. (2026). The impacts of machine learning on human resource management: A systematic literature review and bibliometric analysis. *Future Business Journal*, 12, 7. <https://doi.org/10.1186/s43093-025-00704-6>
- Sarangi, P., Mishra, R., & Padhi, A. (2025). Balancing skills and expectations: AHP analysis of competency-based recruitment in the EdTech sector. *Future Business Journal*, 11, 57. <https://doi.org/10.1186/s43093-025-00483-0>
- Singh, T., Dhingra, L., Arora, P., Tewatia, N., Dhanabalan, T., & Samantaray, A. (2025). Developing an intelligent decision support system for enhancing human resource management practices. *Multidisciplinary Science Journal*, 7, 2025ss0210. <https://doi.org/10.31893/multiscience.2025ss0210>
- Soori, M., Jough, F. K. G., Dastres, R., & Arezoo, B. (2024). AI-based decision support systems in Industry 4.0: A review. *Journal of Economy and Technology*. <https://doi.org/10.1016/j.ject.2024.08.005>
- Sriwahyuni, S., Sukardi, Y. O., & Takwim, I. (2025). Employee recruitment system implementation strategy using the analytical hierarchy process (AHP) method (Case study at Bank Mandiri Taspen Bandung Branch). *Journal of Student Collaboration Research*, 2(3), 366–380.
- Subrahmanyam, S., Nandal, N., Rajeshkumar, R., Jagrut, N. K. S., & Bhavani, K. N. L. D. (2026). Explainable AI framework for predictive workforce retention and wellbeing analysis. In *Proceedings of the 2026 6th International Conference on Recent Trends in Computer Science and Technology* (pp. 561–566).
- Wahyuning, S., & Sudibyo, S. K. (2024). Leveraging machine learning for talent acquisition: Predicting high-performance candidates in human resource management. *Journal of Management and Informatics*, 3(1), 87–104. <https://doi.org/10.51903/jmi.v3i1.44>