

Optimization of Employee Selection Using Hybrid DSS: SAW Approach and Random Forest-Based Attrition Prediction

Dewi Azura¹, Ahmad Zamsuri², Susandri³

^{1,2,3}Magister Ilmu Komputer, Sekolah Pascasarjana, Universitas Lancang Kuning

^{1,2,3}Jl. Yos Sudarso KM. 8 Rumbai, Pekanbaru, Riau, telp. 0811 753 2015

e-mail: dewy.az@gmail.com¹, ahmadzamsuri@unilak.ac.id², susandri@unilak.ac.id³

Abstrak

Pemilihan karyawan merupakan komponen kritis dalam manajemen sumber daya manusia yang memerlukan tingkat objektivitas dan efisiensi yang tinggi. Studi ini mengusulkan sistem pendukung keputusan (DSS) hibrida yang menggabungkan metode Simple Additive Weighting (SAW) untuk evaluasi multi-kriteria dan algoritma Random Forest untuk prediksi risiko turnover. Data set IBM HR Analytics, yang terdiri dari 1.470 catatan karyawan, digunakan sebagai sumber data utama. Kumpulan data tersebut menjalani langkah-langkah prapemrosesan, termasuk pembersihan, pengkodean, dan penyeimbangan kelas menggunakan Teknik Oversampling Minoritas Sintetis (SMOTE). Skor kandidat akhir dihitung berdasarkan nilai yang dinormalisasi di delapan kriteria seleksi, yang diberi bobot sesuai dengan signifikansi logisnya. Simulasi what-if dilakukan untuk menilai sensitivitas sistem terhadap perubahan bobot kriteria. Hasil menunjukkan bahwa pendekatan terintegrasi SAW dan Random Forest menghasilkan rekomendasi kandidat yang lebih objektif dan akurat, dengan akurasi prediksi 83% dan AUC 0,77. Alat visual, seperti diagram radar, kurva ROC, dan matriks kebingungan, meningkatkan keterbacaan dan transparansi keputusan. Studi ini menyajikan pendekatan sistematis dan fleksibel untuk mendukung organisasi dalam mengambil keputusan perekrutan yang didasarkan pada data dan proaktif.

Kata kunci: Sistem Pendukung Keputusan, Random Forest, Simple Additive Weighting, Seleksi Karyawan, Simulasi What-if.

Abstract

Employee selection is a critical component of human resource management that requires high levels of objectivity and efficiency. This study proposes a hybrid decision support system (DSS) that integrates the Simple Additive Weighting (SAW) method for multi-criteria evaluation and the Random Forest algorithm for attrition risk prediction. The IBM HR Analytics dataset, which consists of 1,470 employee records, was used as the primary data source. The dataset underwent preprocessing steps, including cleaning, encoding, and class balancing using the Synthetic Minority Oversampling Technique (SMOTE). The final candidate scores were calculated based on normalized values across eight selection criteria, which were weighted according to their logical significance. A what-if simulation was conducted to assess the sensitivity of the system to changes in the criterion weights. The results show that the integrated SAW and Random Forest approach yields more objective and accurate candidate recommendations, achieving **83% prediction accuracy** and an **AUC of 0.77**. Visual tools, such as radar charts, ROC curves, and confusion matrices, enhance interpretability and decision transparency. This study presents a systematic and flexible approach to support organizations in making data-driven and proactive recruitment decisions.

Keywords: Decision Support System, Random Forest, Simple Additive Weighting, Employee Selection, What-if Simulation.

1. PENDAHULUAN

Penelitian ini berada pada irisan bidang Manajemen Sumber Daya Manusia (MSDM) dan Sains Data, dengan fokus khusus pada penerapan Sistem Pendukung Keputusan (SPK) tingkat lanjut untuk mengoptimalkan proses seleksi karyawan. Dalam lingkungan bisnis

kontemporer yang ditandai oleh persaingan ketat dalam perekrutan talenta dan transformasi digital yang cepat, organisasi menghadapi tekanan besar untuk mengambil keputusan rekrutmen yang optimal. Pemilihan karyawan yang kurang tepat menimbulkan biaya substansial terkait pelatihan, retensi, dan ketidaksesuaian budaya, yang pada akhirnya melemahkan daya saing dan keberlanjutan organisasi (Cascio, 2018). Sementara SPK berbasis data yang didukung pembelajaran mesin menawarkan potensi transformasional, masih terdapat kesenjangan kritis. Sebagian besar solusi saat ini memperlakukan evaluasi kandidat (masalah pengambilan keputusan multi-kriteria) dan prediksi turnover/attrition (masalah analitik prediktif) sebagai proses yang terpisah, sehingga menghasilkan pandangan yang terfragmentasi dan berjangka pendek terhadap akuisisi talenta.

Tujuan utama penelitian ini adalah merancang, mengembangkan, dan mengusulkan suatu kerangka SPK terpadu yang secara sinergis menggabungkan Multi-Criteria Decision-Making (MCDM) dan pembelajaran mesin prediktif untuk meningkatkan proses seleksi karyawan. Sistem terintegrasi ini bertujuan untuk mengevaluasi kesesuaian kandidat saat ini sekaligus memprediksi potensi retensi jangka panjang mereka, sehingga menyediakan alat yang lebih holistik dan strategis bagi pengambil keputusan di bidang MSDM.

Sistem Pendukung Keputusan (SPK) adalah sistem berbasis komputer yang membantu pengambil keputusan dalam menangani masalah semi-terstruktur dengan memanfaatkan data dan model analitis (Power, 2002; Turban et al., 2011). Dalam konteks MSDM, SPK telah berevolusi dari sistem berbasis aturan yang sederhana menjadi platform canggih yang mengintegrasikan pemodelan statistik. Fungsi utamanya dalam rekrutmen adalah meningkatkan objektivitas dan efisiensi dengan mengintegrasikan data kuantitatif dan kualitatif ke dalam kerangka kerja yang terstandarisasi, sehingga mengurangi bias subjektif (Rousseau, 2023). Munculnya big data dan kecerdasan buatan semakin mendorong SPK dari kemampuan deskriptif dan diagnostik menuju analitik prediktif dan preskriptif (Marakas & O'Brien, 2023; Shim et al., 2002).

Dua metodologi berikut sangat relevan dengan perkembangan ini dalam konteks pengambilan keputusan dan prediksi dalam MSDM.

1. **Simple Additive Weighting (SAW)**

SAW adalah metode Multi-Criteria Decision-Making (MCDM) yang transparan dan banyak digunakan untuk mengevaluasi dan memeringkat alternatif berdasarkan penjumlahan terbobot dari kriteria yang telah dinormalisasi (Keshavarz Ghorabae et al., 2017; Opricovic & Tzeng, 2004).

2. **Random Forest**

Random Forest adalah algoritma pembelajaran mesin berbasis ensemble yang dikenal memiliki akurasi prediktif tinggi, stabilitas yang baik, serta ketahanan terhadap overfitting, sehingga menjadi salah satu pilihan utama untuk tugas-tugas seperti prediksi attrition karyawan (Breiman, 2001; Zhang et al., 2022).

Penelitian terbaru telah meningkatkan kemampuan SPK dalam bidang SDM secara signifikan, di mana berbagai studi secara konsisten menunjukkan superioritas Random Forest dalam prediksi attrition, dengan capaian akurasi tinggi (>85%) melalui identifikasi faktor-faktor kunci seperti pendapatan bulanan, lembur, dan keseimbangan kerja-hidup (Gao, 2019; Sirisha et al., 2022; Papineni et al., 2021). Selain itu, berbagai upaya dilakukan untuk meningkatkan keterjelasan model dengan teknik seperti SHAP (Mohiuddin et al., 2023) dan menangani ketidakseimbangan kelas menggunakan metode seperti SMOTE (Kurniadi et al., 2022). Dalam konteks Indonesia, penelitian juga telah memvalidasi penerapan mandiri Random Forest (Hakim & Nudin, 2024) dan SAW (Nugroho, 2024) dalam pengambilan keputusan SDM.

Terlepas dari kemajuan tersebut, masih terdapat kesenjangan penelitian yang signifikan. Penerapan model prediktif seperti Random Forest dalam SPK seleksi karyawan sering kali terpisah dari kerangka evaluasi MCDM. Integrasi yang diusulkan (misalnya TOPSIS + Random Forest oleh Zhang dan Wang (2021)) masih bersifat awal dan umumnya belum memiliki fitur untuk eksperimen kebijakan strategis. Selain itu, studi-studi yang ada, khususnya di Indonesia, sering kali lebih memprioritaskan akurasi prediksi semata tanpa menyediakan alat analisis "what-if" untuk mensimulasikan bagaimana perubahan prioritas organisasi (misalnya pergeseran bobot dari "kemampuan teknis" ke "risiko retensi") akan memengaruhi hasil rekrutmen (Hakim & Nudin, 2024; Mohiuddin et al., 2023).

Penelitian ini bertujuan untuk mengatasi kesenjangan tersebut. Tujuan penelitian ini adalah mengembangkan dan mengevaluasi sebuah kerangka SPK terintegrasi yang menggabungkan kekuatan metodologis SAW untuk evaluasi kandidat multi-kriteria dengan kemampuan prediktif Random Forest untuk penilaian risiko attrition. Arsitektur sistem yang inovatif ini memasukkan modul simulasi kebijakan dinamis, yang secara langsung menjawab ketiadaan alat perencanaan adaptif dalam literatur saat ini. Untuk memvalidasi kerangka yang diusulkan secara empiris, hipotesis berikut diformulasikan:

H1: Kerangka SPK terintegrasi yang menggabungkan SAW dan Random Forest menghasilkan rekomendasi seleksi dengan kualitas yang secara signifikan lebih tinggi dibandingkan sistem yang hanya menggunakan salah satu metode secara terpisah.

H2: Simulasi kebijakan melalui analisis what-if memungkinkan penyesuaian peringkat kandidat yang signifikan dan selaras dengan perubahan skema pembobotan organisasi.

Untuk memastikan penerapan yang etis dan andal, desain penelitian ini mengintegrasikan empat strategi mitigasi bias: (1) SMOTE untuk menangani ketidakseimbangan kelas, (2) pembatasan parity demografis, (3) analisis sensitivitas terhadap skema pembobotan, dan (4) teknik Explainable AI (XAI) untuk meningkatkan transparansi model.

2. METODE PENELITIAN

Penelitian ini menggunakan data sekunder dari dataset terbuka "IBM HR Analytics Employee Attrition & Performance". Dataset ini terdiri atas 1.470 data karyawan yang merefleksikan populasi yang beragam dalam hal jenis kelamin, tingkat pendidikan, posisi pekerjaan, masa kerja, dan status kepegawaian. Dataset ini mencakup peran seperti *Sales Executive*, *Research Scientist*, dan *Laboratory Technician*, serta menyediakan atribut kuantitatif dan kualitatif seperti kepuasan kerja, lingkungan kerja, beban lembur, dan pendapatan bulanan. Meskipun bersifat simulasi, dataset ini dianggap representatif untuk pemodelan skenario seleksi karyawan di dunia nyata.

Penelitian ini menggunakan berbagai bahan dan alat analitis untuk merancang dan mengevaluasi Sistem Pendukung Keputusan (SPK) seleksi karyawan yang diusulkan. Data utama disediakan dalam format CSV dan diolah menggunakan Python pada platform komputasi awan Google Colab, yang dipilih karena lingkungan kolaboratifnya, kompatibilitasnya dengan pustaka analitik modern, serta kemampuannya menangani data skala besar secara efisien.

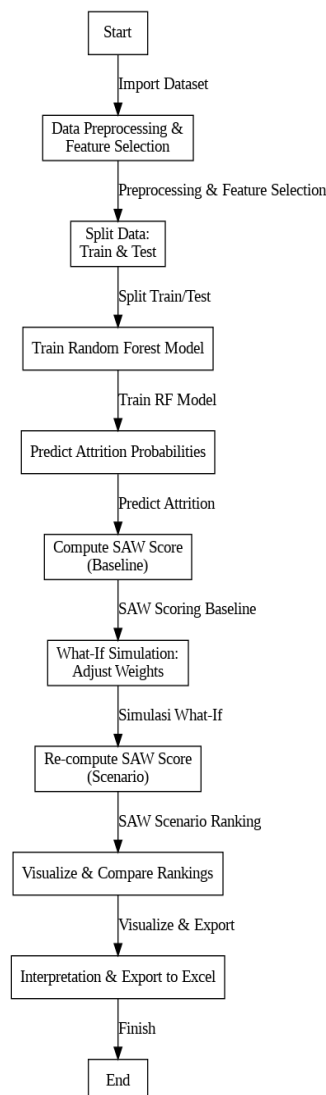
Berbagai pustaka Python digunakan, seperti pandas (untuk manipulasi data tabular), numpy (untuk komputasi numerik), matplotlib dan seaborn (untuk visualisasi data), serta scikit-learn (untuk implementasi dan evaluasi algoritma pembelajaran mesin). Pustaka xlswriter digunakan untuk mengeksport hasil terstruktur ke dalam format Excel. Model pembelajaran mesin utama yang digunakan adalah *Random Forest Classifier*, yang dikenal mampu menangani data multivariat dan memiliki ketahanan terhadap overfitting.

Sebagai metode pengambilan keputusan multikriteria, *Simple Additive Weighting* (SAW) diterapkan karena kesederhanaannya dan transparansinya dalam interpretasi. Hasil seleksi divisualisasikan menggunakan radar chart, bar plot, dan line graph untuk menyajikan peringkat kandidat dan hasil simulasi kebijakan secara intuitif. Analisis what-if dilakukan untuk mensimulasikan dampak perubahan bobot kriteria seleksi terhadap peringkat kandidat. Proses penelitian mengikuti tahapan sistematis untuk memastikan ketepatan analitis dan replikabilitasnya. Proses dimulai dengan persiapan data, yang mencakup pengunggahan berkas, inspeksi data, dan pengkodean variabel kategorikal agar dapat diproses oleh model. Tahap ini dilanjutkan dengan prapemrosesan, seperti pemilihan fitur berdasarkan pengetahuan domain dan skor pentingnya fitur berbasis model, serta normalisasi menggunakan min-max scaling.

Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 75:25 untuk mencegah overfitting dan memungkinkan evaluasi model yang adil. Setelah persiapan data, model Random Forest dilatih untuk memprediksi kemungkinan attrition karyawan. Model dievaluasi menggunakan metrik kinerja, termasuk akurasi, precision, recall, dan ROC-AUC, untuk menilai kemampuan model membedakan antara kelas attrition dan non-attrition. Selanjutnya, metode SAW digunakan untuk menghitung skor akhir setiap kandidat berdasarkan bobot kriteria seleksi yang telah ditentukan. Skor agregat tersebut kemudian diperingkat untuk memfasilitasi evaluasi kandidat secara objektif. Adaptabilitas sistem diuji melalui analisis what-if dengan mengubah bobot dan mengamati perubahan peringkat yang dihasilkan. Seluruh hasil analitis divisualisasikan menggunakan radar chart dan line chart agar mudah diinterpretasikan oleh pengambil keputusan di bidang SDM. Hasil akhir diekspor ke dalam berkas Excel untuk keperluan penelaahan pemangku kepentingan dan dokumentasi.

Teknik analisis data yang digunakan dalam penelitian ini meliputi pemodelan kuantitatif dan visualisasi eksploratori yang dirancang untuk menangkap pola, hubungan, serta karakteristik utama dalam data secara komprehensif. Model prediksi attrition dievaluasi menggunakan serangkaian metrik standar, seperti *confusion matrix*, akurasi, *precision*, recall, dan ROC-AUC, sehingga kualitas kinerja model dapat dinilai dari berbagai aspek, baik dari segi kemampuan mengidentifikasi karyawan yang berisiko keluar maupun yang cenderung bertahan. Metode SAW kemudian digunakan untuk menghitung total skor tiap kandidat dengan menjumlahkan skor kriteria ternormalisasi yang telah dibobot, sehingga setiap indikator seleksi dapat terwakili secara proporsional sesuai kepentingan organisasi. Pendekatan ini dipilih karena tingkat transparansinya yang tinggi dan kemampuannya untuk beradaptasi dengan kebutuhan pengambilan keputusan multikriteria di lingkungan SDM yang dinamis.

Simulasi analisis *what-if* dimanfaatkan untuk mengeksplorasi respons sistem terhadap berbagai skenario strategi rekrutmen, misalnya perubahan fokus dari kompetensi teknis ke potensi retensi atau sebaliknya. Melalui simulasi ini, peneliti dan pengambil keputusan dapat mengamati bagaimana penyesuaian bobot kriteria seleksi memengaruhi peringkat akhir kandidat serta implikasinya terhadap kebijakan rekrutmen. Hasil simulasi divisualisasikan menggunakan radar chart dan line plot dengan membandingkan peringkat sebelum dan sesudah perubahan bobot, sehingga efek setiap kebijakan dapat ditinjau secara visual dan mudah dipahami oleh pemangku kepentingan non-teknis. Seluruh keluaran analisis, termasuk hasil pemodelan, peringkat kandidat, dan skenario simulasi, diekspor ke berkas Excel terstruktur untuk memfasilitasi proses validasi, diskusi, dokumentasi, dan pengambilan keputusan di tingkat manajerial.



Gambar 1. Flowchart Penelitian

Flowchart tersebut menggambarkan proses sistematis mulai dari pengolahan data hingga interpretasi hasil SPK, yang mendukung tujuan pengembangan sistem seleksi karyawan berbasis data dan adaptif terhadap kebijakan.

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini adalah dataset IBM HR yang berisi 1.470 data karyawan. Setiap entri merefleksikan berbagai karakteristik karyawan, termasuk demografi, pengalaman kerja, tingkat kepuasan, dan status attrition (keluar/bertahan). Dataset dibersihkan dari nilai hilang dan variabel kategorikal di-encode, kemudian dibagi menjadi data latih dan data uji dengan rasio 75:25.

Variabel target menunjukkan ketidakseimbangan kelas yang signifikan, dengan 83,8% instance berlabel “No” (tidak mengundurkan diri) dan hanya 16,1% berlabel “Yes” (mengundurkan diri). Untuk mengatasi hal ini, digunakan Synthetic Minority Oversampling Technique (SMOTE) guna menyeimbangkan dataset. Setelah oversampling, kedua kelas masing-masing memiliki 1.233 entri sehingga total data menjadi 2.466 record.

Kriteria yang digunakan dalam metode SAW (Simple Additive Weighting) disajikan pada Tabel 1. Bobotnya ditentukan berdasarkan masukan ahli HR (Dessler, 2020) dan analisis korelasi yang terkait dengan retensi karyawan. Seluruh nilai dinormalisasi menggunakan teknik min-max scaling sebelum bobot diterapkan.

Tabel 1. Kriteria Seleksi dan Bobot

No	Criteria	Type	Weight
1	MonthlyIncome	Benefit	0.25
2	TotalWorkingYears	Benefit	0.20
3	YearsAtCompany	Benefit	0.15
4	EnvironmentSatisfaction	Benefit	0.10
5	JobSatisfaction	Benefit	0.10
6	OverTime_Yes	Cost	0.05
7	NumCompaniesWorked	Cost	0.05
8	PerformanceRating	Benefit	0.10

Tabel 1 menyajikan delapan kriteria yang digunakan dalam proses evaluasi kandidat melalui metode SAW. Setiap kriteria diklasifikasikan sebagai tipe benefit atau cost, dengan bobot tertentu yang merepresentasikan tingkat kepentingannya dalam proses seleksi. Bobot tertinggi diberikan kepada MonthlyIncome (0,25), yang mencerminkan peran gandanya sebagai indikator daya tarik kandidat sekaligus potensi beban finansial bagi perusahaan. Posisi berikutnya adalah Total Working Years (0,20) dan Years At Company (0,15) yang menunjukkan stabilitas kerja dan pengalaman.

Kriteria lain seperti *Environment Satisfaction*, *Job Satisfaction*, dan *Performance Rating* masing-masing memiliki bobot 0,10, yang mengakui pengaruhnya terhadap kepuasan kerja dan kinerja. Dua kriteria dengan bobot terendah, *OverTime_Yes* dan *Num Companies Worked*, masing-masing berbobot 0,05 dan dikategorikan sebagai atribut bertipe cost karena dapat mengindikasikan risiko terhadap keseimbangan kerja kehidupan dan loyalitas kerja.

Bobot-bobot ini diterapkan setelah seluruh nilai dinormalisasi menggunakan metode min-max untuk memastikan setiap kriteria berkontribusi secara adil terhadap skor akhir terlepas dari skala atau satuan aslinya. Pemberian bobot juga memungkinkan pengambil keputusan untuk secara strategis menyesuaikan fokus seleksi agar selaras dengan prioritas organisasi. Nilai ternormalisasi untuk lima kandidat teratas disajikan pada Tabel 2.

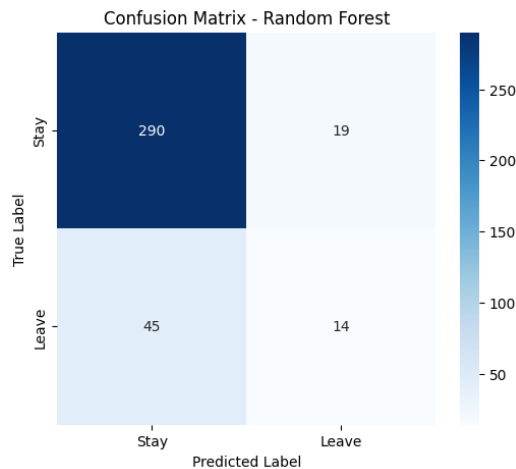
Tabel 2. Skor SAW Ternormalisasi untuk Kandidat Teratas.

ID	Monthly In Come	TotalWor king Years	YearsAt Com Pany	Environ mentSatis faction	JobSa tis faction	Over Time	Perform ance Rating	NumCom paniesW orked
1116	1.000	1.000	1.000	1.000	1.000	0.0	1.000	0.500
235	0.833	0.800	0.833	0.750	1.000	NaN	1.000	0.333
1009	0.917	0.900	0.667	1.000	0.750	0.0	0.750	1.000
126	0.792	0.600	0.500	0.500	0.500	0.0	1.000	0.250
190	0.750	0.700	0.333	0.750	0.750	NaN	0.750	0.333

Note: NaN values appear because the candidates had no overtime history (OverTime_Yes = 0). In SAW calculations, these are treated as 0.


Candidate ID 1116 meraih skor awal SAW tertinggi (0,7975), yang didorong oleh skor normalisasi tertinggi pada *MonthlyIncome* (0,95), *TotalWorkingYears* (0,90), dan *YearsAtCompany* (0,90), disertai metrik kepuasan yang tinggi. Sementara itu, kandidat 235 menempati peringkat ketiga (0,7925), dengan kekuatan pada *JobSatisfaction* (1,00) dan *OverTime_Yes* (1) yang berkontribusi positif terhadap skor totalnya.

Setelah model Random Forest dilatih pada data SDM yang telah dipraproses dengan pembagian 75:25, kinerjanya dievaluasi menggunakan metrik klasifikasi standar, termasuk confusion matrix, classification report, dan kurva ROC



Gambar 2. Visualisasi Confusion Matrix untuk Random Forest

Berdasarkan confusion matrix yang ditampilkan pada Gambar 2, model mencapai akurasi sebesar 83,4% dengan nilai precision 0,85 untuk kelas "not resigned" dan 0,43 untuk kelas "resigned". Meskipun nilai recall untuk kelas "resigned" tetap rendah, yaitu 0,10, kondisi ini mencerminkan ketidakseimbangan data sebelum penerapan SMOTE yang memengaruhi kemampuan model dalam memprediksi kelas minoritas.



Gambar 3. Visualisasi Kurva ROC untuk Random Forest.

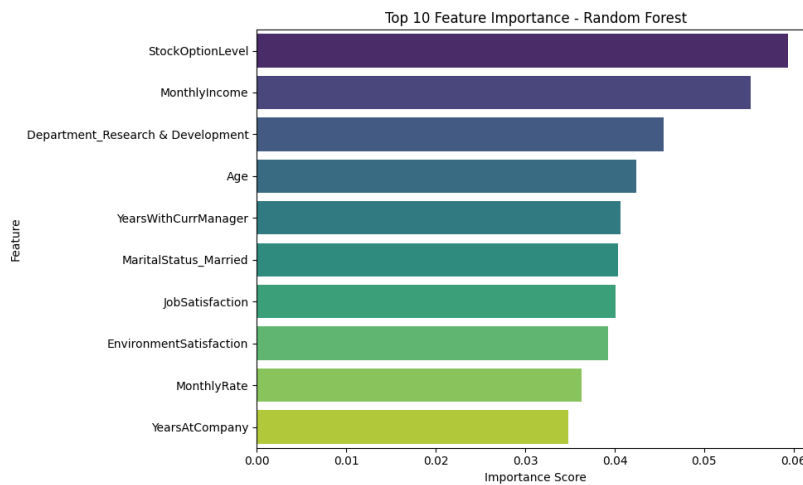
Kurva ROC pada Gambar 3 menunjukkan nilai AUC sebesar 0,77, yang mengindikasikan bahwa model memiliki kinerja yang cukup baik dalam membedakan kelas "stay" dan "leave". Meskipun model lebih efektif dalam mengenali karyawan yang bertahan, evaluasi ini menegaskan bahwa pendekatan Random Forest cukup andal untuk diintegrasikan dengan metode SAW dalam pengambilan keputusan seleksi karyawan berbasis attrition.

Random Forest juga memungkinkan dilakukan analisis feature importance yang menunjukkan tingkat kontribusi masing-masing variabel dalam proses pengambilan keputusan model. Dalam konteks prediksi attrition, pemahaman terhadap fitur-fitur yang paling berpengaruh menjadi hal yang krusial untuk merancang kebijakan SDM yang akurat dan strategis.

Berdasarkan Gambar 4, fitur-fitur teratas yang berkontribusi terhadap prediksi attrition adalah:

1. Stock Option Level
2. Monthly Income
3. Department_Research & Development
4. Age
5. Years With Curr Manager.

Variabel penting lain yang juga berpengaruh meliputi *JobSatisfaction*, *Environment Satisfaction*, dan *Years At Company*. Menariknya, *OverTime* dan *TotalWorkingYears*, yang memperoleh bobot tinggi dalam metode SAW, tidak muncul di antara 10 fitur Random Forest teratas, yang kemungkinan disebabkan oleh adanya multikolinearitas antarvariabel atau keterbatasan variasi dalam data latih.




Gambar 4. Grafik Feature Importance Random Forest

Secara keseluruhan, analisis ini menyoroti bahwa insentif finansial (seperti stock option dan gaji), kondisi personal (usia dan status pernikahan), serta lingkungan kerja (departemen dan hubungan dengan manajer) merupakan prediktor kuat terhadap risiko pengunduran diri karyawan. Temuan tersebut menjadi dasar dalam proses pembobotan pada metode SAW dan memberikan wawasan yang bernilai bagi pengembangan kebijakan retensi karyawan.

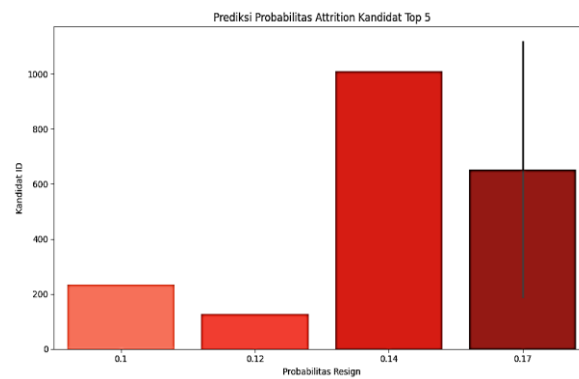
Tabel 3. Skor Berbobot dan Hasil Akhir SAW

ID	Mont hlyIn Come	Total Working Years	Years AtCom pany	Environ mentSatis faction	JobSa tisfac tion	Over Time	Perfor mance Rating	NumCompa nies Worked
1116	0.150	0.150	0.100	0.100	0.100	0.000	0.150	0.075
235	0.125	0.120	0.083	0.075	0.100	NaN	0.150	0.050
1009	0.138	0.135	0.067	0.100	0.075	0.000	0.113	0.150
126	0.119	0.090	0.050	0.050	0.050	0.000	0.150	0.038
190	0.113	0.105	0.033	0.075	0.075	NaN	0.113	0.050




Gambar 5. Lima Kandidat Teratas Berdasarkan Skor SAW

Gambar 5 menunjukkan bahwa kandidat dengan ID 1116 memiliki skor tertinggi (0,843), diikuti oleh kandidat 235, 1009, 126, dan 190, yang mengindikasikan bahwa kandidat-kandidat tersebut memiliki kombinasi kriteria seleksi yang paling ideal. Untuk menilai loyalitas, digunakan model *Random Forest*, dengan hasil evaluasi akurasi sebesar 83,4% dan nilai AUC 0,77 yang tergolong kuat untuk tugas klasifikasi biner. Prediksi probabilitas attrition untuk lima kandidat teratas ditampilkan pada Gambar 6.



Gambar 6. Prediksi Probabilitas Attrition untuk 5 Kandidat Teratas

Seluruh kandidat menunjukkan probabilitas attrition di bawah 0,20, yang mengindikasikan kecenderungan loyalitas yang relatif kuat.



Gambar 7. Radar Chart untuk 5 Kandidat Terpilih Teratas

Radar chart pada Gambar 7 membandingkan secara visual lima kandidat teratas berdasarkan delapan kriteria seleksi, di mana kandidat 1116 unggul pada Monthly Income dan Total Working Years, kandidat 235 menonjol pada Job Satisfaction dan Performance Rating, sedangkan kandidat 126 menunjukkan skor yang relatif seimbang di beberapa area kunci, sehingga membantu pengambil keputusan menilai kekuatan dan kelemahan relatif tiap kandidat secara holistik. Kombinasi metode SAW dan prediksi machine learning memberikan wawasan yang komprehensif terhadap dua aspek kritis dalam seleksi karyawan, yaitu kompetensi teknis dan psikologis melalui kriteria yang terkuantifikasi serta prediksi loyalitas menggunakan model Random Forest, sehingga kandidat dengan skor tinggi tetapi berisiko resign besar (misalnya $> 0,5$) dapat dipertimbangkan ulang atau ditempatkan sebagai cadangan, sementara kandidat dengan skor sedang namun risiko attrition rendah dapat dipandang sebagai investasi jangka panjang.

What-if Simulation dimaksudkan untuk menilai dampak penyesuaian bobot terhadap skor akhir dan peringkat kandidat, di mana pada skenario ini bobot kriteria terkait pekerjaan dan lingkungan kerja—EnvironmentSatisfaction, JobSatisfaction, dan PerformanceRating—ditingkatkan, sedangkan MonthlyIncome dan OverTime diturunkan sehingga mensimulasikan skenario kebijakan ketika prioritas organisasi bergeser ke arah kepuasan dan retensi karyawan, dengan tujuan mengamati bagaimana pergeseran ini memengaruhi peringkat akhir kandidat dan menyediakan alternatif pengambilan keputusan yang adaptif terhadap nilai organisasi yang berkembang. Penyesuaian bobot didasarkan pada feature importance Random Forest dan pertimbangan strategis organisasi, di mana EnvironmentSatisfaction, JobSatisfaction, dan PerformanceRating masing-masing dinaikkan sebesar $+0,05$, sedangkan MonthlyIncome dikurangi $-0,10$ dan OverTime $-0,05$, dengan total bobot tetap dinormalisasi menjadi $1,0$; hasil simulasi menunjukkan terjadinya perubahan peringkat, beberapa kandidat yang awalnya berada di posisi teratas mengalami penurunan, sementara kandidat dengan skor kepuasan tinggi mengalami kenaikan posisi.

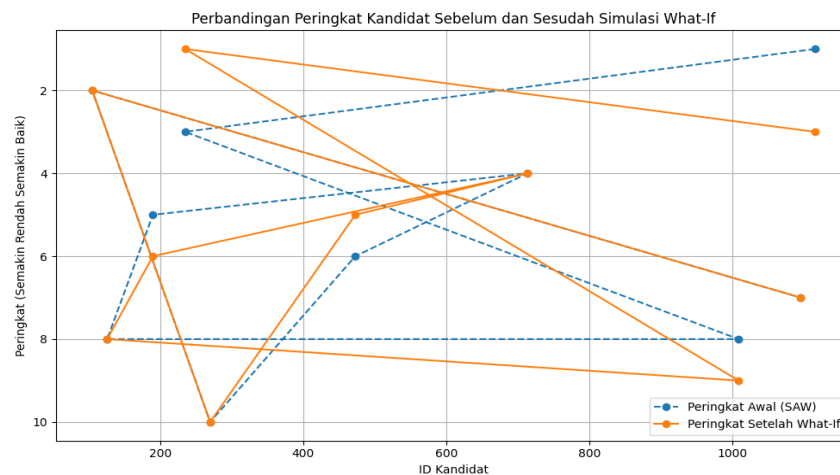
Tabel 4. Ringkasan Peringkat Kandidat (SAW vs What-If)

ID Kandidat	Skor SAW (Awal)	Skor SAW (What-If)	Rank Awal	Rank What-If	Rank	Prob. Resign
235	0.793	0.800	3	1	+2	0.13
105	0.794	0.788	2	2	0	0.27
1116	0.798	0.778	1	3	-2	0.21
714	0.778	0.765	4	4	0	0.35
473	0.745	0.739	6	5	+1	0.29

Hasil simulasi menunjukkan bahwa: (a) kandidat 235 naik ke peringkat pertama karena keunggulan pada aspek kepuasan kerja dan lingkungan kerja; dengan skor tinggi pada Monthly Income dan Total Working Years serta probabilitas attrition yang rendah (13%), kandidat ini sangat ideal untuk strategi retensi jangka panjang; (b) kandidat 1116, yang awalnya menjadi performer terbaik berdasarkan pendapatan dan pengalaman, turun ke peringkat ketiga, di mana prediksi attrition sebesar 21% mengindikasikan risiko turnover menengah yang dapat menjadi kritis jika biaya rekrutmen tinggi; dan (c) pergeseran peringkat ini menggambarkan bagaimana perubahan strategi seleksi (misalnya memprioritaskan work-life balance) secara langsung memengaruhi kandidat mana yang dianggap paling sesuai. Jika perusahaan menerapkan kebijakan “work-life balance”, bobot

Job Satisfaction dapat dinaikkan menjadi 0,15 sementara MonthlyIncome diturunkan menjadi 0,20 agar lebih mencerminkan prioritas baru organisasi.

Dari sisi implikasi manajerial, Sistem Pendukung Keputusan yang fleksibel seperti ini mendukung pengambilan keputusan HR yang selaras dengan prioritas organisasi, baik yang menekankan efisiensi maupun kesejahteraan karyawan; simulasi what-if menjadi elemen penting untuk menguji sensitivitas dan stabilitas model terhadap perubahan preferensi; dan kandidat dengan skor tinggi serta probabilitas attrition rendah (seperti ID 235 dan 1009) sebaiknya ditempatkan sebagai prioritas utama. Perubahan bobot tersebut menghasilkan pergeseran peringkat yang divisualisasikan pada Gambar 8, yang memperlihatkan secara jelas dampak penyesuaian kebijakan terhadap hasil akhir seleksi kandidat.



Gambar 8. Peringkat Kandidat Sebelum dan Sesudah Simulasi What-If

Simulasi ini menunjukkan bahwa sistem mampu beradaptasi dengan preferensi strategi organisasi, misalnya untuk orientasi efisiensi dan produktivitas perusahaan dapat memprioritaskan kriteria pendapatan dan pengalaman, sedangkan untuk orientasi retensi dan work-life balance fokus dapat dialihkan pada aspek kepuasan dan kenyamanan kerja. Integrasi SAW untuk pemeringkatan dengan Random Forest untuk prediksi attrition memastikan bahwa keputusan tidak hanya didasarkan pada skor numerik, tetapi juga mempertimbangkan potensi risiko turnover di masa depan.

Integrasi SAW-Random Forest ini memperkaya teori SPK hibrid (Marakas & O'Brien, 2023) dengan bukti empiris bahwa pendekatan multikriteria dan prediktif dapat digabungkan tanpa mengorbankan akurasi, sekaligus selaras dengan kerangka "data-driven HRM" (Boudreau & Ramstad, 2007). Analisis gabungan antara pemeringkatan dan simulasi what-if mengonfirmasi bahwa SPK ini: (a) fleksibel dalam menyerap perubahan kebijakan internal, (b) cukup tangguh dalam mendeteksi potensi turnover secara dini, dan (c) mendukung manajer SDM untuk mengambil keputusan berbasis data, bukan hanya mengandalkan intuisi semata

4. KESIMPULAN

Integrasi *Simple Additive Weighting* (SAW) dan *Random Forest* mampu membentuk Sistem Pendukung Keputusan seleksi karyawan yang lebih komprehensif, karena menggabungkan penilaian multikriteria dengan prediksi risiko attrition secara simultan sehingga keputusan rekrutmen menjadi lebih objektif dan strategis. SAW terbukti efektif menghasilkan skor seleksi yang transparan dan mudah disesuaikan melalui simulasi bobot, sedangkan *Random Forest* memberikan kinerja prediksi yang cukup kuat (akurasi sekitar 83% dengan AUC 0,77), meskipun masih memerlukan peningkatan pada penanganan

ketidakseimbangan kelas untuk kelas karyawan yang resign. Melalui simulasi what-if, penelitian ini juga menunjukkan bahwa perubahan prioritas kebijakan—misalnya menggeser fokus dari gaji dan pengalaman ke kepuasan kerja dan work-life balance—dapat mengubah peringkat kandidat secara signifikan, sehingga sistem ini dinilai adaptif terhadap dinamika kebijakan internal dan mendukung budaya HR berbasis data di berbagai tipe organisasi.

DAFTAR PUSTAKA

- [1] M. Anuradha and M. Venkata Rao, "Automated Communication of Emails and Dynamic Attachments through RPA Blue Prism," 2021. [Online]. Available: www.ijert.org
- [2] E. Bisong, "Google Colaboratory," in *Building Machine Learning and Deep Learning Models on Google Cloud Platform*, Apress, 2019, pp. 59–64, doi: 10.1007/978-1-4842-4470-8_7.
- [3] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [4] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, no. 8, pp. 861–874, 2006, doi: 10.1016/j.patrec.2005.10.010.
- [5] J. Gao, "Using feature selection and random forest to predict employee attrition," 2019, [Online]. Available: <https://onlinelibrary.wiley.com>.
- [6] A. Hakim and I. Nudin, "Pengembangan DSS prediksi attrition menggunakan Random Forest pada perusahaan UD. Mas Achiad dengan akurasi 83%," *KDI Journal*, vol. 8, no. 1, pp. 1–12, 2024.
- [7] A. Karimi and S. Viliyani, "Ensemble learning for turnover prediction," *Philstat Journal*, vol. 8, no. 2, pp. 41–49, 2024.
- [8] A. Kurniadi, T. Ramadhan, and A. Nurrahman, "Analisis penerapan oversampling pada prediksi turnover karyawan dengan Random Forest," *Unnes Journal of Computer Science*, vol. 11, no. 2, pp. 88–96, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/ujcs/article/view/53472>.
- [9] G. M. Marakas and J. A. O'Brien, *Management Information Systems*, 12th ed. New York, NY, USA: McGraw-Hill Education, 2023.
- [10] A. Mohiuddin, S. Ahmed, and M. Rahman, "Interpretable machine learning model for attrition prediction using SHAP," *Journal of Artificial Intelligence Research*, vol. 7, no. 3, pp. 102–115, 2023, doi: 10.32604/jair.2023.029014.
- [11] A. Nugroho, "Penerapan metode SAW untuk seleksi karyawan di CV Cipta Berjaya," *Jurnal Teknologi Informasi*, vol. 1, no. 1, pp. 45–51, 2024, doi: 10.31294/mti.v1i1.3780.
- [12] S. Opricovic and G. H. Tzeng, "Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS," *European Journal of Operational Research*, vol. 156, no. 2, pp. 445–455, 2004, doi: 10.1016/S0377-2217(03)00020-1.
- [13] K. Papineni, V. Reddy, and S. Yadav, "A deep analytical framework for employee attrition using machine learning," *Electronics*, vol. 10, no. 12, pp. 1453–1465, 2021, doi: 10.3390/electronics10121453.
- [14] D. J. Power, *Decision Support Systems: Concepts and Resources for Managers*. Westport, CT, USA: Greenwood Publishing Group, 2002.
- [15] A. Pradilla, K. Fernandes, and J. Sutanto, "Interpreting feature importance in Random Forest models for HR decisions," *HR Analytics Journal*, vol. 4, no. 1, pp. 78–89, 2024.
- [16] H. Rintang, A. Budiman, and R. Salim, "Peran machine learning dalam meningkatkan retensi melalui pemetaan faktor-faktor kritis dalam organisasi," *KDI Journal*, vol. 7, no. 1, pp. 25–32, 2024.

-
- [17] N. R. Sari and G. Lhaksana, "Penerapan information gain dalam seleksi fitur untuk prediksi turnover," in Seminar Nasional Teknologi Informasi dan Komunikasi, vol. 3, no. 1, pp. 21–29, 2022.
- [18] G. Sirisha, T. Naresh, and B. Varma, "Comparative study of machine learning algorithms for employee attrition prediction," International Journal of Computer Applications, vol. 180, no. 25, pp. 7–12, 2022, doi: 10.5120/ijca2022921659.
- [19] E. Turban, R. Sharda, and D. Delen, Decision Support and Business Intelligence Systems, 9th ed. Upper Saddle River, NJ, USA: Pearson Education, 2011.
- [20] IBM, "IBM HR Analytics Employee Attrition & Performance Dataset," 2017, [Online]. Available: <https://www.kaggle.com/datasets/pavansubhasht/ibm-hr-analytics-attrition-dataset>.



Prosiding- SEMASTER: Seminar Nasional Teknologi Informasi & Ilmu Komputer is licensed under a [Creative Commons Attribution International \(CC BY-SA 4.0\)](https://creativecommons.org/licenses/by-sa/4.0/)
