



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 25051-25060

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Penerapan Algoritma C4.5 untuk Klasifikasi Karyawan Pendukung Keputusan Pengurangan Tenaga Kerja

Abdul Rochman¹, Perani Rosyani²

¹Mahasiswa Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

²Dosen Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

[1abdulrochman1310@gmail.com](mailto:abdulrochman1310@gmail.com), [2dosen00837@unpam.ac.id](mailto:dosen00837@unpam.ac.id)

Abstrak

Perusahaan sering menghadapi tantangan dalam menentukan karyawan yang akan dipertahankan atau dikurangi ketika terjadi efisiensi tenaga kerja, sementara pengambilan keputusan yang masih dilakukan secara manual dan subjektif berisiko menimbulkan bias serta ketidakadilan. Penelitian ini bertujuan menerapkan algoritma C4.5 dalam mengklasifikasikan karyawan pada PT Aranesia Gemilang Nusantara untuk mendukung pengambilan keputusan terkait pengurangan tenaga kerja, dengan mempertimbangkan atribut masa kerja, tingkat kehadiran, kinerja, dan jumlah pelanggaran kedisiplinan. Penelitian menggunakan sampel 200 data karyawan yang diambil secara stratified proportional dari populasi 1.035 data, dengan pembagian data latih dan data uji sebesar 80:20. Oleh karena data kinerja, kehadiran, dan kedisiplinan aktual tidak tersedia dari perusahaan, atribut-atribut tersebut disimulasikan berdasarkan asumsi yang realistis semata untuk mendemonstrasikan cara kerja algoritma C4.5, sehingga hasil yang diperoleh bersifat ilustratif dan bukan merepresentasikan kondisi aktual karyawan. Hasil pengujian pada data simulasi menunjukkan model mencapai akurasi 60% dengan rata-rata precision 66,2%, recall 54,2%, dan F1-score 55,8%, dengan atribut jumlah pelanggaran kedisiplinan sebagai akar (root) pohon keputusan. Model kemudian diimplementasikan ke dalam sistem pendukung keputusan berbasis web dan diuji menggunakan metode black box, white box, serta kuisioner pengguna, dengan hasil yang menunjukkan aplikasi dapat berjalan dengan baik dan mendapat tanggapan positif dari HRD selaku pengguna.

Kata kunci: Data Mining, Algoritma C4.5, Klasifikasi Karyawan, Pohon Keputusan, Sistem Pendukung Keputusan

1. Latar Belakang

Dalam menghadapi persaingan bisnis global yang semakin kompetitif, perusahaan kerap menempuh efisiensi sumber daya manusia melalui pengurangan tenaga kerja untuk menekan biaya operasional dan menjaga stabilitas usaha. Kebijakan ini bersifat sensitif karena berkaitan langsung dengan hak dan kelangsungan hidup karyawan, sehingga membutuhkan proses pengambilan keputusan yang objektif (Bujold et al., 2024; European Parliament & Council of the European Union, 2024).

Pada PT Aranesia Gemilang Nusantara, proses tersebut masih dilakukan secara manual dan bergantung pada intuisi serta pengalaman subjektif pihak manajemen, sehingga rentan menimbulkan bias dan human error, terutama ketika jumlah data karyawan yang harus dianalisis semakin besar (Cai et al., 2024; Rosenthal-von der Pütten & Sach, 2024).

Pendekatan data mining dengan teknik pohon keputusan (decision tree) menjadi solusi yang banyak digunakan untuk mengatasi keterbatasan tersebut, karena mampu mengolah data atribut numerik maupun kategorik dan menghasilkan aturan keputusan yang mudah dipahami oleh manajemen (Pirmansyah & Wahyudi, 2023). Algoritma C4.5 khususnya terbukti mampu mempercepat proses pengolahan informasi, mengurangi kesalahan analisis, serta menghasilkan keputusan yang lebih akurat dan konsisten dibandingkan pendekatan manual (Asyhari et al., 2024; Quinlan, 1993; Rudianto et al., 2022).

Meskipun berbagai penelitian terdahulu telah membuktikan efektivitas algoritma C4.5 dalam klasifikasi karyawan, sebagian besar berfokus pada penilaian kinerja dan promosi jabatan pada perusahaan manufaktur atau instansi pemerintah (Mayangsari & Wahyudi, 2024; Rudianto et al., 2022). Penelitian yang secara khusus menerapkan algoritma C4.5 untuk mendukung keputusan pengurangan tenaga kerja pada perusahaan dengan karakteristik data seperti PT Aranesia Gemilang Nusantara masih relatif terbatas, sehingga menjadi celah (gap) yang diisi oleh penelitian ini.

Berdasarkan uraian tersebut, penelitian ini bertujuan menerapkan algoritma C4.5 untuk mengklasifikasikan karyawan berdasarkan atribut masa kerja, absensi, kinerja, tingkat pendidikan, usia, dan kedisiplinan, serta mengukur tingkat akurasi model yang dihasilkan guna mendukung sistem pengambilan keputusan yang lebih objektif, transparan, dan berbasis data.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode data mining dan metode eksperimen untuk menguji kinerja algoritma C4.5. Data diperoleh melalui observasi, wawancara dengan tim HRD, dan dokumentasi data karyawan (absensi, kinerja, kedisiplinan, dan masa kerja) di PT Aranesia Gemilang Nusantara.

2.1. Algoritma C4.5

Algoritma C4.5 membangun model pohon keputusan dengan menghitung nilai entropy, information gain, dan gain ratio pada setiap atribut untuk menentukan atribut yang paling berpengaruh sebagai node pemisah (Quinlan, 1993). Nilai gain ratio dihitung menggunakan persamaan (1).

$$\text{GainRatio}(A) = \text{Gain}(A) / \text{SplitInfo}(A) \quad (1)$$

dengan $\text{Gain}(A)$ adalah information gain dari atribut A dan $\text{SplitInfo}(A)$ adalah nilai pemecah (split information) atribut tersebut (Quinlan, 1993). Tahapan algoritma C4.5 yang diterapkan meliputi: (1) menghitung entropy, (2) menghitung information gain, (3) menghitung gain ratio, (4) menentukan atribut terbaik sebagai node, dan (5) membentuk pohon keputusan secara rekursif hingga seluruh data terklasifikasi.

2.2. Tahapan Pengolahan Data

Data karyawan diproses melalui tiga tahap utama. Data cleaning dilakukan untuk menangani data tidak lengkap, duplikat, dan tidak konsisten. Data transformation dilakukan dengan mengkategorikan atribut numerik ke dalam bentuk kategorikal agar kompatibel dengan algoritma C4.5. Data splitting membagi dataset dengan rasio 80:20, yaitu 80% data latih untuk membentuk model dan 20% data uji untuk mengevaluasi kemampuan generalisasi model (Géron, 2022).

2.3. Evaluasi Model

Evaluasi model dilakukan menggunakan confusion matrix untuk memperoleh nilai accuracy, precision, recall, dan F1-score. Accuracy mengukur proporsi prediksi yang benar terhadap keseluruhan data uji, precision mengukur ketepatan model dalam memprediksi suatu kelas, dan recall mengukur kemampuan model mendeteksi seluruh data pada kelas yang sebenarnya.

CATATAN METODOLOGIS: Data atribut kinerja, tingkat kehadiran, dan jumlah pelanggaran kedisiplinan aktual tidak dapat diperoleh dari perusahaan pada saat penelitian dilakukan. Oleh karena itu, atribut-atribut tersebut beserta label keputusan (dipertahankan/dipertimbangkan/direkomendasikan PHK) disimulasikan menggunakan distribusi acak dengan asumsi yang realistis, semata untuk mendemonstrasikan cara kerja algoritma C4.5 dalam mendukung pengambilan keputusan. Atribut nama, jenis kelamin, jabatan, dan usia berasal dari data riil 200 karyawan yang diambil melalui stratified proportional sampling dari populasi 1.035 data karyawan. Hasil pengujian pada bagian 3.1 karena itu bersifat ilustratif dan tidak merepresentasikan kondisi aktual karyawan di perusahaan.

2.4. Rancangan Sistem

Model klasifikasi C4.5 diimplementasikan ke dalam sebuah sistem pendukung keputusan berbasis web menggunakan bahasa pemrograman PHP (framework Laravel), basis data MySQL, dan antarmuka yang dirancang dengan Figma serta Bootstrap. Alur sistem dimulai dari perekaman data absensi karyawan melalui mesin fingerprint, dilanjutkan dengan preprocessing indikator penilaian (kehadiran, keterlambatan, izin, dan alfa), penerapan algoritma C4.5 untuk membentuk decision tree, hingga penyajian rekomendasi klasifikasi karyawan (dipertahankan, dipertimbangkan, atau direkomendasikan PHK) kepada pihak HRD.

3. Hasil dan Diskusi

Sistem klasifikasi PHK karyawan berbasis algoritma C4.5 berhasil dibangun dengan fitur pengelolaan data karyawan, data absensi, data kedisiplinan, data performa, serta menu review yang menampilkan hasil klasifikasi kepada pengguna.

3.1. Hasil Penerapan Model C4.5

Model C4.5 dilatih menggunakan 160 data (80%) dan diuji pada 40 data (20%) hasil pembagian stratified dari 200 sampel. Pohon keputusan yang terbentuk menempatkan atribut jumlah pelanggaran kedisiplinan sebagai akar (root node) dengan nilai gain ratio tertinggi (1,4851), diikuti oleh atribut kinerja, tingkat kehadiran, dan masa kerja pada level percabangan berikutnya. Hal ini mengindikasikan bahwa, pada data yang diuji, kedisiplinan merupakan atribut yang paling berpengaruh dalam menentukan klasifikasi keputusan karyawan.

Tabel 1. Confusion Matrix Hasil Pengujian Model (data uji, n=40)

Aktual \ Prediksi	Dipertahankan	Dipertimbangkan	Direkomendasikan PHK
Dipertahankan	8	2	0
Dipertimbangkan	9	14	4
Direkomendasikan PHK	0	1	2

Tabel 2. Precision, Recall, dan F1-Score per Kelas

Kelas	Precision	Recall	F1-Score	Support
Dipertahankan	80,0%	47,1%	59,3%	17
Dipertimbangkan	51,9%	82,4%	63,6%	17
Direkomendasikan PHK	66,7%	33,3%	44,4%	6
Rata-rata (macro)	66,2%	54,2%	55,8%	40

Berdasarkan Tabel 1 dan Tabel 2, model memperoleh akurasi keseluruhan sebesar 60% (24 dari 40 data uji terklasifikasi dengan benar). Kelas "Direkomendasikan PHK" memperoleh precision tertinggi kedua (66,7%) namun recall terendah (33,3%), yang mengindikasikan model masih sering keliru mengklasifikasikan sebagian karyawan pada kelas ini sebagai "Dipertimbangkan". Tingkat akurasi yang moderat ini sejalan dengan ukuran data uji yang relatif kecil (40 data) serta sifat data yang disimulasikan dengan derau (noise) acak, sehingga tidak seluruh pola dapat dipelajari secara sempurna oleh model.

3.2. Pengujian Sistem

Pengujian black box dilakukan terhadap fungsi utama sistem, meliputi login, pengelolaan data karyawan, input data absensi, kedisiplinan, dan performa, serta menu review klasifikasi. Seluruh fungsi yang diuji berjalan sesuai dengan skenario yang diharapkan, baik pada kondisi input valid maupun tidak valid.

Pengujian white box dilakukan terhadap logika kode program, misalnya pada fungsi autentikasi login dan fungsi penyaringan data karyawan berdasarkan departemen. Hasil pengujian menunjukkan bahwa fungsi-fungsi tersebut berjalan sesuai alur logika yang dirancang, termasuk penanganan kesalahan (error handling) yang informatif bagi pengguna.

3.3. Tanggapan Pengguna

Hasil kuisioner yang disebarkan kepada pihak HRD PT Aranesia Gemilang Nusantara menunjukkan tanggapan yang positif terhadap sistem. Pengguna menilai sistem membantu proses pengolahan data karyawan menjadi lebih cepat, terstruktur, dan akurat dibandingkan metode manual, dengan tampilan antarmuka yang mudah dipahami.

3.4. Analisis Mendalam Kinerja Klasifikasi

Hasil pengujian memperlihatkan bahwa model memperoleh akurasi 60% pada 40 data uji. Nilai tersebut menunjukkan bahwa model telah mampu menangkap sebagian pola pada data, tetapi kemampuannya belum cukup kuat untuk dijadikan dasar keputusan pengurangan tenaga kerja secara langsung. Dalam konteks sistem pendukung keputusan, akurasi tidak dapat dibaca sebagai satu-satunya ukuran keberhasilan karena distribusi kesalahan antar kelas memiliki konsekuensi yang berbeda. Kesalahan mengklasifikasikan karyawan yang seharusnya dipertahankan sebagai kelompok yang dipertimbangkan atau direkomendasikan untuk pengurangan tenaga kerja dapat menimbulkan dampak organisasi dan sosial yang lebih besar daripada kesalahan pada kasus administratif biasa. Oleh sebab itu, interpretasi confusion matrix perlu ditempatkan sebagai bagian utama dari evaluasi, bukan hanya sebagai pelengkap nilai akurasi (Géron, 2022; National Institute of Standards and Technology [NIST], 2023).

Kelas "Dipertahankan" memiliki precision 80,0% tetapi recall 47,1%. Precision yang relatif tinggi berarti sebagian besar karyawan yang diprediksi masuk kelas tersebut memang sesuai dengan label aktual pada data uji. Namun,

recall yang rendah menunjukkan bahwa model hanya menemukan kurang dari separuh seluruh karyawan yang sebenarnya berada dalam kelas “Dipertahankan”. Pola ini mengindikasikan adanya kecenderungan model untuk mengalihkan sebagian anggota kelas tersebut ke kelas “Dipertimbangkan”. Dalam praktik HRD, kondisi demikian dapat memperbesar jumlah karyawan yang harus ditinjau ulang secara manual. Meskipun hal itu masih dapat diterima pada tahap penyaringan awal, hasilnya menegaskan bahwa keluaran model sebaiknya diposisikan sebagai prioritas pemeriksaan, bukan keputusan final.

Kelas “Dipertimbangkan” memperoleh recall tertinggi, yaitu 82,4%, tetapi precision hanya 51,9%. Dengan demikian, model cukup sensitif dalam menemukan karyawan yang masuk kelompok pertimbangan, tetapi hampir separuh prediksi pada kelas tersebut berasal dari kelas lain. Temuan ini menjelaskan mengapa kelas menengah menjadi tempat berkumpulnya sebagian besar kesalahan klasifikasi. Secara metodologis, kondisi tersebut umum terjadi ketika batas antar kategori dibentuk dari atribut yang saling tumpang tindih, terutama apabila label disusun dari asumsi atau aturan simulasi yang belum sepenuhnya memisahkan karakteristik tiap kelas. Dalam penggunaannya, kategori “Dipertimbangkan” dapat difungsikan sebagai zona kehati-hatian yang mewajibkan pemeriksaan dokumen, klarifikasi atasan, dan evaluasi kinerja tambahan.

Kelas “Direkomendasikan PHK” memiliki precision 66,7% dan recall 33,3%. Recall yang rendah berarti dua pertiga kasus yang sebenarnya berada pada kelas tersebut belum teridentifikasi dengan benar oleh model. Di sisi lain, penggunaan model untuk keputusan berisiko tinggi tidak boleh hanya diarahkan untuk meningkatkan deteksi terhadap kelas PHK, karena peningkatan sensitivitas tanpa pengendalian dapat memperbesar kemungkinan karyawan yang tidak seharusnya masuk ke kelas tersebut ikut terklasifikasi. Evaluasi selanjutnya perlu menggunakan ukuran yang mempertimbangkan biaya kesalahan, pengujian kestabilan antar pembagian data, serta penilaian dampak pada masing-masing kelompok karyawan. Pendekatan ini sejalan dengan prinsip pengelolaan risiko model yang menekankan validitas, keamanan, transparansi, dan akuntabilitas penggunaan sistem (Bujold et al., 2024; NIST, 2023).

3.5. Interpretasi Pohon Keputusan dan Atribut Kedisiplinan

Pohon keputusan yang terbentuk menempatkan jumlah pelanggaran kedisiplinan sebagai root node dengan gain ratio tertinggi. Secara teknis, posisi tersebut menunjukkan bahwa atribut kedisiplinan menghasilkan pemisahan data paling besar pada proses pembentukan pohon. C4.5 memilih atribut berdasarkan kemampuan informasi dalam mengurangi ketidakpastian kelas, sehingga root node merupakan atribut yang paling efektif membagi data pada dataset yang digunakan, bukan bukti bahwa atribut tersebut menjadi penyebab utama keputusan pengurangan tenaga kerja (Quinlan, 1993). Perbedaan antara hubungan prediktif dan hubungan kausal perlu ditegaskan agar hasil model tidak ditafsirkan secara berlebihan oleh pengguna nonteknis.

Dominannya atribut kedisiplinan juga harus dibaca dengan mempertimbangkan karakter data penelitian. Atribut jumlah pelanggaran dan label keputusan disimulasikan berdasarkan asumsi yang realistis. Apabila aturan simulasi memberi bobot besar pada pelanggaran, model secara alami akan menemukan kedisiplinan sebagai pemisah utama. Temuan tersebut tetap berguna untuk mendemonstrasikan cara kerja algoritma, tetapi belum membuktikan bahwa pola yang sama berlaku pada data riil PT Aranesia Gemilang Nusantara. Pada data aktual, faktor kinerja, kehadiran, masa kerja, kompetensi, kebutuhan jabatan, serta kondisi organisasi dapat menghasilkan struktur pohon yang berbeda. Oleh karena itu, pohon yang diperoleh perlu dipandang sebagai prototipe analitis.

Dari sisi manajemen, penggunaan jumlah pelanggaran sebagai indikator harus disertai definisi operasional yang jelas. Perusahaan perlu membedakan jenis, tingkat keparahan, frekuensi, waktu kejadian, status klarifikasi, dan apakah pelanggaran telah memperoleh sanksi sebelumnya. Dua karyawan dengan jumlah pelanggaran sama belum tentu mempunyai tingkat risiko yang sama apabila konteks pelanggaran berbeda. Data yang hanya berbentuk hitungan dapat menghilangkan konteks dan berpotensi menimbulkan keputusan yang tidak proporsional. Prinsip responsible AI dalam HRM menekankan pentingnya kualitas indikator, keterlacakan sumber data, serta penjelasan yang dapat dipahami oleh pihak yang terkena dampak (Bujold et al., 2024).

Interpretabilitas merupakan keunggulan utama pohon keputusan karena aturan dapat diterjemahkan ke dalam bentuk “jika–maka”. Keunggulan ini perlu dimanfaatkan dengan menampilkan jalur keputusan untuk setiap prediksi, bukan hanya label akhir. HRD sebaiknya dapat melihat atribut yang digunakan, batas kategori, dan urutan percabangan yang dilewati oleh suatu data karyawan. Penjelasan tersebut memungkinkan pengguna memeriksa apakah rekomendasi sistem sesuai dengan bukti administrasi. Namun, transparansi aturan tidak otomatis menjamin keadilan. Sistem yang mudah dijelaskan tetap dapat menghasilkan bias apabila data atau label awal mengandung

ketimpangan, sehingga interpretabilitas harus dipadukan dengan audit kualitas data dan pemeriksaan dampak keputusan (Rosenthal-von der Pütten & Sach, 2024).

3.6. Dampak Penggunaan Data Simulasi terhadap Validitas Hasil

Catatan metodologis dalam penelitian telah menjelaskan bahwa atribut kinerja, kehadiran, kedisiplinan, dan label keputusan disimulasikan karena data aktual tidak tersedia. Keterbukaan tersebut merupakan kekuatan penting karena mencegah pembaca menganggap hasil sebagai gambaran faktual seluruh karyawan perusahaan. Meskipun demikian, penggunaan data simulasi membatasi validitas eksternal. Model dapat menunjukkan bahwa alur C4.5, pembentukan pohon, evaluasi, dan integrasi sistem berjalan, tetapi angka akurasi dan struktur aturan belum dapat digeneralisasikan untuk keputusan organisasi yang nyata. Literatur AI dalam HRM juga menekankan bahwa banyak penelitian masih berada pada skenario eksperimental sehingga pengujian lapangan diperlukan sebelum penerapan operasional (Basu et al., 2023; Bujold et al., 2024).

Validitas data simulasi sangat dipengaruhi oleh asumsi distribusi. Apabila nilai atribut dibuat secara acak tanpa mengikuti hubungan antar variabel yang sebenarnya, korelasi yang terbentuk dapat terlalu lemah atau justru terlalu kuat. Misalnya, kinerja rendah dapat berkaitan dengan kehadiran, jenis pekerjaan, perubahan target, masa adaptasi, atau keterbatasan alat kerja. Hubungan-hubungan tersebut belum tentu muncul dalam data sintesis sederhana. Selain itu, proporsi kelas yang ditentukan saat simulasi akan memengaruhi pola pembelajaran dan nilai evaluasi. Karena itu, dokumentasi aturan pembangkitan data, rentang nilai, proporsi kelas, serta seed acak perlu disimpan agar eksperimen dapat direplikasi.

Risiko lain adalah label leakage atau pembentukan label yang secara langsung menggunakan atribut yang kemudian dijadikan prediktor. Jika kelas “Direkomendasikan PHK” dibentuk berdasarkan jumlah pelanggaran tinggi, lalu jumlah pelanggaran dimasukkan sebagai atribut pelatihan, model hampir pasti menemukan atribut tersebut sebagai faktor dominan. Kondisi ini dapat berguna untuk demonstrasi, tetapi tidak menguji kemampuan model menemukan pola baru. Pengembangan berikutnya perlu memisahkan proses penetapan label dari proses pemilihan atribut, misalnya menggunakan keputusan historis yang telah diverifikasi, hasil penilaian panel, atau kriteria kebijakan yang terdokumentasi.

Tahap lanjutan sebaiknya menggunakan data riil yang telah dianonimkan, mencakup periode waktu yang memadai, dan mewakili berbagai departemen serta jabatan. Data longitudinal memungkinkan peneliti mengamati perubahan kinerja dan kedisiplinan, bukan hanya satu titik pengukuran. Sebelum pelatihan, HRD dan peneliti perlu menyusun data dictionary, definisi label, prosedur penanganan nilai hilang, serta aturan untuk data yang disengketakan. Kerangka adopsi AI pada HRM menempatkan kesiapan data, kompetensi pengguna, dan tata kelola organisasi sebagai prasyarat penting agar teknologi menghasilkan manfaat yang dapat dipertanggungjawabkan (Jatobá et al., 2023; Malik et al., 2023).

3.7. Perbandingan dengan Penelitian Terdahulu

Sejumlah penelitian terdahulu menunjukkan bahwa C4.5 dapat digunakan untuk penilaian kinerja, seleksi karyawan, dan evaluasi kelayakan tenaga kerja. Asyhari et al. (2024) menggabungkan C4.5 dengan penilaian 360 derajat untuk meningkatkan struktur penilaian karyawan. Hijrah (2022) membandingkan implementasi C4.5 pada perangkat lunak data mining dan menunjukkan bahwa pilihan perangkat serta proses pengolahan dapat memengaruhi hasil evaluasi. Mayangsari dan Wahyudi (2024) menerapkan C4.5 untuk seleksi penerimaan karyawan baru, sedangkan Pirmansyah dan Wahyudi (2023) menggunakannya untuk evaluasi anggota satuan pengamanan. Kesamaan penelitian-penelitian tersebut terletak pada pemanfaatan aturan pohon keputusan yang mudah dipahami oleh pengambil keputusan.

Nilai akurasi 60% pada penelitian ini lebih rendah dibandingkan sejumlah hasil yang dilaporkan pada penelitian terdahulu. Perbedaan tersebut tidak serta-merta menunjukkan bahwa implementasi algoritma salah. Performa klasifikasi dipengaruhi oleh ukuran sampel, jumlah kelas, kualitas label, tingkat ketidakseimbangan kelas, variasi atribut, noise, dan skema validasi. Penelitian dengan dua kelas yang batasnya tegas cenderung lebih mudah dibandingkan penelitian dengan tiga kelas yang mempunyai zona transisi. Selain itu, penggunaan data simulasi dengan derau acak dapat membuat hubungan antar atribut kurang konsisten, sehingga pohon keputusan mengalami kesulitan membentuk aturan yang stabil.

Rudianto et al. (2022) memperlihatkan pentingnya membandingkan C4.5 dengan algoritma lain agar pemilihan model tidak hanya didasarkan pada kebiasaan atau kemudahan implementasi. Dalam penelitian ini, C4.5 tepat digunakan sebagai model awal karena transparan dan dapat diterjemahkan menjadi aturan. Namun, penelitian

lanjutan dapat membandingkannya dengan Random Forest, Naive Bayes, Logistic Regression, Support Vector Machine, atau Gradient Boosting. Perbandingan perlu dilakukan pada data dan skema validasi yang sama, serta tidak hanya menggunakan akurasi, tetapi juga macro F1-score, recall per kelas, area under the curve untuk skema yang sesuai, dan waktu komputasi.

Kontribusi penelitian ini berbeda karena tidak hanya membangun model klasifikasi, tetapi juga mengintegrasikannya ke dalam sistem pendukung keputusan berbasis web. Integrasi tersebut memperlihatkan jalur penerapan dari pengelolaan data hingga penyajian rekomendasi kepada HRD. Walaupun demikian, nilai tambah sistem baru akan optimal apabila model yang digunakan telah divalidasi pada data nyata. Dengan demikian, penelitian ini dapat ditempatkan sebagai proof of concept yang berhasil menunjukkan kelayakan teknis aplikasi, sedangkan penelitian terdahulu menjadi dasar pembandingan untuk peningkatan kualitas model dan perluasan skenario pengujian.

3.8. Objektivitas, Keadilan, dan Peran Manusia dalam Keputusan

Tujuan utama sistem adalah membantu proses yang sebelumnya manual dan subjektif menjadi lebih terstruktur. Algoritma dapat meningkatkan konsistensi karena data diproses menggunakan aturan yang sama. Namun, konsistensi matematis tidak identik dengan objektivitas substantif. Apabila indikator, label, atau data historis mengandung bias, model dapat mereproduksi bias tersebut secara konsisten. Penelitian mengenai AI dalam keputusan HR menunjukkan bahwa persepsi keadilan dapat menurun ketika individu merasa keputusan penting sepenuhnya diserahkan kepada sistem otomatis tanpa ruang penjelasan dan koreksi (Cai et al., 2024). Oleh sebab itu, sistem perlu dirancang untuk memperkuat kualitas pertimbangan manusia, bukan menggantikan tanggung jawab manajerial.

Penggunaan sistem pada keputusan pengurangan tenaga kerja termasuk konteks berisiko tinggi karena berdampak pada pekerjaan, pendapatan, reputasi, dan hak karyawan. Regulasi AI Uni Eropa mengategorikan sistem AI yang digunakan untuk evaluasi, promosi, dan pemutusan hubungan kerja sebagai penggunaan berisiko tinggi yang memerlukan tata kelola ketat, dokumentasi, pengawasan manusia, dan manajemen risiko (European Parliament & Council of the European Union, 2024). Walaupun regulasi tersebut tidak secara langsung menjadi hukum operasional perusahaan di Indonesia, prinsipnya relevan sebagai rujukan tata kelola: keputusan final harus dapat ditinjau, dijelaskan, dan dipertanggungjawabkan oleh manusia.

Model sebaiknya menerapkan human-in-the-loop. Setelah sistem memberikan rekomendasi, HRD perlu memeriksa bukti pendukung, meminta penilaian atasan langsung, mempertimbangkan kebutuhan organisasi, dan memberi kesempatan kepada karyawan untuk menjelaskan data yang dipersoalkan. Hasil model dapat menjadi salah satu masukan dalam rapat evaluasi, bukan satu-satunya dasar. Prosedur eskalasi juga diperlukan ketika prediksi bertentangan dengan penilaian lapangan. Pendekatan ini mengurangi kecenderungan automation bias, yaitu kecenderungan pengguna menerima rekomendasi sistem karena dianggap lebih objektif, meskipun terdapat indikasi kesalahan (Rosenthal-von der Pütten & Sach, 2024).

Keadilan juga perlu diuji secara empiris. Penelitian lanjutan dapat membandingkan tingkat kesalahan berdasarkan departemen, jenis jabatan, kelompok usia, masa kerja, atau kategori lain yang sah dan relevan. Atribut sensitif tidak selalu harus digunakan sebagai prediktor, tetapi dapat digunakan secara terbatas untuk audit dampak agar diketahui apakah model menghasilkan perbedaan yang tidak wajar antar kelompok. Audit tersebut harus mengikuti prinsip perlindungan data, pembatasan akses, dan tujuan penggunaan yang jelas. Kajian responsible AI dalam HRM menempatkan bias, diskriminasi, kepercayaan, privasi, transparansi, dan peran manusia sebagai dimensi utama yang harus dianalisis bersama kinerja teknis (Bujold et al., 2024).

3.9. Evaluasi Implementasi Sistem Berbasis Web

Pengujian black box menunjukkan fungsi utama aplikasi berjalan sesuai skenario, sedangkan pengujian white box menunjukkan logika program dapat dieksekusi mengikuti alur yang dirancang. Hasil ini penting karena sistem pendukung keputusan tidak hanya ditentukan oleh model, tetapi juga oleh keandalan proses input, penyimpanan, pengolahan, dan penyajian data. Kesalahan pada validasi formulir, autentikasi, pemetaan atribut, atau penyimpanan hasil dapat mengubah rekomendasi meskipun algoritma sudah benar. Karena itu, pengujian fungsional merupakan dasar untuk memastikan pengguna dapat menjalankan sistem tanpa gangguan teknis yang berarti.

Tanggapan positif dari HRD menunjukkan bahwa antarmuka dan alur aplikasi dapat diterima oleh pengguna awal. Namun, penerimaan pengguna tidak sama dengan validitas keputusan. Pengguna dapat menilai aplikasi mudah

digunakan dan cepat, tetapi model di dalamnya masih memerlukan peningkatan. Evaluasi selanjutnya perlu memisahkan tiga dimensi, yaitu usability, kualitas informasi, dan kualitas keputusan. Usability dapat diukur melalui kemudahan belajar, efisiensi, dan kepuasan. Kualitas informasi dapat dinilai dari kelengkapan, ketepatan, dan keterbaruan data. Kualitas keputusan dapat diukur melalui akurasi, konsistensi, keadilan, serta manfaat nyata bagi proses HRD.

Arsitektur berbasis web memberikan keuntungan berupa akses terpusat, pembaruan sistem yang lebih mudah, dan integrasi dengan sumber data seperti fingerprint. Akan tetapi, sistem juga memerlukan pengendalian akses berbasis peran. Administrator, staf HRD, manajer, dan auditor tidak harus memiliki hak yang sama. Data penilaian karyawan bersifat sensitif sehingga fitur ekspor, perubahan data, dan penghapusan catatan perlu dicatat dalam audit log. Sistem juga perlu menerapkan pengamanan sesi, enkripsi komunikasi, pencadangan, serta prosedur pemulihan apabila terjadi gangguan.

Keberhasilan adopsi tidak hanya bergantung pada perangkat lunak. HRD memerlukan pelatihan untuk membaca confusion matrix, memahami batasan model, dan menafsirkan jalur pohon keputusan. Pengguna juga perlu mengetahui kapan rekomendasi harus ditolak atau diteruskan untuk pemeriksaan tambahan. Kajian tentang adopsi AI pada HRM menekankan pentingnya kompetensi teknis, pemahaman konteks organisasi, komunikasi perubahan, serta pembagian tanggung jawab antara pengembang, manajer, dan profesional HR (Dima et al., 2024; Jatobá et al., 2023; Malik et al., 2023).

3.10. Strategi Peningkatan Kinerja Model

Peningkatan pertama adalah mengganti atau melengkapi data simulasi dengan data aktual yang telah diverifikasi. Jumlah data perlu diperbesar agar setiap kelas memiliki contoh yang memadai, terutama kelas “Direkomendasikan PHK” yang support-nya lebih kecil. Penambahan data harus diikuti pemeriksaan duplikasi, nilai hilang, inkonsistensi kategori, dan perubahan definisi atribut antar periode. Data yang banyak tetapi tidak konsisten tidak otomatis menghasilkan model yang lebih baik. Proses pembersihan harus terdokumentasi agar hasil dapat direplikasi dan diaudit.

Skema evaluasi juga perlu diperkuat. Satu pembagian 80:20 dapat menghasilkan nilai yang berubah apabila komposisi sampel uji berbeda. Stratified k-fold cross-validation dapat digunakan untuk memperoleh estimasi performa yang lebih stabil, selama data tidak memiliki ketergantungan waktu yang harus dipisahkan secara kronologis. Nilai rata-rata dan simpangan antar fold perlu dilaporkan. Apabila data berasal dari beberapa periode, pengujian berbasis waktu dapat digunakan untuk menilai kemampuan model memprediksi kondisi masa depan. Prinsipnya adalah memastikan data uji benar-benar mewakili kasus yang belum dilihat model (Géron, 2022).

Ketidakseimbangan kelas dapat ditangani melalui class weighting, penyesuaian kriteria pemisahan, undersampling, atau oversampling yang diterapkan hanya pada data latih. Teknik sintesis seperti SMOTE dapat dipertimbangkan dengan hati-hati karena data HR mempunyai batas logis dan hubungan kategori yang tidak boleh dilanggar. Evaluasi harus melihat apakah peningkatan recall pada kelas tertentu menyebabkan penurunan precision yang berisiko. Pada keputusan tenaga kerja, optimasi tidak boleh hanya mengejar satu kelas, melainkan mempertimbangkan biaya kesalahan bagi organisasi dan karyawan.

Pada C4.5, pruning dan pengaturan minimum data pada daun dapat mengurangi overfitting. Pohon yang terlalu dalam mungkin menghafal pola kecil, sedangkan pohon yang terlalu sederhana dapat kehilangan informasi penting. Penelitian berikutnya perlu melaporkan kedalaman pohon, jumlah node, aturan hasil pruning, dan perubahan performa sebelum serta sesudah pruning. Selain itu, batas kategorisasi atribut numerik sebaiknya ditentukan berdasarkan analisis data dan kebijakan HR, bukan semata-mata nilai arbitrer. Transparansi parameter membantu pembaca memahami bagaimana aturan akhir dibentuk (Quinlan, 1993).

Perbandingan dengan algoritma lain diperlukan untuk memastikan C4.5 merupakan pilihan yang sesuai. Model ensemble mungkin meningkatkan akurasi, tetapi interpretasinya lebih kompleks. Salah satu pendekatan adalah menggunakan model yang lebih kuat sebagai pembanding dan mempertahankan C4.5 sebagai model transparan. Apabila model kompleks memberikan peningkatan besar, penjelasan lokal dan analisis fitur dapat digunakan, tetapi keputusan final tetap memerlukan pengawasan manusia. Pemilihan model harus mempertimbangkan keseimbangan antara performa, interpretabilitas, biaya implementasi, dan risiko penggunaan (NIST, 2023).

3.11. Tata Kelola Data dan Manajemen Risiko Sistem

Tata kelola data harus dimulai dari penetapan tujuan penggunaan. Data karyawan yang dikumpulkan untuk administrasi kehadiran tidak otomatis boleh digunakan untuk semua bentuk evaluasi tanpa kebijakan yang jelas. Perusahaan perlu menetapkan dasar penggunaan, ruang lingkup atribut, masa penyimpanan, pihak yang berwenang, dan mekanisme koreksi. Prinsip minimisasi data mengarahkan organisasi untuk menggunakan hanya data yang benar-benar diperlukan. Atribut yang tidak relevan atau berpotensi menjadi proxy diskriminatif sebaiknya tidak dimasukkan ke dalam model.

Setiap atribut memerlukan metadata yang menjelaskan sumber, frekuensi pembaruan, format, penanggung jawab, serta aturan validasi. Data fingerprint, misalnya, perlu dibedakan antara terlambat, izin, cuti, penugasan luar, dan gangguan perangkat. Tanpa konteks tersebut, sistem dapat membaca ketidakhadiran yang sah sebagai indikator negatif. Mekanisme koreksi harus tersedia apabila karyawan atau atasan menemukan kesalahan. Perubahan data sebaiknya tidak menghapus rekam sebelumnya, melainkan menghasilkan jejak revisi yang dapat ditelusuri.

Manajemen risiko perlu dilakukan sepanjang siklus hidup sistem: perancangan, pengembangan, validasi, penerapan, pemantauan, dan penghentian. NIST (2023) mengusulkan fungsi govern, map, measure, dan manage untuk membantu organisasi mengidentifikasi konteks, mengukur risiko, dan menentukan tindakan pengendalian. Dalam penelitian ini, kerangka tersebut dapat diterapkan dengan menetapkan pemilik sistem, daftar risiko, indikator pemantauan, jadwal audit, dan prosedur respons apabila model menunjukkan penurunan performa atau perbedaan dampak antar kelompok.

Model drift perlu diperhatikan karena pola organisasi dapat berubah. Perubahan kebijakan kehadiran, struktur pekerjaan, target kinerja, atau komposisi tenaga kerja dapat membuat aturan lama tidak lagi sesuai. Akurasi dan distribusi prediksi perlu dipantau secara berkala. Model tidak seharusnya diperbarui otomatis tanpa validasi, karena perubahan data dapat mengubah aturan keputusan secara signifikan. Setiap versi model perlu diberi nomor, tanggal, dataset pelatihan, parameter, dan hasil evaluasi sehingga keputusan pada suatu periode dapat direkonstruksi.

Laporan OECD (2023) dan ILO (2022) menekankan bahwa algorithmic management dapat meningkatkan konsistensi dan efisiensi, tetapi juga dapat memengaruhi otonomi, privasi, dan kualitas kerja. Oleh sebab itu, pengawasan sistem perlu melibatkan tidak hanya pengembang dan HRD, tetapi juga manajemen, bagian hukum, keamanan informasi, dan perwakilan pihak yang terdampak. Pendekatan multidisiplin membantu memastikan manfaat operasional tidak mengabaikan hak dan kesejahteraan karyawan.

3.12. Rancangan Proses Keputusan yang Disarankan

Berdasarkan hasil penelitian, tiga kelas keluaran lebih tepat digunakan sebagai mekanisme triase. Kelas “Dipertahankan” dapat diarahkan untuk pemeriksaan rutin; kelas “Dipertimbangkan” untuk evaluasi mendalam; dan kelas “Direkomendasikan PHK” untuk pemeriksaan berlapis, bukan eksekusi otomatis. Setiap rekomendasi perlu dilengkapi jalur pohon, ringkasan atribut, sumber data, dan tingkat keyakinan atau stabilitas aturan. Dengan cara ini, sistem membantu HRD memprioritaskan pekerjaan tanpa mengambil alih keputusan.

Proses keputusan dapat dibagi menjadi lima tahap. Tahap pertama adalah validasi data dan pemeriksaan kelengkapan. Tahap kedua adalah pemrosesan model dan pembuatan rekomendasi. Tahap ketiga adalah verifikasi oleh HRD terhadap bukti administrasi dan histori karyawan. Tahap keempat adalah penilaian oleh atasan atau panel yang mempertimbangkan konteks pekerjaan. Tahap kelima adalah keputusan final yang didokumentasikan beserta alasan, pihak yang menyetujui, dan kesempatan keberatan. Struktur tersebut memastikan tanggung jawab tetap berada pada organisasi.

Untuk mengurangi bias, panel peninjau sebaiknya menggunakan pedoman yang sama dan tidak mengetahui informasi yang tidak relevan terhadap keputusan. Sistem dapat menyediakan checklist agar setiap kasus diperiksa berdasarkan kriteria konsisten. Ketika keputusan manusia berbeda dari rekomendasi model, perbedaan tersebut perlu dicatat sebagai bahan evaluasi. Catatan override dapat menunjukkan apakah model sering gagal pada departemen, jabatan, atau kondisi tertentu. Data tersebut berguna untuk memperbaiki model dan kebijakan.

Karyawan yang terkena dampak perlu memperoleh penjelasan yang bermakna. Penjelasan tidak harus memuat seluruh detail teknis, tetapi harus menyampaikan data utama yang digunakan, alasan rekomendasi, dan cara mengajukan koreksi. Pemberian penjelasan mendukung persepsi keadilan prosedural dan mengurangi ketidakpercayaan terhadap sistem. Penelitian mengenai keputusan HR otomatis menunjukkan bahwa persepsi

keadilan dipengaruhi oleh keterlibatan manusia, transparansi, dan kesempatan untuk menanggapi keputusan (Cai et al., 2024; Bujold et al., 2024).

3.13. Implikasi Organisasi dan Pengembangan SDM

Sistem tidak seharusnya hanya digunakan untuk mengidentifikasi karyawan yang berpotensi dikurangi. Aturan yang dihasilkan dapat dimanfaatkan untuk menemukan kebutuhan intervensi lebih awal. Karyawan dengan kehadiran menurun dapat diarahkan ke klarifikasi atau dukungan; kinerja rendah dapat ditindaklanjuti melalui pelatihan; dan pelanggaran berulang dapat ditangani melalui pembinaan bertahap. Pendekatan preventif membuat analitik HR berfungsi sebagai alat pengembangan sumber daya manusia, bukan sekadar instrumen pengendalian.

Penggunaan model untuk pembinaan juga dapat meningkatkan kualitas data. Ketika HRD menindaklanjuti rekomendasi, hasil intervensi dapat dicatat dan menjadi informasi baru untuk evaluasi. Perusahaan dapat mengetahui apakah pelatihan, perubahan penempatan, atau pendampingan menghasilkan perbaikan. Dengan demikian, sistem berkembang dari klasifikasi statis menjadi siklus pembelajaran organisasi. Kerangka AI-assisted HRM menekankan bahwa nilai teknologi muncul ketika terintegrasi dengan strategi, kompetensi, dan proses kerja, bukan hanya ketika algoritma menghasilkan prediksi (Malik et al., 2023).

Dari sisi efisiensi, sistem berbasis web dapat mengurangi waktu penggabungan data dan menyediakan format evaluasi yang seragam. Namun, efisiensi harus diukur secara nyata, misalnya waktu pemrosesan sebelum dan sesudah sistem, jumlah kesalahan administrasi, jumlah kasus yang memerlukan koreksi, dan kepuasan pengguna. Evaluasi manfaat perlu melibatkan dampak pada karyawan, termasuk kejelasan proses dan tingkat kepercayaan. Literatur AI-HRM menunjukkan bahwa hasil organisasi dan hasil bagi pekerja dapat berbeda, sehingga keduanya perlu dinilai secara seimbang (Basu et al., 2023; Dima et al., 2024).

Implementasi juga memerlukan pengelolaan perubahan. Pengguna dapat menolak sistem apabila menganggapnya menambah beban atau mengancam kewenangan. Sebaliknya, pengguna dapat terlalu bergantung apabila sistem dipersepsikan selalu benar. Pelatihan harus menanamkan sikap kritis: sistem membantu menemukan pola, tetapi keputusan membutuhkan pengetahuan konteks. Komunikasi organisasi perlu menjelaskan tujuan, batasan, tanggung jawab, dan perlindungan data agar teknologi diterima secara sehat dan tidak menimbulkan ketakutan yang tidak perlu (Jatobá et al., 2023).

3.14. Sintesis Hasil dan Diskusi

Secara keseluruhan, penelitian berhasil menunjukkan alur lengkap penerapan C4.5 mulai dari pengolahan data, pembentukan pohon keputusan, evaluasi dengan confusion matrix, hingga integrasi ke aplikasi web. Kekuatan utamanya terletak pada interpretabilitas aturan dan keberhasilan fungsi sistem. Hasil pengguna juga menunjukkan bahwa aplikasi mempunyai potensi membantu HRD mengelola data secara lebih terstruktur. Kontribusi tersebut relevan sebagai prototipe sistem pendukung keputusan dan dasar bagi penelitian lanjutan.

Di sisi lain, akurasi 60%, macro F1-score 55,8%, ukuran data uji yang kecil, ketidakseimbangan kelas, dan penggunaan atribut serta label simulasi menunjukkan bahwa model belum layak dijadikan dasar keputusan pengurangan tenaga kerja yang sebenarnya. Root node kedisiplinan harus dipahami sebagai pola pada data eksperimen, bukan kesimpulan kausal tentang karyawan perusahaan. Penggunaan operasional baru dapat dipertimbangkan setelah tersedia data riil, validasi yang lebih kuat, audit keadilan, dokumentasi model, serta prosedur pengawasan manusia.

Dengan menempatkan model sebagai alat bantu, sistem dapat memberikan manfaat tanpa menghilangkan tanggung jawab organisasi. Rekomendasi harus dapat dijelaskan, diperiksa, dikoreksi, dan ditolak apabila tidak sesuai konteks. Tata kelola data, audit log, pembatasan akses, monitoring model, dan mekanisme keberatan merupakan bagian yang sama pentingnya dengan akurasi algoritma. Pendekatan tersebut sejalan dengan prinsip trustworthy dan responsible AI yang menekankan bahwa kualitas sistem ditentukan oleh gabungan aspek teknis, manusia, organisasi, dan dampak sosial (Bujold et al., 2024; NIST, 2023; OECD, 2023).

4. Kesimpulan

Penelitian ini berhasil menerapkan algoritma C4.5 untuk mengklasifikasikan karyawan pada PT Aranesia Gemilang Nusantara guna mendukung pengambilan keputusan terkait pengurangan tenaga kerja. Pada pengujian menggunakan 200 sampel data dengan atribut kinerja, kehadiran, dan kedisiplinan yang disimulasikan (karena data aktual tidak tersedia dari perusahaan), model memperoleh akurasi 60% dengan atribut jumlah pelanggaran

kedisiplinan sebagai penentu utama (root node) pohon keputusan. Sistem pendukung keputusan berbasis web yang dibangun mampu berjalan dengan baik berdasarkan pengujian black box, white box, dan tanggapan positif dari HRD selaku pengguna. Mengingat keterbatasan berupa data atribut kinerja, kehadiran, dan kedisiplinan yang masih bersifat simulasi serta ukuran data uji yang relatif kecil, penelitian selanjutnya sangat disarankan untuk menerapkan model ini pada data riil perusahaan dengan volume yang lebih besar, guna memperoleh hasil klasifikasi yang lebih valid, akurat, dan dapat dipertanggungjawabkan secara empiris.

Referensi

1. Asyhari, M. R., Alijoyo, F. A., & Vernanda, D. (2024). Penerapan algoritma C4.5 dan metode 360 derajat pada sistem informasi penilaian karyawan. *Jurnal Tekno Kompak*, 18(1), 15–27. <https://doi.org/10.33365/jtk.v18i1.3215>
2. Basu, S., Majumdar, B., Mukherjee, K., Munjal, S., & Palaksha, C. (2023). Artificial intelligence–HRM interactions and outcomes: A systematic review and causal configurational explanation. *Human Resource Management Review*, 33(1), Article 100893. <https://doi.org/10.1016/j.hrmr.2022.100893>
3. Bujold, A., Roberge-Maltais, I., Parent-Rochelleau, X., Boasen, J., Sénécal, S., & Léger, P.-M. (2024). Responsible artificial intelligence in human resources management: A review of the empirical literature. *AI and Ethics*, 4(4), 1185–1200. <https://doi.org/10.1007/s43681-023-00325-1>
4. Cai, F., Zhang, J., & Zhang, L. (2024). The impact of artificial intelligence replacing humans in making human resource management decisions on fairness: A case of resume screening. *Sustainability*, 16(9), Article 3840. <https://doi.org/10.3390/su16093840>
5. Dima, J., Gilbert, M.-H., Dextras-Gauthier, J., & Giraud, L. (2024). The effects of artificial intelligence on human resource activities and the roles of the human resource triad: Opportunities and challenges. *Frontiers in Psychology*, 15, Article 1360401. <https://doi.org/10.3389/fpsyg.2024.1360401>
6. European Parliament & Council of the European Union. (2024). Regulation (EU) 2024/1689 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). *Official Journal of the European Union*. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>
7. Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.
8. Hijrah. (2022). Analisis perbandingan aplikasi data mining dalam memprediksi kualitas kinerja karyawan menggunakan metode algoritma C4.5. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 9(2), 1655–1665. <https://doi.org/10.35957/jatisi.v9i2.1992>
9. International Labour Organization. (2022). *The algorithmic management of work and its implications in different contexts*. International Labour Office.
10. Jatobá, M., Ferreira, J. J. M., Fernandes, P. O., & Teixeira, J. P. (2023). Intelligent human resources for the adoption of artificial intelligence: A systematic literature review. *Journal of Organizational Change Management*, 36(7), 1099–1124. <https://doi.org/10.1108/JOCM-03-2022-0075>
11. Malik, A., Budhwar, P., & Kazmi, B. A. (2023). Artificial intelligence (AI)-assisted HRM: Towards an extended strategic framework. *Human Resource Management Review*, 33(1), Article 100940. <https://doi.org/10.1016/j.hrmr.2022.100940>
12. Mayangsari, D., & Wahyudi, T. (2024). Klasifikasi seleksi penerimaan karyawan baru menggunakan algoritma C4.5. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(1), 26–34. <https://doi.org/10.57152/malcom.v5i1.1525>
13. National Institute of Standards and Technology. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)* (NIST AI 100-1). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>
14. Organisation for Economic Co-operation and Development. (2023). *OECD employment outlook 2023: Artificial intelligence and the labour market*. OECD Publishing. <https://doi.org/10.1787/08785bba-en>
15. Pirmansyah, F., & Wahyudi, T. (2023). Implementasi data mining menggunakan algoritma C4.5 untuk prediksi evaluasi anggota satuan pengamanan studi kasus PT. YIMM Pulogadung. *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, 4(3), 1566–1580. <https://doi.org/10.35870/jimik.v4i3.370>
16. Quinlan, J. R. (1993). *C4.5: Programs for machine learning*. Morgan Kaufmann.
17. Rosenthal-von der Pütten, A. M., & Sach, A. (2024). Michael is better than Mehmet: Exploring the perils of algorithmic biases and selective adherence to advice from automated decision support systems in hiring. *Frontiers in Psychology*, 15, Article 1416504. <https://doi.org/10.3389/fpsyg.2024.1416504>
18. Rudianto, R., Wahyudi, T., & Handayani, P. (2022). Perbandingan akurasi C4.5 dan Naive Bayes untuk evaluasi kinerja karyawan PT Catur Sentosa Adiprana. *Jurnal Sistem Informasi dan Ilmu Komputer Prima (JUSIKOM PRIMA)*, 5(2), 61–66. <https://doi.org/10.34012/jurnalsisteminformasidanilmukomputer.v5i2.2350>