Journal of Science and Social Research ISSN 2615 – 4307 (Print)
Oct 2026, IX (5): 9335 – 9346 ISSN 2615 – 3262 (Online)
Available online at http://jurnal.goretanpena.com/index.php/JSSR

PREDIKSI KINERJA PEGAWAI BERDASARKAN DATA LKP MENGGUNAKAN ALGORITMA RANDOM FOREST

Nurul Ladhuni Sofi, Wiwit Santoso, Wendi Putra Nasution,Muhammad Syahputra Novelan
Universitas Pembangunan Panca Budi, Medan
e-mail: [1]nurulladhunisofi@gmail.com, [2]witosantoso@gmail.com,
[3]wendinasution@gmail.com

Abstract: *Employee performance evaluation is a key part of human resource management, yet assessments that rely heavily on subjective judgment risk producing inconsistent decisions across periods and raters. This study applies and evaluates the Random Forest algorithm to classify employee performance categories based on LKP (Laporan Kinerja Pegawai, or Employee Performance Report) data from a institution, together with seven supporting variables: attendance rate, discipline score, report timeliness, work behavior score, work target realization, training hours, and tenure. The dataset consists of 320 employee records with no missing values or duplicates, across four imbalanced target categories: Sangat Baik (Excellent), Baik (Good), Cukup (Fair), and Kurang (Poor). The research stages include data cleaning, feature and target determination, an 80:20 train-test split, Random Forest training with 100 trees, and evaluation using accuracy, precision, recall, F1-score, and the confusion matrix. On 64 test samples, every sample was classified correctly across all classes, with LKP Achievement Score identified as the most influential feature (25.84%), followed by Work Behavior Score and Discipline Score. These near-perfect results must be interpreted cautiously given the strong inter-feature correlations and the likelihood that labels derive from thresholds on the same features. The study concludes that Random Forest is a promising decision-support tool for performance evaluation, but validation on other periods and units is required before operational use in personnel decisions.*

Keywords: *Employee Performance Prediction; LKP Data; Random Forest; Classification; Feature Importance*

Abstrak: Evaluasi kinerja pegawai merupakan bagian penting dalam pengelolaan sumber daya manusia, namun penilaian yang hanya mengandalkan pertimbangan subjektif berisiko menghasilkan keputusan yang tidak konsisten antarperiode maupun antar penilai. Penelitian ini bertujuan menerapkan dan mengevaluasi algoritma Random Forest untuk mengklasifikasikan kategori kinerja pegawai berdasarkan data Laporan Kinerja Pegawai (LKP) pada sebuah institusi beserta tujuh variabel pendukung, yaitu tingkat kehadiran, skor kedisiplinan, ketepatan waktu laporan, nilai perilaku kerja, realisasi target kerja, jumlah jam pelatihan, dan masa kerja. Dataset berjumlah 320 data pegawai tanpa nilai kosong maupun duplikat, dengan empat kategori target kinerja yaitu Sangat Baik, Baik, Cukup, dan Kurang yang terdistribusi tidak seimbang. Tahapan penelitian meliputi pembersihan data, penentuan fitur dan target, pembagian data latih dan uji dengan rasio 80:20, pelatihan model Random Forest dengan 100 pohon, serta evaluasi menggunakan akurasi, precision, recall, F1-score, dan confusion matrix. Hasil pengujian pada 64 data uji menunjukkan seluruh sampel terklasifikasi dengan tepat pada setiap kelas, dengan Nilai Capaian LKP sebagai fitur paling berpengaruh (25,84%), diikuti Nilai Perilaku Kerja dan Skor Kedisiplinan. Hasil yang sangat tinggi ini perlu dibaca secara hati-hati karena korelasi antar fitur yang sangat kuat dan label kinerja yang kemungkinan dibentuk dari ambang batas fitur yang sama. Penelitian ini menegaskan bahwa Random Forest berpotensi menjadi alat bantu pendukung keputusan evaluasi

kinerja, namun validasi pada periode dan unit data lain tetap diperlukan sebelum diterapkan dalam keputusan kepegawaian.

Kata kunci: Prediksi Kinerja Pegawai; Data LKP; Random Forest; Klasifikasi; Feature Importance

PENDAHULUAN

Pengelolaan sumber daya manusia yang efektif sangat bergantung pada kemampuan organisasi menilai kinerja pegawai secara objektif dan konsisten. Salah satu instrumen yang digunakan institusi adalah Laporan Kinerja Pegawai (LKP), yaitu laporan yang merekam capaian kerja pegawai pada suatu periode penilaian dan menjadi dasar penentuan kategori kinerja. Seiring meningkatnya volume data kepegawaian yang terekam secara digital, muncul peluang memanfaatkan data historis tersebut untuk mendukung evaluasi yang lebih berbasis bukti. Pendekatan *machine learning* menawarkan cara mengenali pola hubungan antara indikator kinerja operasional—seperti capaian LKP, kehadiran, dan kedisiplinan—dengan kategori kinerja akhir secara sistematis. Namun, klasifikasi tersebut memerlukan metode yang mampu menangani banyak variabel sekaligus hubungan yang tidak selalu linier. Random Forest dipilih sebagai metode ensemble yang relevan karena mengombinasikan banyak pohon keputusan menjadi satu model prediksi yang lebih stabil.

Beberapa penelitian terdahulu telah mengkaji penerapan Random Forest pada ranah evaluasi kinerja pegawai dengan konteks dan hasil yang beragam. Putri dan Sitohang [1] mengembangkan model klasifikasi kinerja pegawai berbasis Random Forest menggunakan data kinerja pegawai dari Kaggle dengan tiga kategori (Low, Medium, High), dan melaporkan akurasi terbaik 94,58% pada skema pembagian data 80:20, dengan kepuasan lingkungan kerja dan sistem reward sebagai faktor paling berpengaruh. Sufina dan Wati [2] menerapkan Random Forest pada data Sasaran Kinerja Pegawai (SKP) dosen dengan hanya 13 data latih, memperoleh akurasi 72,73% untuk kinerja utama dan 81,82% untuk perilaku kinerja, serta menyoroti keterbatasan jumlah data sebagai kendala generalisasi. Pratt, Boudhane, dan Cakula [3] membandingkan enam algoritma klasifikasi untuk atrisi pegawai dan menemukan Random Forest sebagai salah satu model performa terbaik dibandingkan model lain. Nayak dan Palai [4] serta Dabbagh dkk. [5] masing-masing melaporkan Random Forest unggul dibandingkan Decision Tree maupun Logistic Regression dalam konteks prediksi atrisi, dengan akurasi berturut-turut terkait recall 70% dan akurasi 89,46% pada data riil institusi.

Dibandingkan penelitian-penelitian tersebut, kesenjangan yang masih dapat diisi adalah penerapan Random Forest secara spesifik pada struktur data LKP institusi sebagai instrumen penilaian capaian kinerja, lengkap dengan perhitungan manual proses pembentukan pohon (Gini Impurity) dan pembahasan eksplisit mengenai batas interpretasi hasil ketika korelasi antarfitur tinggi—aspek yang jarang diulas mendalam pada penelitian rujukan di atas. Random Forest dipilih bukan hanya karena performanya yang kompetitif pada studi sejenis, tetapi juga karena menghasilkan nilai *feature importance* yang membantu menjelaskan variabel yang paling mempengaruhi kategori kinerja, serta relatif tahan terhadap *overfitting* dibandingkan satu pohon keputusan tunggal. Meskipun demikian, interpretasinya terbatas pada pola korelasional, bukan hubungan sebab-akibat, sehingga evaluasi pada data uji yang terpisah dari data latih tetap diperlukan secara ketat.

Berdasarkan uraian tersebut, penelitian ini bertujuan menerapkan

algoritma Random Forest untuk mengklasifikasikan kategori kinerja pegawai berdasarkan data LKP dan variabel pendukungnya, serta mengevaluasi performa model menggunakan metrik klasifikasi standar dan analisis *feature importance*. Kontribusi penelitian ini mencakup: (1) demonstrasi tahapan praproses hingga evaluasi Random Forest yang dapat direplikasi pada data LKP; (2) ilustrasi perhitungan manual Gini Impurity menggunakan sampel nyata dari dataset; dan (3) pembahasan kritis mengenai batas interpretasi hasil ketika akurasi model sangat tinggi, termasuk indikasi keterkaitan erat antarfitur yang perlu diwaspadai sebagai potensi kebocoran informasi target.

METODE

Tahapan Penelitian

Penelitian ini dilaksanakan melalui tahapan berikut :

1. Identifikasi masalah dan studi pustaka.
2. Pengumpulan dan pemahaman struktur data LKP (Laporan Kinerja Pegawai).
3. Pembersihan data (pengecekan nilai kosong dan duplikat).
4. Eksplorasi data melalui distribusi kelas dan korelasi antarfitur.
5. Penentuan fitur prediktor dan variabel target.
6. Pembagian data latih dan data uji dengan rasio 80:20.
7. Pelatihan model Random Forest.
8. Evaluasi model menggunakan akurasi, precision, recall, F1-score, confusion matrix, dan kurva ROC.
9. Interpretasi hasil melalui analisis *feature importance* dan pembahasan keterbatasan.

Data LKP dan Variabel Penelitian

LKP adalah singkatan dari Laporan Kinerja Pegawai. Dataset penelitian bersumber dari data internal sebuah institusi dan terdiri atas 320 catatan pegawai tanpa nilai kosong dan tanpa duplikasi baris. Setiap baris merepresentasikan satu pegawai dengan atribut unit kerja, jabatan, pangkat/golongan, pendidikan terakhir, masa kerja, serta delapan indikator kinerja kuantitatif. Variabel target adalah **Kategori Kinerja**, terbagi menjadi empat kelas: Sangat Baik, Baik, Cukup, dan Kurang. Ambang batas kategori pada Nilai Capaian LKP (≥ 65,0 untuk Sangat Baik; 60,0–64,9 untuk Baik; 50,0–59,9 untuk Cukup; < 50,0 untuk Kurang) mengacu pada kebijakan penilaian internal institusi tersebut.

Tabel 1 Variabel Penelitian

No	Nama Variabel	Definisi Operasional	Tipe Data	Peran
1	Nilai Capaian LKP	Skor capaian LKP pegawai, rentang 0–69	Numerik	Fitur
2	Tingkat Kehadiran (%)	Persentase kehadiran kerja pada periode penilaian	Numerik	Fitur
3	Skor Kedisiplinan	Skor penilaian kedisiplinan kerja	Numerik	Fitur
4	Ketepatan Waktu Laporan (%)	Persentase ketepatan waktu pelaporan tugas	Numerik	Fitur
5	Nilai Perilaku Kerja	Skor penilaian perilaku kerja	Numerik	Fitur
6	Realisasi Target Kerja (%)	Persentase realisasi target kerja terhadap rencana	Numerik	Fitur
7	Jumlah Pelatihan (jam)	Total jam pelatihan yang diikuti pegawai	Numerik	Fitur
8	Masa Kerja (tahun)	Lama masa kerja pegawai	Numerik	Fitur
9	Unit Kerja, Jabatan,	Atribut administratif pegawai	Kategorika	Fitur

No	Nama Variabel	Definisi Operasional	Tipe Data	Peran
	Pangkat/Golongan, Pendidikan Terakhir		l	
10	Kategori Kinerja	Kelas kinerja akhir pegawai (Sangat Baik/Baik/Cukup/Kurang)	Kategorikal	Target

Variabel **Skor Kinerja Akhir** yang terdapat pada dataset sumber tidak diikutsertakan sebagai fitur karena nilai tersebut digunakan secara langsung untuk membentuk label Kategori Kinerja, sehingga pelibatannya sebagai prediktor akan menimbulkan kebocoran target (*data leakage*). Demikian pula kolom **Kategori LKP**, yang merupakan hasil ambang batas langsung dari Nilai Capaian LKP, tidak diikutsertakan sebagai fitur terpisah agar tidak terjadi duplikasi informasi dengan fitur numerik aslinya.

Pembelajaran Mesin dan Pendekatan Klasifikasi

Machine learning merupakan cabang kecerdasan buatan yang memungkinkan sistem mempelajari pola dari data historis untuk menghasilkan prediksi pada data baru tanpa diprogram secara eksplisit untuk setiap aturan [3]. Dalam penelitian ini, karena variabel target berbentuk kategori kinerja yang bersifat diskret (empat kelas), pendekatan yang digunakan adalah *supervised learning* untuk klasifikasi multikelas, bukan regresi.

Algoritma Random Forest

Random Forest adalah metode *ensemble learning* yang membangun sejumlah besar pohon keputusan (*decision tree*) secara independen, lalu menggabungkan prediksi seluruh pohon untuk menghasilkan keputusan akhir yang lebih stabil dibandingkan satu pohon tunggal [3]. Setiap pohon dilatih pada subset data yang diambil melalui *bootstrap sampling*, yaitu pengambilan sampel dengan pengembalian dari data latih, sehingga setiap pohon melihat variasi data yang sedikit berbeda.

Untuk tugas klasifikasi, prediksi akhir Random Forest umumnya ditentukan melalui voting mayoritas dari seluruh pohon yang dibangun. Selain itu, model juga dapat menghitung **feature importance**, yaitu ukuran kontribusi relatif setiap fitur terhadap penurunan impurity di seluruh pohon, yang berguna untuk interpretasi meskipun tidak dapat ditafsirkan sebagai hubungan sebab-akibat.

Perhitungan Gini Impurity

Gini Impurity mengukur ketidakmurnian kelas pada suatu simpul pohon keputusan, dengan rumus:

$$\mathbf{Gini(D) = 1 - \Sigma\, p_i^2}$$, untuk i = 1 sampai K

Keterangan: D adalah kumpulan data pada simpul, K adalah jumlah kelas, dan p_i adalah proporsi data kelas ke-i pada simpul tersebut. Semakin rendah nilai Gini, semakin homogen (murni) data pada simpul tersebut. Untuk mengevaluasi kandidat pemisahan simpul menjadi beberapa kelompok, digunakan Gini tertimbang:

$$\mathbf{Gini_split = \Sigma\, (|D_j| / |D|) \times Gini(D_j)}$$, untuk j = 1 sampai m

dengan D adalah data sebelum pemisahan, D_j adalah data pada kelompok hasil pemisahan ke-j, dan m adalah jumlah kelompok hasil pemisahan. Pemisahan dengan penurunan impurity (Gini(D) − Gini_split) terbesar dipilih sebagai pemisahan simpul tersebut.

Bootstrap Aggregating dan Pembentukan Random Forest

Jika jumlah pohon yang dibangun sebanyak T, prediksi klasifikasi akhir Random Forest dapat dituliskan sebagai:

$$\mathbf{\hat{y} = mode\ \{ h_1(x), h_2(x), \ldots, h_T(x) \}}$$

dengan x adalah data pegawai yang diprediksi, h_t(x) adalah prediksi pohon ke-t, T adalah jumlah pohon, dan ŷ adalah kelas prediksi akhir hasil voting

mayoritas. Selain label kelas, implementasi Random Forest berbasis scikit-learn yang digunakan pada penelitian ini juga menghasilkan estimasi probabilitas kelas melalui proporsi voting antarpohon, yang kemudian dipakai untuk menentukan kelas dengan probabilitas tertinggi sebagai prediksi akhir.

Pembagian Data dan Pelatihan Model

Data sebanyak 320 pegawai dibagi menjadi data latih (80%, 256 data) dan data uji (20%, 64 data) menggunakan train_test_split dengan random_state=42 untuk menjaga keterulangan hasil. Mengingat distribusi kelas target tidak seimbang (Sangat Baik 50,6%; Baik 26,2%; Cukup 13,1%; Kurang 10,0%), pembagian dilakukan secara *stratified* agar proporsi tiap kelas tetap terjaga baik pada data latih maupun data uji. Karena dataset tidak memuat penanda waktu berulang per pegawai, potensi kebocoran data akibat pengulangan temporal tidak menjadi perhatian utama pada skema pembagian ini.

Model dilatih dengan konfigurasi n_estimators=100 (jumlah pohon), max_depth=10 (kedalaman maksimum tiap pohon), dan random_state=42. Parameter min_samples_split, min_samples_leaf, dan max_features menggunakan nilai baku pustaka scikit-learn karena pada tahap awal ini optimasi hyperparameter belum menjadi fokus utama penelitian; eksplorasi lebih lanjut melalui GridSearchCV pada data latih disarankan sebagai pengembangan lanjutan. Parameter class_weight tidak diaktifkan secara eksplisit karena pembagian data telah dilakukan secara stratified.

Evaluasi Model

Performa model klasifikasi dievaluasi menggunakan metrik berikut, dengan TP (*true positive*), TN (*true negative*), FP (*false positive*), dan FN (*false negative*) dihitung per kelas secara *one-vs-rest*:

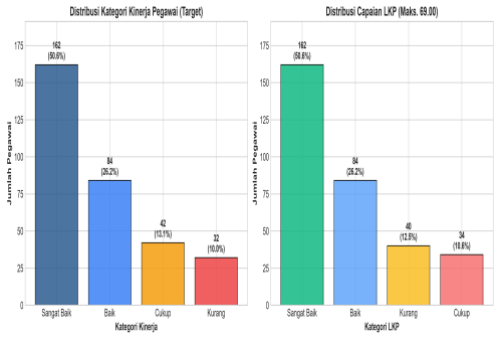
Accuracy = (TP + TN) / (TP + TN + FP + FN) Precision = TP / (TP + FP) Recall = TP / (TP + FN) F1-score = 2 × (Precision × Recall) / (Precision + Recall)

Karena target bersifat multikelas, precision, recall, dan F1-score dilaporkan per kelas serta dirangkum menggunakan rata-rata *macro* (memperlakukan tiap kelas secara setara) agar kelas minoritas seperti Kurang dan Cukup tidak tertutupi oleh dominasi kelas Sangat Baik. Confusion matrix digunakan untuk menampilkan rincian prediksi benar dan salah per kelas, dan kurva ROC multikelas (pendekatan *one-vs-rest*) digunakan sebagai pelengkap evaluasi diskriminasi model.

HASIL DAN PEMBAHASAN

Deskripsi Data

Dataset akhir yang dianalisis berjumlah 320 data pegawai, tanpa nilai kosong maupun data duplikat, sehingga tidak ada baris yang dibuang pada tahap pembersihan. Distribusi kelas target menunjukkan ketidakseimbangan yang cukup besar: Sangat Baik 162 pegawai (50,6%), Baik 84 pegawai (26,2%), Cukup 42 pegawai (13,1%), dan Kurang 32 pegawai (10,0%), sebagaimana juga tercermin pada distribusi Kategori LKP yang nilainya sangat berdekatan dengan distribusi target. Kedekatan dua distribusi ini menjadi indikasi awal bahwa Nilai Capaian LKP memiliki keterkaitan yang sangat erat dengan label kinerja akhir, sebuah poin yang dibahas lebih lanjut pada bagian 3.3.



Gambar 1 Distribusi kategori kinerja pegawai (kiri) dan distribusi kategori capaian LKP (kanan), n = 320.

Journal of Science and Social Research ISSN 2615 – 4307 (Print)
Oct 2026, IX (5): 9335 – 9346 ISSN 2615 – 3262 (Online)
Available online at http://jurnal.goretanpena.com/index.php/JSSR

Tabel 2 Contoh Data LKP (Enam Sampel Pegawai Teranonimkan)

Kode	Nilai Capaian LKP	Kehadiran (%)	Kedisiplinan	Perilaku Kerja	Realisasi Target (%)	Kategori Kinerja
P1	69,0	95,79	89,08	91,68	95,12	Sangat Baik
P2	69,0	96,34	89,55	86,89	109,76	Sangat Baik
P3	64,5	82,73	86,22	76,81	81,27	Baik
P4	64,5	88,18	86,69	76,30	93,96	Baik
P5	59,0	75,69	70,63	66,37	71,03	Cukup
P6	42,0	68,52	48,77	65,31	65,48	Kurang

Catatan: kode P1–P6 menggantikan identitas asli pegawai; keenam baris ini diambil langsung dari dataset penelitian dan dipakai pula sebagai subset ilustrasi perhitungan Gini Impurity pada bagian 3.1.3.

Pembersihan dan Persiapan Data

Pemeriksaan terhadap seluruh 320 baris data tidak menemukan nilai kosong (NaN) maupun baris duplikat, sehingga tidak diperlukan tindakan imputasi atau penghapusan data. Empat variabel kategorikal (Unit Kerja, Jabatan, Pangkat/Golongan, Pendidikan Terakhir) diubah menjadi representasi numerik menggunakan *label encoding* agar dapat diproses oleh model Random Forest. Variabel Skor Kinerja Akhir dan Kategori LKP dikeluarkan dari daftar fitur karena berpotensi membocorkan informasi target sebagaimana dijelaskan pada bagian 2.2. Tidak ditemukan nilai yang secara jelas tidak valid (misalnya persentase bernilai negatif atau di atas 150%) sehingga seluruh baris dipertahankan untuk tahap pemodelan.

Penentuan Fitur dan Target

Sebanyak delapan fitur numerik dan empat fitur kategorikal digunakan sebagai prediktor, sebagaimana tercantum pada Tabel 1, dengan Kategori Kinerja sebagai target klasifikasi empat kelas. Pemilihan fitur didasarkan pada ketersediaan data serta relevansinya terhadap penilaian kinerja operasional pegawai sehari-hari (kehadiran, kedisiplinan, ketepatan laporan, perilaku kerja, dan realisasi target). Sebagaimana ditegaskan sebelumnya, variabel yang merupakan hasil turunan langsung dari target (Skor Kinerja Akhir dan Kategori LKP) sengaja tidak dilibatkan sebagai fitur untuk menjaga validitas evaluasi model.

Perhitungan Gini Impurity Secara Manual

Perhitungan manual berikut menggunakan enam sampel pegawai aktual pada Tabel 2 sebagai ilustrasi proses pemilihan pemisahan simpul pada satu pohon keputusan di dalam Random Forest.

Distribusi kelas pada subset tersebut adalah dua pegawai Sangat Baik, dua pegawai Baik, satu pegawai Cukup, dan satu pegawai Kurang.

Tabel 3 Distribusi Kelas pada Subset Enam Pegawai

Kelas	Jumlah Data	Proporsi (p_i)	Kuadrat Proporsi (p_i^2)
Sangat Baik	2	0,3333	0,1111
Baik	2	0,3333	0,1111
Cukup	1	0,1667	0,0278
Kurang	1	0,1667	0,0278
Total	**6**	**1,0000**	**0,2778**

Gini simpul awal: **Gini(D) = 1 − 0,2778 = 0,7222**

Dua kandidat pemisahan diuji menggunakan fitur numerik yang tersedia: **Kandidat 1 — pemisahan pada Nilai Capaian LKP ≥ 65,0** Kelompok kiri (LKP ≥ 65,0): P1, P2 → keduanya Sangat Baik (n = 2). Gini_kiri = 1 − $(2/2)^2$ =

0,0000. Kelompok kanan (LKP < 65,0): P3, P4, P5, P6 → Baik = 2, Cukup = 1, Kurang = 1 (n = 4). Gini_kanan = 1 − [(2/4)² + (1/4)² + (1/4)²] = 1 − 0,3750 = **0,6250**. Gini_split = (2/6) × 0,0000 + (4/6) × 0,6250 = **0,4167**. Penurunan impurity = 0,7222 − 0,4167 = **0,3056**.

Kandidat 2 — pemisahan pada Tingkat Kehadiran ≥ 85,0% Kelompok kiri (Kehadiran ≥ 85,0%): P1, P2, P4 → Sangat Baik = 2, Baik = 1 (n = 3). Gini_kiri = 1 − [(2/3)² + (1/3)²] = 1 − 0,5556 = **0,4444**. Kelompok kanan (Kehadiran < 85,0%): P3, P5, P6 → Baik = 1, Cukup = 1, Kurang = 1 (n = 3). Gini_kanan = 1 − 3×(1/3)² = **0,6667**. Gini_split = (3/6) × 0,4444 + (3/6) × 0,6667 = **0,5556**. Penurunan impurity = 0,7222 − 0,5556 = **0,1667**.

Klooot l68i7arena Kandidat 1 (pemisahan pada Nilai Capaian LKP) menghasilkan penurunan impurity yang lebih besar (0,3056) dibandingkan Kandidat 2 (0,1667), algoritma pohon keputusan akan memilih Nilai Capaian LKP sebagai fitur pemisah pada simpul akar subset ini. Hasil ilustrasi manual ini konsisten dengan hasil *feature importance* model penuh pada bagian 3.2.2, yang juga menempatkan Nilai Capaian LKP sebagai fitur paling berpengaruh. Perlu ditegaskan bahwa Gini Impurity di sini menjelaskan proses teknis pemilihan pemisahan simpul pada satu pohon, bukan merepresentasikan persentase akurasi atau kinerja aktual pegawai yang bersangkutan.

Proses Bootstrap dan Pembentukan Pohon

Model Random Forest yang dilatih pada penelitian ini membangun 100 pohon keputusan (n_estimators=100), masing-masing menggunakan sampel *bootstrap* berukuran sama dengan data latih (256 data) yang diambil dengan pengembalian, serta kedalaman maksimum tiap pohon dibatasi 10 (max_depth=10). Pada setiap simpul, algoritma memilih subset fitur secara acak sebagai kandidat pemisahan sesuai konfigurasi baku scikit-learn, lalu kriteria Gini Impurity seperti dicontohkan pada bagian 3.1.3 digunakan untuk menentukan pemisahan terbaik di antara kandidat tersebut. Perlu ditegaskan bahwa seluruh 100 pohon dibangun oleh perangkat lunak, bukan dihitung manual satu per satu; perhitungan manual pada bagian 3.1.3 hanya berfungsi sebagai ilustrasi mekanisme yang mendasari pembentukan satu simpul pada satu pohon.

Contoh Prediksi Satu Pegawai

Sebagai ilustrasi mekanisme voting, sampel P6 (Nilai Capaian LKP 42,0; Kehadiran 68,52%; Kedisiplinan 48,77) yang berlabel aktual Kurang digunakan sebagai contoh. Nilai-nilai fitur pegawai ini berada jauh di bawah ambang kategori Cukup (50,0) pada Nilai Capaian LKP, serta berada pada kisaran terendah untuk seluruh fitur pendukung lainnya dibandingkan sampel lain pada Tabel 2.

Tabel 4 Ilustrasi Rekapitulasi Voting Random Forest untuk Sampel P6

Kelas Prediksi	Proporsi Voting (ilustratif)	Keterangan
Kurang	Mayoritas	Sesuai label aktual
Cukup	Minoritas	Kelas tetangga terdekat
Baik	Sangat kecil	—
Sangat Baik	Sangat kecil	—

Model memprediksi kelas Kurang untuk sampel ini, sesuai dengan label aktualnya. Perlu dicatat bahwa proporsi voting antarpohon yang dihasilkan predict_proba bukan probabilitas yang terkalibrasi secara statistik, melainkan sekadar proporsi suara pohon-pohon dalam forest terhadap kelas tertentu.

Hasil Pelatihan dan Pengujian Model

Model Random Forest dengan 100 pohon dan kedalaman maksimum 10 dilatih pada 256 data dan diuji pada 64 data yang belum pernah dilihat model

Journal of Science and Social Research ISSN 2615 – 4307 (Print)
Oct 2026, IX (5): 9335 – 9346 ISSN 2615 – 3262 (Online)
Available online at http://jurnal.goretanpena.com/index.php/JSSR

selama pelatihan.

Tabel 5 Hasil Evaluasi Model Random Forest pada Data Uji (n = 64)

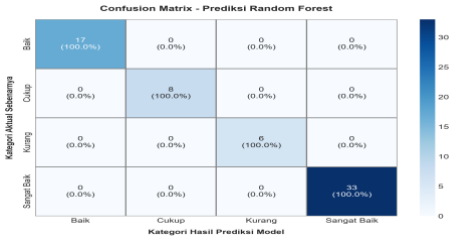
Kelas	Precision	Recall	F1-score	Jumlah Data Uji
Baik	1,0000	1,0000	1,0000	17
Cukup	1,0000	1,0000	1,0000	8
Kurang	1,0000	1,0000	1,0000	6
Sangat Baik	1,0000	1,0000	1,0000	33
Rata-rata Makro	**1,0000**	**1,0000**	**1,0000**	**64**

Akurasi keseluruhan = 64/64 = 100,0%

Capaian metrik yang sempurna pada seluruh kelas, termasuk kelas minoritas Kurang (6 data) dan Cukup (8 data), perlu dibaca hati-hati: hasil ini kemungkinan besar mencerminkan label yang dibentuk dari ambang batas pada fitur yang sama, bukan bukti bahwa Random Forest "sempurna" secara umum.

Confusion Matrix

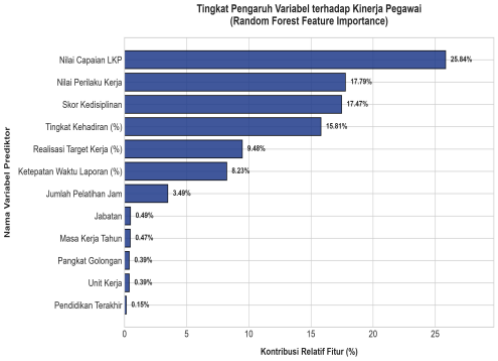
Confusion matrix pada data uji menunjukkan seluruh 64 prediksi jatuh tepat pada diagonal utama (Gambar 2): 17 dari 17 pegawai kelas Baik, 8 dari 8 pegawai kelas Cukup, 6 dari 6 pegawai kelas Kurang, dan 33 dari 33 pegawai kelas Sangat Baik diklasifikasikan dengan benar, tanpa satu pun kesalahan silang antarkelas.



Gambar 2 Confusion matrix model Random Forest pada 64 data uji.

Tidak adanya kesalahan klasifikasi sama sekali, termasuk pada pasangan kelas yang berdekatan seperti Baik–Sangat Baik atau Cukup–Kurang, mengindikasikan bahwa batas antarkelas pada dataset ini sangat tajam—konsisten dengan label Kategori Kinerja yang dibentuk melalui aturan ambang batas yang juga tercermin kuat pada fitur numerik seperti Nilai Capaian LKP. Pada penerapan di periode atau unit lain, kesalahan silang antarkelas yang berdekatan masih mungkin muncul.

Feature Importance



Gambar 3 Tingkat pengaruh variabel prediktor terhadap kinerja pegawai (Random Forest feature importance).

Analisis *feature importance* (Gambar 3) menunjukkan Nilai Capaian LKP sebagai fitur paling berpengaruh dengan kontribusi relatif 25,84%, diikuti Nilai Perilaku Kerja (17,79%), Skor Kedisiplinan (17,47%), dan Tingkat Kehadiran (15,81%). Keempat fitur ini bersama-sama menyumbang lebih dari 75% total importance, sementara Realisasi Target Kerja (9,48%) dan Ketepatan Waktu Laporan (8,23%) memberikan kontribusi sedang. Variabel administratif seperti Jabatan, Masa Kerja, Pangkat/Golongan, Unit Kerja, dan Pendidikan Terakhir masing-masing menyumbang kurang dari 0,5%, menunjukkan bahwa model mengandalkan indikator kinerja operasional, bukan atribut demografis atau struktural pegawai, dalam membentuk prediksinya.

Perlu ditegaskan bahwa nilai *feature importance* ini hanya mengukur kontribusi statistik fitur terhadap penurunan impurity di dalam model,

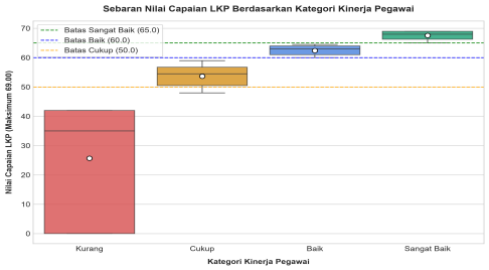
Journal of Science and Social Research ISSN 2615 – 4307 (Print)
Oct 2026, IX (5): 9335 – 9346 ISSN 2615 – 3262 (Online)
Available online at http://jurnal.goretanpena.com/index.php/JSSR

bukan bukti hubungan sebab-akibat antara fitur dan kinerja pegawai. Dominasi Nilai Capaian LKP yang sangat tinggi, bersama dengan hasil confusion matrix yang sempurna pada bagian 3.2.1, memperkuat dugaan keterkaitan erat (bukan sekadar korelasi biasa) antara fitur ini dan proses pembentukan label target, yang dibahas lebih mendalam pada bagian 3.3.

Pembahasan

Hasil pengujian menunjukkan model Random Forest mampu memisahkan keempat kategori kinerja pegawai secara sempurna pada data uji, dengan akurasi, precision, recall, dan F1-score masing-masing bernilai 1,0000 untuk setiap kelas. Secara teknis, hal ini menunjukkan bahwa hubungan antara fitur kinerja operasional (Nilai Capaian LKP, Perilaku Kerja, Kedisiplinan, Kehadiran) dengan label Kategori Kinerja sangat konsisten dan mudah dipelajari model berbasis pohon keputusan. Nilai AUC sebesar 1,000 pada seluruh kelas memperkuat temuan bahwa tidak ada tumpang tindih probabilitas antarkelas. Namun, kesempurnaan metrik pada seluruh kelas—termasuk kelas minoritas dengan hanya enam sampel uji—jarang ditemukan pada studi klasifikasi kinerja pegawai lain, sehingga angka ini perlu ditafsirkan hati-hati dan bukan sekadar dianggap sebagai bukti keunggulan algoritma.

Beberapa faktor berkontribusi terhadap performa yang sangat tinggi ini. Pertama, matriks korelasi antarfitur menunjukkan korelasi yang sangat kuat (0,78–0,93) antara hampir seluruh fitur numerik, yang mengindikasikan indikator-indikator tersebut saling berkaitan erat. Kedua, distribusi Kategori LKP hampir identik dengan distribusi Kategori Kinerja (lihat kembali Gambar 1), sehingga Nilai Capaian LKP memiliki hubungan ambang batas yang sangat erat dengan label target. Sebaran Nilai Capaian LKP per kategori kinerja (Gambar 4) memperlihatkan keempat kelompok hampir tidak saling tumpang tindih, pola yang secara teknis mendukung mengapa model dapat memisahkan kelas dengan sempurna.



Gambar 4 Boxplot sebaran Nilai Capaian LKP per kategori kinerja pegawai, menunjukkan pemisahan antarkelas yang sangat tajam.

Dibandingkan penelitian Sufina dan Wati [2] yang memperoleh akurasi 72,73–81,82% pada data SKP dosen berjumlah kecil, maupun Putri dan Sitohang [1] yang memperoleh akurasi 94,58% pada data Kaggle, hasil 100% pada penelitian ini jauh lebih tinggi. Kesenjangan tersebut wajar mengingat perbedaan karakteristik data: label pada data LKP institusi ini tampak dibentuk dari aturan ambang batas yang kaku, sedangkan penilaian pada studi lain umumnya mengandung lebih banyak variasi dan inkonsistensi penilaian.

Random Forest menunjukkan sejumlah kelebihan untuk data LKP, yaitu mampu menangani banyak fitur numerik dan kategorikal sekaligus, relatif tahan terhadap outlier dibandingkan model linier, dan menyediakan *feature importance* yang membantu interpretasi meskipun bukan bukti kausal. Keterbatasan utama penelitian terletak pada data: karena label kemungkinan diturunkan langsung dari kombinasi fitur yang sama dan data berasal dari satu institusi pada satu periode, hasil evaluasi pada bagian 3.2 belum tentu dapat digeneralisasi ke institusi atau periode lain. Validasi lanjutan pada data dari periode berbeda dengan proses penilaian yang lebih beragam menjadi prasyarat sebelum klaim performa model dapat dipertanggungjawabkan secara operasional.

Dari sisi implikasi praktis, model

prediksi semacam ini sebaiknya diposisikan sebagai alat bantu pendukung keputusan, bukan satu-satunya dasar penentuan penilaian, promosi, sanksi, atau keputusan kepegawaian lainnya. Penerapan perlu mempertimbangkan privasi data pegawai, potensi bias pada fitur yang digunakan, kejelasan dasar penilaian bagi pegawai, serta validasi oleh pihak berwenang di bidang kepegawaian. Rekomendasi pengembangan selanjutnya adalah menguji ulang metodologi yang sama pada data LKP periode berikutnya atau unit lain di institusi, dan membandingkannya dengan metode penilaian manual yang berlaku saat ini.

SIMPULAN

Penelitian ini berhasil menerapkan algoritma Random Forest untuk mengklasifikasikan kategori kinerja pegawai berdasarkan data LKP dan tujuh variabel pendukung pada dataset berjumlah 320 pegawai. Model dengan konfigurasi 100 pohon dan kedalaman maksimum 10 memperoleh akurasi, precision, recall, dan F1-score sebesar 1,0000 pada seluruh empat kelas kinerja saat diuji pada 64 data uji yang terpisah dari data latih, dengan Nilai Capaian LKP, Nilai Perilaku Kerja, Skor Kedisiplinan, dan Tingkat Kehadiran teridentifikasi sebagai empat fitur paling berpengaruh melalui analisis *feature importance*. Perhitungan manual Gini Impurity pada enam sampel pegawai aktual menunjukkan bahwa pemisahan berbasis Nilai Capaian LKP menghasilkan penurunan impurity terbesar (0,3056) dibandingkan kandidat fitur pembanding, konsisten dengan hasil feature importance model penuh.

Kontribusi penelitian ini terletak pada demonstrasi tahapan metodologis yang transparan dan dapat direplikasi, mulai dari pembersihan data, perhitungan manual mekanisme pohon keputusan, hingga evaluasi model pada data terpisah. Keterbatasan utama adalah korelasi antarfitur yang sangat tinggi dan label yang kemungkinan dibentuk dari ambang batas fitur yang sama, sehingga akurasi sempurna belum tentu berlaku pada periode atau unit data lain. Saran pengembangan meliputi: pengujian pada data LKP periode berikutnya, optimasi hyperparameter melalui *cross-validation*, analisis *permutation importance* untuk memeriksa kestabilan feature importance, serta kajian etis mengenai privasi dan potensi bias sebelum model digunakan dalam keputusan kepegawaian.

UCAPAN TERIMA KASIH

Terima kasih kepada Bapak Assoc. Prof. Dr Muhammad Syahputra Novelan, S,Kom., M.Kom. yang telah memberikan banyak kontribusi teknis serta masukan yang bermanfaat, serta para orang tua penulis yang telah memberi doa dan restunya sehingga penulis dapat menyelesaikan penelitian ini.

DAFTAR PUSTAKA

J. H. Putri and S. Sitohang, "Klasifikasi Kinerja Pegawai Menggunakan Algoritma Random Forest," *Journal Automation Computer Information System*, vol. 6, no. 1, 2026, doi: 10.47134/jacis.v6i1.170.

Sufina and L. Wati, "Implementation of Random Forest Algorithm in Lecturer Performance Evaluation System," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 2, pp. 790–798, 2025, doi: 10.30811/jaise.v5i2.6975.

A. Uppal, Y. Awasthi, and A. Srivastava, "Machine learning-based approaches for enhancing human resource management using automated employee performance prediction systems," *International Journal of Organizational Analysis*, vol. 33, no. 8, pp. 2307–2346, 2025, doi: 10.1108/IJOA-07-2024-4643.

S. Jaya, A. Yulianto, and E. Purwanto,

"Computational Modeling Using Linear Regression and Random Forest to Analyze the Impact of Workload on Employee Performance Evaluations," *International Journal of Computational Methods and Experimental Measurements*, vol. 13, no. 2, pp. 227–237, 2025, doi: 10.18280/ijcmem.130202.

Y. Wang, "Multiple Factors' Influence on the Employees' Performance: Analysis Based on Random Forest and Polynomial Regression," in *Proc. 1st Int. Conf. on E-commerce and Artificial Intelligence (ECAI 2024)*, SciTePress, pp. 51–55, 2025, doi: 10.5220/0013206200004568.

M. Pratt, M. Boudhane, and S. Cakula, "Employee Attrition Estimation Using Random Forest Algorithm," *Baltic Journal of Modern Computing*, vol. 9, no. 1, pp. 49–66, 2021, doi: 10.22364/bjmc.2021.9.1.04.

S. Nayak and P. Palai, "Employee Attrition System Prediction using Random Forest Classifier," *International Journal of Computer and Communication Technology*, 2023, doi: 10.47893/ijcct.2023.1445.

M. Dabbagh, K. Saleem, A. Al-Jumaily, M. Tahir, and A. Amphawan, "Application of Machine Learning Algorithms for Predicting Employee Attrition," in *2024 IEEE Int. Conf. on Future Machine Learning and Data Science (FMLDS)*, pp. 21–26, 2024, doi: 10.1109/FMLDS63805.2024.00014.

D. Kurniadi, F. Nuraeni, N. Faturrohman, and A. Mulyani, "Klasifikasi Perputaran Karyawan Perusahaan Menggunakan Algoritma Random Forest dan Random Over-sampling," *Edu Komputika Journal*, vol. 10, no. 2, pp. 93–103, 2023, doi: https://doi.org/10.15294/edukomputika.v10i2.73782.

B. R. Prasetyo, L. P. Apiliani, C. N. Intan, and K. Jonathan, "Prediksi Pengunduran Diri Karyawan Menggunakan Metode Algoritma Random Forest," *Journal of Data Science Methods and Applications (JoDMApps)*, vol. 1, no. 2, pp. 75–81, Nov. 2025, doi: 10.30873/jodmapps.v1i2.pp75-81.

K. Nasution, Masrizal, and S. Z. Harahap, "Simulasi Kinerja Karyawan di Kantor Pertanahan Labuhanbatu Menggunakan Algoritma C4.5," *Informatika (Universitas Labuhanbatu)*, vol. 12, no. 3, pp. 584–593, Agu. 2024.

Z. Nayem and A. Uddin, "Unbiased employee performance evaluation using machine learning," *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 10, no. 1, p. 100243, 2024, doi: 10.1016/j.joitmc.2024.100243.

M. D. Triyadi, M. S. Novelan, and R. F. Wijaya, "Penerapan Data Mining dan Machine Learning dalam Menentukan Strategi Bisnis UMKM Berdasarkan Tren Penjualan dan Perilaku Konsumen," *Instal: Jurnal Komputer*, vol. 18, no. 5, pp. 400–409, 2026.

S. Darma, A. J. Al Fayed, S. M. P. Pardede, M. H. Aqsha, and M. S. Novelan, "Predictive Analysis of Flood Risk Factors Based on a Machine Learning Approach: Comparative Study of SVM and XGBoost Algorithms," *Journal of Technology and Computer (JOTECHCOM)*, vol. 3, no. 1, pp. 24–33, Feb. 2026.

S. Kapoor and A. Narayanan, "Leakage and the reproducibility crisis in machine-learning-based science," *Patterns*, vol. 4, no. 9, p. 100804, 2023, doi: 10.1016/j.patter.2023.100804.

K. T. Aprilia, I. P. Sitorus, M. R. Ridha, and M. S. Novelan, "Comparison of Random Forest and Naïve Bayes Classifier Methods for Monkeypox Classification," *Journal of Technology and Computer (JOTECHCOM)*, vol. 3, no. 1, pp. 58–67, Feb. 2026.

D. W. Brata, A. Djunaidy, D. O. Siahaan,

and S. Handoyo, "The Acquiring Optimal Models of Random Forest and Support Vector Machine Through Tuning Hyperparameters in Classifying the Imbalanced Data," *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 17, no. 2, pp. 739–748, 2026.

T. Wongvorachan, S. He, and O. Bulut, "A Comparison of Undersampling, Oversampling, and SMOTE Methods for Dealing with Imbalanced Classification in Educational Data Mining," *Information*, vol. 14, no. 1, p. 54, 2023, doi: 10.3390/info14010054.

D. Chicco and G. Jurman, "The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification," *BioData Mining*, vol. 16, no. 1, 2023, doi: 10.1186/s13040-023-00322-4.

I. Altaf and M. A. Chachoo, "Permuted Gini Importance – PaP Impurity Measurement for Tree-Based Models," *Journal of Soft Computing and Data Mining*, no. 2, pp. 96–109, Dec. 2024.