

# Komparasi Random Forest dan Artificial Neural Network dalam Prediksi Dampak AI terhadap Pekerjaan 2030

Jefri Jaka Tirta<sup>1,\*</sup>, Heni Sulistiani<sup>2</sup>

<sup>1</sup> Fakultas Teknik dan Ilmu Komputer, Informatika, Universitas Teknokrat Indonesia, Lampung, Indonesia

<sup>2</sup> Fakultas Teknik dan Ilmu Komputer, Magister Ilmu Komputer, Universitas Teknokrat Indonesia, Lampung, Indonesia

Email: <sup>1,\*</sup>jefri\_jaka\_tirta@teknokrat.ac.id, <sup>2</sup>henisulistiani@teknokrat.ac.id,

Email Penulis Korespondensi: jefri\_jaka\_tirta@teknokrat.ac.id

Submitted: 22/04/2026; Accepted: 02/06/2026; Published: 05/06/2026

**Abstrak**—Perkembangan *Artificial Intelligence* (AI) diperkirakan akan memengaruhi struktur pekerjaan di masa depan, khususnya terkait risiko otomatisasi pada tahun 2030 sebagai periode percepatan adopsi AI di berbagai sektor industri. Penelitian ini bertujuan membandingkan kinerja algoritma Random Forest dan Artificial Neural Network (ANN) dalam memprediksi dampak AI terhadap pekerjaan. Penelitian menggunakan dua pendekatan pemodelan, yaitu regresi untuk memprediksi probabilitas otomatisasi pekerjaan dan klasifikasi untuk menentukan kategori risiko pekerjaan ke dalam kelas Low, Medium, dan High melalui proses *discretization*. Dataset diperoleh dari Kaggle dengan jumlah 3.000 data dan diproses melalui tahap pra-pemrosesan, rekayasa fitur, serta pembagian data latih dan data uji dengan rasio 80:20. Evaluasi regresi dilakukan menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi ( $R^2$ ), sedangkan evaluasi klasifikasi menggunakan akurasi dan *F1-score*. Hasil penelitian menunjukkan bahwa Random Forest memiliki performa regresi terbaik dengan nilai MAE 0,0786, RMSE 0,0932, dan  $R^2$  0,8640, lebih baik dibandingkan ANN dengan MAE 0,0949, RMSE 0,1137, dan  $R^2$  0,7973. Pada tugas klasifikasi, kedua algoritma memperoleh akurasi dan *F1-score* sebesar 99,33%. Penelitian ini menunjukkan bahwa Random Forest lebih stabil pada *tabular data* serta berkontribusi dalam analisis komparatif *ensemble learning* dan *neural network* untuk prediksi dampak AI terhadap pekerjaan.

**Kata Kunci:** Random Forest; Artificial Neural Network; Dampak AI; Otomatisasi Pekerjaan; *Machine Learning*

**Abstract**—The development of Artificial Intelligence (AI) is expected to affect the future employment structure, particularly regarding automation risks in 2030 as a period of accelerated AI adoption across various industrial sectors. This study aims to compare the performance of the Random Forest and Artificial Neural Network (ANN) algorithms in predicting the impact of AI on jobs. The study employed two modeling approaches, namely regression to predict job automation probability and classification to determine job risk categories into Low, Medium, and High classes through a discretization process. The dataset was obtained from Kaggle with a total of 3,000 records and processed through preprocessing, feature engineering, and train-test splitting with an 80:20 ratio. Regression evaluation was conducted using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and coefficient of determination ( $R^2$ ), while classification evaluation used accuracy and F1-score. The results showed that Random Forest achieved the best regression performance with an MAE of 0.0786, RMSE of 0.0932, and  $R^2$  of 0.8640, outperforming ANN with an MAE of 0.0949, RMSE of 0.1137, and  $R^2$  of 0.7973. In the classification task, both algorithms achieved an accuracy and F1-score of 99.33%. This study shows that Random Forest is more stable on tabular data and contributes to the comparative analysis of ensemble learning and neural network approaches for predicting the impact of AI on jobs.

**Keywords:** Random Forest; Artificial Neural Network; AI Impact; Job Automation; Machine Learning

## 1. PENDAHULUAN

Perkembangan *Artificial Intelligence* (AI) telah membawa perubahan signifikan pada berbagai sektor industri dan dunia kerja. Penerapan AI dalam proses bisnis, otomasi, dan pengambilan keputusan meningkatkan efisiensi dan produktivitas melalui implementasi *chatbot*, *smart city*, dan *machine learning* [1], [2]. Dalam beberapa tahun terakhir, AI tidak hanya berperan sebagai alat bantu, tetapi juga telah berkembang menjadi sistem yang mampu mengambil keputusan secara otomatis pada berbagai domain seperti keuangan, kesehatan, pendidikan, hingga manufaktur.

Dalam konteks ketenagakerjaan, perkembangan AI memunculkan kekhawatiran terhadap meningkatnya risiko otomatisasi pekerjaan, khususnya pada pekerjaan yang bersifat rutin dan berulang [3], [4]. Laporan *World Economic Forum* [5] menunjukkan bahwa sejumlah pekerjaan administratif dan operasional diperkirakan mengalami penurunan akibat percepatan digitalisasi dan otomatisasi. Hal ini mengindikasikan adanya pergeseran struktur pekerjaan yang cukup signifikan, di mana sebagian pekerjaan lama akan tergantikan, sementara jenis pekerjaan baru akan muncul seiring perkembangan teknologi.

Di sisi lain, pekerjaan yang membutuhkan kreativitas, pemecahan masalah kompleks, dan interaksi sosial dinilai lebih sulit digantikan oleh AI karena masih memerlukan kemampuan kognitif dan kontekstual manusia [6]. Kondisi ini menunjukkan bahwa dampak AI terhadap pekerjaan bersifat tidak merata (*uneven impact*), sehingga perubahan yang terjadi tidak dapat digeneralisasi pada semua sektor pekerjaan. Oleh karena itu, diperlukan pendekatan analitis yang mampu mengukur tingkat risiko otomatisasi secara lebih terstruktur berdasarkan karakteristik pekerjaan.

Selain itu, transformasi digital yang dipicu oleh AI juga berdampak pada perubahan kebutuhan keterampilan tenaga kerja. Perusahaan kini semakin menuntut kemampuan digital, analisis data, dan adaptasi teknologi, yang menyebabkan kesenjangan keterampilan (*skill gap*) semakin melebar antara tenaga kerja yang ada dan kebutuhan industri. Situasi ini menjadikan isu prediksi dampak AI terhadap pekerjaan semakin penting untuk dikaji secara ilmiah, khususnya dalam mendukung pengambilan keputusan di bidang ketenagakerjaan dan pendidikan.

Berbagai penelitian sebelumnya telah memanfaatkan metode *machine learning* untuk melakukan prediksi dan klasifikasi risiko pada data ketenagakerjaan maupun data tabular lainnya. Namun, sebagian besar penelitian masih berfokus pada peningkatan akurasi model tanpa menganalisis karakteristik pembelajaran algoritma terhadap data ketenagakerjaan yang memiliki kombinasi fitur numerik, kategorikal, dan keterampilan berbasis teks [10], [11]. Selain itu, penelitian terkait prediksi dampak AI terhadap pekerjaan masih relatif terbatas dan umumnya lebih menitikberatkan pada analisis konseptual atau statistik deskriptif dibandingkan pendekatan prediktif berbasis *machine learning* yang lebih objektif dan berbasis data. Pada data ketenagakerjaan berbasis tabular, pemilihan algoritma menjadi tantangan penting karena setiap metode memiliki karakteristik pembelajaran yang berbeda. *Random Forest* dikenal efektif dalam menangani data tabular multivariabel karena memiliki kemampuan generalisasi yang baik, tahan terhadap *overfitting*, serta mampu menangkap hubungan nonlinier melalui pendekatan *ensemble learning* [10]. Selain itu, *Random Forest* juga memiliki keunggulan dalam menangani data dengan fitur yang heterogen serta tidak sensitif terhadap skala data, sehingga cocok digunakan pada dataset dengan karakteristik kompleks.

Sementara itu, *Artificial Neural Network (ANN)* memiliki kemampuan dalam mempelajari pola kompleks dan hubungan nonlinier melalui mekanisme jaringan saraf berlapis [11]. *ANN* mampu melakukan representasi fitur secara otomatis (*feature representation learning*), sehingga sering digunakan pada permasalahan dengan struktur data yang kompleks. Meskipun *ANN* lebih sering digunakan pada data tidak terstruktur seperti gambar dan teks, beberapa penelitian menunjukkan bahwa *ANN* tetap memiliki performa kompetitif pada data tabular ketika terdapat interaksi fitur yang kompleks dan multivariat [11].

Namun demikian, perbedaan karakteristik antara *Random Forest* dan *ANN* menyebabkan keduanya memiliki keunggulan dan keterbatasan masing-masing dalam konteks data ketenagakerjaan. *Random Forest* cenderung lebih stabil dan mudah diinterpretasikan, sedangkan *ANN* memiliki fleksibilitas yang lebih tinggi namun membutuhkan tuning parameter yang lebih sensitif. Oleh karena itu, diperlukan kajian komparatif untuk mengetahui algoritma mana yang lebih sesuai dalam konteks prediksi dampak AI terhadap pekerjaan.

Berbagai penelitian sebelumnya telah memanfaatkan *machine learning* pada data tabular untuk tugas prediksi dan klasifikasi. Helmud et al. [10] membandingkan algoritma *Random Forest* dan *Decision Tree* pada tugas klasifikasi dan menunjukkan bahwa *Random Forest* memiliki performa yang lebih baik berdasarkan *confusion matrix*. Namun, penelitian tersebut hanya berfokus pada tugas klasifikasi dan belum membahas prediksi regresi pada data ketenagakerjaan. Rakshith et al. [11] melakukan analisis perbandingan performa *Artificial Neural Network (ANN)* dan *Random Forest* pada data industri manufaktur. Penelitian tersebut menunjukkan bahwa kedua algoritma mampu digunakan untuk memodelkan hubungan nonlinier, tetapi konteks penelitian masih terbatas pada data industri teknis dan belum diterapkan pada prediksi dampak AI terhadap pekerjaan. Haryanto et al. [12] melakukan komparasi beberapa algoritma *machine learning* dalam prediksi harga rumah menggunakan data tabular. Penelitian tersebut menunjukkan pentingnya pemilihan algoritma yang sesuai terhadap karakteristik data, namun hanya berfokus pada pendekatan regresi. Sementara itu, Sihombing dan Yuliati [13] menerapkan *machine learning* pada klasifikasi risiko data kesehatan berbasis tabular. Penelitian tersebut menunjukkan bahwa *machine learning* efektif digunakan pada data heterogen, tetapi belum memanfaatkan kombinasi fitur numerik, kategorikal, dan keterampilan berbasis teks.

Berdasarkan penelitian terdahulu tersebut, masih terdapat *research gap* berupa terbatasnya penelitian yang membandingkan *Random Forest* dan *Artificial Neural Network (ANN)* dalam konteks prediksi dampak AI terhadap pekerjaan menggunakan pendekatan regresi dan klasifikasi secara bersamaan. Selain itu, integrasi fitur numerik, kategorikal, dan keterampilan berbasis teks dalam satu skema pemodelan masih jarang dibahas pada penelitian sebelumnya. Oleh karena itu, penelitian ini dilakukan untuk mengisi kesenjangan tersebut melalui komparasi *Random Forest* dan *ANN* dalam memprediksi probabilitas otomatisasi pekerjaan serta klasifikasi tingkat risiko pekerjaan pada tahun 2030.

Penelitian ini menggunakan dua pendekatan pemodelan, yaitu regresi untuk memprediksi probabilitas otomatisasi pekerjaan serta klasifikasi berbasis *discretization* terhadap probabilitas tersebut guna membentuk kategori risiko pekerjaan. Pendekatan ini digunakan untuk menganalisis kemampuan model dalam mempelajari pola numerik kontinu maupun pola kategorikal yang terbentuk dari tingkat probabilitas otomatisasi.

Berdasarkan kondisi tersebut, penelitian ini tidak hanya berfokus pada pencarian algoritma dengan akurasi terbaik, tetapi juga pada analisis perbandingan karakteristik pembelajaran antara pendekatan *ensemble learning* dan *neural network* dalam memprediksi dampak AI terhadap pekerjaan. Oleh karena itu, penelitian ini bertujuan untuk melakukan komparasi antara *Random Forest* dan *ANN* dalam memprediksi dampak AI terhadap pekerjaan pada tahun 2030 melalui dua pendekatan pemodelan, yaitu regresi probabilitas otomatisasi pekerjaan dan klasifikasi tingkat risiko pekerjaan ke dalam kategori Low, Medium, dan High. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan model prediksi dampak AI pada sektor ketenagakerjaan, sekaligus menjadi dasar dalam perumusan strategi *upskilling* dan *reskilling* tenaga kerja di era AI yang terus berkembang secara cepat.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

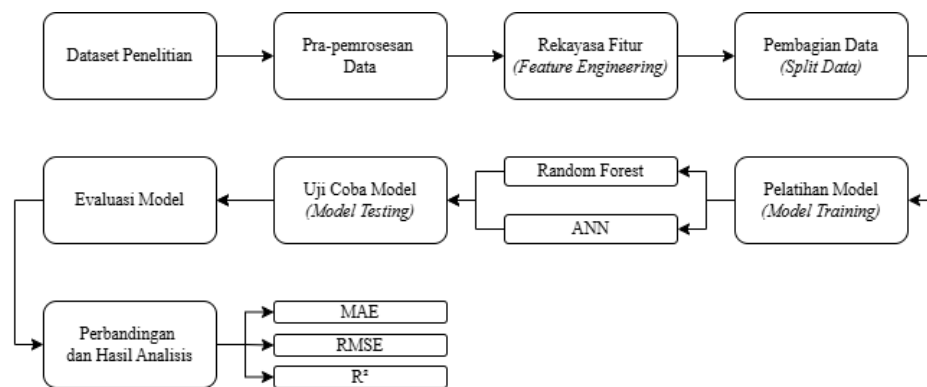
Penelitian ini menggunakan pendekatan *machine learning* untuk melakukan analisis dan perbandingan kinerja algoritma *Random Forest* dan *Artificial Neural Network (ANN)* dalam memprediksi dampak penerapan kecerdasan

buatan (Artificial Intelligence) terhadap pekerjaan pada tahun 2030. Pendekatan komparatif semacam ini umum digunakan dalam penelitian prediktif berbasis data tabular untuk mengidentifikasi algoritma dengan performa paling optimal pada konteks permasalahan tertentu, sekaligus memberikan gambaran yang lebih objektif dalam memilih model terbaik berdasarkan karakteristik data yang digunakan [12].

Metodologi penelitian disusun secara sistematis dan terstruktur, mencakup tahapan pengumpulan dataset, analisis awal data, pra-pemrosesan data, rekayasa fitur, pembagian data, pemodelan dan pelatihan model, serta evaluasi dan analisis komparatif. Penyusunan tahapan secara berurutan ini bertujuan untuk memastikan bahwa setiap proses dalam pipeline machine learning dilakukan secara konsisten, terkontrol, dan dapat dipertanggungjawabkan secara ilmiah, sebagaimana telah diterapkan dalam berbagai penelitian komparasi algoritma machine learning sebelumnya [13].

Alur metodologi penelitian secara keseluruhan ditunjukkan pada Gambar 1, yang menggambarkan tahapan-tahapan utama penelitian serta hubungan antarproses dalam membangun model prediksi dari awal hingga evaluasi akhir. Diagram alur tersebut digunakan sebagai panduan utama dalam pelaksanaan penelitian agar setiap tahapan dapat dilakukan secara berurutan, sistematis, dan konsisten. Dengan demikian, hasil yang diperoleh dapat dianalisis dan dibandingkan secara objektif, sekaligus meminimalkan potensi bias yang dapat muncul pada tahap evaluasi model [14].

Berdasarkan alur metodologi tersebut, tahapan penelitian selanjutnya dijelaskan secara rinci pada subbagian berikutnya, yang mencakup penjelasan mengenai dataset penelitian, proses pra-pemrosesan data, rekayasa fitur, pembagian data, pelatihan model, serta perbandingan kinerja algoritma Random Forest dan Artificial Neural Network dalam konteks prediksi dampak kecerdasan buatan terhadap pekerjaan.



Gambar 1. Diagram Alur Metodologi Penelitian

Gambar 1 menunjukkan alur metodologi penelitian yang menggambarkan tahapan-tahapan utama dalam analisis. Tahapan dimulai dari pengumpulan dataset, dilanjutkan dengan pra-pemrosesan data, rekayasa fitur, dan pembagian data. Setelah itu, model dilatih menggunakan algoritma Random Forest dan Artificial Neural Network (ANN). Tahap akhir adalah evaluasi model, diikuti dengan perbandingan dan analisis hasil. Diagram ini membantu memastikan bahwa setiap langkah dilakukan secara berurutan, konsisten, dan objektif, sehingga hasil yang diperoleh dapat dibandingkan secara adil dan meminimalkan bias pada evaluasi model.

## 2.2 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini adalah `AI_Impact_on_Jobs_2030.csv` yang diperoleh dari platform Kaggle. Dataset ini juga telah digunakan dalam sejumlah penelitian sebelumnya yang membahas prediksi dampak penerapan kecerdasan buatan terhadap pekerjaan, sehingga memiliki validitas empiris yang memadai untuk analisis komparatif algoritma *machine learning* [12].

Dataset dimuat menggunakan pustaka `pandas` dengan perintah `df = pd.read_csv("AI_Impact_on_Jobs_2030.csv")`, kemudian diverifikasi dimensinya melalui pemeriksaan ukuran data menggunakan `df.shape`. Hasil pemeriksaan menunjukkan bahwa dataset terdiri dari 3000 baris dan 18 kolom, yang mencakup atribut numerik, kategorikal, serta indikator keterampilan. Struktur awal dataset ditinjau dengan menampilkan beberapa baris pertama data menggunakan `df.head()` guna memastikan kesesuaian format dan kelengkapan isi data sebelum dilakukan pemodelan lebih lanjut.

Struktur awal dataset ditinjau dengan menampilkan beberapa baris pertama data menggunakan `df.head()` guna memastikan kesesuaian format dan kelengkapan isi data sebelum dilakukan pemodelan lebih lanjut. Contoh sebagian data dari dataset ditunjukkan pada Tabel 1.

Tabel 1. Contoh Data Dataset `AI_Impact_on_Jobs_2030`

Job Title	Average Salary	Years Experience	Education Level	AI Exposure Index	Tech Growth Factor
Security Guard	45795	6	High School	0.32	0.41



Job Title	Average Salary	Years Experience	Education Level	AI Exposure Index	Tech Growth Factor
Research Scientist	133355	12	PhD	0.81	0.79
Construction Worker	146216	9	Diploma	0.55	0.63
Software Engineer	136530	8	Bachelor	0.88	0.91
Financial Analyst	70397	5	Bachelor	0.73	0.68

Berdasarkan Tabel 1, dataset tidak hanya memuat atribut pekerjaan dan faktor teknologi, tetapi juga sejumlah indikator keterampilan yang direpresentasikan dalam variabel Skill\_1 hingga Skill\_10. Variabel tersebut menggambarkan tingkat kemampuan yang dibutuhkan dalam suatu pekerjaan. Kombinasi atribut pekerjaan, faktor teknologi, serta indikator keterampilan pada Tabel 1 menunjukkan bahwa dataset memiliki karakteristik data yang cukup beragam dan kompleks untuk digunakan dalam analisis machine learning.

Karakteristik dataset yang heterogen tersebut sesuai untuk pengujian algoritma Random Forest dan Artificial Neural Network (ANN), yang dikenal memiliki kemampuan dalam menangani hubungan nonlinier serta interaksi kompleks antar fitur pada data multivariabel [13].

### 2.3 Analisis Awal Data

Analisis awal data dilakukan untuk memahami struktur dan kualitas dataset sebelum proses pemodelan. Pemeriksaan tipe data dan struktur dataset dilakukan menggunakan `df.info()` guna mengidentifikasi fitur numerik dan kategorikal yang akan digunakan dalam proses analisis regresi dan klasifikasi. Selanjutnya, keberadaan nilai hilang diperiksa menggunakan `df.isna().sum()`, dan hasil analisis menunjukkan bahwa dataset tidak memiliki nilai hilang pada atribut utama, sehingga tidak diperlukan proses penanganan data hilang. Untuk memperoleh gambaran statistik fitur numerik, dilakukan analisis statistik deskriptif menggunakan `df.describe().T` yang menampilkan nilai minimum, maksimum, rata-rata, serta sebaran data. Selain itu, distribusi variabel target regresi, yaitu probabilitas otomatisasi pekerjaan pada tahun 2030, dianalisis untuk memahami pola sebaran tingkat risiko otomatisasi pekerjaan. Tahapan analisis awal ini penting untuk memastikan kesiapan dan kualitas data sebelum dilakukan transformasi dan pemodelan lebih lanjut, sebagaimana direkomendasikan dalam penelitian prediktif berbasis data tabular [12].

### 2.4 Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap penting dalam machine learning karena kualitas data sangat memengaruhi kinerja model [14]. Tahap ini bertujuan mengubah data mentah menjadi format yang sesuai untuk algoritma Random Forest dan Artificial Neural Network (ANN), serta dilakukan secara terintegrasi untuk menjaga konsistensi data latih dan data uji.

#### a. Pemeriksaan Struktur dan Kualitas Data

Pemeriksaan dilakukan menggunakan `df.info()` untuk melihat tipe data serta `df.isna().sum()` untuk mengecek nilai hilang, dan hasilnya menunjukkan tidak terdapat missing value. Selanjutnya, statistik deskriptif dengan `df.describe().T` digunakan untuk melihat distribusi data, nilai minimum, maksimum, rata-rata, serta potensi outlier guna memastikan data siap untuk pemodelan [13].

#### b. Pra-Pemrosesan Fitur Numerik

Fitur numerik seperti `Average_Salary`, `Years_Experience`, `AI_Exposure_Index`, dan `Tech_Growth_Factor` memiliki skala berbeda yang dapat memengaruhi model, terutama ANN yang sensitif terhadap skala data [14]. Oleh karena itu, dilakukan imputasi menggunakan median (`SimpleImputer(strategy="median")`) untuk menangani nilai ekstrem, kemudian dilakukan standarisasi dengan `StandardScaler()` agar semua fitur memiliki skala yang sama (mean 0 dan standar deviasi 1). Proses ini bertujuan menjaga keseimbangan kontribusi setiap fitur dan umum digunakan dalam penelitian machine learning [12]. Contoh perubahan skala fitur numerik sebelum dan sesudah standarisasi ditunjukkan pada Tabel 2.

**Tabel 2.** Contoh Perubahan Skala Fitur Numerik

Fitur	Nilai Awal	Setelah Standardisasi
<code>Average_Salary</code>	70397	0.12
<code>Years_Experience</code>	5	-0.41
<code>AI_Exposure_Index</code>	0.73	0.56
<code>Tech_Growth_Factor</code>	0.68	0.33

Berdasarkan Tabel 2, proses standarisasi berhasil mengubah fitur numerik yang memiliki rentang nilai berbeda menjadi skala yang lebih seragam. Transformasi ini bertujuan untuk mengurangi dominasi fitur dengan nilai besar terhadap proses pembelajaran model, sehingga setiap fitur dapat memberikan kontribusi yang lebih seimbang.



Standardisasi juga membantu meningkatkan stabilitas dan performa model, khususnya pada algoritma Artificial Neural Network (ANN) yang sensitif terhadap perbedaan skala data.

c. Pra-Pemrosesan Fitur Kategorikal

Fitur kategorikal dalam dataset mencakup Job\_Title dan Education\_Level. Karena algoritma *machine learning* tidak dapat memproses data kategorikal secara langsung, fitur-fitur tersebut ditransformasikan ke dalam bentuk numerik menggunakan teknik *one-hot encoding* dengan OneHotEncoder (`handle_unknown="ignore"`). Sebelum proses encoding, dilakukan imputasi nilai kosong menggunakan SimpleImputer (`strategy="most_frequent"`) untuk memastikan tidak terdapat nilai kosong pada data kategorikal. Teknik *one-hot encoding* dipilih karena mampu merepresentasikan setiap kategori secara independen tanpa memberikan hubungan ordinal yang tidak relevan antar kategori, sehingga sesuai untuk pemodelan data tabular multikategori [13]. Contoh transformasi fitur kategorikal ditunjukkan pada Tabel 3.

**Tabel 3.** Contoh Transformasi One-Hot Encoding

Data Awal	Hasil Encoding
Education_Level = Bachelor	Education_Level_Bachelor = 1
Education_Level = High School	Education_Level_HighSchool = 1
Job_Title = Software Engineer	Job_Title_SoftwareEngineer = 1
Job Title = Financial Analyst	Job Title_FinancialAnalyst = 1

Berdasarkan Tabel 3, proses one-hot encoding mengubah setiap kategori pada fitur kategorikal menjadi representasi numerik berbentuk biner. Setiap kategori direpresentasikan secara independen dengan nilai 1 sebagai penanda keberadaan kategori tertentu. Transformasi ini memungkinkan data kategorikal diproses oleh algoritma machine learning tanpa menimbulkan hubungan ordinal antar kategori yang sebenarnya tidak memiliki tingkatan.

d. Transformasi Fitur Keterampilan

Dataset penelitian ini memiliki sepuluh indikator keterampilan (Skill\_1 hingga Skill\_10) yang merepresentasikan profil keterampilan yang dibutuhkan dalam suatu pekerjaan. Untuk memanfaatkan seluruh indikator tersebut secara komprehensif, dilakukan proses penggabungan fitur keterampilan menjadi satu representasi berbasis teks menggunakan perintah `df["Skills_Text"] = df[skill_cols].astype(str).agg(" ".join, axis=1)`. Penggabungan ini bertujuan untuk membentuk representasi terpadu dari profil keterampilan setiap pekerjaan sehingga informasi yang sebelumnya tersebar pada beberapa kolom dapat dianalisis secara lebih efektif. Selanjutnya, fitur teks tersebut ditransformasikan menjadi vektor numerik menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF) melalui `TfidfVectorizer`. Metode TF-IDF digunakan untuk mengukur tingkat kepentingan relatif setiap keterampilan terhadap keseluruhan data, sehingga informasi keterampilan dapat direpresentasikan dalam bentuk vektor numerik yang dapat diproses oleh algoritma machine learning seperti Random Forest dan Artificial Neural Network (ANN) [14]. Contoh transformasi fitur keterampilan ditunjukkan pada Tabel 4.

**Tabel 4.** Contoh Transformasi Fitur Keterampilan (TF-IDF)

Data Awal	Setelah Digabung	Representasi TF-IDF
Skill_1 = Python, Skill_2 = DataAnalysis, Skill_3 = SQL	Python DataAnalysis SQL	0.34, 0.21, 0.17
Skill_1 = Marketing, Skill_2 = Communication, Skill_3 = Sales	Marketing Communication Sales	0.29, 0.18, 0.25

Berdasarkan Tabel 4, proses transformasi TF-IDF mengubah kumpulan keterampilan berbasis teks menjadi representasi numerik dalam bentuk bobot vektor. Nilai TF-IDF menunjukkan tingkat kepentingan relatif setiap keterampilan terhadap keseluruhan data, sehingga informasi keterampilan dapat direpresentasikan secara lebih terstruktur dan dimanfaatkan secara optimal dalam proses pembelajaran model machine learning [14].

e. Skema Pra-Pemrosesan Terintegrasi

Seluruh tahapan pra-pemrosesan, baik untuk fitur numerik, kategorikal, maupun keterampilan berbasis teks, digabungkan dalam satu skema transformasi terintegrasi menggunakan ColumnTransformer. Pendekatan ini bertujuan untuk memastikan bahwa seluruh transformasi diterapkan secara konsisten pada data latih dan data uji, serta untuk mencegah terjadinya *data leakage* yang dapat memengaruhi validitas hasil evaluasi model. Skema pra-pemrosesan terintegrasi ini sejalan dengan praktik terbaik dalam penerapan machine learning modern dan penelitian komparatif algoritma prediktif [12].

**2.5 Rekayasa Fitur**

Rekayasa fitur dilakukan untuk menghasilkan representasi data yang lebih informatif dan relevan dalam memprediksi dampak kecerdasan buatan terhadap pekerjaan pada tahun 2030. Tahap ini bertujuan meningkatkan kemampuan model dalam menangkap hubungan antarvariabel serta kompleksitas karakteristik pekerjaan. Fitur masukan (X) terdiri dari tiga kelompok, yaitu fitur numerik, fitur kategorikal, dan fitur keterampilan berbasis teks.

Fitur numerik meliputi *Average Salary*, *Years Experience*, *AI Exposure Index*, dan *Tech Growth Factor* yang merepresentasikan aspek ekonomi dan teknologi pekerjaan. Fitur kategorikal mencakup *Job Title* dan *Education Level* yang menggambarkan perbedaan struktur antar pekerjaan. Kedua jenis fitur ini dipertahankan karena memiliki keterkaitan dengan risiko otomatisasi pekerjaan.

Selain itu, terdapat sepuluh indikator keterampilan (*Skill 1–Skill 10*) yang digabung menjadi satu fitur komposit berbasis teks menggunakan  $df["Skills\_Text"] = df[skill\_cols].astype(str).agg(" ".join, axis=1)$ . Penggabungan ini bertujuan membentuk representasi profil keterampilan secara menyeluruh agar dapat diproses sebagai data teks. Pendekatan ini membantu menangkap kompleksitas keterampilan yang tidak optimal jika dipisahkan per fitur [14].

Dengan rekayasa fitur ini, seluruh informasi numerik, kategorikal, dan keterampilan dapat diintegrasikan secara utuh untuk mendukung kinerja Random Forest dan ANN dalam mempelajari pola nonlinier serta meningkatkan kualitas prediksi dampak AI terhadap pekerjaan.

## 2.6 Pembagian Data

Dataset yang telah melalui tahap pra-pemrosesan selanjutnya dibagi menjadi data latih dan data uji menggunakan metode *train–test split* dengan proporsi 80% untuk data latih dan 20% untuk data uji. Pembagian ini bertujuan untuk mengevaluasi kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Proporsi 80:20 umum digunakan dalam penelitian prediktif berbasis *machine learning* karena mampu memberikan keseimbangan yang optimal antara proses pelatihan model dan evaluasi kinerja model [12].

Penelitian ini mencakup dua jenis tugas pemodelan, yaitu regresi dan klasifikasi. Pada tugas regresi, variabel target berupa probabilitas otomatisasi pekerjaan bersifat kontinu, sehingga proses pembagian data dilakukan secara acak tanpa mempertimbangkan distribusi kelas. Pendekatan ini umum diterapkan pada permasalahan regresi karena model bertujuan untuk memprediksi nilai numerik secara langsung.

Sementara itu, pada tugas klasifikasi, kategori risiko pekerjaan tidak tersedia secara langsung pada dataset asli. Oleh karena itu, kategori risiko dibentuk melalui proses *discretization* terhadap nilai probabilitas otomatisasi pekerjaan dengan membagi data ke dalam tiga interval kategori, yaitu *Low*, *Medium*, dan *High*. Selanjutnya, kategori tersebut dipetakan ke dalam label numerik untuk memudahkan proses pemodelan menggunakan algoritma *machine learning*. Pemetaan kategori risiko dilakukan dengan skema *Low* = 0, *Medium* = 1, dan *High* = 2 menggunakan pemetaan {"Low":0, "Medium":1, "High":2}. Distribusi kelas pada variabel *Risk Category* ditunjukkan pada Tabel 5 yang menampilkan jumlah data serta persentase masing-masing kategori risiko pekerjaan dalam dataset.

**Tabel 5.** Distribusi Kelas Kategori Risiko Pekerjaan

Class	Label Code	Count	Percent
Low	0	739	24.63
Medium	1	1521	50.70
High	2	740	24.67

Berdasarkan Tabel 5, distribusi kelas kategori risiko pekerjaan menunjukkan bahwa kelas Medium memiliki jumlah data paling besar dibandingkan kelas Low dan High. Oleh karena itu, proses pembagian data pada tugas klasifikasi dilakukan menggunakan metode *stratified split* untuk mempertahankan proporsi masing-masing kelas pada data latih dan data uji. Pendekatan ini bertujuan menjaga konsistensi distribusi kelas sehingga setiap kategori risiko tetap terwakili secara proporsional pada kedua subset data.

## 2.7 Pemodelan dan Pelatihan Model

Tahap pemodelan dilakukan menggunakan dua algoritma *machine learning*, yaitu Random Forest dan Artificial Neural Network (ANN). Random Forest dipilih karena merupakan metode ensemble berbasis pohon keputusan yang mampu memodelkan hubungan nonlinier pada data tabular serta memiliki ketahanan yang baik terhadap overfitting melalui mekanisme penggabungan banyak pohon keputusan [13].

Sementara itu, ANN diimplementasikan menggunakan arsitektur Multi-Layer Perceptron (MLP) yang terdiri dari beberapa lapisan tersembunyi dengan fungsi aktivasi nonlinier. Arsitektur ini memungkinkan ANN untuk menangkap pola dan hubungan kompleks antar fitur, khususnya pada data multivariabel dengan interaksi nonlinier [14].

Pada tugas regresi, Random Forest Regressor dan ANN Regressor digunakan untuk memprediksi nilai probabilitas otomatisasi pekerjaan pada tahun 2030. Untuk meningkatkan kinerja model regresi, dilakukan pencarian hiperparameter menggunakan pendekatan *randomized search* dengan skema *cross-validation*. Pendekatan ini dipilih karena lebih efisien dibandingkan *grid search* dalam ruang parameter yang besar serta mampu menghasilkan kombinasi hiperparameter yang optimal [12].

Rentang hiperparameter yang diuji pada model Random Forest meliputi jumlah pohon keputusan (*n\_estimators*) sebesar 100–500, kedalaman pohon (*max\_depth*) sebesar 10–None, jumlah minimum sampel untuk pemisahan node (*min\_samples\_split*) sebesar 2–10, serta jumlah minimum sampel pada daun (*min\_samples\_leaf*) sebesar 1–4. Sementara itu, pada model ANN/MLP dilakukan pencarian hiperparameter terhadap jumlah neuron pada hidden layer dengan variasi (64), (128), dan (128,64), nilai *learning rate* sebesar 0.001–0.01, serta jumlah iterasi

maksimum ( $\max\_iter$ ) sebesar 300–500. Parameter terbaik yang diperoleh selanjutnya digunakan dalam proses pelatihan akhir model.

Pada tugas klasifikasi, *Random Forest Classifier* dan *Artificial Neural Network (ANN) Classifier* digunakan untuk memprediksi kategori risiko pekerjaan hasil proses *discretization* probabilitas otomatisasi ke dalam kelas *Low*, *Medium*, dan *High*. Seluruh model dilatih menggunakan skema pra-pemrosesan yang sama untuk memastikan bahwa perbandingan kinerja antar algoritma dilakukan secara adil dan objektif, sehingga perbedaan hasil yang diperoleh benar-benar mencerminkan kemampuan masing-masing algoritma dalam memodelkan data.

## 2.8 Evaluasi dan Analisis Komparatif

Evaluasi model dilakukan menggunakan metrik yang disesuaikan dengan jenis tugas pemodelan. Pada tugas regresi, kinerja diukur menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi ( $R^2$ ), di mana nilai MAE dan RMSE yang lebih kecil serta  $R^2$  yang lebih besar menunjukkan performa prediksi yang lebih baik. Kombinasi metrik ini digunakan untuk menilai akurasi sekaligus kemampuan model dalam menjelaskan variasi data target.

Pada tugas klasifikasi, evaluasi dilakukan menggunakan akurasi, precision, recall, dan F1-score. Selain itu, digunakan confusion matrix untuk menganalisis distribusi kesalahan prediksi pada kelas risiko pekerjaan (*Low*, *Medium*, dan *High*), sehingga kesalahan klasifikasi dapat dianalisis lebih rinci.

Pendekatan multi-metrik ini digunakan untuk memberikan evaluasi yang lebih komprehensif dan mengurangi bias penilaian yang hanya bergantung pada satu metrik. Pendekatan serupa juga banyak digunakan dalam penelitian komparatif machine learning pada data tabular dan masalah klasifikasi-regresi [12], [13].

Hasil evaluasi dari kedua algoritma kemudian dibandingkan untuk menentukan model dengan kinerja terbaik dalam memprediksi dampak AI terhadap pekerjaan pada tahun 2030.

Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi, yang dirumuskan pada Persamaan (1).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Root Mean Squared Error (RMSE) digunakan untuk mengukur akar dari rata-rata kuadrat kesalahan prediksi sebagaimana ditunjukkan pada Persamaan (2).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

Koefisien determinasi ( $R^2$ ) digunakan untuk mengetahui seberapa besar kemampuan model dalam menjelaskan variasi data aktual, yang dirumuskan pada Persamaan (3).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Pada tugas klasifikasi, evaluasi kinerja model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score yang diperoleh dari confusion matrix. Accuracy digunakan untuk mengukur proporsi jumlah prediksi yang benar terhadap seluruh data pengujian sebagaimana ditunjukkan pada Persamaan (4).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi kelas positif, sebagaimana ditunjukkan pada Persamaan (5)

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

Recall digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh data yang termasuk ke dalam kelas positif, sebagaimana ditunjukkan pada Persamaan (6).

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

F1-score merupakan rata-rata harmonis antara precision dan recall yang digunakan untuk memberikan keseimbangan antara kedua metrik tersebut, sebagaimana dirumuskan pada Persamaan (7).

$$F1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

Pendekatan evaluasi multi-metrik ini digunakan untuk memberikan gambaran kinerja model secara menyeluruh dan menghindari bias penilaian yang hanya bergantung pada satu metrik tertentu. Hasil evaluasi dari kedua algoritma selanjutnya dibandingkan untuk menentukan algoritma yang memiliki kinerja terbaik dalam memprediksi dampak penerapan kecerdasan buatan terhadap pekerjaan pada tahun 2030.

### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan analisis kinerja model machine learning yang digunakan untuk memprediksi dampak kecerdasan buatan (*Artificial Intelligence*) terhadap pekerjaan pada tahun 2030. Dua pendekatan pemodelan diterapkan dalam penelitian ini, yaitu regresi untuk memprediksi probabilitas otomatisasi pekerjaan dan klasifikasi untuk menentukan tingkat risiko pekerjaan. Algoritma yang digunakan adalah Random Forest dan Artificial Neural Network (ANN). Hasil pengujian selanjutnya dianalisis untuk mengetahui perbedaan performa kedua algoritma serta implikasinya terhadap prediksi risiko pekerjaan di masa mendatang.

#### 3.1 Hasil Pengujian Model Regresi

Pengujian model regresi bertujuan untuk memprediksi nilai probabilitas otomatisasi pekerjaan pada tahun 2030. Evaluasi kinerja model dilakukan menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi ( $R^2$ ). Hasil evaluasi ditunjukkan pada Tabel 6.

**Tabel 6.** Hasil Evaluasi Model Regresi

Model	MAE	RMSE	$R^2$
Random Forest ( <i>Baseline</i> )	0,0799	0,0949	0,8589
ANN / MLP ( <i>Baseline</i> )	0,0959	0,1147	0,7939
Random Forest ( <i>Tuning</i> )	0,0786	0,0932	0,8640
ANN / MLP ( <i>Tuning</i> )	0,0949	0,1137	0,7973

Berdasarkan Tabel 6, Random Forest menunjukkan performa yang lebih baik dibandingkan Artificial Neural Network (ANN) pada seluruh skenario pengujian. Pada model tuning, Random Forest menghasilkan MAE 0,0786, RMSE 0,0932, dan  $R^2$  0,8640, yang lebih baik dibandingkan ANN dengan MAE 0,0949, RMSE 0,1137, dan  $R^2$  0,7973. Hal ini menunjukkan bahwa Random Forest memiliki tingkat akurasi prediksi yang lebih tinggi dalam memodelkan probabilitas otomatisasi pekerjaan.

Untuk memperkuat analisis kinerja model, dilakukan evaluasi tambahan menggunakan metrik MAE, RMSE, dan  $R^2$  pada data latih dan data uji. Hasil pengujian tersebut disajikan pada Tabel 7.

**Tabel 7.** Perbandingan Performa Model pada Data Latih dan Data Uji

Model	MAE	RMSE	$R^2$
Random Forest (Train)	0,0709	0,0879	0,8731
Random Forest (Test)	0,0786	0,0932	0,8640
ANN / MLP (Train)	0,0557	0,0695	0,9205
ANN / MLP (Test)	0,0949	0,1137	0,7973

Hasil pada Tabel 7 menunjukkan bahwa Random Forest memiliki selisih performa yang relatif kecil antara data latih dan data uji serta nilai  $R^2$  yang stabil, sehingga tidak mengalami overfitting yang signifikan dan memiliki kemampuan generalisasi yang baik. Stabilitas ini menunjukkan bahwa model mampu mempertahankan performa pada data baru, yang merupakan indikator penting dalam evaluasi model prediktif. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa Random Forest sebagai metode ensemble mampu menghasilkan kinerja prediksi yang tinggi dan lebih robust terhadap overfitting karena menggabungkan banyak pohon keputusan melalui mekanisme bagging dan pemilihan fitur secara acak [15].


Sebaliknya, Artificial Neural Network menunjukkan penurunan performa yang cukup besar antara data latih dan data uji, khususnya pada nilai  $R^2$  dari 0,9205 menjadi 0,7973. Hal ini mengindikasikan adanya kecenderungan overfitting pada model ANN, di mana model terlalu menyesuaikan diri terhadap data latih sehingga kemampuan generalisasinya menurun pada data uji. Kondisi ini juga menunjukkan bahwa ANN lebih sensitif terhadap struktur data dan parameter pelatihan, sehingga membutuhkan pengaturan hiperparameter yang lebih optimal untuk mencapai performa yang stabil. Hasil ini sejalan dengan kajian bahwa model single learner seperti ANN memiliki risiko overfitting yang lebih tinggi dibandingkan metode ensemble.

Muhammad Wisnu Nugroho et al. [16] menjelaskan bahwa Random Forest mampu mengurangi overfitting melalui mekanisme penggabungan banyak pohon keputusan secara acak, sehingga menghasilkan performa yang lebih stabil dan generalisasi yang lebih baik. Selain itu, mekanisme ini juga membuat model lebih tahan terhadap noise pada data serta variasi distribusi fitur.

Perbedaan ini juga diperkuat oleh Widjiyati [17] serta Pahlevi et al. [18] yang menyatakan bahwa Random Forest memiliki stabilitas lebih baik pada data tabular karena mekanisme bagging yang menurunkan variansi model dan meningkatkan konsistensi prediksi. Lebih lanjut, Ilham Kurniawan dkk. [19] menunjukkan bahwa Random Forest mampu mencapai performa tinggi dengan keseimbangan False Positive dan False Negative yang baik, sehingga lebih andal pada data dengan kompleksitas tinggi serta distribusi fitur yang beragam.


Gambar 2 menunjukkan distribusi probabilitas otomatisasi pekerjaan tahun 2030 yang tersebar dari tingkat rendah hingga tinggi dengan konsentrasi terbesar pada kategori risiko menengah. Temuan ini mengindikasikan bahwa

sebagian besar pekerjaan berada pada fase transisi, di mana otomatisasi masih bersifat parsial dan sangat dipengaruhi oleh tingkat adopsi teknologi AI.




**Gambar 2.** Distribusi probabilitas otomatisasi pekerjaan tahun 2030

Perbandingan antara nilai aktual dan nilai prediksi probabilitas otomatisasi menggunakan Random Forest disajikan pada Gambar 3.



**Gambar 3.** Perbandingan nilai aktual dan prediksi probabilitas otomatisasi menggunakan Random Forest

Gambar 3 menunjukkan perbandingan antara nilai aktual dan nilai prediksi probabilitas otomatisasi menggunakan Random Forest, di mana sebagian besar titik terkonsentrasi di sekitar nilai aktual. Hal ini menunjukkan tingkat kesalahan yang relatif rendah serta kemampuan model dalam menangkap hubungan nonlinier pada data tabular. Sebagai pembandingan, hasil prediksi menggunakan ANN disajikan pada Gambar 4.



**Gambar 4.** Perbandingan nilai aktual dan prediksi probabilitas otomatisasi menggunakan Artificial Neural Network (MLP)

Gambar 4 menunjukkan bahwa prediksi ANN memiliki sebaran yang lebih luas, khususnya pada rentang probabilitas menengah, yang mencerminkan variabilitas prediksi yang lebih tinggi. Meskipun penyesuaian hiperparameter telah dilakukan, nilai kesalahan yang dihasilkan tetap lebih besar dibandingkan Random Forest, sehingga menunjukkan performa yang relatif lebih rendah pada tugas regresi.

### 3.2 Hasil Pengujian Model Klasifikasi Risiko Pekerjaan

Selain pendekatan regresi, penelitian ini juga melakukan klasifikasi tingkat risiko pekerjaan ke dalam tiga kelas, yaitu Low, Medium, dan High. Kategori risiko dibentuk melalui proses discretization berdasarkan rentang nilai probabilitas otomatisasi pekerjaan, sehingga label klasifikasi merupakan turunan langsung dari hasil regresi.

Evaluasi kinerja model klasifikasi dilakukan menggunakan metrik akurasi dan F1-score. Ringkasan hasil pengujian ditunjukkan pada Tabel 8.

**Tabel 8.** Hasil Evaluasi Model Klasifikasi Risiko Pekerjaan

Model	Akurasi	F1-score (Macro)
Random Forest Classifier	99,33%	0,9933
ANN / MLP Classifier	99,33%	0,9933

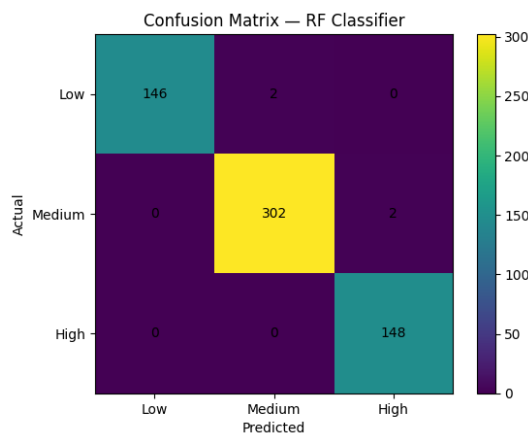
Berdasarkan Tabel 8, kedua model menunjukkan nilai akurasi dan F1-score yang sama tinggi. Namun, tingginya performa ini tidak sepenuhnya mencerminkan kompleksitas proses pembelajaran klasifikasi, melainkan dipengaruhi oleh karakteristik pembentukan label yang berasal dari hasil discretization probabilitas otomatisasi. Dengan demikian, batas antar kelas menjadi bersifat deterministik dan relatif mudah dipisahkan oleh model, sehingga meningkatkan kemudahan proses klasifikasi. Kondisi ini mengindikasikan bahwa performa tinggi lebih dipengaruhi oleh struktur data target dibandingkan kompleksitas pemodelan algoritma itu sendiri.

Selain itu, distribusi kelas yang relatif seimbang antara kategori Low, Medium, dan High juga turut mendukung tingginya performa model klasifikasi. Proporsi data yang tidak terlalu timpang membuat proses pembelajaran model menjadi lebih stabil karena setiap kelas memiliki representasi yang cukup pada data latih maupun data uji. Kondisi ini membantu model dalam mengenali pola pada masing-masing kategori risiko tanpa mengalami bias prediksi terhadap kelas tertentu.

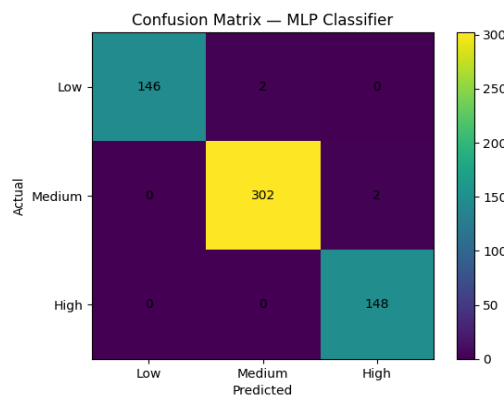
Hasil ini juga menunjukkan bahwa baik Random Forest maupun ANN mampu menangkap pola hubungan antara fitur pekerjaan, faktor teknologi, dan tingkat probabilitas otomatisasi secara konsisten. Random Forest memanfaatkan mekanisme ensemble learning untuk membentuk batas keputusan yang stabil, sedangkan ANN mempelajari pola melalui representasi nonlinier pada hidden layer. Meskipun mekanisme pembelajaran keduanya berbeda, struktur kelas yang relatif jelas menyebabkan kedua algoritma menghasilkan performa yang hampir identik.

Hasil ini juga menjelaskan mengapa baik Random Forest maupun ANN menghasilkan performa yang identik, karena kedua model mempelajari pola yang sudah secara tidak langsung diturunkan dari variabel target regresi. Temuan ini sejalan dengan penelitian Pahlevi et al. yang menyatakan bahwa performa tinggi pada data tabular dengan pembagian kelas yang jelas dapat terjadi ketika struktur kelas memiliki pemisahan yang tegas, sehingga berbagai algoritma dapat mencapai hasil yang serupa [18].

Hasil confusion matrix ditampilkan pada Gambar 5 dan 6. Visualisasi tersebut menunjukkan bahwa kesalahan klasifikasi sangat kecil dan sebagian besar prediksi berada pada kelas yang benar. Kesalahan yang muncul terutama terjadi pada kelas risiko menengah (Medium), yang memiliki rentang nilai yang berdekatan dengan kelas lainnya sehingga secara batas keputusan lebih sulit dipisahkan dibandingkan kelas Low dan High.



Gambar 5. Confusion matrix Random Forest hasil klasifikasi risiko pekerjaan



Gambar 6. Confusion matrix Artificial Neural Network (MLP) hasil klasifikasi risiko pekerjaan

### 3.3 Analisis Komparatif dan Hasil Prediksi Dampak AI terhadap Pekerjaan 2030

Selain komparasi kinerja algoritma, penelitian ini juga menganalisis hasil prediksi dampak *Artificial Intelligence (AI)* terhadap pekerjaan pada tahun 2030 untuk memberikan gambaran perubahan struktur ketenagakerjaan di masa depan.

Hasil regresi menunjukkan bahwa distribusi probabilitas otomatisasi terpusat pada rentang menengah, yang mengindikasikan bahwa sebagian besar pekerjaan mengalami otomatisasi parsial. Temuan ini menunjukkan bahwa AI lebih berperan sebagai teknologi *augmentation* dibandingkan pengganti manusia secara penuh.

Hasil klasifikasi juga memperlihatkan bahwa mayoritas pekerjaan berada pada kategori *Medium risk*, yang mencerminkan fase transisi menuju integrasi AI. Pada kategori ini, pekerjaan mengalami perubahan pada tugas-tugas rutin berbasis aturan, sedangkan tugas yang membutuhkan analisis kompleks dan pengambilan keputusan tetap memerlukan peran manusia.

Tingkat risiko otomatisasi dipengaruhi oleh kombinasi faktor teknologi dan karakteristik pekerjaan. *AI\_Exposure\_Index* dan *Tech\_Growth\_Factor* menjadi indikator utama yang meningkatkan probabilitas otomatisasi. Sementara itu, pekerjaan dengan keterampilan rutin dan repetitif cenderung berada pada kategori *High risk*, seperti pekerjaan administratif dan operasional.

Sebaliknya, pekerjaan yang membutuhkan kreativitas, analisis, dan pemecahan masalah kompleks cenderung berada pada kategori *Low risk*, seperti *Research Scientist* dan *Software Engineer*, karena lebih sulit direplikasi oleh sistem AI.

Secara keseluruhan, temuan menunjukkan bahwa dampak AI bersifat tidak merata (*uneven impact*), di mana tingkat risiko otomatisasi lebih dipengaruhi oleh komposisi keterampilan dibandingkan jenis pekerjaan. Dengan demikian, transformasi pasar kerja lebih ditentukan oleh perubahan kebutuhan keterampilan daripada sekadar penggantian pekerjaan.

### 3.4 Pembahasan dan Analisis Perbandingan Model

Hasil pengujian menunjukkan bahwa Random Forest memiliki kinerja lebih konsisten dibandingkan Artificial Neural Network (ANN), khususnya pada tugas regresi dalam memprediksi probabilitas otomatisasi pekerjaan. Hal ini ditunjukkan oleh nilai MAE dan RMSE yang lebih rendah serta nilai  $R^2$  yang lebih tinggi, yang mengindikasikan kemampuan Random Forest dalam menangkap pola nonlinier pada data tabular secara lebih stabil.

Temuan ini sejalan dengan Sobari et al. [20], yang menunjukkan bahwa Random Forest memiliki performa tinggi dengan stabilitas baik serta ketahanan terhadap noise dan kompleksitas data. Keunggulan ini diperkuat oleh karakteristik ensemble learning yang menggabungkan banyak pohon keputusan, sehingga mampu mengurangi variansi dan risiko *overfitting* melalui mekanisme bagging dan seleksi fitur acak.

Sebaliknya, ANN menunjukkan performa sangat baik pada tugas klasifikasi dengan akurasi dan F1-score tinggi, sejalan dengan temuan Ibnu Haziq Pryandara et al. [21] serta Gupita Nurmalitasari et al. [22]. Namun pada regresi, ANN menunjukkan selisih performa antara data latih dan data uji, yang mengindikasikan kecenderungan *overfitting*. Hal ini dipengaruhi sensitivitas ANN terhadap arsitektur jaringan, parameter pelatihan, dan skala data.

Perbedaan ini menunjukkan bahwa Random Forest lebih stabil dan robust untuk data tabular, sedangkan ANN lebih kuat dalam menangkap pola kompleks tetapi membutuhkan tuning yang lebih optimal. Secara keseluruhan, Random Forest unggul pada regresi, sementara ANN tetap kompetitif pada klasifikasi, sehingga pemilihan algoritma bergantung pada tujuan dan karakteristik data.

### 3.5 Implikasi dan Keterbatasan Hasil Penelitian

Hasil penelitian ini memberikan implikasi bahwa dampak kecerdasan buatan terhadap pekerjaan bersifat parsial, dengan mayoritas pekerjaan berada pada kategori risiko menengah. Oleh karena itu, kebijakan ketenagakerjaan tidak hanya berfokus pada pengurangan pengangguran, tetapi juga pada pengelolaan transisi tenaga kerja melalui program reskilling untuk pekerjaan berisiko tinggi dan upskilling untuk pekerjaan berisiko menengah, terutama pada keterampilan berbasis data, analisis, dan pemanfaatan teknologi AI. Selain itu, hasil penelitian menunjukkan bahwa perubahan pasar kerja lebih dipengaruhi oleh kebutuhan keterampilan dibandingkan jumlah pekerjaan, sehingga penguatan keterampilan non-rutin seperti berpikir kritis, kreativitas, dan pemecahan masalah menjadi penting.

Namun, penelitian ini memiliki keterbatasan, yaitu ketergantungan pada karakteristik dataset yang belum sepenuhnya merepresentasikan kondisi pasar kerja global yang dinamis serta keterbatasan pada penggunaan dua algoritma machine learning. Penelitian selanjutnya disarankan menggunakan dataset yang lebih beragam, mempertimbangkan faktor eksternal seperti kebijakan industri dan kondisi ekonomi makro, serta mengeksplorasi model yang lebih kompleks agar hasil lebih general dan robust.

## 4. KESIMPULAN

Penelitian ini membandingkan kinerja algoritma Random Forest dan Artificial Neural Network (ANN) dalam memprediksi dampak kecerdasan buatan terhadap pekerjaan pada tahun 2030 melalui pendekatan regresi dan klasifikasi. Hasil pengujian menunjukkan bahwa pada tugas regresi, Random Forest memiliki performa yang lebih baik dibandingkan ANN dengan nilai MAE dan RMSE yang lebih rendah serta nilai  $R^2$  yang lebih tinggi pada data latih maupun data uji. Hasil tersebut menunjukkan bahwa Random Forest memiliki performa yang lebih stabil dan kemampuan generalisasi yang lebih baik pada data ketenagakerjaan berbasis *tabular data*. Pada tugas klasifikasi, kedua model menghasilkan akurasi dan *F1-score* sebesar 99,33%, yang menunjukkan bahwa kedua algoritma mampu mengklasifikasikan kategori risiko pekerjaan dengan sangat baik berdasarkan pembagian kelas melalui proses

*discretization*. Secara keseluruhan, hasil penelitian menunjukkan bahwa Random Forest lebih unggul pada tugas regresi, sedangkan Random Forest dan ANN memiliki performa yang setara pada tugas klasifikasi. Penelitian ini berkontribusi dalam memberikan analisis komparatif antara pendekatan *ensemble learning* dan *neural network* pada prediksi dampak AI terhadap pekerjaan menggunakan skema regresi dan klasifikasi secara terintegrasi. Selain itu, penelitian ini menunjukkan bahwa kombinasi fitur numerik, kategorikal, dan keterampilan berbasis teks dapat digunakan secara efektif untuk memodelkan risiko otomatisasi pekerjaan. Hasil penelitian diharapkan dapat menjadi referensi dalam pengembangan sistem prediksi risiko pekerjaan serta mendukung penyusunan strategi *upskilling* dan *reskilling* tenaga kerja di era perkembangan AI.

## REFERENCES

- [1] A. B. R. Imam Zaenuddin, “Perkembangan Kecerdasan Buatan (AI) dan Dampaknya pada Dunia Teknologi,” *JITU: Jurnal Informatika Utama*, vol. 2, no. 2, pp. 128–153, 2024. <https://doi.org/10.55903/jitu.v2i2.240>
- [2] M. Marsella, C. S. Wijaya, I. Wijaya, M. T. Shidqi, and D. Novita, “Analisis Implementasi Artificial Intelligence Untuk Bisnis: Systematic Literature Review,” *Device J. Inf. Syst. Comput. Sci. Inf. Technol.*, vol. 4, no. 2, pp. 133–145, 2023, doi: 10.46576/device.v4i2.4037.
- [3] F. Syahputra *et al.*, “AI dan Masa Depan Pekerjaan: Ancaman Atau Peluang,” *J. Manag. Educ. Soc. Sci. Information and Religion*, vol. 2, no. 1, pp. 148–155, 2025, doi: 10.57235/mesir.v2i1.5608.
- [4] D. H. Autor, F. Levy, and R. J. Murnane, “The Skill Content of Recent Technological Change: An Empirical Exploration\*,” *Q. J. Econ.*, vol. 118, no. 4, pp. 1279–1333, Nov. 2003, doi: 10.1162/003355303322552801.
- [5] W. E. Forum, “Future of Jobs Report 2023: Up to a Quarter of Jobs Expected to Change in Next Five Years,” 2023. [Online]. Available: <https://www.weforum.org/reports/future-of-jobs-report-2023>
- [6] C. B. Frey and M. A. Osborne, “The future of employment: How susceptible are jobs to computerisation?,” *Technol. Forecast. Soc. Change*, vol. 114, pp. 254–280, 2017, doi: <https://doi.org/10.1016/j.techfore.2016.08.019>.
- [7] S. Faradillah, D. Irmansyah, B. A. Lokatara, M. I. Saputra, and A. Wulansari, “Analisis Perkembangan Artificial Intelligence Dalam Bidang Bisnis : Systematic Literature Review,” *Djtechno J. Teknol. Inf.*, vol. 4, no. 2, pp. 298–309, 2023, doi: 10.46576/djtechno.v4i2.3404.
- [8] Adhitha Prasetyo Sudaryanto and Stevy Hanny, “Manajemen Sumber Daya Manusia Sektor Publik Menghadapi Kemajuan Kecerdasan Buatan (Artificial Intelligence),” *Musamus Journal of Public Administration*, vol. 6, no. 1, pp. 514–521, 2023. <https://doi.org/10.35724/mjpa.v6i1.5402>
- [9] Royhan Zaki Ramadhana and Muhammad Irwan Padli Nasution, “Analisis Dampak Penerapan Teknologi AI pada Pengambilan Keputusan Strategis dalam Sistem Informasi Manajemen,” *J. Ilm. Res. Dev. Student*, vol. 2, no. 1, pp. 161–168, 2024, doi: 10.59024/jis.v2i1.579.
- [10] E. Helmud, E. Helmud, F. Fitriyani, and P. Romadiana, “Classification Comparison Performance of Supervised Machine Learning Random Forest and Decision Tree Algorithms Using Confusion Matrix,” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 13, no. 1, pp. 92–97, 2024, doi: 10.32736/sisfokom.v13i1.1985.
- [11] M. C. Rakshith, R. C. Kamath, and G. S. Vijay, “Prediction of the Reaming Torque Using Artificial Neural Network and Random Forest Algorithm: Comparative Performance Analysis,” *Eng. Proc.*, vol. 59, no. 1, 2023, doi: 10.3390/engproc2023059097.
- [12] C. Haryanto, N. Rahaningsih, and F. M. Basysyar, “Komparasi Algoritma Machine Learning dalam Memprediksi Harga Rumah,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 1, pp. 533–539, 2023. <https://doi.org/10.36040/jati.v7i1.6343>
- [13] P. R. Sihombing and I. F. Yuliaty, “Penerapan Metode Machine Learning dalam Klasifikasi Risiko Kejadian Berat Badan Lahir Rendah di Indonesia,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 20, no. 2, pp. 417–426, 2021, doi: 10.30812/matrik.v20i2.1174.
- [14] N. Yudistira, “Peran Big Data dan Deep Learning untuk Menyelesaikan Permasalahan Secara Komprehensif,” *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 11, no. 2, p. 78, 2021, doi: 10.36448/expert.v11i2.2063.
- [15] J. M. A. S. Dachi and P. Sitompul, “Analisis Perbandingan Algoritma XGBoost dan Algoritma Random Forest Ensemble Learning pada Klasifikasi Keputusan Kredit,” *Jurnal Riset Rumpun Matematika dan Ilmu Pengetahuan Alam*, vol. 2, no. 2, pp. 87–103, Jul. 2023. <https://doi.org/10.55606/jurrimipa.v2i2.1470>
- [16] M. W. Nugroho, “Analisis Performa Algoritma Random Forest dalam Mengatasi Overfitting pada Model Prediksi,” *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 9, no. 4, pp. 1562–1571, 2025, doi: 10.35870/jtik.v9i4.4236.
- [17] N. Widjiyati, “Implementasi Algoritma Random Forest Pada Klasifikasi Dataset Credit Approval,” *J. Janitra Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 1–7, 2021, doi: 10.25008/janitra.v1i1.118.
- [18] O.- Pahlevi, A.- Amrin, and Y.- Handrianto, “Implementasi Algoritma Klasifikasi Random Forest Untuk Penilaian Kelayakan Kredit,” *J. Infortech*, vol. 5, no. 1, pp. 71–76, 2023, doi: 10.31294/infortech.v5i1.15829.
- [19] I. Kurniawan, D. Cahya Putri Buani, W. Apriliah, R. Amegia Saputra, and P. Korespondensi, “Implementasi Algoritma Random Forest Untuk Menentukan Penerima Bantuan Raskin Implementation of Random Forest Algorithm for Determining Recipients of Raskin,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 2, pp. 421–428, 2023, doi: 10.25126/jtik.202396225.
- [20] S. Sobari, A. I. Purnamasari, A. Bahtiar, and K. Kaslani, “Meningkatkan Model Prediksi Kelulusan Santri Tahfidz Di Pondok Pesantren Al-Kautsar Menggunakan Algoritma Random Forest,” *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 1, 2025, doi: 10.23960/jitet.v13i1.5704.
- [21] Ibni Haziq Pryandara, Genta Akbar, Nouval Daffa, Perdi Firdaus R, M. Sidik Aljabar, and Rudianto, “Klasifikasi Depresi Pada Siswa Menggunakan Neural Network dan Random Forest,” *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 7, no. 2, pp. 188–198, 2025, doi: 10.52005/restikom.v7i2.453.
- [22] G. N. Sari, R. E. Saputro, and G. Karyono, “Pengaruh Prediksi Kredit Bermasalah terhadap Keputusan Bank dengan Komparasi Metode ANN, CNN, dan Random Forest,” *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 12, pp. 3702–3710, 2025. <https://doi.org/10.52436/1.jpti.1276>