

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil

Berdasarkan metodologi yang telah dirancang pada kasus prediksi turnover karyawan menggunakan metode *Decision Tree*, *Random Forest*, *K-Nearest Neighbors (KNN)*.

Yang terdiri dari beberapa proses pada gogle colabatory diantaranya sebagai berikut

https://colab.research.google.com/drive/1FCOIW-AHJ2gdIcTMVnJ_C76HXlelhdUG?usp=sharing

4.1.1 Data Collection

1. Menyiapkan dataset

Dataset yang digunakan dalam penelitian ini bebrbentuk file CSV yang bersumber dari repositori *Kaggle*. Data yang akan diolah dalam penelitian ini terdiri dari 4653 baris dan 9 column, Adapun dataset tesebut sebagai sebagai berikut

A	B	C	D	E	F	G	H	I
Education	JoiningYear	City	PaymentTier	Age	Gender	EverBenched	ExperienceInCurrentDomain	LeaveOrNot
Bachelors	2017	Bangalore	3	34	Male	No		0
Bachelors	2013	Pune	1	28	Female	No		1
Bachelors	2014	New Delhi	3	38	Female	No		0
Masters	2016	Bangalore	3	27	Male	No		1
Masters	2017	Pune	3	24	Male	Yes		1
Bachelors	2016	Bangalore	3	22	Male	No		0
Bachelors	2015	New Delhi	3	38	Male	No		0
Bachelors	2016	Bangalore	3	34	Female	No		1
Bachelors	2016	Pune	3	23	Male	No		0
Masters	2017	New Delhi	2	37	Male	No		0
Masters	2012	Bangalore	3	27	Male	No		1
Bachelors	2016	Pune	3	34	Male	No		0
Bachelors	2018	Pune	3	32	Male	Yes		1
Bachelors	2016	Bangalore	3	39	Male	No		0
Bachelors	2012	Bangalore	3	37	Male	No		0
Bachelors	2017	Bangalore	1	29	Male	No		0
Bachelors	2014	Bangalore	3	34	Female	No		0
Bachelors	2014	Pune	3	34	Male	No		0
Bachelors	2015	Pune	2	30	Female	No		1
Bachelors	2016	New Delhi	2	22	Female	No		1
Bachelors	2012	Bangalore	3	37	Male	No		0
Masters	2017	New Delhi	2	28	Male	No		0
Bachelors	2017	New Delhi	2	36	Male	No		0
Bachelors	2015	Bangalore	3	27	Male	Yes		0
Bachelors	2017	Bangalore	3	29	Male	No		0
Bachelors	2013	Bangalore	3	22	Female	Yes		0

Gambar 4.1. 1 Dataset

2. Menyiapkan Data dan Library

Tahap selanjutnya, jika dataset yang dibutuhkan sudah tersedia maka menyiapkan library pada google colab untuk memudahkan dalam proses pengolahan data.

```
import pandas as pd
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
from sklearn.neighbors import KNeighborsClassifier
from sklearn.metrics import accuracy_score, f1_score, precision_score,
recall_score, confusion_matrix, classification_report
import matplotlib.pyplot as plt
from sklearn.model_selection import RandomizedSearchCV
from scipy.stats import randint
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
```

Gambar 4.1. 2 Import library

3. Mengimpor data ke google colab

Pada tahapan ini penulisan mengimpor dataset yang telah didapat ke google colab untuk mempermudah pengolahan data.

```
From google.colab import drive
Drive.mount('/content/drive')
File_path = "/content/drive/MyDrive/SKRIPSI AULIA MAHARANI/Employee
(1).csv"
```

Gambar 4.1. 3 Import Dataset

4.1.2 Exploratory Data Analysis

a) Describe

Pada tahapan pertama exploratory data analysis yaitu describe untuk menampilkan ringkasan statistik data numerik, seperti jumlah nilai yang tersedia (**count**), rata-rata (**mean**), standar deviasi (**std**), nilai minimum (**min**), kuartil pertama, kuartil kedua (**median**), kuartil ketiga, dan nilai maksimum (**max**).

	JoiningYear	PaymentTier	Age	ExperienceInCurrentDomain	LeaveOrNot
count	4653.000000	4653.000000	4653.000000	4653.000000	4653.000000
mean	2015.062970	2.698259	29.393295	2.905652	0.343864
std	1.863377	0.561435	4.826087	1.558240	0.475047
min	2012.000000	1.000000	22.000000	0.000000	0.000000
25%	2013.000000	3.000000	26.000000	2.000000	0.000000
50%	2015.000000	3.000000	28.000000	3.000000	0.000000
75%	2017.000000	3.000000	32.000000	4.000000	1.000000
max	2018.000000	3.000000	41.000000	7.000000	1.000000

Gambar 4.1. 4 Describe

b) Missing Value

Pada tahapan missing value yaitu memeriksa dan menghitung jumlah nilai hilang (missing values) di setiap kolom dalam dataset. agar data menjadi lengkap dan siap dianalisis.

	0
Education	0
JoiningYear	0
City	0
PaymentTier	0
Age	0
Gender	0
EverBenched	0
ExperienceInCurrentDomain	0
LeaveOrNot	0
dtype: int64	

Gambar 4.1. 5 Missing Value

c) Duplicate

Pada tahapan ini mengecek data yang duplikat, untuk memastikan tidak ada pengaruh ganda dalam analisis data.




```
data.duplicated()
```




0


Gambar 4.1. 6 Duplicate

d) Outlier

Untuk pengecekan outlier pada dataset menggunakan visualisasi boxplot dan countplot.







Gambar 4.1. 7 Outlier

Setelah dilakukan outlier visualisasi dengan boxplot dan countplot, maka dilakukan deteksi outlier untuk menghitung ambang batas atas dan ambang batas bawah.

```


Kolom: Education (Categorical)
  Kategori Langka: []
  Jumlah Kategori Langka: 0
-----
Kolom: JoiningYear (Numerical)
  Ambang Batas Atas: 2023.0
  Jumlah Outlier di Atas: 0
  Ambang Batas Bawah: 2007.0
  Jumlah Outlier di Bawah: 0
-----
Kolom: City (Categorical)
  Kategori Langka: []
  Jumlah Kategori Langka: 0
-----
Kolom: PaymentTier (Numerical)
  Ambang Batas Atas: 3.0
  Jumlah Outlier di Atas: 0
  Ambang Batas Bawah: 3.0
  Jumlah Outlier di Bawah: 1161
-----
Kolom: Age (Numerical)
  Ambang Batas Atas: 41.0
  Jumlah Outlier di Atas: 0
  Ambang Batas Bawah: 17.0
  Jumlah Outlier di Bawah: 0
-----
Kolom: Gender (Categorical)
  Kategori Langka: []
  Jumlah Kategori Langka: 0
-----
Kolom: EverBenched (Categorical)
  Kategori Langka: []
  Jumlah Kategori Langka: 0
-----
Kolom: ExperienceInCurrentDomain (Numerical)
  Ambang Batas Atas: 7.0
  Jumlah Outlier di Atas: 0
  Ambang Batas Bawah: -1.0
  Jumlah Outlier di Bawah: 0
-----
Kolom: LeaveOrNot (Numerical)
  Ambang Batas Atas: 2.5
  Jumlah Outlier di Atas: 0
  Ambang Batas Bawah: -1.5
  Jumlah Outlier di Bawah: 0
-----

```

Gambar 4.1. 8 Outlier Ambang Batas

e) *Heatmap*

pada tahapan ini dilakukan untuk membuat heatmap korelasi antara beberapa kolom dalam dataset, yaitu Age, ExperienceInCurrentDomain, PaymentTier. Dan digunakan untuk menghitung korelasi antar kolom numerik, lalu hasilnya divisualisasikan. Dengan ini, kita dapat melihat hubungan antar-variabel tersebut secara visual, termasuk kekuatan dan arah korelasinya.




Gambar 4.1. 9 Heatmap

Heatmap ini menunjukkan hubungan antarvariabel Age, ExperienceInCurrentDomain, dan PaymentTier menggunakan matriks korelasi. Hasilnya, hubungan antarvariabel sangat lemah, dengan nilai korelasi mendekati nol. Terdapat korelasi negatif lemah antara Age dan ExperienceInCurrentDomain (-0.13), menunjukkan bahwa usia tidak selalu

berkaitan dengan pengalaman di domain saat ini. Korelasi antara Age dan PaymentTier (0.0076), serta antara ExperienceInCurrentDomain dan PaymentTier (0.018), sangat kecil, menandakan bahwa tidak ada hubungan antara variabel-variabel tersebut. Secara keseluruhan, variabel-variabel ini tidak memiliki hubungan signifikan satu sama lain.

f) Matrix Colleration

mengukur dan menganalisis hubungan antar variabel dalam dataset. Matriks ini membantu mengidentifikasi seberapa kuat dan arah hubungan antar variabel (positif, negatif, atau tidak ada hubungan), sehingga dapat digunakan untuk pemilihan fitur, deteksi multikolinearitas, atau memahami pola data sebelum analisis lebih lanjut.



Gambar 4.1. 10 Matrix Correlation

4.1.3 Data Preprocessing

Berdasarkan Hasil Observasi Exploratory Data Analysis, diperlukannya beberapa preprocessing terlebih dahulu sebelum data dimasukkan keakurasi perbandingan algoritma turnover karyawan. Adapun tahapan preprocessing yang dibutuhkan sebagai berikut.

a. Encoding

proses transformasi data kategorikal menjadi representasi numerik, seperti 0 dan 1, sehingga data tersebut dapat digunakan pada tahapan selanjutnya. Encoding memastikan bahwa data non-numerik dapat dipahami oleh algoritma, yang umumnya hanya menerima masukan berupa angka.

	Education	JoiningYear	City	PaymentTier	Age	Gender	EverBenchd	ExperienceInCurrentDomain	LeaveOrNot
0	0	2017	0	3	34	1	0	0	0
1	0	2013	2	1	28	0	0	3	1
2	0	2014	1	3	38	0	0	2	0
3	1	2016	0	3	27	1	0	5	1
4	1	2017	2	3	24	1	1	2	1

Gambar 4.1. 11 Encoding

b. Splitting

Mengecek pembagian data menjadi data pelatihan (training) dan data pengujian (testing), serta menampilkan jumlah data di masing-masing set.

```
Total train data : 3117
Total test data : 1536
```

Gambar 4.1. 12 Splitting

4.1.4 Perbandingan Akurasi Algoritma


perbandingan algoritma untuk turnover karyawan dalam kode digunakan untuk membandingkan kinerja berbagai algoritma (seperti Decision Tree, Random Forest,

KNN) dalam memprediksi keputusan karyawan untuk tetap atau meninggalkan perusahaan berdasarkan data yang ada. kemudian membandingkan kinerja masing-masing algoritma berdasarkan metrik evaluasi seperti akurasi, precision, recall, dan F1-score.

a) *Decision Tree*

	precision	recall	f1-score	support
0	0.84	0.88	0.86	1004
1	0.76	0.68	0.72	532
accuracy			0.81	1536
macro avg	0.80	0.78	0.79	1536
weighted avg	0.81	0.81	0.81	1536

[[886 118]
[168 364]]




Gambar 4.1. 13 Decision Tree

b) Random Forest

	precision	recall	f1-score	support
0	0.86	0.91	0.88	1004
1	0.81	0.71	0.76	532
accuracy			0.84	1536
macro avg	0.84	0.81	0.82	1536
weighted avg	0.84	0.84	0.84	1536

[[917 87]
[153 379]]




Gambar 4.1. 14 Random Forest

c) *K-Nearest Neighbors (KNN)*

	precision	recall	f1-score	support
0	0.81	0.92	0.86	1004
1	0.80	0.59	0.68	532
accuracy			0.81	1536
macro avg	0.80	0.76	0.77	1536
weighted avg	0.80	0.81	0.80	1536

```
[[924  80]
 [218 314]]
```



Gambar 4.1. 15 K-Nearest Neighbors

d) *Evaluasi Model*


Setelah dilakukan evaluasi terhadap beberapa algoritma, diperoleh hasil akurasi terbaik untuk masing-masing model sebagai berikut.

	model	best_score
0	RandomForest	0.855791
1	DecisionTree	0.841607
2	KNN	0.803776

Gambar 4.1. 16 Evaluasi Model

e) *Visualisasi Perbandingan Algoritma*

Gambar tersebut membandingkan akurasi tiga algoritma machine learning: Random Forest, Decision Tree, dan K-Nearest Neighbors (KNN). Random Forest memiliki akurasi tertinggi sebesar 86%, diikuti oleh Decision Tree dengan 84%, dan KNN dengan 80%. menunjukkan bahwa Random Forest adalah algoritma terbaik yang paling optimal untuk memprediksi turonver karyawan.



Gambar 4.1. 17 Visualisasi Perbandingan Algoritma

4.1.5 Proses Algoritma Decision Tree

Langkah-langkah dalam pembentukan pohon keputusan pada prediksi turnover karyawan salah satu menggunakan metode decision tree dilakukan sesuai pada tabel 4.5.1, berikut perhitungan decision tree:

NILAI ENTROPY DAN GAIN UNTUK MENENTUKAN SIMPUL AKAR

Atribut	Nilai	Jumlah kasus	LeaveOrNot=0	LeaveOrNot=1	Entropy	Gain	Akurasi
Total		4653	3053	1600	0,9284685		0,656135826
Leave		1600					
Not		3053					
Education						0,3903654557	
	Bachelors	3601	2472	1129	0,8971995		0,686475978
	Masters	873	447	426	0,9995825		0,512027491
	PHD	179	134	45	0,8134842		0,748603352
Joining Year						0,9228294393	
	2012	504	395	109	0,7532976		0,783730158
	2013	669	445	224	0,9197833		0,665171898
	2014	699	526	173	0,8072858		0,752503576
	2015	781	463	318	0,9749907		0,592829705
	2016	525	408	318	0,7207918		0,777142857
	2017	1108	811	297	0,8386533		0,731949458
	2018	367	5	362	0,1039581		0,013623978
City						0,4789659861	
	Bangalore	2228	1633	595	0,8372078		0,732944344
	New Delh	1157	791	366	0,9003516		0,68366465
	Pune	1268	629	639	0,9999551		0,496056782
PaymentTier						0,4336019544	
	1	243	154	89	0,9477532		0,633744856
	2	918	368	550	0,9714580		0,400871459
	3	3492	2531	961	0,8488283		0,724799541
Age						1,033501223	
	22	49	30	19	0,9633355		0,612244898
	23	48	32	16	0,9182958		0,666666666
	24	385	232	153	0,9694109		0,602597402
	25	418	242	176	0,9819407		0,578947368
	26	645	422	223	0,9302025		0,654263565
	27	625	399	226	0,9440032		0,6384
	28	630	444	186	0,8753918		0,704761904
	29	230	155	75	0,9108783		0,673913043
	30	220	143	77	0,9340680		0,65
	31	125	88	37	0,8763462		0,704
	32	132	78	54	0,9760206		0,590909090
	33	124	84	40	0,9071657		0,677419354
	34	136	94	42	0,8918107		0,691176470
	35	123	78	45	0,9474351		0,634146341
	36	139	94	45	0,9084033		0,676258992
	37	141	98	43	0,8872751		0,695035461
	38	136	96	40	0,8739810		0,705882352
	39	131	92	39	0,8784734		0,702290076
	40	134	93	41	0,8884667		0,694029850
	42	82	59	23	0,8561146		0,719512195
Gender						1,017997561	
	Male	2778	2062	716	0,8233158		0,742260619
	Female	1875	991	884	0,9976495		0,528533333

Everbench					0,2084845036	
	Yes	478	261	217	0,9938791	0,546025104
	No	4175	2792	1383	0,9162059	0,668742515
Experience						0,9519932168
	0	355	231	124	0,9334375	0,650704225
	1	558	370	188	0,9218384	0,663082437
	2	1087	688	399	0,9483920	0,632934682
	3	786	487	299	0,9583290	0,619592875
	4	931	634	297	0,9033036	0,680988184
	5	919	631	288	0,8970412	0,686615886
	6	8	6	2	0,8112781	0,75
	7	9	6	3	0,9182958	0,666666666

4.1.6 Proses Algoritma Random Forest

Langkah-langkah pada prediksi turnover karyawan salah satu menggunakan metode Random Forest dilakukan sesuai pada tabel 4.5.1, berikut perhitungan Random Forest:

Education	JoiningYear	City	PaymentTier	Age	Gender	EverBench	ExperienceInCurrentDomain	Actual	Predicted	True/False	Total Benar	Akurasi
0	2016	0	3	24	1	0	2	1	0	Salah	4001	0.86006
0	2013	0	3	26	1	0	4	0	0	Benar		
0	2017	2	2	25	1	0	3	1	0	Salah		
1	2015	1	2	28	1	0	2	0	0	Benar		
0	2012	0	3	33	0	0	1	0	0	Benar		
1	2012	2	3	24	1	0	2	1	0	Salah		
0	2016	1	3	27	1	0	5	1	1	Benar		
0	2015	1	2	25	1	1	3	1	1	Salah		
0	2015	2	3	28	0	0	1	0	0	Benar		
0	2015	1	2	27	1	0	5	1	1	Benar		
0	2013	0	3	27	0	0	5	0	0	Benar		
0	2017	0	3	24	1	0	2	0	0	Benar		
0	2018	1	2	39	1	0	4	1	1	Benar		
0	2012	0	3	27	0	1	5	0	0	Benar		
1	2017	2	2	34	0	1	2	0	0	Benar		
0	2015	1	2	26	1	0	4	1	1	Benar		
0	2014	1	3	24	0	0	2	0	0	Benar		
2	2016	2	2	28	0	0	3	1	0	Salah		
1	2012	1	3	27	0	0	5	1	1	Benar		
0	2016	0	3	40	0	0	5	0	0	Benar		
0	2012	0	3	28	0	0	0	0	1	Salah		
0	2015	1	2	25	0	0	3	1	1	Benar		
0	2017	1	2	33	1	0	2	1	1	Benar		
0	2015	0	3	27	1	0	5	0	0	Benar		
0	2012	0	1	27	1	0	5	0	0	Benar		
0	2015	0	3	26	0	0	4	0	0	Benar		

Gambar 4.1 19 Proses Algoritma Random Forest

4.1.7 Proses Algoritma K-Nearest Neighbor

Langkah-langkah pada prediksi turnover karyawan salah satu menggunakan metode K-Nearest Neighbor dilakukan sesuai pada tabel 4.5.1, berikut perhitungan K-Nearest Neighbor:

Education	JoiningYear	City	PaymentTier	Age	Gender	EverBenched	ExperienceInCurrentDomain	Actual	Predicted	Correct Prediction	Akurasi
0	0.666666667	0	1	0.105263	0	0	0.285714286	1	0	0	0.78981
0	0.166666667	0	1	0.210526	0	0	0.571428571	0	0	1	
0	0.833333333	1	0.5	0.157895	0	0	0.428571429	1	0	0	
1	0.5	2	0.5	0.315789	0	0	0.285714286	0	0	1	
0	0	0	1	0.578947	1	0	0.142857143	0	0	1	
1	0	1	1	0.105263	0	0	0.285714286	1	0	0	
0	0.666666667	2	1	0.263158	0	0	0.714285714	1	0	0	
0	0.5	2	0.5	0.157895	0	1	0.428571429	1	1	1	
0	0.5	1	1	0.315789	1	0	0.142857143	0	0	1	
0	0.5	2	0.5	0.263158	0	0	0.714285714	1	1	1	
0	0.166666667	0	1	0.263158	1	0	0.714285714	0	1	0	
0	0.833333333	0	1	0.105263	0	0	0.285714286	0	0	1	
0	1	2	0.5	0.894737	0	0	0.571428571	1	0	0	
0	0	0	1	0.263158	1	1	0.714285714	0	0	1	
1	0.833333333	1	0.5	0.631579	1	1	0.285714286	0	0	1	
0	0.5	2	0.5	0.210526	0	0	0.571428571	1	0	0	
0	0.333333333	2	1	0.105263	1	0	0.285714286	0	0	1	
2	0.666666667	1	0.5	0.315789	1	0	0.428571429	1	1	1	
1	0	2	1	0.263158	1	0	0.714285714	1	0	0	
0	0.666666667	0	1	0.947368	1	0	0.714285714	0	0	1	
0	0	0	1	0.315789	1	0	0	0	1	0	
0	0.5	2	0.5	0.157895	1	0	0.428571429	1	0	0	
0	0.833333333	2	0.5	0.578947	0	0	0.285714286	1	1	1	
0	0.5	0	1	0.263158	0	0	0.714285714	0	0	1	
0	0	0	0	0.263158	0	0	0.714285714	0	0	1	
0	0.5	0	1	0.210526	1	0	0.571428571	0	0	1	

Gambar 4.1. 20 Proses algoritma K-Nearest Neighbor

4.1.8 Pohon Keputusan

Pohon keputusan atau graph view menunjukkan hasil dari percabangan yang dapat dihasilkan kesimpulan. Berikut adalah hasil dari *decision tree*.

