

Klasifikasi Kepribadian *Introvert* dan *Extrovert* Menggunakan *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor*

Moh. Erkamim^{1*}, Nurhayati², Nofitri Heriyani³, Umbar Riyanto⁴

¹Program Studi Manajemen Bisnis Internasional, Jurusan Administrasi Bisnis, Politeknik Negeri Bali

^{2,3,4}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Tangerang

Email: ¹erkamim@pnb.ac.id, ²nurhayati09011@ft-umt.ac.id, ³nofitri.heriyani@ft-umt.ac.id,

⁴umbar@ft-umt.ac.id

Penulis Korespondensi*

(received: 10-11-25, revised: 21-11-25, accepted: 27-11-25)

Abstrak

Kepribadian merupakan faktor penting yang memengaruhi cara individu berpikir, berperilaku, dan berinteraksi dalam kehidupan sosial. Salah satu dimensi utama dalam model *Big Five Personality Traits* adalah ekstrasversi, yang merepresentasikan kecenderungan seseorang untuk bersosialisasi dan berinteraksi aktif dengan lingkungannya. Penelitian ini bertujuan mengembangkan model klasifikasi kepribadian *introvert* dan *extrovert* menggunakan tiga algoritma *machine learning*, yaitu *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor* (KNN). Dataset yang digunakan berjumlah 2.900 entri dengan delapan atribut perilaku sosial seperti waktu yang dihabiskan sendirian, frekuensi menghadiri acara sosial, ukuran lingkaran pertemanan, dan tingkat aktivitas di media sosial. Proses penelitian meliputi pembersihan data, transformasi variabel kategorikal, pembagian data secara stratifikasi (80:20), pembangunan model, serta evaluasi menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Hasil pengujian menunjukkan bahwa model KNN dengan $k = 11$ memberikan performa terbaik dengan akurasi 92,59% dan nilai *ROC-AUC* 0,9494, diikuti oleh *Naïve Bayes* dengan akurasi 92,24% (*ROC-AUC* 0,8988) dan *Random Forest* dengan akurasi 90,86% (*ROC-AUC* 0,9480). Kontribusi utama penelitian ini adalah memberikan analisis komparatif terhadap tiga algoritma yang mewakili paradigma pembelajaran berbeda, yaitu probabilistik, berbasis jarak, dan *ensemble* pohon keputusan, dalam konteks klasifikasi kepribadian berdasarkan dimensi ekstrasversi. Hasil penelitian ini dapat menjadi dasar bagi pengembangan sistem prediksi kepribadian berbasis perilaku sosial yang efisien dan adaptif.

Kata Kunci: Data Mining, *Extrovert*, *Introvert*, *K-Nearest Neighbor*, *Naïve Bayes*, *Random Forest*

Abstract

Personality is an essential factor that influences how individuals think, behave, and interact within social contexts. One of the core dimensions of the *Big Five Personality Traits* model is extraversion, which represents the extent to which individuals tend to socialize and engage actively with their environment. This study aims to develop a classification model for identifying *introvert* and *extrovert* personality types using three machine learning algorithms, namely *Random Forest*, *Naïve Bayes*, and *K-Nearest Neighbor* (KNN). The dataset consists of 2,900 entries with eight attributes describing social behavior, including time spent alone, frequency of attending social events, size of the friendship circle, and social media activity levels. The research process includes data cleaning, categorical variable transformation, stratified data splitting (80:20), model construction, and evaluation using accuracy, precision, recall, *F1-score*, and *ROC-AUC* metrics. The experimental results show that the KNN model with $k = 11$ achieves the best performance with an accuracy of 92.59% and a *ROC-AUC* value of 0.9494, followed by *Naïve Bayes* with an accuracy of 92.24% (*ROC-AUC* 0.8988) and *Random Forest* with an accuracy of 90.86% (*ROC-AUC* 0.9480). The main contribution of this study is the comparative analysis of three algorithms representing different learning paradigms, namely probabilistic, distance-based, and tree-ensemble approaches, in the context of personality classification based on extraversion. The findings provide a foundation for developing efficient and adaptive behavior-based personality prediction systems.

Keywords: Data Mining, *Extrovert*, *Introvert*, *K-Nearest Neighbor*, *Naïve Bayes*, *Random Forest*

1. PENDAHULUAN

Kepribadian merupakan salah satu aspek penting yang membedakan cara individu berpikir, berperilaku, dan berinteraksi dengan lingkungannya. Dalam psikologi modern, kerangka yang paling banyak digunakan untuk

mengkaji kepribadian adalah *Big Five Personality Traits* atau model OCEAN, yang terdiri atas lima dimensi utama yaitu *Openness*, *Conscientiousness*, *Extraversion*, *Agreeableness*, dan *Neuroticism* [1]. Salah satu dimensi utama dalam model ini adalah ekstrasversi, yang merepresentasikan sejauh mana seseorang cenderung terbuka dalam bersosialisasi, aktif berinteraksi, serta memperoleh energi dari lingkungan sosial [2]. Dimensi ini dipandang berada pada spektrum dua kutub, yaitu *introvert* yang cenderung lebih tertutup dan reflektif, serta *extrovert* yang lebih ekspresif dan dominan dalam interaksi sosial [3].

Identifikasi kepribadian berbasis ekstrasversi memiliki banyak potensi aplikasi praktis. Di bidang pendidikan, misalnya, informasi mengenai kecenderungan *introvert-extrovert* dapat membantu pendidik merancang metode belajar yang sesuai [4]. Dalam ranah ketenagakerjaan, klasifikasi ini bermanfaat untuk menilai kesesuaian kandidat dengan posisi tertentu [5]. Selain itu, sistem rekomendasi berbasis perilaku juga dapat memanfaatkan informasi kepribadian guna memberikan layanan yang lebih personal. Namun, metode pengukuran tradisional seperti psikotes masih memerlukan waktu, biaya, serta tenaga ahli dalam pelaksanaannya. Kehadiran pendekatan data mining memungkinkan proses identifikasi dilakukan secara otomatis, lebih cepat, serta berskala besar dengan memanfaatkan data perilaku yang tersedia [6].

Berbagai penelitian sebelumnya telah menerapkan algoritma klasifikasi untuk mengidentifikasi tipe kepribadian dengan hasil yang bervariasi. Studi yang membandingkan algoritma C4.5 dan *Naïve Bayes* pada data siswa SMK menunjukkan tingkat akurasi yang relatif rendah, yaitu masing-masing 60,69% dan 60,00%, yang mengindikasikan bahwa kedua metode tersebut belum mampu menangkap pola perilaku dengan baik pada dataset tersebut [7]. Selanjutnya, penelitian berbasis media sosial menggunakan *K-Nearest Neighbor* (KNN) untuk memprediksi tipe kepribadian berdasarkan status Facebook menghasilkan akurasi sebesar 58,96%, sementara *Naïve Bayes* pada dataset yang sama menunjukkan peningkatan performa hingga 98,80% [8]. Penelitian lain mengembangkan sistem klasifikasi sidik jari berbasis citra digital menggunakan *Support Vector Machine* (SVM) dengan kernel RBF, yang menunjukkan adanya korelasi antara pola sidik jari dan kecenderungan kepribadian dengan akurasi 89,25% [9]. Sementara itu, penelitian lain yang menggunakan *Naïve Bayes* dengan teknik SMOTE pada data Twitter untuk klasifikasi MBTI memperoleh akurasi sekitar 80%, namun performanya masih rendah pada kelas minoritas [10].

Hasil-hasil tersebut memperlihatkan bahwa tidak ada satu algoritma tunggal yang selalu unggul pada seluruh konteks data kepribadian. Performa suatu model sangat bergantung pada karakteristik data, termasuk jumlah fitur, tingkat linearitas, serta distribusi kelas. Oleh karena itu, penelitian ini berfokus pada tiga algoritma yang dinilai representatif dari paradigma pembelajaran yang berbeda namun relevan untuk data tabular, yaitu *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor* (KNN). *Random Forest* dipilih karena kemampuannya dalam mengatasi varians tinggi melalui mekanisme *bagging* dan agregasi hasil dari banyak pohon keputusan, sehingga mampu memberikan prediksi yang lebih stabil dan tahan terhadap *overfitting* [11]. *Naïve Bayes* dipertahankan karena kesederhanaannya serta kemampuannya menghasilkan estimasi probabilistik yang efisien, terutama pada dataset dengan ukuran terbatas dan fitur yang relatif independen [12]. Sementara itu, KNN memberikan perspektif yang berbeda karena bekerja berdasarkan jarak antar *instance* [13].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi kepribadian *introvert* dan *extrovert* menggunakan algoritma *Random Forest*, *Naïve Bayes*, dan KNN. Kontribusi utama penelitian ini adalah memberikan analisis komparatif terhadap kinerja tiga algoritma yang mewakili pendekatan probabilistik, berbasis jarak, dan *ensemble* pohon keputusan dalam konteks klasifikasi kepribadian berdasarkan dimensi ekstrasversi. Dengan demikian, penelitian ini dapat memperkaya literatur di bidang klasifikasi kepribadian sekaligus menawarkan pendekatan yang praktis dan aplikatif untuk berbagai domain penerapan.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk membangun model klasifikasi kepribadian berdasarkan *introvert* dan *extrovert*. Pendekatan ini melibatkan serangkaian tahapan sistematis, mulai dari pengumpulan dataset, normalisasi dan encoding data, analisis eksploratif, pembangunan model menggunakan algoritma pembandingan (*Random Forest*, *Naïve Bayes*, dan KNN), hingga pengujian kinerja model. Proses penelitian secara umum dapat digambarkan melalui diagram pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

2.1. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform *Kaggle* dengan judul “*Extrovert vs Introvert Behavior Data*” [14]. Dataset tersebut berisi 2.900 entri dengan delapan atribut yang merepresentasikan perilaku sosial individu. Fitur numerik meliputi *Time_spent_Alone* (waktu yang dihabiskan sendirian), *Social_event_attendance* (frekuensi menghadiri acara sosial), *Going_outside* (intensitas aktivitas di luar rumah), *Friends_circle_size* (ukuran lingkaran pertemanan), dan *Post_frequency* (frekuensi unggahan di media sosial). Sementara itu, fitur kategorikal terdiri atas *Stage_fear* (ketakutan tampil di depan umum) dan *Drained_after_socializing* (tingkat kelelahan setelah bersosialisasi). Label target dari dataset ini adalah tipe kepribadian yang diklasifikasikan ke dalam dua kategori, yaitu *Introvert* dan *Extrovert*. Dataset ini dipilih karena memiliki indikator perilaku yang relevan untuk menggambarkan kecenderungan ekstrasversi dan berukuran cukup besar untuk mendukung pelatihan serta pengujian model secara komprehensif.

2.2. Normalisasi dan Encoding Data

Tahap ini bertujuan untuk memastikan bahwa data siap digunakan pada proses pelatihan model. Nilai kategorikal seperti “Yes” dan “No” dikonversi menjadi nilai biner (1 dan 0) agar dapat diproses oleh algoritma pembelajaran mesin. Selain itu, dilakukan pemeriksaan terhadap nilai kosong atau data yang tidak konsisten untuk menjaga integritas dataset. Setelah data dinyatakan bersih, dilakukan pemisahan menjadi data latih dan data uji dengan rasio 80:20 secara *stratified sampling*. Pemisahan ini bertujuan agar setiap kategori kepribadian terdistribusi secara proporsional pada kedua subset data [15]. Hasil akhir dari tahap ini adalah dua himpunan data yang siap digunakan untuk membangun serta mengevaluasi model klasifikasi.

2.3. Analisis Deskriptif Dataset

Analisis deskriptif dilakukan untuk memahami karakteristik dasar data sebelum proses pemodelan. Tahap ini mencakup analisis distribusi kelas, visualisasi histogram untuk fitur numerik, serta pembuatan *heatmap* korelasi antar variabel. Distribusi kelas diperiksa guna memastikan keseimbangan jumlah data antara kategori *introvert* dan *extrovert*, sehingga model tidak bias terhadap salah satu kelas. Histogram membantu dalam mengamati pola sebaran nilai serta membedakan karakteristik antar kelas [16]. Sementara itu, *heatmap* korelasi digunakan untuk mengidentifikasi hubungan antar fitur numerik, sehingga potensi multikolinearitas dapat diketahui lebih awal [17]. Hasil analisis ini menjadi dasar untuk memahami perilaku data dan mendukung pemilihan parameter yang tepat pada tahap pelatihan model.

2.4. Implementasi Model Klasifikasi

Tahap implementasi model bertujuan untuk membangun sistem klasifikasi yang mampu memprediksi kecenderungan kepribadian *introvert* atau *extrovert* berdasarkan fitur perilaku sosial individu. Pada penelitian ini digunakan tiga algoritma utama, yaitu *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor* (KNN). Ketiganya dipilih karena mewakili tiga pendekatan pembelajaran mesin yang berbeda, yaitu *ensemble learning*, *probabilistic learning*, dan *instance-based learning* [18].

Random Forest merupakan algoritma berbasis *ensemble decision tree* yang bekerja dengan membangun sejumlah pohon keputusan (*decision trees*) secara paralel, kemudian menggabungkan hasil klasifikasi dari masing-masing pohon melalui mekanisme *majority voting* [19]. Setiap pohon dibentuk dari subset acak data pelatihan dan subset acak atribut (fitur), sehingga antar pohon memiliki tingkat variasi yang tinggi dan mengurangi risiko *overfitting*. *Random Forest* unggul karena stabil terhadap *noise*, mampu menangani data

non-linier, serta memberikan estimasi pentingnya fitur melalui frekuensi keterlibatan atribut dalam pemisahan *node* [20]. Proses prediksi akhir ditentukan berdasarkan suara mayoritas dari seluruh pohon, sebagaimana ditunjukkan pada persamaan (1).

$$\hat{y} = \arg \arg \sum_{t=1}^T I(h_t(x) = c) \quad (1)$$

dimana C adalah himpunan kelas target, adalah jumlah pohon dalam hutan, h_t merupakan hasil prediksi pohon ke- t , dan I adalah fungsi indikator yang bernilai 1 jika prediksi benar, dan 0 jika salah.

Naïve Bayes merupakan algoritma klasifikasi probabilistik yang didasarkan pada *Bayes' Theorem*. Model ini menghitung peluang *posterior* dari setiap kelas berdasarkan nilai fitur pada data masukan dengan asumsi independensi antar fitur [21]. Pendekatan ini sederhana namun sangat efisien untuk dataset dengan ukuran menengah dan distribusi yang relatif seimbang [22]. Dasar *Naïve Bayes* dinyatakan dalam persamaan (2).

$$P(X) = \frac{P(C_k) P(C_k)}{P(X)} \quad (2)$$

dimana $P(C_k|X)$ adalah probabilitas posterior dari kelas C_k terhadap data X , $P(X|C_k)$ adalah probabilitas kemunculan fitur X pada kelas C_k , $P(C_k)$ adalah probabilitas awal kelas C_k , dan $P(X)$ yaitu probabilitas total data.

Model akan memilih kelas dengan nilai probabilitas *posterior* tertinggi. Karena fitur-fiturnya dianggap independen, maka probabilitas gabungan dapat dihitung sebagai hasil kali dari setiap fitur tunggal, seperti pada persamaan (3).

$$P(X) = \prod_{i=1}^n P(C_k) \quad (3)$$

dimana X adalah himpunan fitur yang diamati, C_k menyatakan kelas ke- k , dan $P(x_i|C_k)$ adalah probabilitas kemunculan fitur ke- i ketika data termasuk ke dalam kelas C_k .

K-Nearest Neighbor (KNN) merupakan algoritma berbasis jarak yang melakukan klasifikasi dengan melihat kedekatan suatu data uji terhadap k data latih terdekat [23]. Tidak ada proses pelatihan eksplisit pada KNN, model hanya menyimpan seluruh data latih dan melakukan pencarian jarak saat proses prediksi. [24] Jarak antara dua titik data x dan x_i umumnya dihitung menggunakan metrik *Euclidean* seperti pada Persamaan (4).

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2} \quad (4)$$

di mana $d(x, x_i)$ adalah jarak *Euclidean* antara data uji x dan data latih ke- i , n menyatakan jumlah fitur pada setiap sampel, x_j adalah nilai fitur ke- j dari data uji, dan x_{ij} merupakan nilai fitur ke- j pada data latih ke- i .

Nilai jarak ini menentukan seberapa mirip suatu sampel dengan titik data lain di ruang fitur. Semakin kecil nilai jaraknya, semakin besar tingkat kemiripan antara dua data tersebut. Setelah jarak setiap titik dihitung, algoritma memilih k tetangga terdekat, kemudian menentukan kelas berdasarkan suara mayoritas dari tetangga tersebut, seperti ditunjukkan pada persamaan (5).

$$\hat{y} = \arg \arg \sum_{i=1}^k I(y_i = c) \quad (5)$$

di mana \hat{y} adalah hasil prediksi kelas untuk data uji, C merupakan himpunan semua kelas yang mungkin, y_i adalah label kelas dari tetangga ke- i .

2.5. Pengujian Kinerja Model

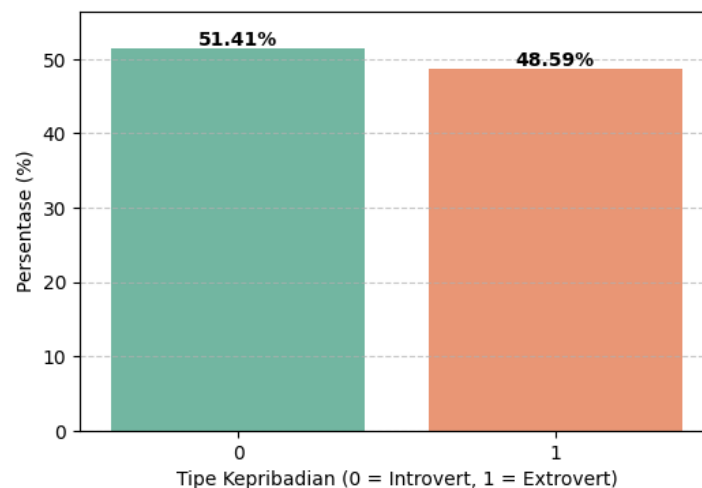
Tahap akhir penelitian adalah pengujian kinerja model menggunakan data uji. Pengukuran dilakukan dengan menggunakan *confusion matrix* yang menggambarkan jumlah prediksi benar dan salah untuk setiap kelas, melalui empat komponen utama yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan

False Negative (FN) [25]. Dari matriks ini diturunkan metrik evaluasi berupa akurasi, presisi, *recall*, dan *F1-score*. Selain itu, *Receiver Operating Characteristic* (ROC) *Curve* digunakan untuk menilai kemampuan model dalam membedakan kedua kelas, dan nilai *Area Under the Curve* (AUC) menjadi indikator kuantitatif terhadap performa keseluruhan model. Hasil evaluasi ketiga algoritma dibandingkan untuk memperoleh model dengan kinerja paling optimal dalam klasifikasi kepribadian berbasis ekstrasversi.

3. HASIL DAN PEMBAHASAN

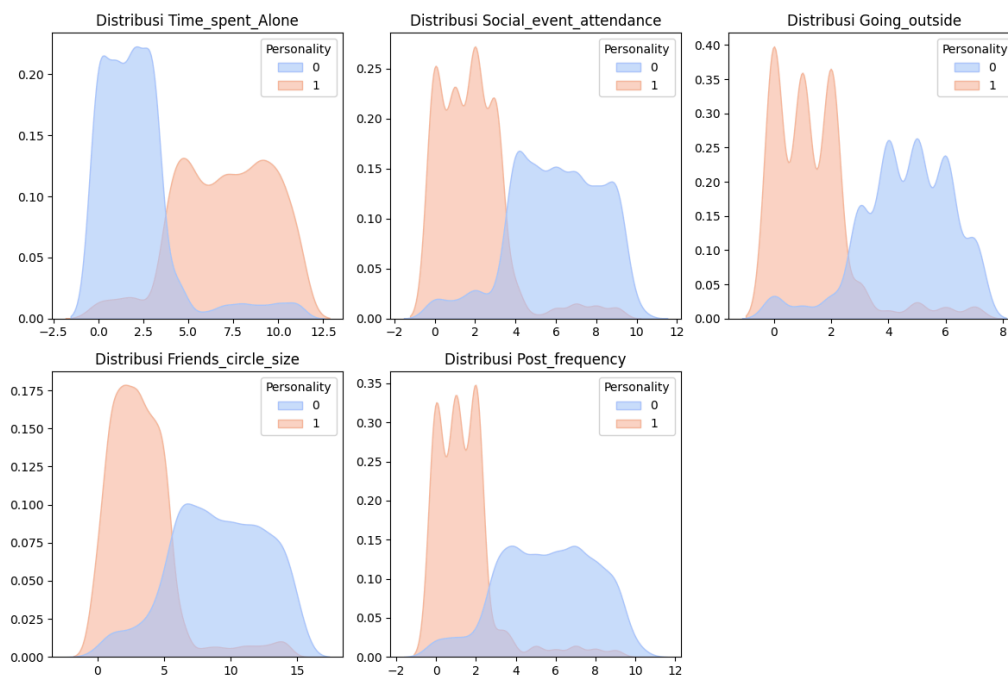
Dataset yang digunakan dalam penelitian ini terdiri atas 2.900 entri dengan delapan atribut yang merepresentasikan perilaku sosial individu [14]. Terdapat lima fitur numerik, yaitu *Time_spent_Alone*, *Social_event_attendance*, *Going_outside*, *Friends_circle_size*, dan *Post_frequency*, serta dua fitur kategorikal, yakni *Stage_fear* dan *Drained_after_socializing*. Label target yang digunakan adalah *Personality*, yang dikategorikan menjadi dua kelas: *Introvert* dan *Extrovert*. Fitur *Time_spent_Alone* menunjukkan jumlah waktu yang dihabiskan seseorang untuk beraktivitas sendiri, sedangkan *Social_event_attendance* merepresentasikan frekuensi individu menghadiri kegiatan sosial. Fitur *Going_outside* menggambarkan kecenderungan seseorang untuk keluar rumah, sementara *Friends_circle_size* menunjukkan ukuran lingkaran sosial yang dimiliki. Selanjutnya, *Post_frequency* menggambarkan tingkat aktivitas individu di media sosial. Dua fitur kategorikal, *Stage_fear* dan *Drained_after_socializing*, masing-masing menggambarkan tingkat ketakutan tampil di depan umum dan kondisi energi setelah melakukan interaksi sosial.

Proses selanjutnya yaitu normalisasi dan encoding data, dimana pada tahap ini dilakukan dengan mengonversi variabel kategorikal menjadi numerik, di mana nilai *Yes* direpresentasikan sebagai 1 dan *No* sebagai 0. Label target juga diubah menjadi *Introvert* = 0 dan *Extrovert* = 1. Dataset kemudian dibagi secara stratifikasi menjadi 80% data latih dan 20% data uji agar proporsi kedua kelas tetap seimbang. Analisis deskriptif dilakukan untuk memahami karakteristik dasar dataset sebelum pembangunan model. Tahap ini meliputi analisis distribusi label, visualisasi distribusi fitur numerik berdasarkan label kepribadian, dan analisis korelasi antar variabel numerik. Analisis distribusi label kepribadian dilakukan untuk memastikan keseimbangan proporsi kelas sebelum proses pelatihan model. Gambar 2 menampilkan distribusi kelas kepribadian berdasarkan kategori *Introvert* dan *Extrovert*.




Gambar 2. Distribusi Kelas Kepribadian Berdasarkan Kategori *Introvert* Dan *Extrovert*

Berdasarkan Gambar 2, proporsi *Extrovert* sebesar 51,41% dan *Introvert* sebesar 48,59%, menunjukkan distribusi yang hampir seimbang. Kondisi ini memastikan model tidak bias terhadap salah satu kelas sehingga evaluasi performa menjadi lebih representatif. Analisis berikutnya dilakukan terhadap distribusi fitur numerik, seperti yang diperlihatkan pada Gambar 3.



Gambar 3. Distribusi Variabel Numerik Berdasarkan Label Kepribadian

Gambar 3 memperlihatkan perbedaan pola distribusi yang cukup jelas antara *Introvert* dan *Extrovert*. Kelompok *Introvert* memiliki nilai *Time_spent_Alone* yang lebih tinggi, sedangkan kelompok *Extrovert* cenderung menunjukkan nilai lebih besar pada *Social_event_attendance*, *Going_outside*, *Friends_circle_size*, dan *Post_frequency*. Hal ini menunjukkan adanya perbedaan mendasar dalam perilaku sosial antar dua tipe kepribadian. Untuk mengidentifikasi hubungan antar variabel numerik, dilakukan analisis korelasi menggunakan *Pearson Correlation*, seperti yang divisualisasikan pada Gambar 4.



Gambar 4. Korelasi antar variabel numerik menggunakan Pearson Correlation

Dari Gambar 4 terlihat bahwa *Time_spent_Alone* memiliki korelasi negatif kuat dengan *Going_outside* (-0.74), sedangkan korelasi positif tinggi ditemukan antara *Social_event_attendance*, *Friends_circle_size*, dan *Post_frequency* (0.69 – 0.75). Pola ini memperkuat hubungan antara intensitas aktivitas sosial dengan tingkat ekstrasversi seseorang.

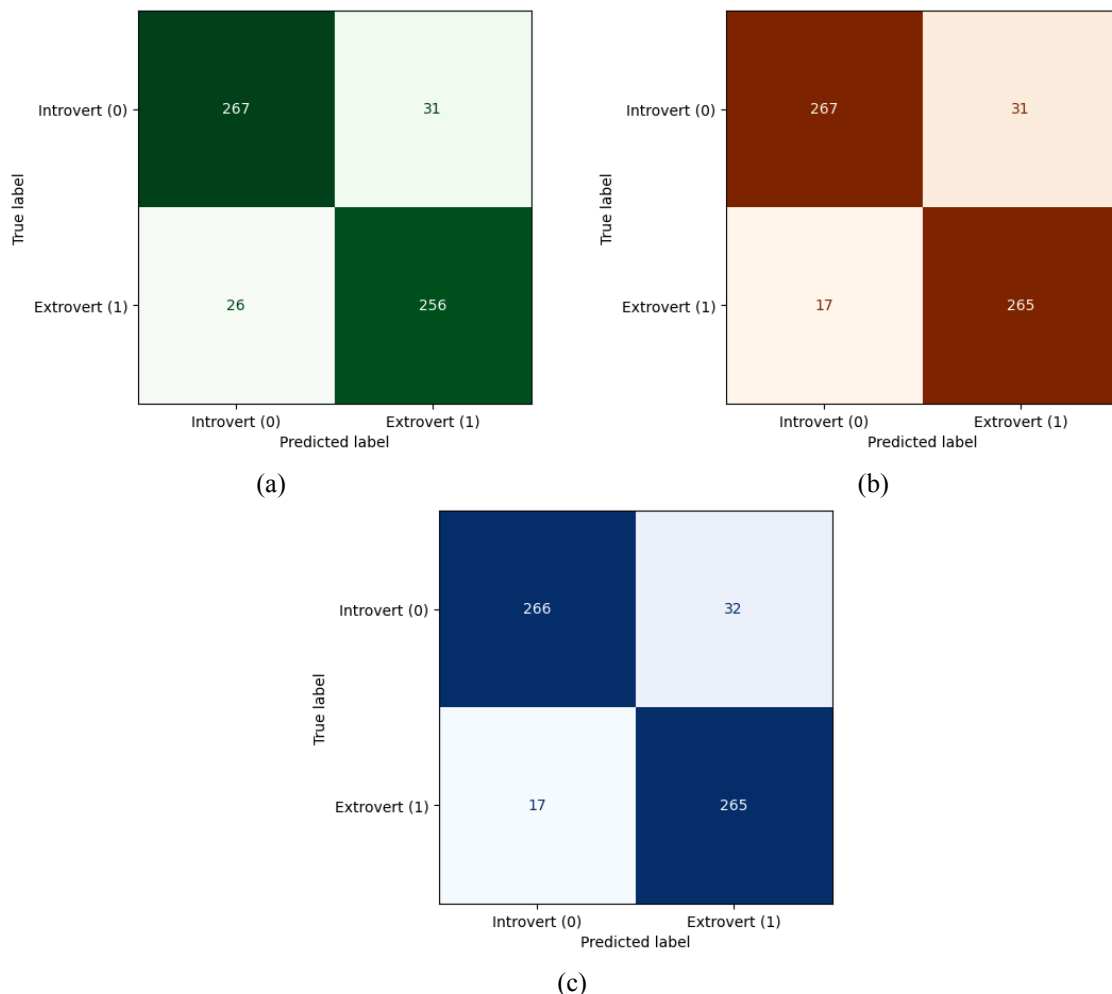
Proses selanjutnya adalah membangun model klasifikasi kepribadian berbasis tiga algoritma utama, yaitu *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor* (KNN). Ketiga algoritma ini dipilih karena mewakili pendekatan yang berbeda dalam pembelajaran mesin: *ensemble-based learning* pada *Random Forest*, probabilistic learning pada *Naïve Bayes*, serta *instance-based learning* pada KNN. Sebelum model dilatih, dataset yang telah melalui tahap normalisasi dan encoding dibagi menjadi 80% data latih dan 20% data uji dengan teknik *stratified split* untuk menjaga keseimbangan proporsi kelas *Introvert* dan *Extrovert*. Setiap algoritma kemudian diinisialisasi dengan konfigurasi parameter yang ditampilkan pada Tabel 1.

Tabel 1. Parameter Model Yang Digunakan

Algoritma	Parameter Utama	Nilai yang Digunakan	Keterangan
<i>Random Forest</i>	<i>n_estimators</i>	400	Jumlah pohon yang digunakan dalam <i>ensemble</i> ; nilai besar membantu mengurangi varians dan meningkatkan stabilitas model.
	<i>max_features</i>	“sqrt”	Menentukan jumlah fitur yang dipertimbangkan pada setiap pemisahan; pendekatan akar kuadrat umum digunakan untuk menjaga keseimbangan antara bias dan varians.
	<i>random_state</i>	42	Menjamin reproduisibilitas hasil eksperimen.
<i>Naïve Bayes</i>	-	-	Tidak memerlukan parameter khusus karena merupakan model berbasis probabilitas sederhana; hanya bergantung pada estimasi distribusi <i>Gaussian</i> untuk fitur numerik.
KNN	<i>n_neighbors</i>	11	Menentukan jumlah tetangga terdekat untuk klasifikasi; nilai 11 dipilih karena memberikan stabilitas hasil akurasi terbaik berdasarkan uji variasi nilai <i>k</i> .
	<i>metric</i>	“minkowski”	Menggunakan metrik jarak <i>Euclidean</i> sebagai standar pengukuran kedekatan antar <i>instance</i> .

Konfigurasi parameter pada Tabel 2 dipilih berdasarkan hasil eksplorasi awal serta pertimbangan literatur yang relevan. Pada *Random Forest*, jumlah *estimator* yang relatif tinggi (400) memberikan hasil yang lebih stabil tanpa menimbulkan *overfitting*, karena setiap pohon dibangun dari subset data dan fitur yang berbeda. Algoritma *Naïve Bayes* tidak memerlukan parameter kompleks, menjadikannya baseline yang cepat dan efisien untuk dibandingkan dengan model lain. Sedangkan pada KNN, nilai $k = 11$ ditetapkan setelah dilakukan pengujian terhadap beberapa nilai k dan ditemukan bahwa akurasi relatif konstan pada rentang 5–15, dengan nilai optimal pada $k = 11$ yang memberikan keseimbangan terbaik antara bias dan varians.

Setelah proses pelatihan selesai, masing-masing model diuji menggunakan data uji sebesar 20% dari total dataset. Evaluasi kinerja dilakukan menggunakan *confusion matrix* untuk melihat distribusi prediksi benar dan salah pada setiap kelas kepribadian. *Confusion matrix* menggambarkan performa model dalam membedakan antara kelas *Introvert* (0) dan *Extrovert* (1), dengan empat komponen utama yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Hasil *confusion matrix* untuk ketiga model ditunjukkan pada Gambar 5.



Gambar 5. Confusion Matrix: (a) *Random Forest*, (b) *Naïve Bayes*, dan (c) *K-Nearest Neighbor* (KNN)

Gambar 5 menampilkan *confusion matrix* dari tiga model klasifikasi kepribadian. Model *Random Forest* (Gambar 5a) menunjukkan prediksi yang seimbang antara kelas *introvert* dan *extrovert*, sedangkan *Naïve Bayes* (Gambar 5b) menghasilkan akurasi lebih tinggi dengan kesalahan prediksi yang lebih sedikit. Model KNN dengan $k = 11$ (Gambar 5c) memberikan hasil terbaik, menunjukkan bahwa kesamaan perilaku antar individu menjadi indikator efektif dalam membedakan kedua kecenderungan kepribadian. Berdasarkan hasil tersebut, metrik evaluasi seperti *precision*, *recall*, *F1-score*, *accuracy*, dan ROC-AUC dihitung untuk menilai kinerja model secara komprehensif, sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Kinerja Model

Model	Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>	ROC-AUC
<i>Random Forest</i>	<i>Introvert</i>	0.9018	0.9113	0.9065	0.9086	0.948
	<i>Extrovert</i>	0.9153	0.9060	0.9106		
<i>Naïve Bayes</i>	<i>Introvert</i>	0.9100	0.9326	0.9212	0.9224	0.8988
	<i>Extrovert</i>	0.9347	0.9128	0.9236		
KNN	<i>Introvert</i>	0.9135	0.9362	0.9247	0.9259	0.9494
	<i>Extrovert</i>	0.9381	0.9161	0.9270		

Hasil pengujian pada Tabel 2 menunjukkan bahwa seluruh model yang diuji memiliki performa tinggi. Namun, terdapat variasi kecil antar model yang menggambarkan karakteristik algoritma masing-masing terhadap pola data perilaku sosial yang digunakan. Model *K-Nearest Neighbor* (KNN) dengan nilai $k = 11$ menunjukkan kinerja terbaik dengan akurasi 92,59%, *F1-score* rata-rata 0.9259, dan ROC-AUC tertinggi yaitu 0.9494. Kinerja unggul KNN dapat dijelaskan oleh sifat dataset yang relatif bersih, terdistribusi seimbang, serta

memiliki pemisahan yang jelas antara fitur perilaku sosial seperti *Time_spent_Alone* dan *Friends_circle_size*. Dalam konteks ini, pendekatan berbasis jarak Euclidean memungkinkan KNN mengenali pola lokal antar individu secara efektif, karena individu dengan kepribadian serupa memiliki nilai fitur yang berdekatan. Nilai $k = 11$ terbukti optimal karena menjaga keseimbangan antara sensitivitas terhadap variasi lokal dan reduksi *noise*.

Model *Naïve Bayes* menempati posisi kedua dengan akurasi 92,24% dan recall tertinggi pada kelas *Introvert* (0.9326). Hal ini menunjukkan bahwa model probabilistik ini mampu menangkap pola kepribadian yang cenderung stabil dan terprediksi secara konsisten, meskipun asumsi independensi antar fitur tidak sepenuhnya terpenuhi. Karakteristik data yang memiliki variabel sosial cukup berhubungan (misalnya korelasi tinggi antara *Social_event_attendance* dan *Post_frequency*) menyebabkan sedikit penurunan nilai AUC (0.8988), karena korelasi antar fitur dapat mengganggu estimasi peluang bersyarat yang menjadi dasar prediksi *Naïve Bayes*.

Model *Random Forest* menghasilkan akurasi 90,86% dengan nilai ROC-AUC 0.9480, menunjukkan performa yang stabil dan kemampuan generalisasi yang kuat. Meskipun sedikit di bawah KNN dan *Naïve Bayes* dalam hal accuracy, *Random Forest* unggul dalam hal ketahanan terhadap *outlier* dan *overfitting*. Hal ini karena mekanisme *ensemble* yang menggabungkan banyak pohon keputusan dengan pemilihan fitur acak pada setiap node, sehingga menghasilkan prediksi yang lebih *robust*. Namun, karena data yang digunakan relatif sederhana dengan jumlah fitur terbatas dan distribusi yang tidak kompleks, keunggulan *ensemble learning* belum memberikan peningkatan signifikan dibandingkan pendekatan berbasis jarak seperti KNN.

Secara keseluruhan, hasil ini menunjukkan bahwa KNN paling sesuai untuk data dengan pola sosial yang membentuk kluster jelas antar individu. *Naïve Bayes* tetap unggul untuk prediksi cepat pada data bersih, sementara *Random Forest* lebih andal menghadapi *outlier* dan pola non-linear. Temuan ini menegaskan bahwa karakteristik perilaku sosial dalam dataset memiliki struktur lokal yang kuat dan mudah dikenali oleh metode berbasis jarak.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi kepribadian *Introvert* dan *Extrovert* menggunakan tiga algoritma *machine learning*, yaitu *Random Forest*, *Naïve Bayes*, dan *K-Nearest Neighbor* (KNN). Hasil pengujian menunjukkan bahwa model KNN dengan $k = 11$ memberikan performa terbaik dengan akurasi 92,59% dan nilai ROC-AUC 0,9494, menandakan kemampuannya mengenali pola perilaku sosial secara efektif melalui pendekatan berbasis kedekatan antar individu. Model *Naïve Bayes* mendapatkan akurasi 92,24% dan ROC-AUC 0,8988, menunjukkan keunggulannya dalam mengklasifikasikan individu dengan kecenderungan introversi secara konsisten. Sementara itu, *Random Forest* memperoleh akurasi 90,86% dan ROC-AUC 0,9480, yang mencerminkan kestabilan prediksi dan kemampuan generalisasi yang baik. Secara keseluruhan, ketiga algoritma menunjukkan kinerja kompetitif dengan perbedaan yang relatif kecil pada seluruh metrik evaluasi. Namun, penelitian ini masih terbatas pada dataset dengan jumlah fitur yang sederhana dan belum melibatkan faktor demografis atau psikologis tambahan. Untuk penelitian selanjutnya, disarankan memperluas cakupan fitur serta mengimplementasikan pendekatan *deep learning* atau *hybrid ensemble* guna meningkatkan akurasi dan kemampuan generalisasi dalam pemodelan kepribadian berbasis data perilaku sosial.

DAFTAR PUSTAKA

- [1] M. M. Rahmatullah, D. Savara, R. G. Salsabila, and F. N. Rahmasari, "Big Five Personality Traits dan Kesehatan Mental Remaja di Era Media Sosial," *RISOMA J. Ris. Sos. Hum. dan Pendidik.*, vol. 3, no. 4, pp. 152–180, 2025.
- [2] T. Simanullang, "Pengaruh Tipe Kepribadian the Big Five Model Personality Terhadap Kinerja Aparatur Sipil Negara (Kajian Studi Literatur Manajemen Keuangan)," *J. Manaj. Pendidik. Dan Ilmu Sos.*, vol. 2, no. 2, pp. 747–753, 2021, doi: 10.38035/jmpis.v2i2.634.
- [3] N. Fatmayanti, S. Sukiatni, and R. Kusumandari, "Tingkat stres pada mahasiswa: Berbedakah antara mahasiswa dengan kepribadian introvert dan ekstrovert?," *J. Psychol. Res.*, vol. 2, no. 3, pp. 232–239, 2022.
- [4] S. Saiddaeni, "Gaya Belajar Tipe Anak Introvert dan Ekstrovert," *SIBATIK J. J. Ilm. Bid. Sos. Ekon. Budaya, Teknol. dan Pendidik.*, vol. 2, no. 6, pp. 1653–1660, 2023, doi: 10.54443/sibatik.v2i6.874.
- [5] M. W. Haryanti and Y. Margaretha, "Efektivitas Penggunaan MBTI Sebagai Tolak Ukur Penerimaan Karyawan," *J. Ilm. MEA (Manajemen, Ekon. dan Akuntansi)*, vol. 6, no. 1, pp. 932–946, 2024.
- [6] A. Trifani, A. P. Windarto, and H. Qurniawan, "Penerapan Data Mining Klasifikasi C4.5 dalam Menentukan Tingkat Stres Mahasiswa Akhir," *J. Ris. Rumpun Ilmu Tek.*, vol. 1, no. 2, pp. 91–105, 2022, doi: 10.55606/jurritek.v1i2.414.
- [7] A. Subtinanda and N. Yuliana, "Kepribadian Ekstrovert dan Introvert dalam Konteks Komunikasi

- Antarpribadi Mahasiswa Ilmu Komunikasi UNTIRTA,” *J. Pendidik. Non Form.*, vol. 1, no. 2, p. 15, 2023, doi: 10.47134/jpn.v1i2.187.
- [8] A. Oktafiqurahman, K. Kusriani, and A. Nasiri, “Prediksi Kepribadian Berdasarkan Status Sosial Media Facebook Menggunakan Metode Naive Bayes dan KNN,” *J. Teknol. Inf. dan Komun.*, vol. 11, no. 2, pp. 30–34, 2023, doi: 10.30646/tikomsin.v11i2.747.
- [9] P. J. Alifiyah and N. Pratiwi, “Deteksi Tipe Sidik Jari Untuk Mengenali Kepribadian Menggunakan Metode Support Vector Machine (SVM),” *Metik J.*, vol. 9, no. 2, pp. 375–384, 2025, doi: 10.47002/metik.v9i2.1073.
- [10] M. P. Pulungan, A. Purnomo, and A. Kurniasih, “Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Kepribadian MBTI Menggunakan Naive Bayes Classifier,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 5, pp. 1033–1042, 2024, doi: 10.25126/jtiik.2024117989.
- [11] D. Al Mahkya, K. A. Notodiputro, and B. Sartono, “Extra Trees Method for Stock Price Forecasting With Rolling Origin Accuracy Evaluation,” *Media Stat.*, vol. 15, no. 1, pp. 36–47, 2022, doi: 10.14710/medstat.15.1.36-47.
- [12] G. A. Putri, A. Trimaysella, and A. Khoiriah, “Penerapan Klasifikasi Data Mining pada Diabetes Menggunakan Metode Naive Bayes,” *J. Ilmu Komput. Teknol. Terap.*, vol. 1, no. 14, pp. 1–9, 2024.
- [13] A. Yogianto, A. Homaidi, and Z. Fatah, “Implementasi Metode K-Nearest Neighbors (KNN) untuk Klasifikasi Penyakit Jantung,” *G-Tech J. Teknol. Terap.*, vol. 8, no. 3, pp. 1720–1728, 2024, doi: 10.33379/gtech.v8i3.4495.
- [14] R. Kapilavayi, “Extrovert vs. Introvert Behavior Data,” Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/rakeshkapilavai/extrovert-vs-introvert-behavior-data>
- [15] H. Bichri, A. Chergui, and M. Hain, “Investigating the Impact of Train / Test Split Ratio on the Performance of Pre-Trained Models with Custom Datasets,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 2, pp. 331–339, 2024, doi: 10.14569/IJACSA.2024.0150235.
- [16] A. Sah, C. Niesa, R. R. Jafar, and M. Muharrom, “Analisis Model Prediksi Penyakit Jantung Menggunakan Adaptive Boosting, Gradient Boosting, dan Extreme Gradient Boosting,” *J. Ilm. FIFO*, vol. 17, no. 1, pp. 46–56, 2025, doi: 10.22441/fifo.2025.v17i1.006.
- [17] A. Candra, M. Erkamim, M. Muharrom, and E. Prayitno, “Klasifikasi Stunting Pada Balita Berdasarkan Status Gizi Menggunakan Pendekatan Support Vector Machine (SVM),” *J. Ilm. FIFO*, vol. 16, no. 2, pp. 171–181, 2024.
- [18] A. Samosir, M. Hasibuan, W. E. Justino, and T. Hariyono, “Komparasi Algoritma Random Forest, Naïve Bayes dan K- Nearest Neighbor Dalam klasifikasi Data Penyakit Jantung,” in *Seminar Nasional Hasil Penelitian dan Pengabdian Masyarakat*, 2021, pp. 214–222.
- [19] C. Arafat, M. C. Ramadhan, F. A. Jafar, M. R. A. Pramudya, and E. Ismanto, “Perbandingan Algoritma Random Forest Dan Xgboost Untuk Klasifikasi Penyakit Jantung Berdasarkan Data Medis,” *J. Fasilkom*, vol. 15, no. 2, pp. 430–435, 2025.
- [20] S. Affandi, E. Maryanto, and Y. I. Kurniawan, “Prediksi Nilai Pasar Pemain Sepak Bola Menggunakan Algoritma Random Forest Berdasarkan Atribut Permainan Dari Game Football Manager 2023 Pada Lima Liga Top Eropa (Berdasarkan Koefisien UEFA) Prediction Of Football Player Market Value Using Random Forest,” *J. Pendidik. dan Teknol. Indones. Vol.*, vol. 4, no. 10, pp. 515–536, 2024.
- [21] O. P. Barus, K. Lauwren, J. J. Pangaribuan, and Romindo, “Implementation of the Naive Bayes Algorithm to Predict the Safety of Heart Failure Patients,” *IAIC Int. Conf. Ser.*, vol. 4, no. 1, pp. 172–177, 2023, doi: 10.34306/conferenceseries.v4i1.651.
- [22] D. Larassati, A. Zaidiah, and S. Afrizal, “Sistem Prediksi Penyakit Jantung Koroner Menggunakan Metode Naive Bayes,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 7, no. 2, pp. 533–546, 2022, doi: 10.29100/jupi.v7i2.2842.
- [23] M. Ula, A. F. Ulva, I. Saputra, M. Mauliza, and I. Maulana, “Implementation of Machine Learning Using the K-Nearest Neighbor Classification Model in Diagnosing Malnutrition in Children,” *Multica Sci. Technol. J.*, vol. 2, no. 1, pp. 94–99, 2022, doi: 10.47002/mst.v2i1.326.
- [24] M. Bansal, A. Goyal, and A. Choudhary, “A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning,” *Decis. Anal. J.*, vol. 3, pp. 1–21, 2022, doi: 10.1016/j.dajour.2022.100071.
- [25] Parjito, I. Ahmad, R. I. Borman, A. D. Alexander, and Y. Jusman, “Combining Extreme Learning Machine and Linear Discriminant Analysis for Optimized Apple Leaf Disease Classification,” in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, IEEE, 2024, pp. 138–143. doi: 10.1109/ICE3IS62977.2024.10775844.