

## *Personality and Child Development Detection Using Fingerprints with K-Nearest Neighbor and Decision Tree Algorithm*

### **Deteksi Kepribadian dan Tumbuh Kembang Anak dengan Sidik Jari Menggunakan Algoritma K-Nearest Neighbor dan Decision Tree**

Andi Gunawan<sup>1\*</sup>, Chair Anggita Fitriani<sup>2</sup>, Wira Hadinata<sup>3</sup>, Wieke Ricesa<sup>4</sup>

<sup>1,2,3,4</sup>Computer Engineering, Institut Teknologi dan Bisnis Bina Sarana Global, Indonesia

E-Mail: <sup>1</sup>1120120015@global.ac.id <sup>2</sup>1119110105@global.ac.id  
<sup>3</sup>wira@global.ac.id <sup>4</sup>wricesa@gmail.com

Received Jun 08th 2025; Revised Jul 04th 2025; Accepted Jul 28th 2025; Available Online Jul 31th 2025, Published Aug 15th 2025

Corresponding Author: Andi Gunawan

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*Personality and learning styles are two essential aspects that support a child's growth and development. This study aims to identify children's personality traits and developmental tendencies based on fingerprint patterns using K-Nearest Neighbor (K-NN) and Decision Tree (DT) classification algorithms. The research was conducted on 10 participants from Annisa Kindergarten in Tangerang, where fingerprint data were collected from the middle, ring, and little fingers using an ink-based fingerprinting method. The collected fingerprints were scanned and categorized into three main patterns: Arch, Loop, and Whorl. The classification process was carried out using K-NN and DT algorithms and evaluated through both hold-out validation and Leave-One-Out Cross-Validation (LOOCV). The evaluation results showed that the classification models achieved accuracy, precision, recall, and F1-score values of 1.0, with a LOOCV accuracy of 90%. Prediction results revealed that 50% of the children exhibited personalities with strong memory, 40% were ambitious and disciplined, and 10% were perfectionist and communicative. The learning styles identified using K-NN were visual (60%) and kinesthetic (40%), while the DT method classified them as visual (50%), kinesthetic (40%), and auditory (10%). This study indicates a correlation between fingerprint patterns and children's personality tendencies and learning styles, suggesting that such analysis can serve as an early detection tool and a basis for character-based educational interventions.*

*Keywords: Child Personality, Decision Tree, Early Detection, Fingerprint, K-Nearest Neighbor, Learning Style*

#### **Abstrak**

Kepribadian dan gaya belajar merupakan dua aspek penting dalam mendukung tumbuh kembang anak. Penelitian ini bertujuan untuk mengidentifikasi kepribadian dan tumbuh kembang anak berdasarkan pola sidik jari menggunakan algoritma klasifikasi K-Nearest Neighbor (K-NN) dan Decision Tree (DT). Penelitian dilakukan pada 10 partisipan di taman kanak-kanak Annisa Tangerang, dengan pengumpulan data sidik jari dari jari tengah, manis, dan kelingking menggunakan metode sidik tinta. Data kemudian dipindai dan dikategorikan ke dalam tiga pola utama: *Arch*, *Loop*, dan *Whorl*. Proses klasifikasi dilakukan menggunakan algoritma K-NN dan DT, serta diuji menggunakan pendekatan *hold-out validation* dan *Leave-One-Out Cross-Validation* (LOOCV). Hasil pengujian menunjukkan bahwa model klasifikasi mencapai nilai akurasi, *precision*, *recall*, dan *F1 score* sebesar 1.0, serta akurasi LOOCV sebesar 90%. Hasil prediksi menunjukkan bahwa 50% anak memiliki kepribadian dengan daya ingat tajam, 40% ambisius dan disiplin, serta 10% perfeksionis dan komunikatif. Gaya belajar yang teridentifikasi menggunakan K-NN adalah visual (60%) dan kinestetik (40%), sementara dengan DT terdiri dari visual (50%), kinestetik (40%), dan auditori (10%). Penelitian ini menunjukkan adanya korelasi antara pola sidik jari dengan kecenderungan kepribadian dan gaya belajar anak serta bisa menjadi alat bantu dalam deteksi dini dan intervensi edukatif berbasis karakter anak.

Kata Kunci: Decision Tree, Deteksi Dini, Gaya Belajar, Kepribadian Anak, K-Nearest Neighbor, Sidik Jari

#### **1. PENDAHULUAN**

Perkembangan tumbuh kembang anak pada usia dini merupakan fondasi utama dalam pembentukan karakter, kecerdasan, dan gaya belajar yang akan terus berkembang sepanjang hidupnya. Dalam konteks



pendidikan, dua aspek penting yang saling berkaitan dengan tumbuh kembang berperan besar terhadap efektivitas proses pembelajaran adalah kepribadian dan gaya belajar. Kepribadian merepresentasikan karakteristik unik seseorang dalam berinteraksi dengan orang lain, sedangkan gaya belajar adalah preferensi seseorang dalam menerima dan mengolah informasi, baik secara visual, auditori, maupun kinestetik [1][2][3]. Memahami keterkaitan antara kepribadian dan gaya belajar sejak dini akan memberikan dampak signifikan terhadap peningkatan kualitas pendidikan anak.

Penelitian-penelitian sebelumnya menunjukkan bahwa pemanfaatan teknologi biometrik, khususnya sidik jari, tidak hanya digunakan untuk identifikasi identitas, tetapi juga mulai diarahkan untuk menganalisis kecenderungan psikologis dan potensi belajar anak [4][5][6]. Dermatoglifi, ilmu yang mempelajari pola sidik jari, menyatakan bahwa pola-pola seperti *Arch*, *Loop*, dan *Whorl* memiliki keterkaitan dengan karakter neurologis dan genetik yang terbentuk sejak dalam kandungan [7]. Oleh karena itu, sidik jari memiliki potensi besar untuk dijadikan sebagai alat bantu non-invasif dalam mendeteksi kepribadian dan gaya belajar seseorang secara objektif dan ilmiah.

Beberapa penelitian sebelumnya telah mengaitkan teknologi biometrik dan kecerdasan buatan dalam analisis kepribadian dan potensi belajar [8]. Menggunakan metode Artificial Neural Network (ANN) untuk klasifikasi sidik jari anak dalam mengidentifikasi kecerdasan majemuk, namun belum menjangkau aspek gaya belajar secara eksplisit [9]. Menerapkan algoritma backpropagation dalam prediksi kepribadian berdasarkan pola sidik jari, tetapi tanpa mengintegrasikan variabel gaya belajar [10]. Mengembangkan model Decision Tree (DT) untuk klasifikasi sidik jari di bidang forensik, bukan pendidikan [11]. Menggunakan metode K-Nearest Neighbor (K-NN) untuk mengklasifikasikan tipe kepribadian siswa berdasarkan kuesioner, bukan data biometrik [12].

Dari hasil telaah terhadap studi terdahulu, terdapat beberapa celah penelitian (research gap) yang dapat diidentifikasi: (1) Minimnya penelitian yang secara simultan mengkaji keterkaitan pola sidik jari, kepribadian, dan gaya belajar. (2) Terbatasnya penggunaan pendekatan *machine learning* secara ganda (*multi-model*) untuk perbandingan performa klasifikasi. (3) Serta kurangnya penerapan metode non-invasif dan praktis untuk keperluan deteksi dini tumbuh kembang anak secara komprehensif. Berdasarkan hal tersebut, Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kepribadian dan gaya belajar anak berdasarkan pola sidik jari menggunakan algoritma K-NN dan DT. Data yang digunakan berupa pola sidik jari dari tiga jari tangan anak, yaitu jari tengah, jari manis, dan jari kelingking. Data ini akan dianalisis untuk mengidentifikasi pola dominan dan dipetakan ke dalam karakteristik kepribadian serta gaya belajar yang sesuai.

Penelitian ini penting dilakukan karena dapat menjadi solusi deteksi dini kepribadian dan gaya belajar anak yang praktis, objektif, dan non-invasif, sehingga mendukung pengambilan keputusan yang lebih tepat dalam proses pembelajaran dan intervensi psikologis. Dampak dari penelitian ini diharapkan dapat membantu guru dan orang tua dalam merancang pendekatan pendidikan yang lebih sesuai dengan karakter dan kebutuhan anak, serta membuka peluang pemanfaatan teknologi dalam pendidikan usia dini secara lebih luas.

## 2. BAHAN DAN METODE

Penelitian ini menggunakan pendekatan observasi dan pendekatan kuantitatif dengan metode klasifikasi berbasis *machine learning*, yaitu algoritma K-NN dan DT. Tujuan dari metodologi ini adalah untuk membangun sistem klasifikasi kepribadian dan gaya belajar anak berdasarkan pola sidik jari yang dianalisis secara sistematis.

### 2.1. Flowchart Metodologi

Diagram alur metodologi pada Gambar 1. Alur Proses Penelitian menggambarkan tahapan penelitian secara sistematis dari awal hingga implementasi akhir. Penelitian dimulai dengan akuisisi data sidik jari dari partisipan, dilanjutkan dengan proses pelabelan pola sidik jari berdasarkan tiga klasifikasi utama yaitu *Arch*, *Loop*, dan *Whorl*. Tahap berikutnya adalah preprocessing data untuk membersihkan dan mempersiapkan data mentah agar siap digunakan dalam proses pelatihan model. Setelah itu, data dibentuk menjadi format dataset yang memuat fitur-fitur penting dan label target. Dua algoritma klasifikasi, yaitu K-NN dan DT, digunakan dalam proses pelatihan dan pengujian model. Evaluasi dilakukan menggunakan metrik seperti *confusion matrix* untuk menilai akurasi dan efektivitas model. Tahap akhir dari proses ini adalah evaluasi Hasil.

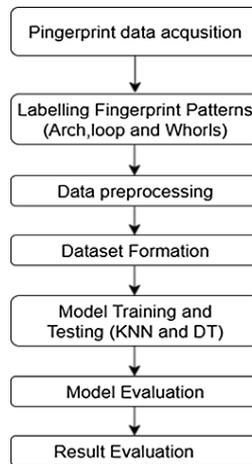
### 2.2. Literatur Review

#### 2.2.1. Sidik Jari

Sidik jari manusia sedemikian uniknya sehingga tidak ada seorang pun yang memiliki sidik jari yang identik dengan orang lain, meskipun antara saudara kembar [13]. Penggunaan sidik jari sebagai metode identifikasi menjadikannya sebuah alat valid untuk mengidentifikasi seseorang. Pola sidik jari terdiri dari pola alur pada garis ujung jari tangan manusia, yang membentuk pola-pola khusus [14]. Sidik jari berasal dari sumber yang sama akan mempunyai alur garis lokal yang sama. Meskipun berasal dari satu embrio, tidak ada

dua individu yang memiliki pola sidik jari yang identik, karena pola sidik jari yang terbentuk dalam embrio tidak diwariskan [15].

Jika terjadi goresan luka pada sidik jari, maka setelah pulih, sidik jari akan memulihkan bentuknya kembali seperti semula. Sidik jari memiliki sifat yang menetapkan bentuknya seumur hidup, kecuali jika seseorang mengalami kecelakaan serius yang menyebabkan kehilangan jaringan asli pada sidik jari dan pada seseorang yang sudah meninggal yang membuat tubuhnya mengalami proses pembusukan atau penguraian [16]. Secara umum, pola sidik jari di kategorikan menjadi 3 kategori seperti *Arch* (melengkung), *Loop* (lingkaran) serta *Whorl* (pusaran) [17]. Dapat dilihat pada Gambar 2.



**Gambar 1.** Alur Proses Penelitian



**Gambar 2.** Pola Sidik jari

#### 1. Terminologi Identifikasi Sidik Jari

Teknologi biometri memanfaatkan identifikasi unik berdasarkan ciri-ciri fisik individu, seperti punggung bukit dan pola jari, untuk mengautentikasi pengguna. Dalam proses autentikasi ini, perangkat lunak khusus digunakan untuk memeriksa perbedaan-perbedaan signifikan yang terdapat dalam tiga aspek utama, yaitu punggung bukit, fitur global dan fitur lokal. Dengan demikian, sistem biometri ini mampu memberikan keamanan tambahan dan tingkat ketepatan yang tinggi dalam mengidentifikasi individu secara unik dan akurat [15].

#### 2. Tipe Kepribadian Berdasarkan Pola Sidik Jari

Setiap pola sidik jari tidak hanya mencerminkan gaya belajar seseorang, tetapi juga dapat memberikan gambaran mengenai tipe kepribadian individu. Berikut adalah penjabaran mengenai karakter anak berdasarkan hasil analisis pola sidik jari (*fingerprint analysis*):

- a. Pola sidik jari berbentuk *whorl* umumnya dikaitkan dengan pribadi yang jujur, kritis, perfeksionis, serta memiliki semangat bersaing yang tinggi. Mereka biasanya komunikatif dan memiliki tekad yang kuat [18].
- b. Pola sidik jari berbentuk *Pola Loop* sangat unggul. Mereka mampu mengingat detail dengan mudah dan teliti [18].

- c. *Pola Arch* Mereka yang memiliki pola arch pada sidik jarinya biasanya menjunjung tinggi nilai-nilai tradisional dan etika. Pandangan mereka terhadap ambisi, karier dan kepemimpinan umumnya bersifat konservatif dan berlandaskan prinsip moral yang kuat [18].

### 2.2.2. K-Nearest Neighbor (K-NN)

Metode K-NN adalah sebuah pendekatan dalam klasifikasi yang berdasarkan pada prinsip perhitungan jarak antara objek yang akan diklasifikasikan dengan data pelatihan yang ada. Konsep dasar dari metode ini adalah bahwa objek akan diklasifikasikan berdasarkan kesamaan jaraknya dengan objek-objek pelatihan yang paling dekat dengannya. Dalam proses ini, semua data pelatihan digunakan sebagai referensi untuk mengklasifikasikan sampel pelatihan. Ketika sampel baru diuji, jaraknya dihitung terhadap setiap sampel X pelatihan yang ada dan sampel baru tersebut akan diklasifikasikan ke dalam kelas yang memiliki sekumpulan jarak terdekat K yang paling sedikit [7].

Dalam klasifikasi K-NN, pemilihan metrik *Euclidean Distance* sering dianggap sebagai pilihan yang efektif untuk mengukur kemiripan antar sampel karena kesederhanaannya dan kestabilan secara umum. Wahyono dkk. (2020) menemukan bahwa Euclidean memberikan performa terbaik dibandingkan dengan Manhattan dan Minkowski dalam klasifikasi teks, dan nilai  $k = 3$  terbukti optimal pada dataset tersebut [22]. Setiawan (2023) memperlihatkan bahwa variasi nilai  $k$  antara 1 hingga 31 memengaruhi ketepatan akurasi dan F1-score, dengan nilai  $k = 5$  memberikan hasil terbaik pada pengujian data uji 20% [23]. Sementara itu, Pulungan dkk. (2019) menunjukkan bahwa Euclidean distance lebih stabil dibandingkan metrik lain seperti Canberra dan Bray–Curtis saat menangani dataset numerik dan citra dengan noise rendah [23].

Pernyataan ini mendukung alasan praktis penggunaan nilai  $K = 3$  dan *Euclidean Distance* dalam penelitian ini. Nilai  $k$  kecil seperti 3 sering direkomendasikan untuk menjaga keseimbangan antara sensitivitas terhadap noise dan kemampuan klasifikasi, serta menghindari ambiguitas dalam voting kelas bila jumlah kelas berjumlah ganjil.

Adapun Rumus *Euclidean distance* sebagaimana yang terlihat pada persamaan (1):

$$d_{xy} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Dalam proses pelatihan model, dilakukan eksplorasi terhadap beberapa parameter penting guna memperoleh performa klasifikasi terbaik. Untuk algoritma K-NN, diuji beberapa nilai tetangga terdekat yaitu  $K = 1, 3,$  dan  $5$ . Hasil menunjukkan bahwa nilai  $K = 3$  memberikan akurasi paling stabil pada data uji dan validasi silang. Nilai  $K$  yang terlalu kecil seperti  $K = 1$  cenderung menyebabkan *overfitting*, sedangkan nilai  $K = 5$  menghasilkan penurunan akurasi pada data yang jumlahnya terbatas.

### 2.2.3. Decision Tree (DT)

DT merupakan metode pengklasifikasian yang memiliki bentuk bercabang seperti sebuah pohon yang sangat sering digunakan sebagai penentuan dalam mengenali pola. Data sidik jari yang telah di ambil data nya dibedakan melalui cirinya, dan diklasifikasikan sesuai dengan bentuk pola sidik jari yang sudah ditentukan polanya. Data yang diklasifikasikan dapat digunakan dalam membuat pola yang menjadi peraturan bagi data yang akan diujikan untuk menentukan suatu prediksi dalam pengindentifikasian tipe sidik jari pada data [7].

DT merupakan metode klasifikasi yang umum digunakan dalam aplikasi *supervised learning* karena kemampuannya dalam menghasilkan model berbentuk pohon keputusan yang mudah diinterpretasikan. Namun, kompleksitas model ini sangat bergantung pada pengaturan parameter seperti *max\_depth* (kedalaman maksimum pohon) dan *criterion* (fungsi evaluasi pembelahan seperti *gini* atau *entropy*). Misalnya, Syahputri & Hasibuan (2020) menunjukkan bahwa penerapan teknik *pruning*, baik *pre-pruning* maupun *post-pruning*, dapat meningkatkan akurasi dari 0.83 menjadi 0.8841 dengan menurunkan *overfitting* pada dataset penyakit jantung [24]. Studi lainnya oleh Maori & Annisa (2024) menemukan bahwa meskipun model dengan *max\_depth* yang sangat besar ( $\geq 8$ ) dapat mencapai akurasi sempurna pada data latih, hal tersebut menandakan *overfitting* yang tinggi dan menurunkan kemampuan generalisasi ke data baru [25]. Temuan ini selaras dengan prinsip dasar bahwa pemilihan *max\_depth* yang optimal (seperti 2–5) dan fungsi *criterion* yang tepat dapat menghasilkan model yang lebih *robust* tanpa mengorbankan akurasi pada data uji.

### 2.2.4. Confusion Matrix

Dalam penelitian yang dilakukan oleh Chen dan Zhu (2018) berjudul "*Design and Implementation of Fingerprint Identification System Based on K-NN Neural Network*", digunakan metode klasifikasi berbasis K-NN untuk mengidentifikasi sidik jari berdasarkan fitur yang diekstraksi secara numerik. Untuk mengevaluasi performa model klasifikasi, penelitian ini menggunakan *confusion matrix* sebagai alat analisis utama. *Confusion matrix* digunakan untuk menampilkan jumlah prediksi benar dan salah untuk setiap kelas

sidik jari, sehingga memungkinkan peneliti untuk mengetahui secara rinci distribusi kesalahan pada klasifikasi. Melalui *confusion matrix*, dapat diidentifikasi kelas mana yang paling sering salah diprediksi, serta seberapa baik model dalam membedakan antar kelas. Penggunaan *confusion matrix* dalam penelitian ini memperkuat hasil evaluasi model, karena mampu memberikan insight lebih dari sekadar nilai akurasi keseluruhan. Hasil evaluasi menunjukkan bahwa metode K-NN cukup efektif dalam pengenalan pola sidik jari, terutama ketika fitur-fitur yang relevan telah berhasil diekstraksi dan direpresentasikan secara numerik [8].

### 2.2.5. Literature review penelitian terdahulu

Literatur review yang digunakan untuk landasan dukungan dari karya tulis ilmiah ini, menggunakan jurnal dengan judul yang relevan terhadap permasalahan dan mengurangi risiko plagiarisme. Pada karya tulis ilmiah – Vol.2 No.2 Tahun 2022 Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Padang, oleh Annisa Syaifullah, Mutia Oktaviani, Siti Atikah Salsabilla, Naura Nazhifah, Arsyah Gusnita, Syahrul Ramadhani, Aldi Wahyuda Vestimarta dengan judul “Variasi Pola Sidik Jari Antara Jurusan Biologi Dan Jurusan Kimia Terhadap Penderita Miopi (Rabun Jauh) Dan Mata Normal”. Pada jurnal ini didapatkan data yang menunjukkan pada pola sidik jari yang dimiliki pada kebanyakan penderita penyakit *myopia* adalah pola sidik jari *whorl*, yaitu sekitar 46% pada jurusan biologi dan 47% pada jurusan kimia. Sedangkan pada mata normal memiliki dominasi yaitu pola *loop*, yakni sebesar 57% pada jurusan biologi dan pada jurusan kimia memiliki potensi sebesar 54%. Hal ini menunjukkan bahwa *myopia* memiliki efek kerentanan. Pola sidik jari dipengaruhi oleh genetik yang menunjukkan susunan gen dan DNA seseorang. Penelitian ini sudah dilakukan oleh *nousbeck*, faktor genetik dapat mengatur dermatoglifi yang dapat mengkode gen terhadap protein [19].

Pada karya tulis ilmiah – Vol.6 Tahun 2017 Department of Anatomy, SMS&R Sharda University, Greater Noida, Uttar Pradesh, India Oleh Durga Paswan, Poonam Kharb, Prajna Paramita Samanta dengan judul “*Identification and Correlation of the Multiple Intelligences and Finger Print Patterns*”. Penelitian ini dilakukan untuk mengidentifikasi pola dermatoglif dan MI pada mahasiswa Universitas Sharda dari aliran yang berbeda dan untuk menemukan apakah ada korelasi antara pola dermatoglif dan MI. Pada jurnal ini didapatkan data yang menunjukkan Kecerdasan intrapersonal memiliki skor rata-rata tertinggi (74,5±22,93) diikuti oleh kecerdasan interpersonal (69,59±30,83) dan kecerdasan spasial (65,69±26,45). Kecerdasan linguistik memiliki skor terendah (52,45±28,55). Pola ulnar *loop* (61%) adalah yang paling umum diikuti oleh *whorls* (33,2%), lengkungan (3,3%) dan radial *loop* (2,8%). Persentase ulnar *loop* adalah yang tertinggi pada siswa dengan skor tinggi untuk kinestetik dan *whorl* pada siswa dengan kecerdasan logis. Persentase lengkungan tertinggi terlihat pada siswa dengan skor tinggi dalam kecerdasan linguistik, sedangkan berkinerja tinggi dalam kecerdasan logis memiliki jumlah lengkungan terendah. Tidak ada korelasi signifikan yang diamati antara tipe MI dengan FPP mana pun, kecuali untuk kecerdasan logis, yang menunjukkan korelasi negatif yang signifikan dengan prevalensi lengkungan. Hasil penelitian ini menegaskan bahwa setiap individu memiliki tipe kecerdasan yang berbeda dengan tingkat yang berbeda. Namun, hasil korelasi antara tipe MI dan FPP menunjukkan korelasi yang lemah dan tidak konklusif [20].

## 3. HASIL DAN PEMBAHASAN

Proses metodologi ini mencakup beberapa tahap yaitu Pengumpulan data, Pra-pemrosesan, *Dataset formation, Model training and testing* (K-NN and DT), Evaluasi model, serta Evaluasi hasil. Berikut adalah beberapa tahapan metodologi tersebut :

### 3.1. Pengumpulan Data Sidik Jari

Data sidik jari dikumpulkan secara langsung dari partisipan yang terdiri dari 10 anak-anak (6 laki-laki dan 4 perempuan) di taman kanak-kanak Annisa Tangerang. Metode pengambilan menggunakan tinta cetak pada jari tengah, jari manis, dan jari kelingking, alasan penggunaan ketiga jari tersebut di dasarkan pada kutipan berikut “menurut analisa penelitian ilmiah dengan metode *dermatoglyphic multiple intelligence test (DMIT)* menggunakan tiga jari karena dianggap lebih efisien, praktis, dan mewakili tiga domain kecerdasan utama (logika, kreativitas, komunikasi). Ketiga jari tersebut memberikan akurasi tinggi dalam pemetaan potensi anak, sehingga menjadi standar praktis yang digunakan secara luas” [21]. Selanjutnya ketiga sidik jari tersebut kemudian ditempelkan ke atas kertas. Setelah itu, gambar sidik jari difoto menggunakan kamera *smartphone* dan dipindai untuk mendapatkan citra digital. Dalam penelitian ini tidak digunakan alat biometrik ataupun dataset publik.

### 3.2. Pra-pemrosesan Data

Setelah data diperoleh dalam bentuk digital, dilakukan pra-pemrosesan untuk memastikan kualitas citra memadai. Tahapan ini meliputi:

1. Resize gambar agar memiliki dimensi seragam.
2. *Enhancement* kontras untuk menonjolkan pola ridge sidik jari.

- Ekstraksi Pola Dominan (manual labeling) ke dalam 3 kategori yaitu *Arch*, *Loop*, dan *Whorl*.

### 3.3. Dataset Formation

Setelah data sidik jari diperoleh dan diklasifikasikan ke dalam tiga jenis pola utama (*Arch*, *Loop*, dan *Whorl*), dilakukan proses penyusunan dataset agar dapat digunakan dalam pelatihan model klasifikasi. Dataset ini dibentuk dalam format tabel data yang terdiri atas dua komponen utama:

- Fitur (*Features*):

Yaitu representasi dari pola sidik jari pada tiga jari yaitu jari tengah, jari manis, dan jari kelingking. Masing-masing jari memiliki nilai kategorikal (*Arch*, *Loop*, atau *Whorl*) yang dapat dikodekan sebagai nilai numerik ( $Arch = 0$ ,  $Loop = 1$ ,  $Whorl = 2$ ) untuk memudahkan proses klasifikasi oleh model machine learning.

- Label (Target):

Label terdiri dari dua jenis tergantung dari tujuan klasifikasi yaitu :

- Label Kepribadian: berdasarkan pola dominan sidik jari, seperti “Ambisius dan Disiplin”, “Kritis dan Perfeksionis”, atau “Daya Ingat Tajam”.
- Label Gaya Belajar: seperti “Visual”, “Kinestetik”, atau “Auditori”.

### 3.4. Pemodelan dan Klasifikasi

Setelah data sidik jari dikumpulkan, diproses, dan disusun ke dalam format dataset yang sesuai, tahap selanjutnya adalah melakukan proses pemodelan dan klasifikasi. Tujuan dari tahap ini adalah untuk membangun model prediktif yang dapat mengklasifikasikan kepribadian dan gaya belajar anak berdasarkan pola dominan sidik jari menggunakan algoritma pembelajaran mesin. Dua algoritma yang digunakan dalam penelitian ini adalah K-NN dan DT, yang keduanya termasuk dalam kategori algoritma klasifikasi *supervised learning*. Keduanya dipilih karena kemampuannya dalam menangani data kategorikal dan memiliki interpretasi yang cukup jelas, sehingga sesuai untuk penerapan sistem berbasis pendidikan anak usia dini.

Pada proses implementasi, kedua algoritma digunakan secara terpisah untuk tujuan perbandingan performa klasifikasi. DT digunakan untuk membangun model klasifikasi berbasis aturan logis yang mudah dipahami, dan cocok digunakan ketika diperlukan interpretasi yang jelas terhadap hasil prediksi. Sementara itu, K-NN digunakan untuk mengklasifikasikan data baru berdasarkan jarak kedekatannya (kemiripan fitur) dengan data-data yang sudah diberi label, sehingga sangat efektif untuk menangkap pola lokal dari data. Evaluasi performa pada kedua model dilakukan melalui pembagian data latih dan uji dan menggunakan metode LOOCV untuk memastikan hasil yang konsisten.

Pendekatan dari kedua Model K-NN dan DT digunakan secara terpisah untuk keperluan perbandingan kinerja. Hasil dari kedua model kemudian dievaluasi secara individual.

### 3.5. Evaluasi Model

Evaluasi terhadap performa model klasifikasi dilakukan dengan menggunakan dua pendekatan validasi:

- Hold-Out Validation

Dataset dibagi menjadi 80% data latih dan 20% data uji.

- Leave-One-Out Cross Validation (LOOCV)

Setiap data diuji satu per satu dengan menggunakan sisa data sebagai data latih, untuk menghindari bias akibat dataset kecil. Tabel 1 adalah hasil uji model dengan LOOCV.

**Tabel 1.** Hasil uji model LOOCV

Model	Parameter	Mean Accuracy
Decision Tree (default)	-	90%
K-NN	K = 3	90%
K-NN Hyperparameter Tuning	K = 1	90%
	K = 2	90%
	K = 3	90%
	K = 4	90%
	K = 5	90%
Decision Tree Tuning	criterion=gini, max_depth=2	80%
	criterion=gini, max_depth=3	90%
	criterion=gini, max_depth=5	90%
	criterion=entropy, max_depth=2	80%
	criterion=entropy, max_depth=3	90%
	criterion=entropy, max_depth=5	90%

Berdasarkan Tabel 1, hasil uji model *Leave-One-Out Validation (LOOCV)*, semua model klasifikasi yang diuji, baik DT maupun K-NN, menunjukkan performa yang relatif stabil dengan rata-rata akurasi sebesar 90%. Model DT default menghasilkan akurasi sebesar 90%, sama seperti model K-NN dengan nilai  $K=3$ , yang digunakan sebagai baseline. Pada proses tuning hyperparameter K-NN, seluruh nilai  $K$  dari 1 hingga 5 tetap menghasilkan akurasi yang konsisten, yaitu 90%, menunjukkan bahwa perubahan nilai  $K$  pada dataset ini tidak mempengaruhi hasil akurasi secara signifikan.

Sementara itu, pada tuning DT, kombinasi kriteria pemisahan (gini dan entropy) serta variasi kedalaman pohon (*max\_depth*) memberikan hasil yang bervariasi. Kedalaman pohon yang terlalu dangkal (*max\_depth=2*) menghasilkan akurasi yang lebih rendah yaitu 80%, baik pada kriteria gini maupun entropy. Namun, saat kedalaman ditingkatkan ke 3 dan 5, akurasi meningkat kembali ke 90%, menunjukkan bahwa kedalaman pohon berperan penting dalam meningkatkan kinerja model DT.

Secara keseluruhan, semua model menunjukkan akurasi yang cukup tinggi, namun tuning pada DT menunjukkan bahwa pemilihan parameter yang tepat berpengaruh terhadap performa model, terutama pada dataset kecil seperti dalam penelitian ini.

selanjutnya untuk mengukur performa model, digunakan metrik evaluasi sebagai berikut :

1. Akurasi (*Accuracy*) untuk mengukur seberapa banyak prediksi yang benar dibandingkan dengan seluruh jumlah data yang diuji.
2. Presisi (*Precision*) menunjukkan seberapa akurat model dalam memprediksi kelas positif berapa banyak dari yang diprediksi positif ternyata benar-benar positif.
3. *Recall* untuk mengukur seberapa baik model menangkap semua data yang benar-benar positif dari total data positif yang ada.
4. *F1 Score* adalah harmonisasi antara *Precision* dan *Recall*.

Tabel 2 merupakan gambaran hasil akurasi, presisi, *recall*, dan *F1 Score* dari pengujian klasifikasi kepribadian dan gaya belajar anak berdasarkan pola sidik jari menggunakan metode K-NN dan DT.

**Tabel 2.** Hasil *accuracy score* K-NN dan Decision Tree

Model	Accuracy	Precision	Recall	F1 Score
K-NN ( $K=3$ )	100%	1.00	1.00	1.00
Decision Tree	90%	0.91	0.90	0.90

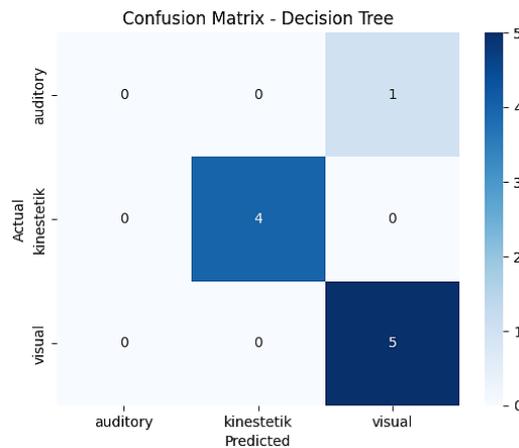
Berdasarkan hasil evaluasi yang ditampilkan dalam Tabel 2, hasil *accuracy score* K-NN ( $K=3$ ) dan DT, model K-NN dengan nilai  $K=3$  menunjukkan performa yang sangat baik dengan skor akurasi, precision, recall, dan F1-score masing-masing sebesar 100% atau 1.00. Hal ini menunjukkan bahwa model K-NN berhasil mengklasifikasikan seluruh data uji dengan benar tanpa kesalahan, baik dari segi prediksi positif maupun negatif. Sementara itu, model DT menunjukkan performa yang sedikit lebih rendah dengan akurasi sebesar 90%, precision 0.91, recall 0.90, dan F1-score 0.90. Meskipun tidak setinggi K-NN, nilai evaluasi ini tetap tergolong tinggi dan menunjukkan bahwa DT juga mampu mengklasifikasikan data dengan cukup baik. Perbedaan ini mengindikasikan bahwa pada dataset ini, model K-NN memiliki kemampuan klasifikasi yang lebih optimal dibandingkan dengan DT.

### 3.5.1. Hasil *Confusion Matrix*

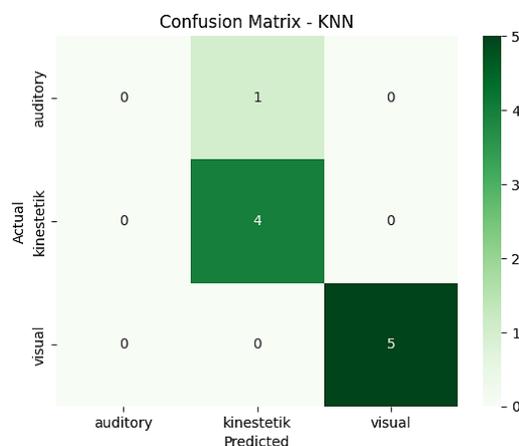
Gambar 3 dan 4 adalah gambar hasil evaluasi yang ditampilkan melalui *confusion matrix* dan ringkasan metrik performa dari kedua algoritma. Gambar 3 merupakan hasil *confusion matrix* DT dan Gambar 4 merupakan hasil *confusion matrix* K-Nearest Neighbor, Hasil visualisasi *confusion matrix* dari pengujian menggunakan metode LOOCV menunjukkan bahwa algoritma K-NN dan DT memiliki kemampuan klasifikasi yang sangat baik terhadap dua dari tiga kelas gaya belajar. Pada model K-NN, seluruh data untuk gaya belajar Kinestetik (sebanyak 4 partisipan) dan Visual (sebanyak 5 partisipan) berhasil diklasifikasikan dengan benar, sedangkan 1 partisipan dengan gaya belajar Auditory salah diklasifikasikan sebagai Kinestetik. Hal serupa juga terjadi pada model DT, di mana partisipan dengan gaya belajar Auditory justru diklasifikasikan sebagai Visual, sementara gaya belajar Kinestetik dan Visual tetap terklasifikasi dengan akurat. Ketidaktepatan dalam klasifikasi gaya belajar auditory ini kemungkinan besar disebabkan oleh ketidakseimbangan data, di mana jumlah partisipan auditory sangat sedikit (hanya satu orang) dibandingkan kelas lainnya. Meskipun demikian, kedua model tetap menunjukkan performa klasifikasi yang sangat baik terhadap kelas-kelas yang dominan dalam data. Tabel 3 adalah tabel hasil *Confusion matrix* kedua algoritma tersebut.

Berdasarkan tabel 3, *confusion matrix* – K-NN (3 Class), model klasifikasi K-NN menghasilkan hasil yang sangat baik. Dari total 10 partisipan, sebanyak 9 partisipan berhasil diklasifikasikan dengan benar. Seluruh partisipan dengan gaya belajar kinestetik (4 orang) dan visual (5 orang) berhasil diklasifikasikan dengan tepat oleh model. Satu-satunya kesalahan klasifikasi terjadi pada partisipan dengan gaya belajar

auditory, yang diprediksi sebagai kinestetik. Dengan demikian, akurasi model K-NN mencapai 90%, yang menunjukkan performa yang tinggi dalam mengenali pola gaya belajar dari data yang digunakan



**Gambar 3.** Hasil *confusion matrix* Decision Tree



**Gambar 4.** Hasil *confusion matrix* K-Nearest Neighbor

**Tabel 3.** *Confusion matrix* – K-NN (3 Class)

Actual	Predicted Auditory	Predicted Kinestetik	Predicted Visual
Auditory	0	1	0
Kinestetik	0	4	0
Visual	0	0	5

**Tabel 4.** *Confusion matrix* – Decision Tree

Actual	Predicted Auditory	Predicted Kinestetik	Predicted Visual
Auditory	0	0	1
Kinestetik	0	4	0
Visual	0	0	5

Sementara itu pada Tabel 4 *confusion matrix* – Decision Tree, menampilkan *confusion matrix* untuk model DT, hasil yang diperoleh identik dengan K-NN. Model berhasil mengklasifikasikan semua partisipan dengan gaya belajar kinestetik dan visual secara akurat, masing-masing 4 dan 5 partisipan. Namun, model gagal dalam mengklasifikasikan partisipan dengan gaya belajar auditory, yang diprediksi sebagai visual. Sehingga, sama seperti K-NN, model DT juga memiliki akurasi sebesar 90%, dengan satu kesalahan klasifikasi pada kelas auditory.

### 3.5.2. Ringkasan Matrix Evaluasi

Berdasarkan pengujian yang telah dilakukan maka diperoleh perbandingan hasil evaluasi performa model klasifikasi dari antara K-NN dan DT. Tabel 5 merupakan perbandingan performa model tersebut.

**Tabel 5.** Perbandingan Performa Model

Model	Accuracy	Precision	Recall	F1 Score	LOOCV Accuracy
K-NN (K=3)	100%	1.00	1.00	1.00	90%
Decision Tree	90%	0.91	0.90	0.90	80%

Berdasarkan Tabel 5, perbandingan performa model, diperoleh perbandingan hasil evaluasi performa model klasifikasi antara algoritma K-NN dan DT berdasarkan lima metrik utama, yaitu akurasi, *precision*, *recall*, *F1-score*, dan akurasi validasi silang menggunakan LOOCV. Model K-NN dengan parameter K=3 menunjukkan performa tertinggi dengan akurasi 100% pada data uji, serta nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 1.00. Meskipun demikian, nilai akurasi pada validasi LOOCV menurun menjadi 90%, yang menunjukkan adanya kemungkinan *overfitting* pada data uji.

Di sisi lain, model DT menunjukkan akurasi 90% pada data uji dengan *precision*, *recall*, dan *F1-score* sebesar 0.91, 0.90, dan 0.90 secara berurutan. Akurasi LOOCV model DT berada pada angka 80%, yang menandakan performa yang sedikit lebih rendah dibandingkan K-NN, namun tetap konsisten dalam klasifikasi terhadap kelas target. Hasil ini menunjukkan bahwa kedua algoritma dapat digunakan secara efektif untuk mendeteksi kepribadian dan gaya belajar anak, dengan K-NN lebih unggul dalam hal akurasi, namun DT memiliki kelebihan dalam interpretabilitas model.

### 3.6. Hasil Evaluasi

Berdasarkan hasil evaluasi, algoritma K-NN menghasilkan akurasi sempurna (100%) pada data uji, dengan *precision*, *recall*, dan *F1-score* yang juga maksimal. Namun, setelah diuji menggunakan *Leave-One-Out Cross Validation*, akurasinya turun menjadi 90%, yang menunjukkan potensi *overfitting* akibat keterbatasan jumlah data. Sementara itu, model DT menunjukkan akurasi 90% pada data uji, dan performa menurun menjadi 80% pada uji LOOCV. Hal ini menunjukkan bahwa DT sedikit lebih stabil terhadap perubahan data, namun memiliki keterbatasan dalam menangani pola yang sangat mirip antar kelas. Hasil klasifikasi kepribadian menunjukkan 50% anak tergolong memiliki kepribadian “daya ingat yang tajam” 40% anak “ambisius dan disiplin” dan 10% “perfeksionis dan komunikatif”. Untuk gaya belajar:

1. K-Nearest Neighbor menghasilkan gaya belajar 60% visual, 40% kinestetik
2. Decision Tree menghasilkan gaya belajar 50% visual, 40% kinestetik, dan 10% auditori

**Tabel 6.** Hasil klasifikasi gaya belajar

Gaya Belajar	K-NN (%)	Decision Tree (%)
Visual	60%	50%
Kinestetik	40%	40%
Auditori	0%	10%

Tabel 6 adalah hasil klasifikasi gaya belajar menunjukkan klasifikasi gaya belajar berdasarkan dua algoritma. Model K-NN mengidentifikasi 60% partisipan memiliki gaya belajar visual dan 40% kinestetik, tanpa ada klasifikasi ke gaya auditori. Sebaliknya, model DT menunjukkan hasil yang sedikit berbeda dengan 50% visual, 40% kinestetik, dan 10% auditori. Perbedaan ini menunjukkan bahwa DT sedikit lebih adaptif terhadap data minoritas, meskipun secara keseluruhan performanya lebih rendah dari K-NN. Temuan ini memperkuat bahwa pola sidik jari dapat digunakan sebagai indikator awal untuk mendeteksi kecenderungan belajar dan kepribadian anak secara non-invasif dan efisien.

Berdasarkan Tabel 7, hasil evaluasi model K-NN dan DT, model K-NN menunjukkan performa terbaik pada data uji dengan akurasi, *precision*, *recall*, dan *F1-score* masing-masing sebesar 100%. Namun, pada pengujian validasi silang menggunakan metode LOOCV, akurasi menurun menjadi 90%, yang mengindikasikan adanya potensi *overfitting*. Di sisi lain, model DT memiliki akurasi yang lebih rendah, yakni 90% pada data uji dan 80% pada LOOCV, tetapi menunjukkan kestabilan yang lebih baik terhadap data yang lebih variatif, meskipun kurang akurat dalam membedakan pola yang mirip antar kelas.

Tabel 8 hasil Klasifikasi kepribadian anak menggambarkan hasil klasifikasi kepribadian anak dari total 10 partisipan. Hasil menunjukkan bahwa mayoritas anak (50%) diklasifikasikan memiliki kepribadian dengan daya ingat tajam, disusul oleh 40% anak yang tergolong ambisius dan disiplin, serta 10% lainnya memiliki karakteristik perfeksionis dan komunikatif. Hasil ini menunjukkan distribusi kecenderungan kepribadian yang beragam berdasarkan pola dominan sidik jari.

**Tabel 7.** Hasil evaluasi model K-Nearest Neighbor dan Decision Tree

Metode	Akurasi (Data Uji)	Akurasi (LOOCV)	Precision	Recall	F1 Score	Catatan
K-NN	100%	90%	100%	100%	100%	Sangat akurat pada data uji,

Metode	Akurasi (Data Uji)	Akurasi (LOOCV)	Precision	Recall	F1 Score	Catatan
Decision Tree	90%	80%	90%	90%	90%	namun kemungkinan overfitting Lebih stabil, tapi kurang menangkap pola mirip antar kelas

**Tabel 8.** Hasil klasifikasi kepribadian anak

Kepribadian	Persentase
Daya ingat yang tajam	50%
Ambisius dan disiplin	40%
Perfeksionis dan komunikatif	10%

### 3.7. Diskusi

Berdasarkan hasil evaluasi model K-NN dan DT yang diterapkan pada data pola sidik jari anak, ditemukan bahwa kedua model mampu mengklasifikasikan kepribadian dan gaya belajar dengan akurasi yang cukup tinggi. Model K-NN mencapai akurasi sempurna pada data uji (100%), namun mengalami penurunan menjadi 90% saat diuji dengan teknik LOOCV, yang menunjukkan indikasi *overfitting* terhadap data latih. Hal ini kemungkinan disebabkan oleh jumlah data yang masih terbatas sehingga model terlalu menyesuaikan diri terhadap data pelatihan. Sementara itu, model DT menunjukkan hasil yang sedikit lebih stabil, dengan akurasi 90% pada data uji dan menurun menjadi 80% pada LOOCV. DT tampaknya mampu menangani data yang bervariasi dengan struktur aturan yang lebih eksplisit, meskipun akurasinya lebih rendah dibandingkan K-NN.

Jika dilihat dari hasil prediksi kepribadian, mayoritas anak (50%) diklasifikasikan memiliki kemampuan daya ingat yang tajam, disusul oleh 40% yang tergolong ambisius dan disiplin, serta 10% yang perfeksionis dan komunikatif. Dalam konteks gaya belajar, metode K-NN lebih mendominasi pada gaya visual (60%) dan kinestetik (40%), sedangkan DT mencakup tiga gaya: visual (50%), kinestetik (40%), dan auditori (10%). Hal ini memperkuat hipotesis bahwa pola sidik jari memiliki korelasi terhadap kecenderungan gaya belajar dan karakter individu.

Penelitian ini mengonfirmasi temuan dari studi terdahulu bahwa sidik jari sebagai biometrik dapat digunakan tidak hanya untuk identifikasi fisik, tetapi juga sebagai pendekatan untuk memahami potensi psikologis anak. Namun, untuk memperoleh generalisasi hasil yang lebih kuat, diperlukan dataset yang lebih besar dan eksplorasi parameter model yang lebih luas.

## 4. KESIMPULAN

Penelitian ini berhasil membangun sistem klasifikasi kepribadian dan gaya belajar anak berbasis pola sidik jari menggunakan algoritma K-NN dan DT. Berdasarkan hasil pengujian, algoritma K-NN menunjukkan performa klasifikasi yang sangat tinggi dengan akurasi 100% pada data uji dan 90% pada LOOCV, sementara DT mencatatkan akurasi 90% pada data uji dan 80% pada LOOCV. Hal ini membuktikan bahwa pola sidik jari memiliki hubungan yang signifikan terhadap kecenderungan kepribadian dan gaya belajar anak. Kontribusi utama dari penelitian ini adalah pengembangan sistem klasifikasi kepribadian dan gaya belajar anak dengan sidik jari yang dapat dimanfaatkan oleh pendidik dan orang tua untuk melakukan deteksi dini terhadap potensi belajar dan kepribadian anak. Sistem ini dapat memberikan informasi yang bermanfaat bagi pengambilan keputusan pendidikan secara individual. Kelemahan dari penelitian ini adalah keterbatasan jumlah data partisipan yang hanya melibatkan 10 anak, sehingga hasil klasifikasi belum dapat digeneralisasi secara luas. Selain itu, pengujian parameter model (seperti nilai K optimal atau kedalaman pohon pada DT) belum dieksplorasi secara menyeluruh. Untuk pengembangan lebih lanjut, Penelitian disarankan untuk menggunakan dataset yang lebih besar, untuk memperluas variasi pola sidik jari, dan menerapkan teknik validasi lanjutan seperti *k-fold cross-validation* serta *tuning parameter model*.

## REFERENSI

- [1] Y. Wahyuni, "Identifikasi Gaya Belajar (Visual, Auditorial, Kinestetik) Mahasiswa Pendidikan Matematika Universitas Bung Hatta."
- [2] A. Gaya *et al.*, "Analysis Of Children's Learning Styles And Personality Using The Hebb Rule Artificial Neural Network Method," vol. 14, no. 1, 2024, doi: 10.30700/sisfotenika.v14i1.417.
- [3] D. Y. Sari, S. Mutiara, and A. Rahma, "Kesiapan Orang Tua dalam Menyediakan Lingkungan Bermain di Rumah untuk Anak Usia Dini Dimasa Pandemi Covid-19," *Tumbuh Kembang: Kajian Teori dan Pembelajaran PAUD*, vol. 7, no. 2, pp. 122–132, Nov. 2020, doi: 10.36706/jtk.v7i2.12271.

- [4] D. Bona, B. Nurina Sari, U. Singaperbangsa Karawang Jl HSRonggo Waluyo, K. Telukjambe Tim, K. Karawang, and J. Barat, "Implementasi Jaringan Hierarki Attention untuk Klasifikasi Basis Data Multimodal Biometrik," Sep. 2022.
- [5] M. Rifai *et al.*, "Kegunaan Sidik Jari dalam Proses Investigasi Perkara Kriminal untuk Mengetahui Identitas Korban dan Yang Melakukan Perbuatan Pidana Use Of Fingerprint In The Criminal Personnel Investigation Process To Know The Victims And The Identity Of The Doingcriminal Development," *Jalan Putroe Phang No.1. Darussalam, Provinsi Aceh*, vol. 3, no. 3, p. 23111, 2019.
- [6] A. I. Reski, M. Muhallim, S. Paembonan, D. Dasril, H. Abduh, and H. Hasnahwati, "Aplikasi Sistem Absensi Fingerprint Dosen Dan Staff Fakultas Teknik Universitas Andi Djemma," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4985.
- [7] ziqrahaniffah, "Deteksi Kepribadian Anak Dengan Sidik Jari Menggunakan Metode K-Nearest Neighbor (K-Nn) Dan Decision Tree Detection Of Children's Personality With Fingerprint Using K-Nearest Neighbor (K-Nn) And Decision Tree Methods," Aug. 2019.
- [8] I. G. Dakhil and A. A. Ibrahim, "Design and Implementation of Fingerprint Identification System Based on K-NN Neural Network," *Journal of Computer and Communications*, vol. 06, no. 03, pp. 1–18, 2018, doi: 10.4236/jcc.2018.63001.
- [9] Prof. Dr. Raúl Rojas, "Rojas, R. (1996). The backpropagation algorithm. In Neural networks: a systematic introduction (pp. 149-182). Berlin, Heidelberg: Springer Berlin Heidelberg.," *The backpropagation algorithm. In Neural networks: a systematic introduction*, vol. pp. 149-182, 1996.
- [10] S. M. Kadhim, J. Koh Siaw Paw, Y. C. Tak, and S. Ameen, "Deep Learning Models for Biometric Recognition based on Face, Finger vein, Fingerprint, and Iris: A Survey," *Journal of Smart Internet of Things*, vol. 2024, no. 1, pp. 117–157, Jun. 2024, doi: 10.2478/jsiot-2024-0007.
- [11] A. Kharisma Putri, I. Bambang Hidayat, drg Yuti Malinda, and M. Kes, "Identifikasi Pola Sidik Bibir Pada Identitas Manusia Menggunakan Metode Gray Level Co-Occurrence Matrix Dan Local Binary Pattern Dengan Klasifikasi Decision Tree Pattern Sebagai Aplikasi Bidang Forensik Biometrik Identification of Lip Print Pattern on Human Identity Using Gray Level Co-Occurrence Matrix and Local Binary Pattern Method with Decision Tree Pattern Classification for Biometric of Forensic Application."
- [12] D. Kurniadi, A. Mulyani, and I. Muliana, "Prediction System for Problem Students using k-Nearest Neighbor and Strength and Difficulties Questionnaire," *Jurnal Online Informatika*, vol. 6, no. 1, pp. 53–62, Jun. 2021, doi: 10.15575/join.v6i1.701.
- [13] A. I. Reski, M. Muhallim, S. Paembonan, D. Dasril, H. Abduh, and H. Hasnahwati, "Aplikasi Sistem Absensi Fingerprint Dosen Dan Staff Fakultas Teknik Universitas Andi Djemma," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4985.
- [14] R. Rizal Isnanto *et al.*, "Identifikasi Sidik Jari Menggunakan Teknik Pencocokan Template Tapis Gabor".
- [15] M. Gufron, E. Budi Cahyono, G. Indah Marthasari, K. Kunci, S. Analisa Sidik Jari, and S. Analisa Kecerdasan, "Sistem Pelaporan Identifikasi Karakter Seorang Anak Berdasarkan Pola Sidik Jari dan Sudut Tangan," vol. 1, no. 1, pp. 17–26, 2019.
- [16] Katherine Harmon, "Can You Lose Your Fingerprints?," May 2009.
- [17] C. Militello, L. Rundo, S. Vitabile, and V. Conti, "Fingerprint classification based on deep learning approaches: Experimental findings and comparisons," *Symmetry (Basel)*, vol. 13, no. 5, May 2021, doi: 10.3390/sym13050750.
- [18] "exploring\_the\_relationship\_of\_fingerprints\_with.6".
- [19] A. Syaifullah *et al.*, "Prosiding SEMNAS BIO 2022 UIN Syarif Hidayatullah Jakarta Variasi Pola Sidik Jari Antara Jurusan Biologi dan Jurusan Kimia Terhadap Penderita Miopi (Rabun Jauh) dan Mata Normal Fingerprint Pattern Variations Between Biology Majors and Chemistry Majors Against Myopic Sufferes (Nearsightedness) with Normal Eyes," 2022.
- [20] D. Paswan, P. Kharb, and P. Samanta, "Identification and Correlation of the Multiple Intelligences and Finger Print Patterns." [Online]. Available: [https://www.ijars.net/article\\_fulltext.asp?issn=0973-709x&year=2017&month=April&volume=6&issue=2&page=AO05&id=2258](https://www.ijars.net/article_fulltext.asp?issn=0973-709x&year=2017&month=April&volume=6&issue=2&page=AO05&id=2258)
- [21] H. Marie, "Peran Dermatoglyphics Multiple Intellegence Assesmen dalam Pengenalan Bakat Anak," *Jurnal Pelita PAUD*, vol. 5, no. 2, pp. 247–255, Jun. 2021, doi: 10.33222/pelitapaud.v5i2.1337.
- [22] W. Wahyono, I. N. P. Trisna, S. L. Sariwening, M. Fajar, and D. Wijayanto, "Comparison of distance measurement on k-nearest neighbour in textual data classification," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 1, pp. 54–58, Jan. 2020, doi: 10.14710/jtsiskom.8.1.2020.54-58.
- [23] A. Setiawan, "Perbandingan Penggunaan Jarak Manhattan, Jarak Euclid, dan Jarak Minkowski dalam Klasifikasi Menggunakan Metode K-NN pada Data Iris," *Jurnal Sains dan Edukasi Sains*, vol. 5, no. 1, pp. 28–37, May 2022, doi: 10.24246/juses.v5i1p28-37.

- [24] C. N. Syahputri and M. S. Hasibuan, "Optimasi Klasifikasi Decision Tree Dengan Teknik Pruning Untuk Mengurangi Overfitting," *JSiI (Jurnal Sistem Informasi)*, vol. 11, no. 2, pp. 87–96, Sep. 2024, doi: 10.30656/jsii.v11i2.9161.
- [25] H. Mulyo and N. A. Maori, "Peningkatan Akurasi Prediksi Pemilihan Program Studi Calon Mahasiswa Baru Melalui Optimasi Algoritma Decision Tree Dengan Teknik Pruning Dan Ensemble Enhacing Prediction Accuracy Of New Student Program Selection Through Decision Tree Algorithm Optimization With Pruning Technique And Ensemble," vol. 15, no. 1, pp. 15–25, 2024, doi: 10.34001/jdpt.