

Identifikasi Kepribadian Anak Sebagai Rekomendasi Pendampingan Untuk Guru Dan Orang Tua Menggunakan Machine Learning

1st Alifia Mutiara Rahma
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

alifiamutiara@telkomuni-
versity.ac.id

2nd Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuni-
versity.ac.id

3rd Marisa W. Paryasto
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

marisaparyasto@telkomuni-
versity.ac.id

Abstrak — Kepribadian seseorang mencerminkan identitas individu mereka, yang tidak selalu terlihat secara fisik. Kepribadian dapat dipengaruhi oleh lingkungan, keluarga, dan sifat bawaan sejak lahir. Kepribadian anak yang terbentuk melalui gaya pengasuhan di rumah secara signifikan berdampak pada lingkungan sekolahnya, sehingga penting bagi orang tua dan guru untuk memahami kepribadian anak agar dapat memberikan dukungan yang tepat. Namun, tes psikologi yang ada saat ini yang digunakan untuk menilai kepribadian anak tidak efektif karena durasinya yang panjang. Sehingga diperlukan sistem berbasis *machine learning* yang mampu mengidentifikasi kepribadian anak melalui analisis garis telapak tangan. Hasil pengujian menunjukkan bahwa sistem dapat mengidentifikasi kepribadian anak dengan akurasi yang tinggi. Algoritma pendeteksi garis telapak tangan mencapai akurasi 100%, dengan mAP50 sebesar 99,5% dan mAP50-95 sebesar 97,4%. Algoritma klasifikasi menunjukkan akurasi 92,3% pada data latih dan 92,2% pada data uji untuk model pertama, dan akurasi 100% pada data latih dan 93,3% pada data uji untuk model kedua. Pengujian sistem deteksi pada aplikasi menunjukkan akurasi 100%.

Kata kunci— kepribadian anak, pembelajaran mesin, analisis garis telapak tangan

I. PENDAHULUAN

Kepribadian atau *personality* seseorang menggambarkan ciri dari sifat seseorang [1]. Walaupun kepribadian ini bawaan lahir, tapi kepribadian dapat dibentuk dan diarahkan pada periode usia emas atau usia dini. Tahap usia keemasan anak tidak dapat diulang di masa mendatang. Oleh karena itu, penting untuk mengetahui kepribadian anak. Faktor yang mempengaruhi kepribadian anak antara lain lingkungan keluarga, pengalaman masa kecil, interaksi sosial, dan pendidikan [2]. Beberapa pihak yang berperan aktif didalamnya adalah orang tua dan guru. Sehingga penting bagi orang tua dan guru untuk mengetahui jenis kepribadian anak. Sehingga kepribadian anak dapat dibentuk ke arah yang positif.

Kepribadian seseorang dapat diketahui dengan melakukan beberapa tes kepribadian. Beberapa cara yang biasa dilakukan untuk mengetahui kepribadian seseorang antara lain, tes *big five personalities* yang dilakukan dengan cara menjawab beberapa soal dan datang ke psikolog [3], [4]. Namun, cara tersebut masih konvensional dan memerlukan

waktu lebih banyak. Selain itu, hasil yang didapatkan belum tentu akurat karena berdasarkan pandangan dari masing-masing orang [5]. Biaya yang dikeluarkan juga cukup besar yaitu mulai dari \$0.83 hingga \$66.66 [6]. Untuk mengatasi beberapa masalah tersebut, diperlukan cara yang lebih optimal agar tidak menghabiskan waktu dan biaya yang besar. Saat ini kepribadian dapat diidentifikasi berdasarkan biometrik yang dimiliki masing-masing orang. Biometrik yang umum digunakan yaitu sidik jari dan garis telapak tangan [7], [8]. Biometrik ini dapat diidentifikasi menggunakan metode identifikasi masing-masing bentuk biometriknya.

Identifikasi kepribadian menggunakan sidik jari, terdapat beberapa penelitian yang menggunakan *machine learning* untuk proses klasifikasinya [7]. Metode yang digunakan juga beragam. Namun, sidik jari memiliki kelas yang lebih sedikit tapi garis tangan [9], [10], [11]. Sehingga keberagaman kelas garis tangan menawarkan variasi data yang lebih banyak dan mencerminkan keragaman kepribadian manusia [12]. Identifikasi kepribadian menggunakan garis telapak tangan menjadi alternatif menarik dengan potensi hasil yang lebih akurat. Namun, penelitian yang menggunakan garis telapak tangan untuk mengidentifikasi kepribadian masih menggunakan *image* klasifikasi konvensional. Sehingga pembuatan sistemnya masih manual mengandalkan posisi garis tangan yang ada dalam gambar dan penggunaan metode algoritma *machine learning* belum diterapkan dalam mengidentifikasi garis telapak tangan. Penerapan *machine learning* dapat mengklasifikasikan kepribadian dengan mengurangi keterbatasan metode konvensional. Sehingga penelitian ini, akan mencoba mengidentifikasi kepribadian menggunakan pembacaan garis telapak tangan dengan bantuan metode algoritma *machine learning*.

II. KAJIAN TEORI

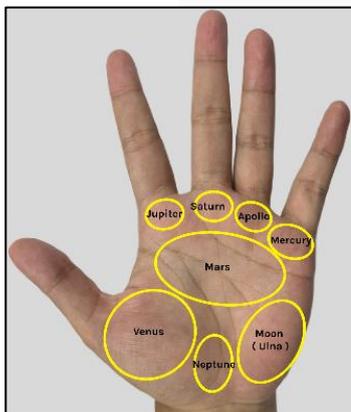
Dalam era kemajuan teknologi, banyak ahli yang mengembangkan teknologi dengan memanfaatkan kecerdasan buatan. Salah satu cabang ilmu yang terdapat di dalamnya adalah *machine learning*. Bukan lagi hal yang mustahil untuk menciptakan sistem identifikasi kepribadian seseorang menggunakan biometrik. Hal ini dikarenakan setiap orang mempunyai biometrik yang unik dan beragam. Beberapa biometrik yang digunakan berupa sidik jari dan

garis telapak tangan. Keunikan bentuk ini yang menghasilkan arti dan merepresentasikan kepribadian seseorang. Identifikasi kepribadian dengan memanfaatkan bentuk sidik jari dapat menghasilkan tiga kelas, antara lain *Arch*, *Loop*, dan *Whorl* [7]. Sedangkan garis telapak tangan mempunyai lebih banyak ragam arti kepribadian. Hal ini dikarenakan, terdapat tiga garis utama di garis tangan, sementara masing-masing garis terdapat bentuk yang beragam pula dalam penggambaran arti kepribadian seseorang [8]. Identifikasi kepribadian seseorang sangat penting untuk mengetahui karakter anak sejak dini untuk memaksimalkan potensi anak serta memberikan metode pola asuh yang sesuai. Beberapa metode *machine learning* yang digunakan antara lain, metode *K-Nearest Neighbor* (KNN), *Decision Tree*, *Forward Chaining*, *Random Forest*, dan *Maximum Entropy* [9], [13]. Metode tersebut pernah dilakukan penelitian menggunakan klasifikasi sidik jari. Penelitian menggunakan metode klasifikasi masing-masing mendapatkan hasil akurasi yang berbeda. Penggunaan metode KNN mempunyai akurasi sebesar 85% dan *Decision Tree* mempunyai akurasi sebesar 89% [9]. Penggunaan algoritma *Random Forest* mendapatkan akurasi sebesar 95% dan ketika menggunakan metode *Maximum Entropy* hanya mendapat akurasi sebesar 44% dengan 123 *dataset* [13]. Hal ini menjadi kajian untuk diteliti lebih lanjut untuk penggunaan sidik jari. Sedangkan metode yang sudah ada dapat diganti dengan metode lain seperti YOLOv8 serta menggunakan garis telapak tangan untuk cara pengambilan informasi kepribadiannya.

III. METODE

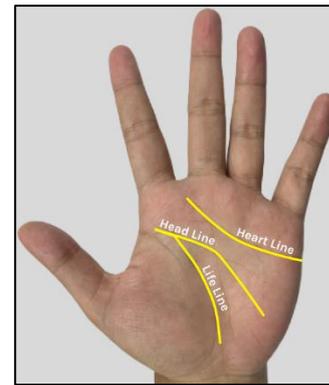
Bagian ini akan membahas beberapa metode penelitian yang digunakan.

A. Kepribadian Menurut Garis Telapak Tangan



GAMBAR 1
Posisi Bukit Tangan Pada Telapak Tangan

Kepribadian seseorang bisa diidentifikasi dengan menggunakan pembacaan garis telapak tangan. Sebelum memahami garis telapak tangan, ada tata letak tunggangan pada telapak tangan. Tata letak ini menunjukkan arah dan posisi garis-garis dalam bentuk garis telapak tangan. Gambar 1 menjelaskan secara rinci tata letak bukit tangan [14]. Tata letak ini menunjukkan arah dan letak garis dalam bentuk garis telapak tangan. Umumnya terdapat tiga garis utama yang dapat dilihat langsung oleh mata manusia, yakni garis hati (*heart line*), garis kepala (*head line*), dan garis kehidupan (*life line*) seperti gambar berikut:



GAMBAR 2
Fitur dalam garis telapak tangan (*palmprint*)

Setiap garis ini memiliki makna mengenai karakteristik manusia seperti penyayang, mudah bergaul, ramah, temperamental, dan sebagainya. Garis hati, yang dikenal sebagai garis mental, menunjukkan keadaan emosi seseorang dan hubungan emosional dengan orang lain [8]. Garis kepala menggambarkan kemampuan intelektual dan keterampilan intuitif, diposisikan di atas garis kehidupan antara ibu jari dan jari telunjuk, memanjang secara horizontal di telapak tangan ke arah tepi [8]. Sementara itu, garis kehidupan memberikan informasi tentang kesehatan, kesejahteraan emosional, dan kesehatan fisik seseorang [8]. Oleh karena itu, penelitian ini akan memanfaatkan garis telapak tangan untuk mendeteksi ciri-ciri kepribadian dengan menggunakan teknologi *machine learning*.

Pada penelitian ini, digunakan garis hati, garis kepala, dan garis kehidupan. Untuk membuat sistem identifikasi kepribadian, diperlukan gambar garis-garis tersebut dalam berbagai bentuk. Ciri-ciri kepribadian yang diwakili oleh bentuk-bentuk garis hati tercantum dalam TABEL I [14].

TABEL 1
Arti Kepribadian Garis Hati

Nama Garis Hati	Arti Kepribadian
garis hati panjang	Menggambarkan seseorang yang mempunyai sifat yang hangat, penyayang, dan ramah. Orang ini mempunyai pandangan hubungan yang indah, di mana mereka membayangkan hubungan yang penuh kasih sayang dan bahagia layaknya cerita dongeng.
garis hati yang melengkung sampai sisi antara Jupiter dan Saturnus	Menggambarkan seseorang yang lembut, tenang, perhatian, hangat, dan aktif. Orang ini juga mau berkorban untuk orang lain, seperti menolong teman yang sedang kesulitan.
garis hati yang terputus	Menggambarkan seseorang yang mungkin mengalami kesulitan dalam berteman. Karena hal ini, hubungan dengan teman-teman bisa menjadi kurang akurat dan kadang-kadang bisa terjadi kesalahpahaman.
garis hati pendek	Fokus pada kepentingan pribadi dan kecenderungan untuk hidup bagi diri sendiri digambarkan oleh garis hati yang pendek. Perhatian terhadap kebahagiaan orang di sekitar mungkin kurang diberikan oleh mereka.

Dalam *dataset* garis hati terdapat empat kelas yang dibuat. Masing-masing kelas ini merepresentasikan arti kepribadian. *Dataset* ini sudah dilakukan proses pemotongan gambar. Berikut detail gambar *dataset* garis hati dari masing-masing kelas:



GAMBAR 3
Kelas 1 (Garis hati panjang)

Gambar garis hati yang masuk ke dalam kelas 1 atau berbentuk garis hati panjang tandanya garis ini berbentuk lurus dan melebihi jari tengah atau berada di dekat jari tengah.



GAMBAR 4
Kelas 2 (garis hati yang melengkung sampai sisi antara Jupiter dan Saturnus)

Gambar garis hati kelas 2, sesuai namanya garis ini melengkung hingga ke sisi antara jari tengah dan jari telunjuk.



GAMBAR 5
Kelas 3 (garis hati yang terputus)

Gambar garis hati kelas 3 bernama garis hati yang terputus. Sesuai namanya garis hati ini terputus di tengahnya.



GAMBAR 6
Kelas 4 (garis hati pendek)

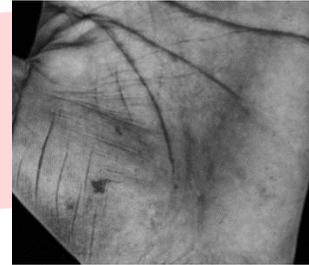
Gambar garis hati kelas 4 bernama garis hati pendek. Sesuai namanya garis hati ini pendek karena sebelum telunjuk atau berada di tengah jari telunjuk. Selanjutnya dijelaskan masing-masing arti kepribadian berdasarkan garis kepala dan garis kehidupan :

TABEL 2
Arti Kepribadian Garis Kepala dan Garis Kehidupan

Nama Garis Kepala	Arti Kepribadian
garis kepala bersinggungan/segaris dengan garis kehidupan dan garis hidup lengkung lebar	Menggambarkan seseorang yang butuh banyak bantuan, pemalu, dan sering merasa ragu pada diri sendiri. Orang ini juga memerlukan pujian dan dorongan dari orang di sekitarnya. Menggambarkan seseorang yang terbuka dan mudah bergaul dengan orang lain. Orang ini mempunyai semangat yang bagus dan tidak mudah menyerah.
garis kepala terpisah sempit dari garis kehidupan dan garis hidup lengkung lebar	Menggambarkan seseorang yang mandiri dan mempunyai kepercayaan diri yang tinggi. Orang ini juga mudah mengekspresikan diri dan bisa bertanggung jawab. Menggambarkan seseorang yang terbuka dan mudah bergaul dengan orang lain. Orang ini

Nama Garis Kepala	Arti Kepribadian
	mempunyai semangat yang bagus dan tidak mudah menyerah.
tanda cabang dua/tiga diujung garis kepala dan garis hidup lengkung lebar	Menggambarkan seseorang yang mempunyai daya imajinasi, kekuatan pikir dan mental yang bagus. Orang ini juga mempunyai pengetahuan luas dan banyak bakat (multitalenta). Menggambarkan seseorang yang terbuka dan mudah bergaul dengan orang lain. Orang ini mempunyai semangat yang bagus dan tidak mudah menyerah.

Langkah selanjutnya adalah memilih gambar yang sesuai dengan kombinasi garis untuk membuat 3 kelas dalam *dataset* garis kepala dan garis kehidupan. Beberapa gambar dari masing-masing kelas dalam kombinasi garis kepala dan garis kehidupan:



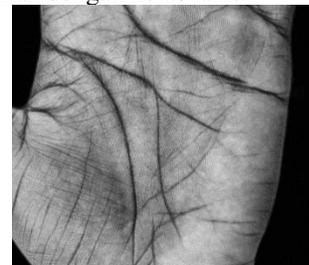
GAMBAR 7
Garis kombinasi kelas 1

Gambar garis kombinasi kelas 1 merupakan kombinasi dari garis kepala bersinggungan/segaris dengan garis kehidupan dan garis hidup lengkung lebar. Sesuai namanya garis kepala ini bersinggungan langsung dengan garis kehidupan.



GAMBAR 8
Garis kombinasi kelas 2

Gambar garis kombinasi kelas 2 merupakan kombinasi dari garis kepala terpisah sempit dari garis kehidupan dan garis hidup lengkung lebar. Sesuai namanya garis kepala ini terpisah atau tidak menempel dengan garis kehidupan. Hal ini yang membedakan dengan kelas lain.



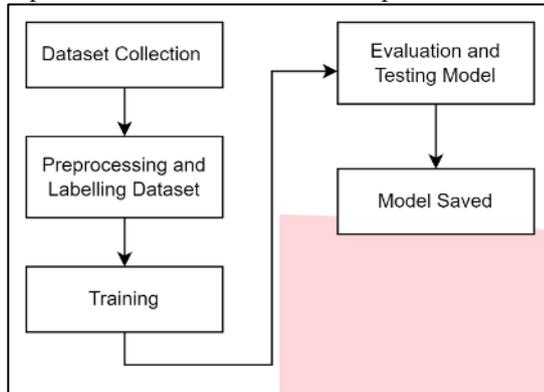
GAMBAR 9
Garis kombinasi kelas 3

Gambar garis kombinasi kelas 3 merupakan kombinasi dari tanda cabang dua/tiga diujung garis kepala dan garis

hidup lengkung lebar. Sesuai namanya garis kepala ini terdapat cabang dua atau tiga pada ujung garisnya.

B. Machine Learning

Penelitian sistem identifikasi kepribadian berbasis *palm hand line* menggunakan YOLOv8 akan terbagi menjadi lima proses antara lain *dataset collection, preprocessing, labelling dataset, training, testing*, dan model *saved*. Berikut ini adalah proses pembuatan sistem identifikasi kepribadian:



GAMBAR 10

Diagram blok pembuatan sistem identifikasi kepribadian

1. Dataset Collection

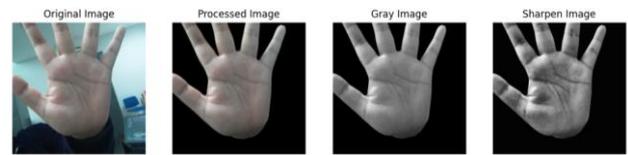
Proses pengumpulan *dataset* dilakukan secara manual dan sumber di internet. Untuk membuat sistem identifikasi kepribadian dengan membaca garis telapak tangan diperlukan *dataset* berupa gambar telapak tangan beserta garisnya. Pengambilan gambar secara manual diambil dari beberapa gambar telapak tangan mahasiswa Universitas Telkom. Gambar yang diambil terdiri dari gambar telapak tangan kiri mahasiswa berusia antara 18 hingga 23 tahun, berjenis kelamin laki-laki maupun perempuan, dan berasal dari ras Asia Tenggara. Sedangkan pengambilan gambar telapak tangan dari internet diambil dari Human *Palm Image* [15]. *Dataset* human *palm image* dikumpulkan dari staf dan mahasiswa Redeemers *University*, Ede, Osun State, Nigeria dan terdiri dari 800 gambar yang diambil dari 200 subjek [15]. Gambar tersebut dipilih berdasarkan gambar telapak tangan yang terlihat jelas bentuk garisnya. Berikut detail informasi gambar dari masing-masing *dataset*.

TABEL 3
Detail Informasi Gambar Untuk *Dataset*

Cara Pengambilan	Dataset	Gender	Umur	Total Orang	Total Gambar
Dari Kaggle	Human <i>Palm Image</i>	Wanita & Pria	-	400	800
Secara manual	Mahasiswa telkom	Wanita & Pria	18-23 tahun	130 orang	130 gambar

2. Preprocessing Dataset

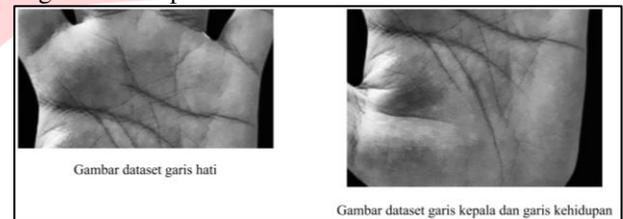
Preprocessing gambar dengan mengonversinya ke dalam skala abu-abu dapat meningkatkan kejelasan garis-garis yang akan digunakan dan bentuk-bentuknya [16]. Penggunaan telapak tangan yang digunakan yaitu telapak tangan kiri. Proses *preprocessing* yang dilakukan antara lain *remove background, grayscale* gambar, dan pertajam gambar. Berikut ilustrasi *preprocessing* gambar yang dilakukan pada masing-masing gambar yang akan digunakan dalam *dataset*:



GAMBAR 11

Preprocessing dataset

Gambar yang sudah dikumpulkan untuk membuat *dataset* dipilih sebelum dilakukan *preprocessing*. Gambar-gambar tersebut tidak semuanya digunakan. Hal ini dikarenakan, gambar dalam *dataset* yang diambil tidak semuanya jelas garisnya. Sehingga *dataset* yang dibuat tidak bias dan terlihat perbedaan bentuk garisnya. Kelas yang digunakan dalam *dataset* dijelaskan dalam proses *labelling dataset*. Berdasarkan gambar tersebut, proses yang dilakukan yaitu menghilangkan *background* pada gambar, mengubah warna gambar menjadi abu, dan mempertajam gambar menggunakan CLAHE (*Contrast Limited Adaptive Histogram Equalization*). Selanjutnya dilakukan proses pemotongan gambar. berikut ilustrasi pemotongan gambar untuk *dataset* garis hati dan *dataset* kombinasi garis kepala dan garis kehidupan:



GAMBAR 12

Ilustrasi pemotongan gambar untuk masing-masing *dataset*

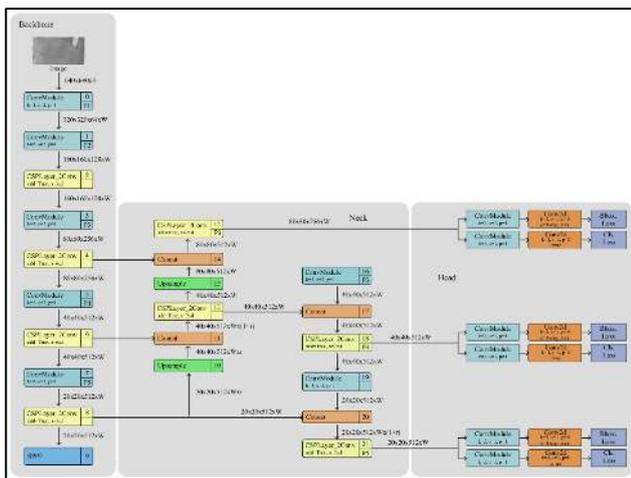
Pemotongan garis ini dilakukan untuk memperjelas bentuk dari garis hati dan kombinasi garis kepala dan garis kehidupan yang akan digunakan. Bentuk garis ini diambil sesuai dengan beberapa perwakilan bentuk garis dari masing-masing arti dalam garis yang akan digunakan dalam *dataset*.

3. Labelling Dataset

Proses pemberian label dilakukan menggunakan Roboflow. Masing-masing gambar diberi label dan *keypoint* sesuai dengan delapan titik. Empat titik paling atas berfungsi sebagai penanda jari. Sedangkan dua titik dibawahnya sebagai penanda garis hati dan dua titik paling bawah sebagai garis telapak tangan yang lain. Sedangkan untuk *dataset* garis hati dan *dataset* kombinasi garis kepala dan garis kehidupan disesuaikan dengan jumlah kelasnya.

4. Training Model by Using YOLOv8 Classification

Ekstraksi Fitur: Dalam sistem deteksi percobaan, digunakan YOLO Versi 8 atau YOLOv8 yang merupakan versi terbaru YOLO dari Ultralytics [17], [18]. YOLOv8 dapat digunakan untuk menyelesaikan beberapa tugas antara lain *detection, instance segmentation, pose/keypoints, oriented detection, classification* [17]. Oleh karena itu, untuk mendukung pembuatan model algoritma, dua tugas yang dapat digunakan oleh YOLOv8 klasifikasi. Arsitektur YOLOv8 diilustrasikan dalam gambar berikut:



GAMBAR 13
Arsitektur YOLOv8 Classification

Dalam sub-bab ekstraksi fitur dari model YOLOv8, arsitektur dibagi menjadi tiga komponen utama: *backbone*, *neck*, dan *head*. *Backbone* menggunakan CSPDarknet53 yang dimodifikasi, menangkap fitur *input* beberapa kali untuk menghasilkan berbagai fitur yang berbeda [20]. Komponen ini diilustrasikan secara signifikan pada GAMBAR 13, di mana modul *Cross Stage Partial* (CSP) tradisional digantikan oleh model C2f yang lebih canggih [20]. Model ini meningkatkan aliran informasi melalui koneksi *gradient shunt*, mempromosikan pemrosesan fitur yang ringan namun efektif. Selain itu, *backbone* diakhiri dengan *Spatial Pyramid Pooling Fast* (SPPF), yang secara efisien mengumpulkan peta fitur menjadi *output* ukuran tetap, mengoptimalkan upaya komputasi dan latensi dengan persamaan:

$$SPPF(x) = \max(\max(P1(x)), \max(\max(P2(x)), \max(\max(P3(x)))) \quad (1)$$

di mana P1, P2, dan P3 mewakili operasi penggabungan maksimum berurutan pada *input* x.

Beralih ke bagian *neck*, konfigurasi PAN+FPN mengintegrasikan aliran informasi yang jarang dan padat, menghasilkan rangkaian fitur yang lebih kaya dan lebih komprehensif [19]. Bagian arsitektur ini telah disederhanakan dibandingkan dengan pendahulunya seperti YOLOv5 dan YOLOv7 dengan menghapus beberapa operasi konvolusi pasca-*undersampling*, sehingga membantu mempertahankan kinerja sekaligus mengurangi kompleksitas.

Model *head* berfokus pada tugas klasifikasi dan deteksi akhir, memanfaatkan struktur terpisah dengan beberapa cabang [19]. Setiap cabang menggunakan *binary cross-entropy loss* untuk mengklasifikasikan fitur yang diproses secara akurat, memastikan hasil deteksi yang tepat dengan persamaan *loss*:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i * \log(\hat{y}_i) + (1 - y_i) * \log(1 - \hat{y}_i)] \quad (2)$$

di mana y_i adalah label aktual, dan \hat{y}_i adalah probabilitas yang diprediksi dari model. Pendekatan terstruktur di kepala ini memfasilitasi diferensiasi dan klasifikasi objek yang efektif di berbagai skenario.

Proses Training: Untuk melakukan training perlu menyiapkan setup berikut GPU NVIDIA Tesla T4 dengan Intel(R) Xeon(R) Silver 4208 CPU @ 2.10GHz. Selain itu, Yolov8 perlu menginstall library Ultralytics. Oleh karena itu,

optimizer, learning rate, batch size, dan momentumnya sudah ada di dalamnya.

IV. HASIL DAN PEMBAHASAN

A. Pengujian Algoritma Deteksi dan Klasifikasi Bentuk Garis Tangan

Bentuk garis tangan dapat diklasifikasikan menjadi beberapa kelas yang masing-masing memiliki arti kepribadian tersendiri. Pengujian algoritma klasifikasi bentuk garis tangan bertujuan untuk menguji keakuratan model algoritma dalam mengklasifikasikan bentuk garis tangan dan memastikan algoritma dapat mengenali berbagai variasi bentuk garis tangan di luar data pelatihan.

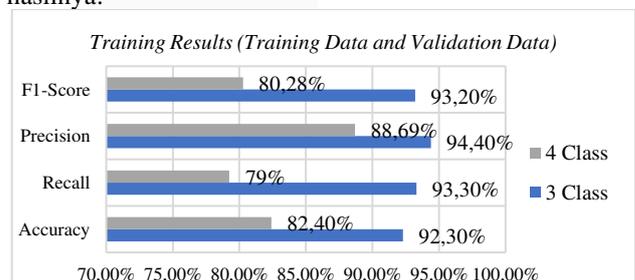
1. Jumlah Kelas Untuk Dataset Garis Hati

Terdapat perbedaan jumlah kelas dalam *dataset* garis hati yaitu 3 kelas dan 4 kelas. *Dataset* ini terbagi menjadi 80% data *training*, 10% data validasi, dan 10% data testing. Berikut hasil perbandingan matriks evaluasi dalam pengujian ukuran *dataset* untuk garis hati:

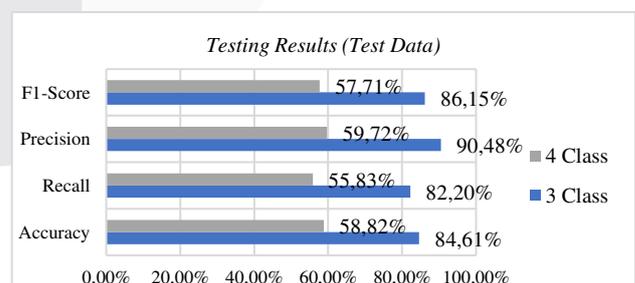
TABEL 4
Perbandingan hasil pengujian jumlah *dataset* garis hati

Jumlah Kelas	Data	Accuracy	Recall	Precision	F1-Score
3 Kelas	Train	92,3%	93,3%	94,4%	93,2%
	Test	84,61%	82,2%	90,48%	86,15%
4 Kelas	Train	82,4%	79,25%	88,69%	80,28%
	Test	58,82%	55,83%	59,725%	57,71%

Berdasarkan tabel hasil pengujian jumlah kelas untuk *dataset* garis hati, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* yang berjumlah 3 kelas. Berikut visualisasi hasilnya:



GAMBAR 14
Visualisasi data hasil pelatihan



GAMBAR 15
Visualisasi data hasil pengujian

Berdasarkan gambar visualisasi tersebut, 3 kelas lebih unggul dibandingkan 4 kelas. Selisih nilai akurasi *dataset* berjumlah 3 kelas lebih kecil dibandingkan *dataset* berjumlah 4 kelas. Sehingga *dataset* garis hati berjumlah 3 kelas akan digunakan pada pengujian selanjutnya.

2. Partisi Data

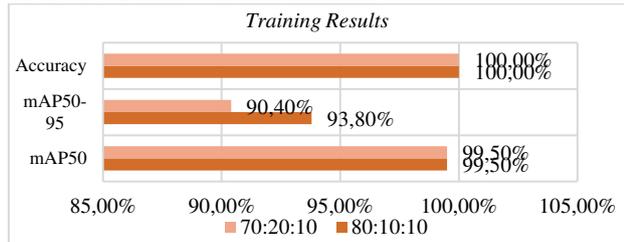
Pengujian kedua dilakukan pada *dataset* telapak tangan, *dataset* garis hati, dan *dataset* kombinasi garis kepala dan garis hidup. Pengujian ini melibatkan partisi data yang memiliki hasil evaluasi terbaik. Hasil terbaik akan dipilih untuk pengujian selanjutnya.

a. *Dataset* Gambar Telapak Tangan

TABEL 5 Perbandingan hasil pengujian partisi data *dataset* telapak tangan

Partisi Data	Data	mAP50	mAP50-95	Accuracy
80:10:10	Train	99,5%	93,8%	100%
70:20:10	Train	99,5%	90,4%	100%

Berdasarkan tabel hasil pengujian partisi data untuk *dataset* gambar telapak tangan, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* dengan partisi data 80:10:10. Berikut visualisasi hasil:



GAMBAR 16 Visualisasi data hasil pelatihan perbandingan partisi data

Berdasarkan visualisasi gambar 17, mAP50, mAP50-95, dan akurasi tertinggi didapatkan pada penggunaan partisi data 80:10:10. Hal ini berarti, model dapat mendeteksi dengan lebih baik. Sehingga pengujian selanjutnya akan menggunakan partisi data 80:10:10 pada *dataset* gambar telapak tangan.

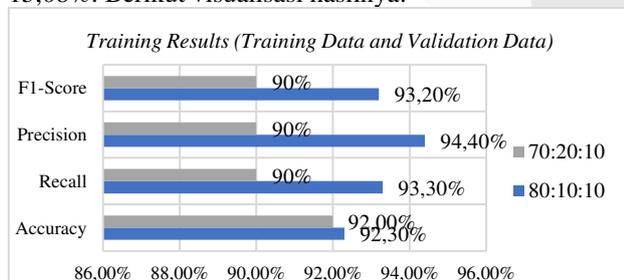
b. *Dataset* Garis Hati

TABEL 6

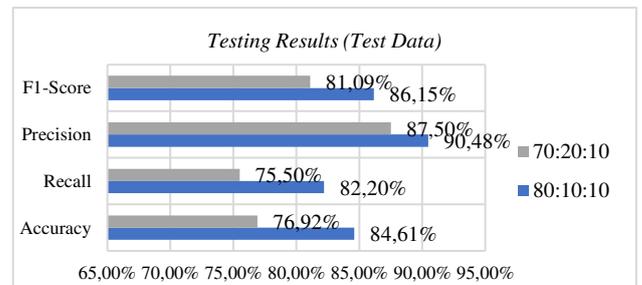
Perbandingan hasil pengujian partisi data *dataset* garis hati

Partisi Data	Data	Accuracy	Recall	Precision	F1-Score
80:10:10	Train	92,3%	93,3%	94,4%	93,2%
	Test	84,61%	82,2%	90,48%	86,15%
70:20:10	Train	92%	90%	90%	90%
	Test	76,92%	75,5%	87,5%	81,09%

Berdasarkan tabel hasil pengujian partisi data untuk *dataset* garis hati, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* dengan partisi data 80:10:10. Selisih antara pelatihan dan pengujian sebesar 7,69%. Nilai ini lebih kecil dibanding selisih pelatihan dan pengujian pada *dataset* dengan partisi data 70:20:10 yaitu 15,08%. Berikut visualisasi hasilnya:



GAMBAR 17 Visualisasi data hasil pelatihan



GAMBAR 18 Visualisasi data hasil pengujian

Berdasarkan visualisasi gambar 18 dan 19, akurasi tertinggi didapatkan pada penggunaan partisi data 80:10:10. Sehingga pengujian selanjutnya akan menggunakan partisi data 80:10:10 pada *dataset* garis hati.

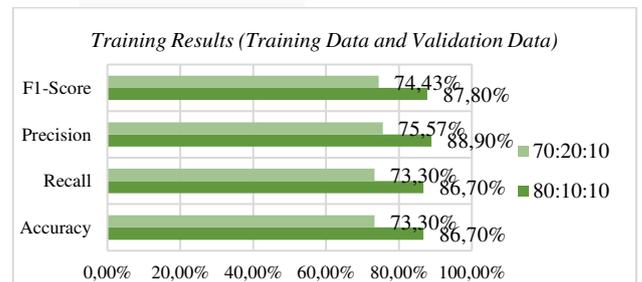
c. *Dataset* Kombinasi Garis Kepala dan Gari Kehidupan

TABEL 7

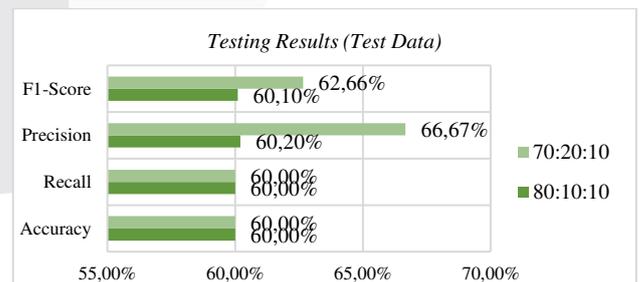
Perbandingan hasil pengujian partisi data *dataset* garis kombinasi

Partisi Data	Data	Accuracy	Recall	Precision	F1-Score
80:10:10	Train	86,7%	86,7%	88,9%	87,8%
	Test	60%	60%	60,2%	60,1%
70:20:10	Train	73,3%	73,3%	75,57%	74,43%
	Test	60%	60%	66,67%	62,66%

Berdasarkan tabel hasil pengujian partisi data untuk *dataset* kombinasi garis kepala dan garis kehidupan, hasil terbaik di dapatkan oleh *dataset* dengan partisi data 80:10:10. Berikut visualisasi hasilnya:



GAMBAR 19 Visualisasi data hasil pelatihan



GAMBAR 20 Visualisasi data hasil pengujian

Berdasarkan visualisasi gambar 20 dan 21, akurasi tertinggi didapatkan pada penggunaan partisi data 80:10:10. Walaupun hasil pelatihan partisi data 80:10:10 dan 70:10:10 hasil sama. Namun, hasil pelatihan partisi 80:10:10 lebih tinggi dibandingkan partisi data 70:10:10. Sehingga pengujian selanjutnya akan menggunakan partisi data 80:10:10 pada *dataset* kombinasi garis kepala dan garis kehidupan.

3. Optimizer

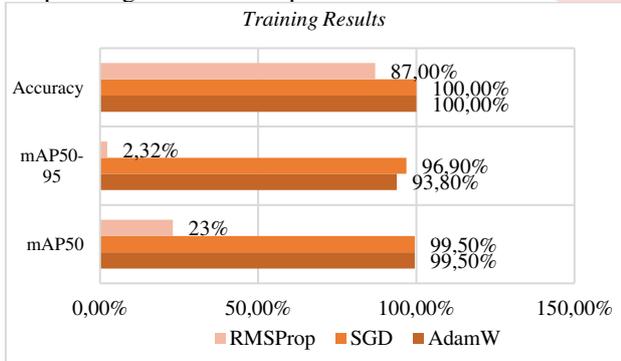
Terdapat beberapa *optimizer* yaitu Adam, SGD, dan RMSprop. *Optimizer* AdamW modifikasi yang menggabungkan *optimizer* SGD dan RMSprop [20]. Sedangkan *optimizer* RMSprop modifikasi dari *optimizer* AdaGrad [21]. Lalu AdaGrad bentuk perbaikan *optimizer* SGD non-adaptif [22]. Oleh karena itu perlu penentuan *learning rate* yang tepat agar hasil klasifikasi dapat optimal. Hasil evaluasi *learning rate* terbaik, akan digunakan dalam pengujian selanjutnya.

a. Dataset Gambar Telapak Tangan

TABEL 8 Perbandingan hasil pengujian *optimizer dataset* telapak tangan

Optimizer	Data	mAP50	mAP50-95	Accuracy
AdamW	Train	99,5%	93,8%	100%
SGD	Train	99,5%	96,9%	100%
RMSProp	Train	23,2%	2,32%	87%

Berdasarkan tabel hasil pengujian *optimizer* untuk *dataset* gambar telapak tangan, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* dengan *optimizer* SGD. Berikut adalah diagram batang untuk hasil pelatihan dan hasil pengujian perbandingan *optimizer dataset* gambar telapak tangan untuk mempermudah visualisasi:



GAMBAR 21 Visualisasi data hasil pelatihan perbandingan *optimizer*

Berdasarkan visualisasi gambar tersebut, mAP50, mAP50-95, dan akurasi tertinggi didapatkan pada penggunaan *optimizer* SGD. Hal ini berarti, model dapat mendeteksi dengan lebih baik. Sehingga pengujian selanjutnya akan menggunakan *optimizer* SGD pada *dataset* gambar telapak tangan.

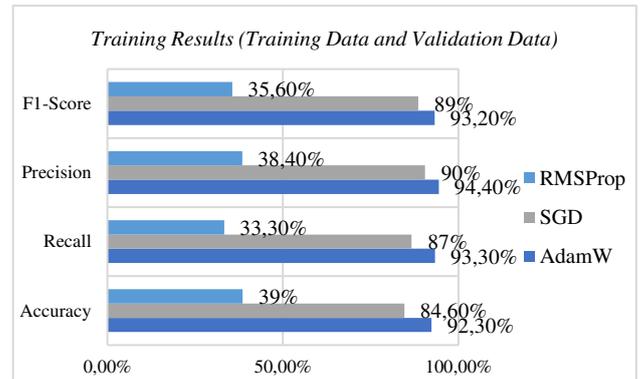
b. Dataset Garis Hati

TABEL 9

Perbandingan hasil pengujian *optimizer dataset* garis hati

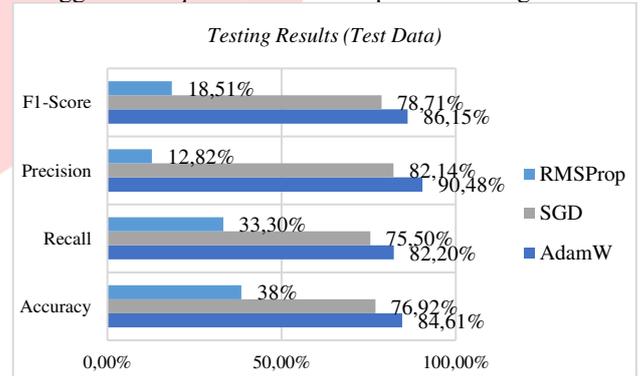
Optimizer	Data	Accuracy	Recall	Precision	F1-Score
AdamW	Train	92,3%	93,3%	94,4%	93,2%
	Test	84,61%	82,2%	90,48%	86,15%
SGD	Train	84,6%	86,67%	90,48%	88,53%
	Test	76,92%	75,5%	82,14%	78,71%
RMSprop	Train	38,5%	33,3%	38,4%	35,6%
	Test	38,46%	33,3%	12,82%	18,51%

Berdasarkan tabel hasil pengujian *optimizer* untuk garis hati, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* dengan *optimizer* AdamW. Selisih antara pelatihan dan pengujian sebesar 7,69%. Berikut visualisasi hasilnya:



GAMBAR 22 Visualisasi data hasil pelatihan

Berdasarkan visualisasi gambar 5. 19 dan 5. 20, akurasi tertinggi didapatkan pada penggunaan *optimizer* AdamW. Sehingga pengujian selanjutnya akan menggunakan *optimizer* AdamW pada *dataset* garis hati.



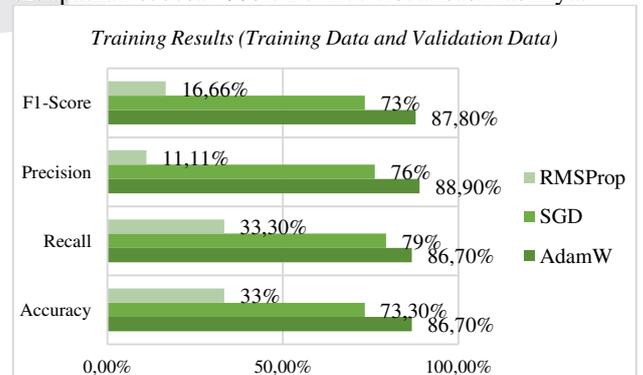
GAMBAR 23 Visualisasi data hasil pengujian

c. Dataset Kombinasi Garis Kepala dan Gari Kehidupan

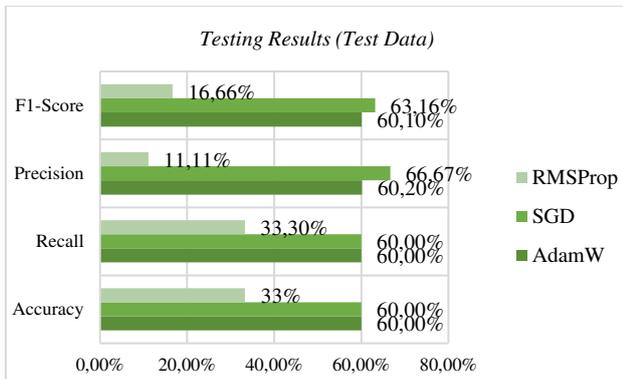
TABEL 10 Perbandingan hasil pengujian *optimizer dataset* garis kombinasi

Optimizer	Data	Accuracy	Recall	Precision	F1-Score
AdamW	Train	86,7%	86,7%	88,9%	87,8%
	Test	60%	60%	60,2%	60,1%
SGD	Train	73,3%	79,36%	76,22%	73,33%
	Test	60%	60%	66,67%	63,16%
RMSprop	Train	33,3%	33,3%	11,11%	16,66%
	Test	86,7%	86,7%	88,9%	87,8%

Berdasarkan tabel evaluasi matriks, nilai matriks evaluasi terbaik dengan *optimizer* AdamW dengan hasil pelatihan dengan akurasi, *recall*, *precision*, dan F1-Score masing-masing bernilai 86,7%, 86,7%, 88,9%, dan 87,8%. Sedangkan hasil pengujian dengan data *test* didapatkan sebesar 60%. Berikut visualisasi hasilnya:



GAMBAR 24 Visualisasi data hasil pelatihan



GAMBAR 25
Visualisasi data hasil pengujian

Berdasarkan visualisasi gambar tersebut, hasil pelatihan *optimizer* AdamW dan SGD sama. Namun, hasil pelatihan *optimizer* AdamW lebih tinggi akurasi. Sehingga pengujian selanjutnya akan menggunakan *optimizer* AdamW pada *dataset* kombinasi garis kepala dan garis kehidupan.

4. Epoch

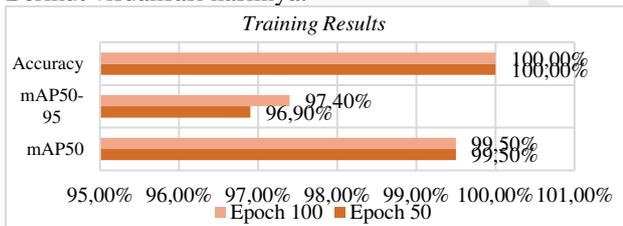
Banyaknya *epoch* berpengaruh pada hasil pelatihan model. *Epoch* yang terlalu banyak dapat menyebabkan model *overfitting*. Sementara *epoch* yang terlalu sedikit dapat membuat model *underfitting*. Sehingga dalam hal ini penting untuk menentukan *epoch* terbaik agar model tidak *underfitting* dan *overfitting*.

a. Dataset Gambar Telapak Tangan

TABEL 11
Perbandingan hasil pengujian *epoch dataset* telapak tangan

Epoch	Data	mAP50	mAP50-95	Accuracy
50	Train	99,5%	96,9%	100%
100	Train	99,5%	97,4%	100%

Berdasarkan tabel hasil pengujian *epoch* untuk *dataset* gambar telapak tangan, nilai matriks evaluasi terbaik di dapatkan oleh *dataset* dengan *epoch* 100. Berikut visualisasi hasilnya:



GAMBAR 26
Visualisasi data hasil pelatihan perbandingan *epoch*

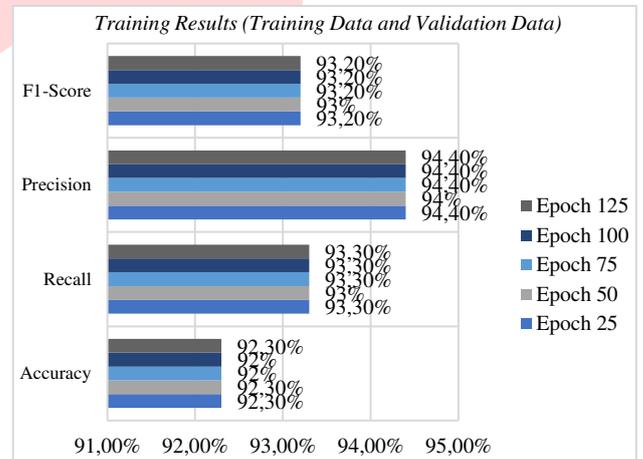
Berdasarkan visualisasi gambar 29, mAP50, mAP50-95, dan akurasi tertinggi didapatkan pada penggunaan *epoch* 100. Hal ini berarti, model dapat mendeteksi telapak tangan dengan akurasi tinggi. Sehingga model untuk deteksi gambar telapak tangan akan menggunakan partisi data 80:10:10, *optimizer* SGD, dan *epoch* 100 pada *dataset* gambar telapak tangan.

b. Dataset Garis Hati

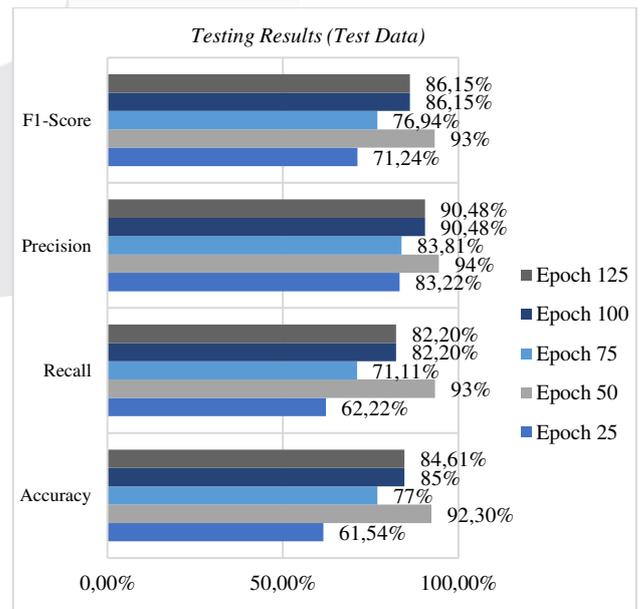
TABEL 12
Perbandingan hasil pengujian *epoch dataset* garis hati

Epoch	Data	Accuracy	Recall	Precision	F1-Score
25	Train	92,3%	93,3%	94,4%	93,2%
	Test	61,54%	62,22%	83,33%	71,24%
50	Train	92,3%	93,3%	94,4%	93,2%
	Test	92,3%	93,3%	94,4%	93,2%
75	Train	92,3%	93,3%	94,4%	93,2%
	Test	76,92%	71,11%	83,81%	76,94%
100	Train	92,3%	93,3%	94,4%	93,2%
	Test	84,61%	82,2%	90,48%	86,15%
125	Train	92,3%	93,3%	94,4%	93,2%
	Test	84,61%	82,2%	90,48%	86,15%

Berdasarkan tabel hasil matriks evaluasi tersebut, hasil pelatihan mendapatkan hasil yang sama di setiap *epoch* yang sudah ditentukan. Namun, terdapat perbedaan dalam hasil pengujian menggunakan data tes. Hasil pengujian *epoch* 50 akurasi sebesar 92,3%, *recall* sebesar 93,3%, *precision* sebesar 94,4%, dan *f1-score* sebesar 93,2%. Hasil pengujian ini merupakan hasil yang paling tinggi dan antara hasil pelatihan dan pengujian sama. Berikut visualisasi hasilnya:



GAMBAR 27
Visualisasi data hasil pelatihan



GAMBAR 28
Visualisasi data hasil pengujian

Berdasarkan visualisasi gambar 30 dan 31, akurasi tertinggi didapatkan pada penggunaan *epoch* 50 pada hasil pengujian. Hasil pelatihan dan pengujian dari *epoch* 50 lebih tinggi dibandingkan penggunaan *epoch* lainnya. Sehingga model akan menggunakan *dataset* berjumlah 3 kelas, partisi data 80:10:10, *optimizer* AdamW, dan *epoch* 50.

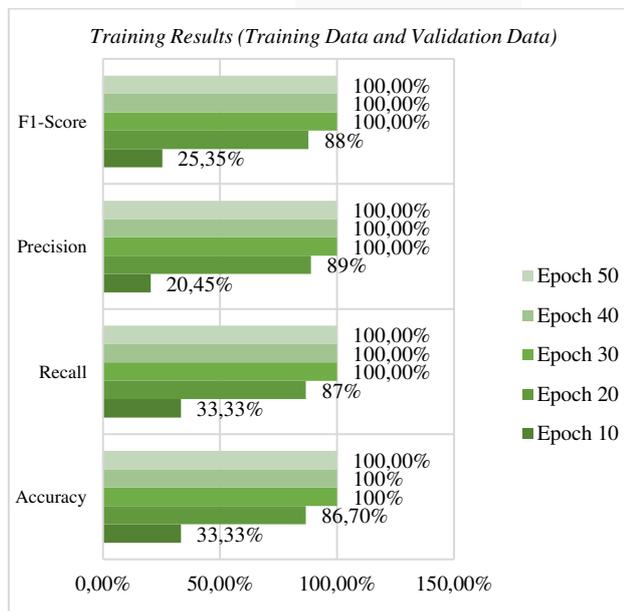
c. *Dataset* Kombinasi Garis Kepala dan Gari Kehidupan

TABEL 13

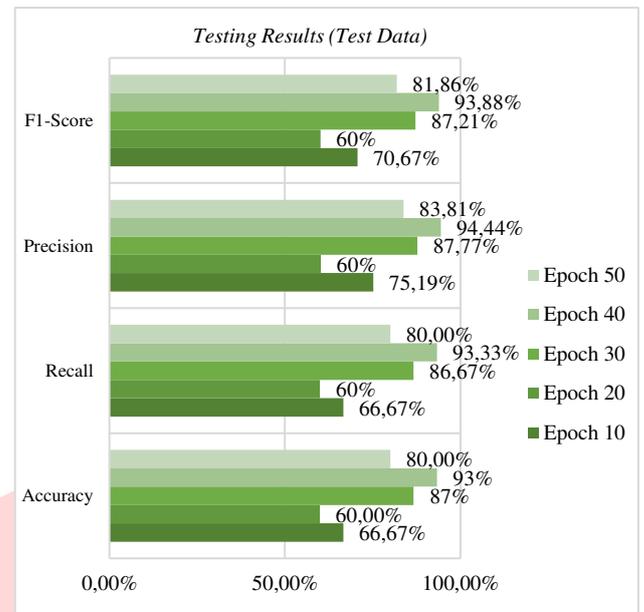
Perbandingan hasil pengujian epoch dataset garis kombinasi

Epoch	Data	Accuracy	Recall	Precision	F1-Score
10	Train	33,33%	33,33%	20,45%	25,35%
	Test	66,67%	66,67%	75,19%	70,67%
20	Train	86,7%	86,7%	88,9%	87,8%
	Test	60%	60%	60,2%	60,1%
30	Train	100%	100%	100%	100%
	Test	86,67%	86,67%	87,77%	87,21%
40	Train	100%	100%	100%	100%
	Test	93,33%	93,33%	94,44%	93,88%
50	Train	100%	100%	100%	100%
	Test	80%	80%	83,81%	81,86%

Berdasarkan hasil evaluasi matriks pengujian *epoch*, hasil pelatihan *epoch* 30, 40, dan 50 mendapat akurasi 100%. Hasil pengujian *epoch* 40 menjadi model terbaik untuk pengujian *epoch* dengan akurasi sebesar 93,33%, *recall* sebesar 93,33%, *precision* sebesar 94,44%, dan *f1-score* sebesar 93,88%. Pada *epoch* 40 selisih akurasi hasil pelatihan dan pengujian sebesar 6,67%. Berikut visualisasi hasilnya:



GAMBAR 29
Visualisasi data hasil pelatihan



GAMBAR 30
Visualisasi data hasil pengujian

Berdasarkan visualisasi gambar 33 dan 34, akurasi tertinggi didapatkan pada penggunaan *epoch* 40. Hasil pelatihan dan pengujian dari *epoch* 40 lebih tinggi dibandingkan penggunaan *epoch* lainnya. Sehingga model akan menggunakan *dataset* berjumlah 3 kelas, partisi data 80:10:10, *optimizer* AdamW, dan *epoch* 40.

V. KESIMPULAN

Berdasarkan penelitian dan hasil pengujian yang dilakukan, dapat ditarik beberapa kesimpulan. Kecerdasan buatan memainkan peran penting dalam mengidentifikasi kepribadian secara akurat berdasarkan pembacaan garis telapak tangan, dengan model pendeteksian mencapai akurasi 100%, mAP50 sebesar 99,5%, dan mAP50-95 sebesar 97,4%. Klasifikasi bentuk garis hati mencapai akurasi 92,3% pada data pelatihan dan pengujian, sedangkan model klasifikasi gabungan garis kepala dan garis kehidupan mencapai akurasi 100% pada data pelatihan dan 93,3% pada data pengujian. Hal ini berarti sistem dapat menghasilkan model yang baik dalam mengidentifikasi kepribadian anak.

REFERENSI

- [1] I. Ali, "Personality traits, individual innovativeness and satisfaction with life," *Journal of Innovation & Knowledge*, vol. 4, no. 1, pp. 38-46, 2019.
- [2] I. Imroatun, F. Widat, M. Fauziddin, S. Farida, S. Maryam dan Zulaiha, "Youtube as a Media For Strengthening Character Education in Early Childhood," *2nd Bukittinggi International Conference on Education (BICED)*, vol. 1779, no. 1, pp. 1-6, 2021.
- [3] C. Barbaranelli, G. V. Caprara, A. Rabasca dan C. Pastorelli, "A questionnaire for measuring the Big

- Five in late childhood,” *Personality and Individual Differences*, vol. 34, no. 4, pp. 645-664, 2003.
- [4] F. B. Evans dan S. E. Finn, “Training and Consultation in Psychological Assessment With Professional Psychologists: Suggestions for Enhancing the Profession and Individual Practices,” *Journal of Personality Assessment*, vol. 99, no. 2, pp. 175-185, 2016.
- [5] N. Abood, “Big Five Traits: A Critical Review,” *Gadjah Mada International Journal of Business*, vol. 21, no. 2, pp. 159-186, 2019.
- [6] B. T. Yates dan J. Taub, “Assessing the Costs, Benefits, Cost-Effectiveness, and Cost-Benefit of Psychological Assessment: We Should, We Can, and Here’s How,” *Psychological Assessment*, vol. 15, no. 4, pp. 478-495, 2003.
- [7] E. A. Kastama, Variasi perilaku manusia menurut sidik jarinya, Jakarta: Lembaga Penerbit Fakultas Ekonomi Universitas Indonesia, 2000.
- [8] H. H. K. Tin, “An Effective Method of a Person’s Character or Future using the Palm Print Images,” *3rd International Conference on Multidisciplinary Research & Practice*, vol. IV, no. I, pp. 9-12, 2016.
- [9] Z. Haniffah, B. Dirgantoro dan C. Setianingsih, “Detection of Children’s Personality with Fingerprint Using K-Nearest Neighbor (Knn) and Decision Tree Methods,” *2019 International Conference on Advanced Mechatronics, Intelligent Manufacture and Industrial Automation (ICAMIMIA)*, vol. doi: 10.1109/ICAMIMIA47173.2019.9223387., pp. 25-30, 2019.
- [10] F. Imanda, C. Setianingsih dan M. W. Paryasto, “Child Personality Detection by Fingerprint Using Support Vector Machine Method,” *2022 6th International Conference on Informatics and Computational Sciences (ICICoS)*, vol. doi: 10.1109/ICICoS56336.2022.9930575., pp. 163-168, 2022.
- [11] J. Preciozzi, G. Garella, V. Camacho, F. Franzoni, L. D. Martino, G. Carbajal dan A. Fernandez, “Fingerprint Biometrics From Newborn to Adult: A Study From a National,” *IEEE Transactions on Biometrics, Behavior, and Identity Science*, vol. 2, no. 1, pp. 68-79, 2020.
- [12] S. Prasad dan T. Chai, “Palmprint for Individual’s Personality Behavior Analysis,” *The British Computer Society 2020*, vol. 65, no. 2, p. 355-370, 2020.
- [13] J. Arianda, B. Dirgantoro dan C. Setianingsih, “Detection of Children with Personality Through Fingerprint Random Forest And Maximum Entropy Method,” *2019 International Conference on Advanced Mechatronics, Intelligent Manufacture and Industrial Automation (ICAMIMIA)*, vol. doi: 10.1109/ICAMIMIA47173.2019.9223383., pp. 7-12, 2019.
- [14] Harijanto, *Kitab Palmistry Rahasia Telapak Tangan*, Malang: Media Nusa Creative, 2020.
- [15] F. A. Bamidele dan M. E. Osehobo, “Kaggle - Human Palm Images,” Kaggle, 2023. [Online]. Available: <https://www.kaggle.com/datasets/feyiamujo/human-palm-images>. [Diakses 22 Mei 2024].
- [16] Y.-C. Chen, M. Syamsudin dan S. S. Berutu, “Pretrained Configuration of Power-Quality Grayscale-Image Dataset for Sensor Improvement in Smart-Grid Transmission,” *Electronics 2022*, vol. 11, no. 19, pp. 1-16, 2022.
- [17] D. Hindarto, “Exploring YOLOv8 Pretrain for Real-Time Detection of Indonesian Native Fish Species,” *Sinkron : Jurnal Dan Penelitian Teknik Informatika*, vol. 8, no. 4, pp. 2776-2785, 2023.
- [18] J. Terven, D.-M. Cordova-Esparza dan J.-A. Romero-González, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” *Deep Learning in Image Analysis and Pattern Recognition*, vol. 5, no. 4, pp. 1680-1716, 2023.
- [19] G. Wang, Y. Chen, P. An, H. Hong, J. Hu dan T. Huang, “UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios,” *Sensors 2023*, vol. 23, no. 16, pp. 1-27, 2023.
- [20] D. P. Kingma dan J. Ba, “Adam: A Method for Stochastic Optimization,” *3rd International Conference for Learning Representations*, vol. 3rd International Conference for Learning Representations, pp. 1-15, 2015.
- [21] E. Dago, O. Afolabi dan B. Twala, “On the Relative Impact of Optimizers on Convolutional Neural Networks with Varying Depth and Width for Image Classification,” *Applied Sciences*, vol. 12, no. 23, pp. 1-36, 2022.
- [22] J. Duchi, E. Hazan dan Y. Singer, “Adaptive Subgradient Methods for Online Learning and Stochastic Optimization,” *Journal of Machine Learning Research*, vol. 12, pp. 2121-2159, 2011.