

KLASIFIKASI GAYA BELAJAR MAHASISWA BERDASARKAN GARIS TELAPAK TANGAN MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Irennada¹, Achmad Solichin^{2*}, Goenawan Brotosaputro³

¹Teknik Informatika, Universitas Budi Luhur

²Ilmu Komputer, Universitas Budi Luhur

³Sistem Informasi, Universitas Budi Luhur

email: irennada67@gmail.com¹, achmad.solichin@budiluhur.ac.id², goenawan.brotosaputro@budiluhur.ac.id³

Abstrak

Gaya belajar dapat diartikan sebagai cara seorang siswa dalam menangkap berbagai informasi dalam proses pembelajaran. Model gaya belajar yang paling populer adalah model Visual, Auditori dan Kinestetik (VAK). Walaupun setiap siswa pada dasarnya dapat menerima materi dalam berbagai bentuk, namun pembelajaran akan lebih efektif jika materi disajikan sesuai gaya belajar siswa. Untuk mengetahui gaya belajar, dapat dilakukan dengan melakukan serangkaian asesmen menggunakan instrumen yang terdiri dari sejumlah pertanyaan. Asesmen tersebut memerlukan waktu yang cukup lama untuk memperoleh kesimpulan gaya belajar yang dominan. Pada penelitian ini, diusulkan metode identifikasi gaya belajar berdasarkan pola garis tangan (palmistry). Citra telapak tangan yang diperoleh dari 40 responden dianalisis memanfaatkan metode Convolutional Neural Network (CNN) untuk mendapatkan klasifikasi gaya belajar. Hasil pengujian terhadap model CNN diperoleh akurasi sebesar 70%, presisi 72%, dan recall 70%. Dengan demikian, identifikasi gaya belajar berbasis citra telapak tangan memiliki potensi yang besar dalam pengembangan sistem identifikasi gaya belajar yang lebih cepat dan akurat.

Kata kunci: gaya belajar, telapak tangan, convolutional neural network, model VAK.

Abstract

Learning style is a student's way of capturing various information in the learning process. The most popular learning style model is the Visual, Auditory and Kinesthetic (VAK) model. Although every student can basically receive material in various forms, learning will be more effective if the material is presented according to the student's learning style. To find out the learning style, it can be done by conducting a series of assessments using an instrument consisting of a number of questions. The assessment takes a long time to arrive at the conclusion of the dominant learning style. In this study, a method of identifying learning styles based on palmistry is proposed. Palm images obtained from 40 respondents were analyzed using the Convolutional Neural Network (CNN) method to obtain a classification of learning styles. The test results on the CNN model obtained accuracy of 70%, precision of 72%, and recall of 70%. Thus, palm image-based learning style identification has great potential in developing a faster and accurate learning style identification system.

Keywords : learning style, palmistry, convolutional neural network, VAK model

Diterima Redaksi: 04-11-2022 | Selesai Revisi: 11-12-2022 | Diterbitkan Online: 27-12-2022

DOI: <https://doi.org/10.23887/janapati.v11i3.53721>

PENDAHULUAN

Pendidikan merupakan salah satu kebutuhan dasar dan utama bagi manusia [1]. Kebutuhan akan pendidikan berkaitan dengan kebutuhan manusia dalam menyelesaikan permasalahan kehidupan. Pendidikan juga memiliki peran yang sangat penting untuk membentuk dan membangun karakter

seseorang dalam rangka menghadapi tantangan global di masa mendatang [2]. Dalam dunia pendidikan, mahasiswa mempunyai peranan penting dalam memperbaiki kualitas pendidikan di Indonesia. Mahasiswa sering dimasukkan dalam golongan masyarakat terdidik yang memiliki peran sebagai agen perubahan, pengendali sosial, dan kekuatan

sosial [3], serta menentukan masa depan suatu negara.

Di Indonesia, pendidikan dapat diperoleh melalui sejumlah lembaga atau institusi pendidikan baik formal maupun tidak formal. Dalam lembaga pendidikan formal, materi pembelajaran disampaikan sesuai dengan kurikulum dan rancangan pembelajaran. Walaupun disampaikan dengan kurikulum yang sama, seringkali materi pembelajaran tidak seluruhnya dapat diserap oleh peserta didik. Salah satu faktor yang mempengaruhi perbedaan penyerapan materi pembelajaran adalah perbedaan gaya belajar dari masing-masing individu. Proses pembelajaran akan lebih efektif dan efisien jika setiap individu, termasuk mahasiswa, dapat diketahui gaya belajar masing-masing dan dapat menyesuaikan dengan bentuk dari materi pembelajaran. Gaya belajar setiap orang mempengaruhi kemampuan seseorang dalam menyerap informasi yang baru, kemampuan berkonsentrasi, memproses dan menampung informasi yang masuk ke otak [4].

Masing-masing individu, termasuk mahasiswa, memiliki gaya belajar yang berbeda-beda. Begitu juga dalam lingkungan perkuliahan, mahasiswa mempunyai beragam cara belajar untuk memahami informasi selama proses pembelajaran. Ada yang lebih suka belajar bersama-sama dalam suasana ramai atau ada juga yang suka belajar fokus di saat sepi dan tidak diganggu kebisingan apapun. Untuk memperoleh hasil belajar yang maksimal setiap individu diharapkan dapat mengenai gaya belajar yang dimilikinya.

Saat ini, lebih dari 70 model gaya belajar yang diusulkan oleh para ahli, seperti model Kolb, Dun and Dun, Felder Silvermann, dan model VAK [5]. Model gaya belajar VAK terdiri dari 3 (tiga) gaya belajar yang mewakili kemampuan seseorang dalam melihat, mendengar dan bergerak selama proses pembelajaran. Kemampuan yang menonjol diantara ketiganya akan menentukan jenis atau tipe gaya belajar yang dimiliki. Dengan menerapkan model VAK, mahasiswa dapat mengenali potensi yang ada dalam dirinya [6] dan dapat menangkap materi dengan lebih efektif. Bagi mahasiswa yang memiliki gaya belajar visual, akan lebih mudah menangkap informasi dalam bentuk visual seperti gambar dan video. Sementara bagi mahasiswa yang memiliki gaya belajar auditori akan lebih mudah mendengarkan paparan materi secara lisan oleh dosen. Terakhir, mahasiswa dengan gaya belajar kinestetik akan lebih tertarik mengikuti praktikum di laboratorium atau lapangan dibanding mengikuti kelas teori.

Berbagai cara dapat dilakukan untuk mengetahui gaya belajar seseorang. Cara yang paling umum adalah dengan melakukan asesmen menggunakan sejumlah pertanyaan yang diberikan [7]. Hasil jawaban tersebut dianalisis dan selanjutnya dapat disimpulkan gaya belajar apa yang paling dominan. Cara tersebut memiliki kekurangan dari sisi lamanya waktu untuk melakukan asesmen dan mendapatkan hasil analisis, serta berpotensi kurang akuratnya isian yang diakibatkan oleh kondisi psikologis responden selama mengikuti asesmen.

Dengan perkembangan ilmu komputer dan komputasi, banyak peneliti mengusulkan cara alternatif yang lebih efektif untuk mengidentifikasi gaya belajar seseorang. Fatimah Mohd dkk mengusulkan sebuah model Sistem Pendukung Keputusan (SPK) untuk mengidentifikasi gaya belajar VAK berdasarkan perilaku siswa [5]. Selanjutnya, Hasibuan dkk. mengusulkan model identifikasi gaya belajar berdasarkan pengetahuan utama siswa yang dianalisis menggunakan metode Artificial Neural Network [8]. Model mampu melakukan deteksi gaya belajar dengan akurasi sebesar 80%.

Berbagai metode lainnya juga dikembangkan untuk mendeteksi gaya belajar, seperti dirangkum pada [9]. Beberapa metode yang populer digunakan antara lain metode Decision Tree [10], [11], K-NN + Algoritma Genetika [12], Naïve Bayes [13], dan Fuzzy Logic [14]. Dari penelitian terkait, gaya belajar diidentifikasi berdasarkan profil atau perilaku individu dalam menerima pembelajaran. Penelitian sebelumnya belum ditemukan metode identifikasi yang didasarkan pada ciri biometris, termasuk garis telapak tangan.

Oleh karena itu, pada penelitian ini diusulkan model identifikasi gaya belajar berdasarkan pola garis telapak tangan yang diperoleh dari citra digital. *Palmistry* merupakan metode ilmiah yang bertujuan untuk mengidentifikasi, mengevaluasi dan memahami karakter melalui analisis pola garis tangan. Pada dasarnya, manusia memiliki bentuk garis tangan yang berbeda satu dengan yang lain. Hal tersebutlah yang dijadikan dasar bagi seorang pakar *palmistry* untuk mengidentifikasi karakter dan kepribadian seseorang. Di bidang ilmu komputer, analisis pola garis telapak tangan menjadi bagian dari bidang ilmu biometrik yang memanfaatkan bagian tubuh manusia untuk berbagai keperluan. Sebagaimana bentuk biometrik yang lain seperti sidik jari dan retina mata, garis telapak tangan juga harus direkam menjadi citra digital, diekstraksi, dan dianalisis untuk tujuan tertentu [15]. Penggunaan pola garis telapak

tangan sudah cukup populer di berbagai penelitian, antara lain untuk pengenalan atau rekognisi individu [16]–[18] dan pengenalan karakter atau sifat seseorang [19], [20].

Kontribusi dari penelitian ini adalah untuk menerapkan metode pengolahan citra digital untuk menganalisis citra garis telapak tangan dan mengidentifikasi gaya belajar mahasiswa menggunakan metode *Convolutional Neural Network* (CNN). CNN dipilih dengan pertimbangan memiliki banyak kelebihan dibandingkan dengan jaringan saraf tiruan biasa, terutama dalam masalah pengolahan citra [21]. CNN mampu menangani input yang memiliki struktur spasial, sehingga mampu mengekstrak fitur-fitur yang lebih baik dari citra. Selain itu, CNN juga dapat diaplikasikan pada data yang memiliki ukuran yang tidak seimbang, sehingga lebih fleksibel dibandingkan dengan jaringan saraf tiruan biasa.

Hal tersebut berbeda dengan penelitian sebelumnya yang sebagian besar menggunakan citra garis telapak tangan untuk rekognisi dan pengenalan individu. Pemanfaatan citra garis tangan untuk mengidentifikasi sifat (*personality*) seseorang memang masih perlu dibuktikan secara ilmiah. Prasad dan Chai [22] ternyata telah membuktikan bahwa hal tersebut dibuktikan secara ilmiah. Penelitian ini bertujuan memperkuat penelitian yang telah dilakukan oleh [22] dan menguji hipotesis apakah garis telapak tangan dapat mengidentifikasi gaya belajar seseorang. Manfaat yang dari penelitian ini adalah mengetahui gaya belajar mahasiswa dari garis telapak tangan secara cepat dan efektif sebagai salah satu alternatif dalam penentuan gaya belajar mahasiswa.

METODE

Penelitian ini dilakukan melalui tahapan utama yaitu pengumpulan data, persiapan data atau (*data preprocessing*), pembelajaran atau training, dan evaluasi (*testing*) sebagaimana disajikan pada Gambar 1. Tahapan pertama pada penelitian ini merupakan pengumpulan

data dari citra telapak tangan dari sejumlah responden. Tahapan selanjutnya yaitu pembuatan *dataset* dari data yang sudah dikumpulkan sebelumnya, lalu berlanjut ke tahapan *pre-processing*. Pada tahapan *pre-processing* dilakukan normalisasi, *scaling* atau penskalaan, dan penerapan metode *edge detection*. Tahapan selanjutnya adalah pelatihan dan pemodelan menggunakan metode *Convolution Neural Network* (CNN). Pada tahap ini dirancang model CNN yang digunakan untuk mengklasifikasikan gaya belajar berdasarkan citra telapak tangan. Tahapan terakhir dalam metode ini adalah pengujian atau *testing* untuk menerapkan metode pada data yang sebelumnya sudah diolah.

Pengumpulan Dataset

Penggunaan *dataset* pada penelitian ini berupa data gambar. Pada penelitian ini data citra telapak tangan kanan dan kiri dikumpulkan dari 40 responden. Masing-masing responden mengirimkan foto telapak tangan kanan dan kiri yang diambil menggunakan perangkat masing-masing dan kemudian dikumpulkan ke peneliti. Setiap responden memberikan 2 foto yaitu foto telapak tangan kanan dan telapak tangan kiri. Total data yang diperoleh dalam penelitian ini adalah 80 citra telapak tangan yang terdiri dari telapak tangan kanan dan kiri. Data hasil tangkapan kamera dari responden dilakukan standardisasi terutama dari sisi ukuran dan format citra. Gambar 2 menyajikan cuplikan dataset citra telapak tangan yang diperoleh dari proses perekaman sejumlah responden.

Selanjutnya, setiap data citra diberikan label auditori, kinestetik dan visual. Proses labelisasi dilakukan berdasarkan pengisian instrumen gaya belajar dari AkuPintar.ID. Instrumen terdiri dari 30 pertanyaan yang dapat diisikan secara daring pada laman <https://akupintar.id/tesgaya-belajar>. Hasil identifikasi gaya belajar menggunakan instrumen tersebut terdiri dari 13 responden bertipe visual (V), 7 responden tipe auditori (A), dan 20 responden tipe kinestetik (K).



Gambar 1. Tahapan Penelitian



Gambar 2. Contoh Dataset Telapak Tangan

Preprocessing

Preprocessing adalah tahapan memberikan peningkatan kualitas citra yang ingin diolah sehingga diperoleh citra yang lebih baik dari citra asli. Beberapa proses yang dilakukan pada tahap pre-processing yaitu *cropping image*, augmentasi, dan deteksi tepi dengan metode *canny*. Citra data telapak tangan yang sudah dikumpulkan dipangkas sehingga yang digunakan adalah bagian garis telapak tangannya saja. Hal ini bertujuan agar lebih deteksi citra akan lebih fokus pada garis telapak tangan. *Cropping image* dilakukan manual dengan memangkas citra menggunakan *software* tambahan yaitu *Snipping Tool*.

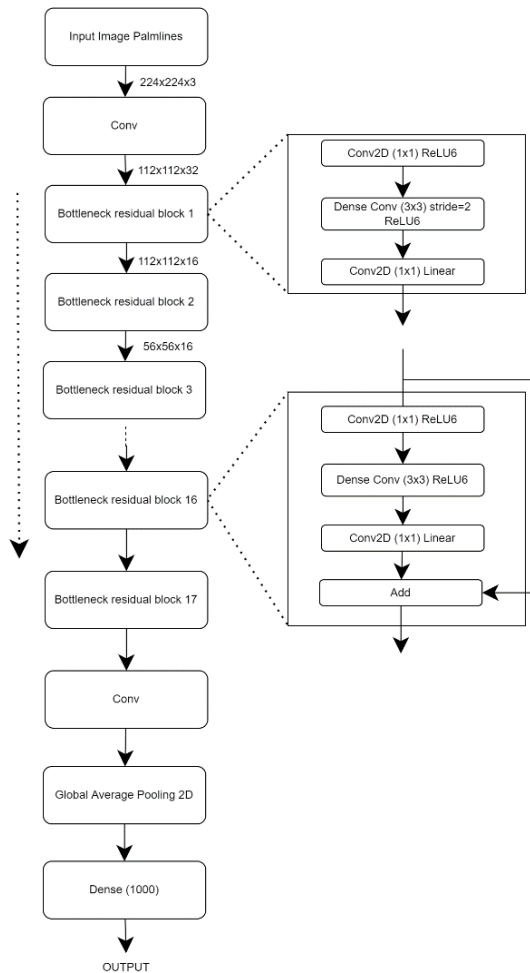
Jumlah dataset yang dihasilkan relatif sedikit dan kurang bervariasi, sehingga dilakukan proses augmentasi data. Augmentasi data citra bertujuan untuk mengubah atau memodifikasi gambar agar menjadi lebih bervariasi. Dalam beberapa penelitian, augmentasi data dapat meningkatkan nilai akurasi model atau metode [23]–[25]. Dengan augmentasi diperoleh data tambahan yang berguna untuk membuat komposisi data lebih berimbang dan bervariasi sehingga menghasilkan model yang dapat digeneralisasi dengan lebih baik. Proses augmentasi pada penelitian ini adalah melakukan rotasi serta *zoom* gambar. *Edge Detection* atau deteksi tepi dilakukan pada citra ini dengan menggunakan metode *Canny* dari *library* OpenCV yang mengidentifikasi tepi pada objek garis telapak tangan. Beberapa proses deteksi tepi pada citra adalah akuisisi citra, filter *gaussian*, menghitung

gradien citra, non-maksimum *suppression*, dan terakhir menggunakan *hysteresis thresholding*.

Model Pembelajaran (Training)

Tahapan ini bertujuan untuk mengekstraksi fitur dari citra garis telapak tangan dengan menggunakan algoritme *Covolutional Neural Network* (CNN). Pada CNN terdapat beberapa *layer* untuk proses utama yaitu *Convolutional Layer*, *Pooling Layer*, *Flatten*, *Dense Layer*, dan *Activation*. *Training model* dapat dilakukan setelah mengatur nilai *epoch* dan *batch_size* terlebih dahulu. Setelah itu baru bisa dilakukan *training* data. Proses *training* bertujuan untuk memperoleh model CNN terbaik yang memiliki akurasi tertinggi.

Pada penelitian ini, digunakan *MobileNetV2* untuk memperoleh model klasifikasi terbaik. Gambar 3 menyajikan arsitektur Model *MobileNetV2*. *Dataset* untuk *training model* dibagi menjadi 2 yaitu data uji dan data latih. Sebuah CNN terdiri dari beberapa *layer*. Proses klasifikasi gambar terdiri dari beberapa tahapan *layer*. *Layer* pertama menyimpan gambar dalam representasi vektor dimensi rendah. Pada *convolutional layer* dilakukan operasi konvolusi pada *output layer* sebelumnya. Konvolusi citra pada dasarnya bertujuan untuk melakukan ekstraksi ciri dari citra *input*. Konvolusi menghasilkan transformasi linear dari data *input* sesuai informasi spasial yang diperoleh.



Gambar 3. Arsitektur MobileNetV2

Evaluasi dan Testing

Pada tahap evaluasi terhadap hasil *training* akan didapatkan empat plot matriks yaitu *accuracy*, *loss*, *precision*, dan *recall*. Selain itu akan ditampilkan *confusion matrix* yang akan menunjukkan seberapa banyak keberhasilan terhadap *data testing* yang diberikan. Apabila hasil *confusion matrix* mendapatkan nilai tinggi terdistribusi pada diagonal pojok kiri atas sampai kanan bawah, maka model yang dihasilkan dikatakan baik. Dapat juga untuk mencetak laporan model untuk tiap kategori menggunakan pustaka *Scikit-Learn* untuk dapat dijadikan acuan mencari kategori mana yang hasil prediksinya jelek. Pada tahap *testing dataset* akan disiapkan dalam tahap *preprocessing*. Kemudian citra akan diekstraksi menggunakan metode deteksi tepi. Setelah ekstraksi selesai, baru dilakukan *testing* data menggunakan model CNN yang diperoleh dari proses *training*. Hasil yang diperoleh dari *testing* selanjutnya akan dilihat tingkat akurasi.

Akurasi, Presisi, dan Recall

Model CNN yang dikembangkan diuji tingkat akurasi, presisi, dan recall menggunakan Persamaan 1, Persamaan 2, dan Persamaan 3. Pada penelitian ini, pengujian dilakukan dengan cara membandingkan beberapa data hasil prediksi (data hasil tahap klasifikasi) dengan sekumpulan data aktual (data hasil tahap *labeling*). Adapun dimaksud dengan beberapa data hasil prediksi yaitu sekumpulan data yang telah diproses melalui algoritme CNN (*Pre-trained Model*).

Persamaan untuk mencari nilai akurasi, presisi, dan *recall* adalah [26]:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$


Keterangan:

- True Positive* (TP) merupakan data dengan label X yang diprediksi sebagai X. Misalnya: data uji 1 berlabel auditori dan diprediksi sebagai auditori.
- True Negative* (TN) merupakan data dengan label selain X yang diprediksi sebagai selain X. Misalnya: data uji 1 berlabel selain auditori dan diprediksi sebagai selain auditori.
- False Positive* (FP) merupakan data dengan label bukan X, tetapi diprediksi sebagai X. Misalnya: data 1 berlabel bukan auditori, tetapi diprediksi sebagai auditori.
- False Negative* (FN) merupakan data dengan label X, tetapi diprediksi sebagai selain X. Misalnya: data uji 1 berlabel auditori, tetapi diprediksi sebagai selain auditori.


HASIL DAN PEMBAHASAN

Augmentasi Data dan Preprocessing

Pengumpulan *dataset* berupa foto telapak tangan disimpan dalam folder *dataset* yang didalamnya juga terdapat tiga buah folder yang berisi citra yang sudah di kelompokkan sesuai dengan tipe gaya belajar yaitu visual, auditori, dan kinestetik. Jumlah citra telapak tangan yang digunakan untuk penelitian ini adalah 240 citra dan juga termasuk citra yang sudah melewati tahap augmentasi yaitu dengan dirotasi dan *zoom* citra. Setelah melakukan *cropping* citra, gambar disimpan dengan format PNG. Augmentasi dilakukan untuk menambah variasi *dataset* baik dari sisi ukuran dan kualitas dari *training dataset* [27].



Gambar 4. Augmentasi Citra dengan Rotasi



Gambar 5. Augmentasi Citra dengan Zoom

Rotasi citra dilakukan dengan memutar citra sebesar 20° secara horizontal dan 20° secara vertikal. Citra yang sudah dirotasi akan disimpan dalam folder baru dengan nama yang berurutan. Gambar 4 menyajikan contoh hasil augmentasi citra dengan operasi rotasi. Sementara itu, *zoom* citra dilakukan dengan memperbesar gambar sampai 30% untuk sudut horizontal dan 50% untuk sudut vertikal. Sementara itu, Gambar 5 menampilkan contoh hasil augmentasi citra dengan operasi zoom sebesar 30%.

Deteksi Tepi

Implementasi metode deteksi tepi pada penelitian ini menggunakan metode *Canny Edge Detection* dan melewati beberapa proses seperti berikut:

a. Filter Gaussian

Deteksi tepi sangat rentan terhadap derau pada gambar. Salah satu metode untuk menghilangkan derau pada citra adalah dengan menggunakan filter Gaussian Blur berukuran 5×5 .

b. Menghitung Gradien Citra

Gradien citra dihitung menggunakan algoritma Canny. Gradien pada setiap piksel citra yang telah diperhalus ditentukan dengan menerapkan operator Sobel. Gradien citra dihitung melalui Persamaan 4. Selanjutnya, untuk menentukan tepian dilakukan dengan perhitungan arah tepian menggunakan Persamaan 5.

$$M = \sqrt{Sx^2 + Sy^2} \quad (4)$$

$$\theta = \arctan \left(\frac{Gy}{Gx} \right) \quad (5)$$


c. Non-maksimum Suppression

Selanjutnya, berdasarkan arah tepi yang telah diperoleh pada langkah sebelumnya, dilakukan pengurangan nilai piksel di sekitar tepi sedemikian hingga diperoleh tepi yang lebih jelas dan tegas. Nilai piksel yang dianggap bukan nilai maksimum dihilangkan atau diubah menjadi 0 (hitam). Proses tersebut dikenal dengan *non-maksimum suppression*.

d. Ambang Batas Hysteresis

Metode deteksi tepi Canny menggunakan 2 (dua) nilai ambang batas (*threshold*), yaitu ambang batas bawah (disimbolkan dengan $T1$) dan ambang batas atas ($T2$). Nilai yang kurang dari $T1$ diubah menjadi hitam (nilai pixel 0), dan nilai yang lebih besar dari $T2$ diubah menjadi putih (nilai pixel 255). Sementara itu, nilai yang berada di antara $T1$ dan $T2$ akan diubah menjadi nilai pixel 128, yang berarti nilai abu-abu atau belum jelas. Nilai ini akan dijadikan 0 atau 255. Hal tersebut disebut ambang batas *hysteresis*.

Pada penelitian ini, nilai ambang batas ditentukan setelah melakukan serangkaian percobaan dengan berbagai nilai ambang batas ($T1$ dan $T2$). Percobaan dilakukan dengan kombinasi ambang batas $T1$ dan $T2$: (60, 100), (40, 80), dan (20, 60). Berdasarkan pengamatan secara visual, kombinasi nilai ambang batas (20, 60) menunjukkan hasil deteksi tepi yang jelas dan optimal sebagaimana disajikan pada Gambar 6.



Gambar 6. Contoh Penerapan Deteksi Tepi pada Citra Telapak Tangan dengan nilai $T1=20$ dan $T2=60$

Pembagian Data

Pada penelitian ini pembagian data yang dilakukan adalah pembagian *data testing* dan *data training* dengan perbandingan 2:8 yaitu 20% dan 80%. Dengan rasio tersebut maka *data training* berjumlah 193 citra dan *data testing* berjumlah 47 citra berdasarkan dari 3 kelas. Semua citra sebelumnya telah disiapkan dan disimpan dalam *Google Drive* untuk digunakan pada *training model Convolutional Neural Network (CNN)*.

Pemodelan (Training) dengan Custom MobileNetV2

Model yang digunakan pada penelitian ini menggunakan *MobileNetV2* yang merupakan model yang sudah di *training* berkali-kali. Model tersebut dikembangkan oleh *Google* dan telah dilatih pada *dataset ImageNet*. Pengujian model *MobileNetV2* dilakukan dengan menggunakan data yang sudah dikumpulkan. Citra garis telapak tangan diuji untuk melihat apakah citra dapat diidentifikasi. Setelah dilakukan proses model, citra garis telapak tangan tidak teridentifikasi dari 1000 kelas *ImageNet*. *Layer* ditambahkan pada model menjadi *rescaling*, *dropout layer*, dan *dense (output layer)*. Proses *rescale* = $1/255$ akan mengonversi piksel dalam rentang [0, 255] ke rentang [0, 1]. Proses ini juga disebut normalisasi *input*. Menskalakan setiap gambar ke rentang yang sama [0, 1] akan membuat gambar berkontribusi lebih merata terhadap total *loss*. *Neural network* memiliki peluang lebih tinggi untuk konvergen karena membuat koefisien dalam kisaran [0, 1] dibandingkan dengan [0, 255] sehingga membantu model memproses *input* lebih cepat.

Lapisan selanjutnya yang ditambahkan pada *base model MobileNet-v2* adalah *dropout*. Persentase *dropout layer* yang digunakan yaitu 0,2 atau 20%. Pada *output layer*, *dense* disesuaikan dengan jumlah *label* atau kelas pada penelitian ini yang berjumlah 3 kelas dengan fungsi aktivasi *softmax*. *Output shape* juga diinisialisasi sebesar 1280 seperti pada Gambar 7.

```
Model: "sequential"
-----
Layer (type)                Output Shape              Param #
-----
keras_layer (KerasLayer)    (None, 1280)              2257984
dropout (Dropout)           (None, 1280)              0
dense (Dense)                (None, 3)                 3843
-----
Total params: 2,261,827
Trainable params: 3,843
Non-trainable params: 2,257,984
```

Gambar 7. Model Custom CNN

Training custom model CNN dengan *dataset* citra garis telapak tangan hasil *preprocessing*. Pada awal dilakukan sebanyak 100 iterasi (*epochs*), dengan durasi 1 menit 40 detik dan menghasilkan informasi *loss* = 0,2049, *acc* = 0,9689, *val_loss* = 0,4919 dan *val_acc* = 0,8723 sebagaimana terlihat pada Gambar 8. *Loss* adalah *training loss* yaitu nilai dari perhitungan *loss function* dari *training dataset* dan prediksi dari model yang sudah dibuat.

Selanjutnya, nilai *accuracy* merupakan perhitungan akurasi dari *training dataset* dan prediksi dari model. *Val_loss* atau *validation loss* adalah nilai perhitungan *loss function* dari validasi *dataset* dan prediksi model dengan *input data*. *Val_acc* atau *validation accuracy* merupakan nilai perhitungan akurasi dari validasi *dataset* dengan *input data* untuk. Nilai *loss* merupakan ukuran tingkat kesalahan yang dibuat oleh jaringan dalam tahap pemodelan. Semakin kecil nilai *loss* pada iterasi maka nilai semakin baik model yang dihasilkan. Sementara itu, nilai akurasi menggambarkan tingkat keberhasilan model yang diuji. Dengan demikian, pada nilai akurasi jika nilai semakin tinggi maka semakin baik.

Hasil Pengujian Model

Pengujian dilakukan dengan mengambil 20% dari data latih yaitu masing-masing kelas menguji 20 citra garis telapak tangan yang telah diaugmentasi dan *preprocessing*. Tabel 1 menyajikan jumlah data uji untuk setiap kelas. Dari semua data yang telah diuji, hasil prediksi direpresentasikan dengan *confusion matrix* sebagaimana disajikan pada Gambar 9. Sementara itu, rangkuman hasil pengujian dapat dilihat pada Tabel 2.

Tabel 1 *Dataset* Pengujian

Gaya Belajar	Jumlah Citra Baru
Visual	20
Auditori	20
Kinestetik	20
Jumlah	60

Confusion matrix (CM) menggambarkan secara visual mengenai perbandingan hasil klasifikasi yang dilakukan oleh model atau metode klasifikasi (*predicted*) dengan hasil klasifikasi yang sebenarnya (*actual*). Berdasarkan hasil *confusion matrix* sebagaimana disajikan pada Gambar 9, didapatkan informasi data aktual dan data prediksi.

Pada pengujian *dataset* untuk model yang telah dilakukan menghasilkan nilai masing-masing untuk data pada kelas auditori, kinestetik, dan visual. Untuk kotak yang berwarna merupakan nilai data aktual yang diprediksi benar atau *True Positive* (TP). Misal, data citra garis telapak tangan yang sebenarnya auditori dan diprediksi benar sebagai auditori berjumlah 14. Data yang sebenarnya auditori diprediksi bukan sebagai auditori berjumlah 6 (hasil dari 5+1) atau *False Negative* (FN). Data yang bukan auditori diprediksi sebagai bukan auditori berjumlah 46 (hasil dari jumlah semua

data kecuali TP auditori) atau *True Negative* (TN). Data yang sebenarnya bukan auditori diprediksi sebagai auditori berjumlah 7 (hasil dari 3+4) atau *False Positive* (FP).



Gambar 8. Training Loss Model

Confusion Matrix
Klasifikasi Gaya Belajar VAK

		Data Prediksi		
		Auditori	Kinestetik	Visual
Data Aktual	Auditori	14	5	1
	Kinestetik	3	16	1
	Visual	4	4	12

Gambar 9. Confusion Matrix

Tabel 2 Nilai Akurasi, Presisi, dan Recall

	Precision	Recall	F1-score	Support
Auditori	0,67	0,70	0,68	20
Kinestetik	0,64	0,80	0,71	20
Visual	0,86	0,60	0,71	20
Accuracy	-	-	0,70	60
Macro Avg	0,72	0,70	0,70	60
Weighted Avg	0,72	0,70	0,70	60

Pengujian dilakukan untuk mengetahui nilai atau tingkat akurasi, presisi, dan recall dari model latih menggunakan algoritme yang diusulkan. Pada penelitian ini, pengujian dilakukan dengan cara membandingkan beberapa data hasil prediksi (data hasil tahap klasifikasi) dengan sekumpulan data aktual

(data hasil tahap *labeling*). Adapun dimaksud dengan beberapa data hasil prediksi yaitu sekumpulan data yang telah diproses melalui algoritme CNN (*Pre-trained Model*)

Akurasi model:

Nilai akurasi pada keseluruhan model dapat dilihat dengan rumus yang telah dijabarkan sebelumnya. Jumlah TP dan TN didapat dari jumlah data uji. Berikut perhitungan untuk nilai akurasi keseluruhan:

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
 &= \frac{42}{60} \times 100\% \\
 &= 0,7 \times 100\% \\
 &= 70\%
 \end{aligned}$$

Berdasarkan hasil perhitungan nilai akurasi dapat disimpulkan bahwa data akurasi keseluruhan memiliki 70% data yang memiliki rasio prediksi benar (positif dan negatif). Sehingga disimpulkan bahwa algoritme CNN dapat melakukan klasifikasi gaya belajar dari citra garis telapak tangan dengan cukup baik.

$$\begin{aligned}
 \text{Presisi} &= \frac{\sum_{j=1}^n \text{Presisi}_j}{n} \\
 &= \frac{0,67 + 0,64 + 0,86}{3} \\
 &= 0,72 \\
 &= 72\%
 \end{aligned}$$

Sementara itu, untuk menghitung nilai presisi pada klasifikasi dengan kelas berjumlah lebih dari dua, dapat diperoleh dengan menghitung rerata dari nilai presisi setiap kelas. Berdasarkan perhitungan, didapatkan hasil 72% nilai presisi keseluruhan data yaitu ketepatan sistem antara informasi yang diberikan oleh sistem untuk menunjukkan secara benar data kelas negatif atau kelas positif.

Nilai *recall* keseluruhan merupakan nilai yang menunjukkan tingkat keberhasilan untuk mengetahui kembali informasi secara benar. Nilai *recall* keseluruhan didapat sebesar 70%.

$$\begin{aligned}
 \text{Recall} &= \frac{\sum_{j=1}^n \text{Recall}_j}{n} \\
 &= \frac{0,70 + 0,80 + 0,60}{3} \\
 &= 0,7 \\
 &= 70\%
 \end{aligned}$$

Secara keseluruhan, hasil pengujian performa algoritma disajikan pada Tabel 2. Berdasarkan tabel tersebut, secara keseluruhan sistem mampu mendeteksi gaya belajar seseorang berdasarkan citra garis telapak tangan dengan nilai akurasi sebesar 70%.

presisi 72%, recall 70%, dan f1-score 70%. Hasil tersebut cukup menjanjikan dan memiliki potensi besar untuk dikembangkan. Walaupun tingkat ketepatan sistem tidak terlalu besar, namun secara keseluruhan dapat disimpulkan bahwa citra garis telapak tangan dapat digunakan untuk mengetahui gaya belajar seseorang.

Berdasarkan Tabel 2, terlihat bahwa nilai presisi tertinggi dicapai untuk data kelas visual yaitu 86%, sementara nilai recall tertinggi dicapai untuk kelas kinestetik yaitu 80%. Dengan demikian, untuk gaya belajar visual, sistem mampu mengenalinya dengan lebih baik dibanding gaya belajar lainnya. Dengan nilai recall sebesar 80% pada kelas kinestetik menunjukkan bahwa untuk gaya belajar kinestetik, sistem memiliki kemampuan deteksi lebih baik dibanding lainnya.

Tampilan Layar Sistem

Tampilan layar pada Gambar 10 merupakan tampilan layar sistem utama ini memiliki 4 menu utama yang dapat digunakan. Didalam aplikasi ini terdapat judul pada bagian atas dan terdiri dari menu Gaya Belajar VAK, Augmentasi & Preprocessing, Training Data, Testing, dan Pengujian Performa.



Gambar 10. Beberapa tampilan layar aplikasi yang menyajikan menu utama (atas), proses augmentasi data (tengah) dan hasil klasifikasi gaya belajar (bawah)

KESIMPULAN

Berdasarkan hasil serangkaian pengujian menggunakan metode serta algoritma yang telah dilakukan, dapat disimpulkan bahwa proses deteksi tepi menggunakan *Canny Edge Detection* berhasil diterapkan untuk proses *preprocessing* data citra garis telapak tangan, dengan nilai ambang batas terbaik sebesar $T1 = 20$, dan $T2 = 60$. Selanjutnya, pemodelan menggunakan algoritma *Convolutional Neural Network* (CNN) berhasil dilakukan. Model menggunakan *custom* model *MobileNetV2* dengan nilai validasi *loss* 0,4919 dan validasi *accuracy* 0,8723. Hasil dari pemodelan menggunakan algoritme CNN untuk mengklasifikasi gaya belajar ditunjukkan dengan presentase akurasi sebesar 70%, nilai presisi sebesar 72%, nilai *recall* sebesar 70% dan f1-score sebesar 70%. Dari besarnya nilai presentase akurasi, presisi, dan recall ini menunjukkan bahwa klasifikasi gaya belajar melalui garis telapak tangan menggunakan algoritme CNN adalah cukup akurat. Sehingga dapat memudahkan para mahasiswa untuk mengetahui gaya belajar agar dapat belajar dengan efektif. Beberapa citra tidak berhasil diidentifikasi dikarenakan beberapa faktor dalam pengambilan gambar sehingga gambar menjadi kurang jelas.

Adapun saran yang dapat peneliti berikan sebagai pengembangan lebih lanjut untuk aplikasi ini, agar dapat berjalan lebih baik lagi yaitu dengan memperbanyak dan memperbaiki *dataset* citra dengan pengambilan gambar yang optimal untuk hasil yang lebih baik, hasil pengujian identifikasi gaya belajar berdasarkan citra garis telapak tangan dapat disimpan, dan dapat mengidentifikasi citra tanpa melakukan *cropping* citra pada garis telapak tangan terlebih dahulu.

REFERENSI

- [1] R. Hidayat dan Abdillah, *Ilmu Pendidikan "Konsep, Teori dan Aplikasinya."* Medan: Lembaga Peduli Pengembangan Pendidikan Indonesia (LPPPI), 2019.
- [2] S. Mustoip, M. Japar, dan Zulela, *Implementasi Pendidikan Karakter.* Surabaya: CV. Jakad Publishing Surabaya 2018, 2018.
- [3] H. Cahyono, "Peran Mahasiswa di Masyarakat," *Banten-Bode J. Pengabd. Masy. Setiabudhi*, vol. 1, no. 1, hal. 32–43, 2019.
- [4] L.-L. N. Mufidah, "Memahami Gaya Belajar untuk meningkatkan Potensi Anak," *Martabat: Jurnal Perempuan dan*

- Anak, vol. 1, no. 2. 2017.
- [5] F. Mohd, W. F. F. A. Wan Yahya, S. Ismail, M. A. Jalil, dan N. M. M. Noor, "An Architecture of Decision Support System for Visual-Auditory-Kinesthetic (VAK) Learning Styles Detection Through Behavioral Modelling," *Int. J. Innov. Enterp. Syst.*, vol. 3, no. 02, hal. 24–30, 2019.
- [6] D. R. Lazuardi dan S. Murti, "Peningkatan Kemampuan Menulis Puisi Menggunakan Model Pembelajaran Quantum Tipe VAK (Visual, Audiovisual, Kinestetik)," *J. Kaji. Bahasa, Sastra dan Pengajaran*, vol. 2, no. 1, hal. 87–95, 2018.
- [7] F. Rozi *et al.*, "Learning management; identifying learning styles of language learners in madrasah," *Proc. Int. Conf. Ind. Eng. Oper. Manag.*, no. August, hal. 3783–3790, 2020.
- [8] M. S. Hasibuan, L. E. Nugroho, dan P. I. Santosa, "Model detecting learning styles with artificial neural network," *J. Technol. Sci. Educ.*, vol. 9, no. 1, hal. 85–95, 2019.
- [9] J. Feldman, A. Monteserin, dan A. Amandi, "Automatic detection of learning styles: state of the art," *Artif. Intell. Rev.*, vol. 44, no. 2, hal. 157–186, 2015.
- [10] R. R. Maaliw dan M. A. Ballera, "Classification of learning styles in virtual learning environment using J48 decision tree," in *14th International Conference on Cognition and Exploratory Learning in the Digital Age, CELDA 2017*, 2017, hal. 149–156.
- [11] A. A. Kalhor, S. Rajper, dan G. A. Mallah, "Detection of E-Learners' Learning Styles: An Automatic Approach using Decision Tree," *Int. J. Comput. Sci. Inf. Secur.*, vol. 14, no. 8, hal. 420–425, 2016.
- [12] Y. C. Chang, W. Y. Kao, C. P. Chu, dan C. H. Chiu, "A learning style classification mechanism for e-learning," *Comput. Educ.*, vol. 53, no. 2, hal. 273–285, 2009.
- [13] L. X. Li dan S. S. A. Rahman, "Students' learning style detection using tree augmented naive Bayes," *R. Soc. Open Sci.*, vol. 5, no. 7, hal. 1–13, 2018.
- [14] O. El Aissaoui, Y. El Alami El Madani, L. Oughdir, dan Y. El Alloui, "A fuzzy classification approach for learning style prediction based on web mining technique in e-learning environments," *Educ. Inf. Technol.*, vol. 24, no. 3, hal. 1943–1959, 2019.
- [15] F. C. H. Slamet Prasetyo, Budhi Irawan, "Perancangan Aplikasi Deteksi Sifat Manusia Menggunakan Garis Tangan Dengan Metode Citra Gray-Level Co-Occurrence Matrix (Glcm) Pada Citra Berbasis Android," vol. 7, no. 1, hal. 1603–1609, 2020.
- [16] B. Pradinta, Ernawati, dan E. P. Purwandari, "Identifikasi Citra Garis Telapak Tangan Menggunakan Metode Linear Discriminant Analysis dengan Probabilitas Naive Bayesian," *J. Pseudocode*, vol. 4, no. 2, hal. 156–167, 2017.
- [17] A. K. Haq, R. R. Isnanto, dan A. A. Zahra, "Perancangan Sistem Pengenal Garis Utama Telapak Tangan Pada Sistem Presensi Menggunakan Metode Principal Component Analysis (PCA) Dan Jarak Euclidean," *TRANSIENT*, vol. 4, no. 4, hal. 7–11, 2015.
- [18] N. Fajriani dan J. Y. Sari, "Pengenalan Pola Garis Telapak Tangan Menggunakan Metode Fuzzy K- Nearest Neighbor," *J. Ilm. Educic*, vol. 4, no. 1, hal. 36–43, 2017.
- [19] E. Andriyanto dan Y. Melita, "Pengenalan Karakteristik Manusia Melalui Pola Garis Telapak Tangan Menggunakan Metode Probabilistic Neural Network," *J. Ilm. Teknol. Inf. STMIK ASIA Malang*, vol. 7, no. 2, hal. 1–9, 2013.
- [20] V. Nigam, D. Yadav, dan M. K. Thakur, "A Novel Approach for Hand Analysis Using Image Processing Techniques," *Int. J. Comput. Sci. Inf. Secur.*, vol. XXX, no. XXX, hal. 1–5, 2010.
- [21] R. Haridas dan J. R. L., "Convolutional Neural Networks: A Comprehensive Survey," *Int. J. Appl. Eng. Res.*, vol. 14, no. 3, hal. 780, 2019.
- [22] S. Prasad dan T. Chai, "Palmprint for Individual's Personality Behavior Analysis," *Comput. J.*, vol. 65, no. 2, hal. 355–370, 2022.
- [23] J. Sanjaya dan M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, hal. 311–323, 2020.
- [24] M. Resa, A. Yudianto, dan H. Al Fatta, "Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network," *J. Teknol. Inf.*, vol. 4, no. 2, hal. 182–190, 2020.
- [25] W. D. Mega Pradnya dan A. Putri Kusumaningtyas, "Analisis Pengaruh

- Data Augmentasi Pada Klasifikasi Bumbu Dapur Menggunakan Convolutional Neural Network,” *J. Media Inform. Budidarma*, vol. 6, no. 4, hal. 2022–2031, 2022.
- [26] Yuyun, Nurul Hidayah, dan Supriadi Sahibu, “Algoritma Multinomial Naïve Bayes Untuk Klasifikasi Sentimen Pemerintah Terhadap Penanganan Covid-19 Menggunakan Data Twitter,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 4, hal. 820–826, 2021.
- [27] C. Shorten dan T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, 2019.