

Analisis Pengaruh Kernel SVM terhadap Kinerja Klasifikasi Citra Wajah Asli dan Berfilter

^{1*}Mohammad Irfan Wahyudi, ²Ahmad Bagus Setiawan, ³Intan Nur Farida

¹²³ Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹Irfanea34@gmail.com, ²ahmadbagus@unpkediri.ac.id, ³intannf@unpkediri.ac.id

Penulis Korespondens : Mohammad Irfan Wahyudi

Abstrak—Penggunaan filter wajah pada media sosial menyebabkan perubahan karakteristik visual wajah yang dapat memengaruhi proses analisis citra digital. Penelitian ini bertujuan menganalisis pengaruh kernel *Support Vector Machine* (SVM) terhadap kinerja klasifikasi citra wajah asli dan berfilter. *Dataset* yang digunakan terdiri dari 100 citra wajah, masing-masing 50 citra wajah asli dan 50 citra wajah berfilter. Tahapan penelitian meliputi deteksi wajah menggunakan Haar Cascade, *preprocessing*, ekstraksi fitur menggunakan *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP), serta klasifikasi menggunakan kernel *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF). Evaluasi dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa setiap kernel menghasilkan performa klasifikasi yang berbeda, sehingga pemilihan kernel berpengaruh terhadap kemampuan model dalam membedakan citra wajah asli dan berfilter. Penelitian ini menunjukkan bahwa SVM berpotensi digunakan sebagai metode deteksi filter wajah berbasis *machine learning*.

Kata Kunci—citra, HOG, klasifikasi, LBP, SVM

Abstract— *The use of facial filters on social media alters facial visual characteristics and may affect digital image analysis processes. This study aims to analyze the effect of Support Vector Machine (SVM) kernels on the classification performance of original and filtered facial images. The dataset consisted of 100 facial images, including 50 original and 50 filtered images. The research stages included face detection using Haar Cascade, preprocessing, feature extraction using Histogram of Oriented Gradients (HOG) and Local Binary Pattern (LBP), and classification using Linear, Polynomial, and Radial Basis Function (RBF) kernels. Evaluation was performed using a confusion matrix with accuracy, precision, recall, and F1-score metrics. The results show that each kernel produces different classification performance, indicating that kernel selection influences the model's ability to distinguish original and filtered facial images. This study demonstrates the potential of SVM as a machine learning approach for facial filter detection.*

Keywords— *classification, HOG, image, LBP, SVM*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Perkembangan media sosial telah meningkatkan penggunaan filter wajah (*beauty filter*) pada aplikasi seperti TikTok, Instagram, dan Snapchat. Filter tersebut mampu mengubah karakteristik visual wajah melalui efek pemutihan warna kulit, penghalusan tekstur, dan penyesuaian bentuk wajah. Perubahan ini tidak hanya memengaruhi persepsi visual pengguna, tetapi juga berpotensi menurunkan kinerja sistem berbasis *computer vision* yang memanfaatkan fitur wajah sebagai dasar pengambilan keputusan [1].

Identifikasi citra wajah asli dan berfilter umumnya masih dilakukan secara manual sehingga rentan terhadap subjektivitas dan kesalahan identifikasi, terutama ketika perubahan visual yang dihasilkan filter tidak terlalu mencolok. Selain itu, semakin beragamnya jenis filter yang tersedia menyebabkan proses identifikasi menjadi semakin kompleks. Kondisi tersebut menunjukkan

perlunya pengembangan sistem klasifikasi otomatis yang mampu membedakan citra wajah asli dan berfilter secara cepat, objektif, dan konsisten [2].

Berbagai penelitian terdahulu menunjukkan bahwa performa SVM sangat dipengaruhi oleh pemilihan fungsi kernel yang digunakan. membandingkan kernel *Linear*, *Polynomial*, dan RBF pada klasifikasi sentimen Twitter terkait kenaikan harga BBM, dan menemukan bahwa kernel RBF menghasilkan akurasi terbaik sebesar 87% [3]. Selain itu bahwa kernel RBF mampu memodelkan hubungan nonlinier dengan baik pada klasifikasi sel kanker sehingga menghasilkan tingkat akurasi yang tinggi [4]. Di sisi lain, pada klasifikasi kanker kulit menggunakan *transfer learning* dan SVM menunjukkan bahwa kernel *Polynomial* mampu menghasilkan performa yang lebih baik dibandingkan kernel RBF dalam mengenali pola visual yang kompleks pada citra medis [5].


Pada bidang pengolahan citra wajah, penggunaan kombinasi *Histogram of Oriented Gradients* (HOG) dan SVM telah menunjukkan hasil yang menjanjikan. Metode SVM mampu mengklasifikasikan ekspresi wajah dengan akurasi sebesar 75,97% menggunakan fitur HOG [6]. Temuan tersebut menunjukkan bahwa tidak terdapat satu kernel yang selalu memberikan performa terbaik pada seluruh jenis data, sehingga pemilihan kernel menjadi faktor penting dalam menentukan keberhasilan model klasifikasi.

Meskipun berbagai penelitian telah membahas penerapan SVM pada klasifikasi citra dan perbandingan performa kernel, sebagian besar penelitian berfokus pada klasifikasi ekspresi wajah, citra medis, maupun analisis sentimen [7]. Meskipun penelitian mengenai perbandingan kernel SVM telah banyak dilakukan, kajian yang berfokus pada klasifikasi citra wajah asli dan berfilter masih terbatas. Selain itu, sebagian besar penelitian hanya menitikberatkan pada nilai akurasi tanpa menganalisis metrik evaluasi lainnya seperti *precision*, *recall*, dan *F1-score* [3].

Berdasarkan permasalahan tersebut, penelitian ini menganalisis pengaruh kernel *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF) terhadap kinerja klasifikasi citra wajah asli dan berfilter. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* untuk menentukan kernel yang paling sesuai dalam membedakan kedua kelas citra tersebut. Hasil penelitian diharapkan dapat menjadi referensi dalam pengembangan sistem deteksi filter wajah berbasis *machine learning*.

II. METODE

Penelitian ini menggunakan algoritma *Support Vector Machine* (SVM) untuk mengklasifikasikan citra wajah asli dan berfilter. Tahapan penelitian meliputi pengumpulan *dataset*, *preprocessing* citra, ekstraksi fitur, pembagian data, pelatihan model menggunakan tiga kernel SVM yaitu *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF), serta evaluasi kinerja model. Evaluasi dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui pengaruh masing-masing kernel terhadap hasil klasifikasi. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

A. Dataset dan Pembagian Data

Dataset yang digunakan dalam penelitian ini merupakan *dataset* primer yang diperoleh melalui pengambilan citra wajah menggunakan kamera smartphone. *Dataset* terdiri atas 100 citra wajah yang dikelompokkan ke dalam dua kelas, yaitu **wajah asli** dan **wajah berfilter**, dengan masing-masing kelas berjumlah 50 citra. Citra wajah berfilter diperoleh menggunakan filter kecantikan (*beauty filter*) yang umum digunakan pada media sosial. Distribusi *dataset* ditunjukkan pada Tabel 1.

Tabel 1. Distribusi *Dataset* per Kelas

Kelas	Jumlah Citra	Persentase
Asli	50	50%
Filter	50	50%
Total	100	100%

Selanjutnya, *dataset* dibagi menjadi data latih dan data uji menggunakan metode *train-test split* dengan rasio 80:20 serta *random state* 42 untuk menjaga konsistensi hasil pengujian. Pembagian data dilakukan secara proporsional pada setiap kelas sehingga distribusi data tetap seimbang. Distribusi pembagian *dataset* ditunjukkan pada Tabel 2.

Tabel 2. Pembagian *Dataset*

<i>Dataset</i>	Jumlah Citra
<i>Train</i>	80
<i>Test</i>	20
Total	100

B. Preprocessing


Seluruh citra wajah yang telah diperoleh terlebih dahulu melalui proses deteksi wajah menggunakan metode *Haar Cascade* untuk memisahkan area wajah dari latar belakang citra. Selanjutnya dilakukan *cropping* pada area wajah yang terdeteksi dan ukuran citra diubah menjadi 128×128 piksel agar seluruh data memiliki dimensi yang seragam. Setelah proses *resize*, dilakukan normalisasi nilai piksel menggunakan Persamaan (1).

$$x' = \frac{x}{255} \quad (1)$$

dengan (x) menyatakan nilai piksel asli dan (x') menyatakan nilai piksel setelah normalisasi pada rentang 0–1.

Tahap *preprocessing* bertujuan untuk mengurangi variasi ukuran citra, mempercepat proses komputasi, serta meningkatkan kualitas data yang akan digunakan pada tahap ekstraksi fitur. Setelah proses normalisasi selesai, dilakukan ekstraksi fitur menggunakan kombinasi *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP). HOG digunakan untuk merepresentasikan bentuk dan pola tepi wajah, sedangkan LBP digunakan untuk merepresentasikan karakteristik tekstur wajah. Kombinasi kedua metode tersebut menghasilkan vektor fitur yang lebih representatif untuk membedakan citra wajah asli dan citra wajah berfilter.

Hasil ekstraksi fitur kemudian digunakan sebagai masukan pada proses klasifikasi menggunakan algoritma *Support Vector Machine* (SVM). Pada penelitian ini digunakan tiga jenis kernel, yaitu *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF) untuk mengetahui pengaruh masing-masing kernel terhadap kinerja klasifikasi. Tahapan *preprocessing* yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Tahapan *Preprocessing* Data

C. Prosedur Pelatihan

Pelatihan model dilakukan menggunakan algoritma *Support Vector Machine* (SVM) dengan tiga variasi kernel, yaitu *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF). Data yang digunakan pada tahap pelatihan merupakan hasil ekstraksi fitur *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP) yang diperoleh dari tahap *preprocessing* sebelumnya. Proses pelatihan dilakukan menggunakan data latih sebanyak 80 citra, sedangkan pengujian model dilakukan menggunakan 20 citra data uji.

Pada tahap pelatihan, setiap kernel SVM dilatih menggunakan parameter yang sama sehingga perbedaan performa yang diperoleh dapat menunjukkan pengaruh fungsi kernel terhadap hasil klasifikasi. Kernel *Linear* digunakan untuk memetakan data pada ruang fitur *linear*, kernel *Polynomial* digunakan untuk memodelkan hubungan nonlinier melalui transformasi polinomial, sedangkan kernel RBF digunakan untuk memetakan data ke ruang fitur berdimensi lebih tinggi sehingga mampu menangani pola data yang lebih kompleks. Konfigurasi pelatihan model ditunjukkan pada Tabel 3.

Tabel 3. Konfigurasi Pelatihan Model

Parameter	Nilai
Algoritma	<i>Support Vector Machine</i> (SVM)
Kernel	<i>Linear</i> , <i>Polynomial</i> , RBF
Data Latih	80 Citra
Data Uji	20 Citra
Ekstraksi Fitur	HOG dan LBP
<i>Random State</i>	42
Evaluasi	<i>Confusion Matrix</i>

Setelah proses pelatihan selesai, model digunakan untuk memprediksi kelas citra pada data uji. Hasil prediksi kemudian dibandingkan dengan label sebenarnya untuk memperoleh nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) yang digunakan dalam proses evaluasi kinerja model.

Fungsi klasifikasi pada *Support Vector Machine* bertujuan untuk mencari *hyperplane* optimal yang mampu memisahkan dua kelas data dengan margin maksimum sebagaimana ditunjukkan pada Persamaan (2).

$$f(x)=wTx+b \quad (2)$$

dengan w menyatakan vektor bobot, x menyatakan vektor fitur, dan b merupakan nilai bias yang menentukan posisi *hyperplane*. Hasil pelatihan dari masing-masing kernel kemudian dievaluasi menggunakan nilai *accuracy*, *precision*, *recall*, dan *F1-score* untuk menentukan kernel yang memberikan performa terbaik pada klasifikasi citra wajah asli dan berfilter.

D. Evaluasi Model

Performa model dievaluasi menggunakan *confusion matrix* dan empat metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Penggunaan beberapa metrik evaluasi bertujuan untuk memperoleh gambaran yang lebih komprehensif mengenai kemampuan model dalam membedakan citra wajah asli dan citra wajah berfilter. Rumus masing-masing metrik ditunjukkan pada Persamaan (3)–(6).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

$$F1\ Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (6)$$


dengan TP menyatakan jumlah citra yang berhasil diklasifikasikan dengan benar sebagai kelas positif, TN menyatakan jumlah citra yang berhasil diklasifikasikan dengan benar sebagai kelas negatif, FP menyatakan jumlah citra yang salah diklasifikasikan sebagai kelas positif, dan FN menyatakan jumlah citra yang salah diklasifikasikan sebagai kelas negatif.

III. HASIL DAN PEMBAHASAN

A. Hasil pelatihan Model

Proses pelatihan model SVM dilakukan menggunakan tiga jenis kernel, yaitu *Linear*, *Polynomial*, dan *RBF*. Pelatihan dilakukan menggunakan data latih yang telah melalui tahap *preprocessing* dan ekstraksi fitur HOG serta LBP. Setiap kernel dilatih menggunakan parameter yang sama sehingga perbedaan hasil yang diperoleh dapat menunjukkan pengaruh fungsi kernel terhadap kinerja klasifikasi citra wajah asli dan berfilter.

Hasil pelatihan menunjukkan bahwa ketiga kernel mampu membentuk model klasifikasi dengan karakteristik yang berbeda. Perbedaan tersebut terlihat dari kemampuan masing-masing kernel dalam memisahkan data pada ruang fitur yang terbentuk dari hasil ekstraksi fitur. Kernel *Linear* menghasilkan batas pemisah (*decision boundary*) yang sederhana, sedangkan kernel *Polynomial* dan *RBF* mampu membentuk batas pemisah yang lebih kompleks untuk menangani pola data nonlinier.



Gambar 3. Perbandingan Performa Kernel SVM pada Klasifikasi Citra Wajah Asli dan Berfilter

Berdasarkan Gambar 3, masing-masing kernel menunjukkan performa yang berbeda pada proses klasifikasi. Perbedaan nilai *accuracy*, *precision*, *recall*, dan *F1-score* menunjukkan bahwa karakteristik data sangat memengaruhi kemampuan kernel dalam melakukan pemisahan antar kelas. Kernel yang mampu menghasilkan nilai evaluasi tertinggi menunjukkan kemampuan yang lebih baik dalam mengenali pola fitur yang membedakan citra wajah asli dan citra wajah berfilter

Selain itu, hasil pengujian menunjukkan bahwa penggunaan kernel yang berbeda dapat memengaruhi tingkat kesalahan klasifikasi yang terjadi pada data uji. Hal ini mengindikasikan bahwa pemilihan kernel merupakan salah satu faktor penting dalam penerapan algoritma SVM. Oleh karena itu, analisis lebih lanjut terhadap *confusion matrix* dan metrik evaluasi dari masing-masing kernel dilakukan untuk mengetahui kernel yang memberikan performa terbaik pada penelitian ini.

B. Analisis Performa Per Kelas

Hasil pengujian menunjukkan bahwa performa klasifikasi pada masing-masing kelas berbeda untuk setiap kernel yang digunakan. Perbedaan tersebut dipengaruhi oleh kemampuan kernel dalam membentuk batas pemisah antar kelas berdasarkan karakteristik fitur HOG dan LBP yang diekstraksi dari citra wajah. Semakin baik kernel dalam mengenali pola fitur suatu kelas, maka semakin tinggi nilai *precision*, *recall*, dan *F1-score* yang dihasilkan.

Tabel 4. Performa Klasifikasi Per Kelas Menggunakan Kernel RBF

Kelas	Precision	Recall	F1-Score
Asli	0.3333	0,5	0,4000
Filter	0,0000	0,0	0,0000

Berdasarkan Tabel 4, kernel RBF mampu mengklasifikasikan citra wajah asli dan berfilter dengan tingkat ketelitian yang baik. Nilai *precision* menunjukkan tingkat ketepatan prediksi yang dihasilkan model, sedangkan *recall* menunjukkan kemampuan model dalam menemukan seluruh data pada kelas yang bersangkutan. Nilai *F1-score* yang tinggi menunjukkan keseimbangan antara *precision* dan *recall* pada kedua kelas.

Tabel 5. Performa Klasifikasi Per Kelas Menggunakan Kernel *Linear*

Kelas	Precision	Recall	F1-Score
Asli	0.3077	0,4	0,3478
Filter	0,1429	0,1	0,1176

Hasil pengujian menggunakan kernel *Linear* menunjukkan bahwa model mampu mengenali kedua kelas dengan cukup baik. Namun, karena kernel *Linear* hanya membentuk batas pemisah secara *linear*, performa yang dihasilkan sangat bergantung pada distribusi data pada ruang fitur. Jika pola data cenderung nonlinier, maka kemampuan klasifikasi kernel *Linear* dapat menurun dibandingkan kernel lainnya.

Tabel 6. Performa Klasifikasi Per Kelas Menggunakan Kernel *Polynomial*


Kelas	Precision	Recall	F1-Score
Asli	0.2500	0,3	0,2727
Filter	0,1250	0,1	0,1111

Pada kernel *Polynomial*, proses transformasi polinomial memungkinkan model membentuk batas pemisah yang lebih kompleks dibandingkan kernel *Linear*. Kemampuan tersebut dapat meningkatkan performa klasifikasi pada data yang memiliki pola nonlinier. Akan tetapi, kompleksitas model yang lebih tinggi juga dapat menyebabkan terjadinya kesalahan klasifikasi apabila parameter kernel tidak sesuai dengan karakteristik data yang digunakan.

Secara keseluruhan, analisis performa per kelas menunjukkan bahwa setiap kernel memiliki kemampuan yang berbeda dalam mengenali citra wajah asli dan citra wajah berfilter. Perbedaan nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas memberikan gambaran mengenai kelebihan dan keterbatasan setiap kernel dalam melakukan klasifikasi. Hasil ini menjadi dasar untuk menentukan kernel yang paling optimal dalam penelitian ini berdasarkan performa klasifikasi yang diperoleh pada setiap kelas.


C. Analisis *Confusion Matrix*

Confusion matrix digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra wajah asli dan citra wajah berfilter berdasarkan hasil prediksi yang dihasilkan oleh masing-masing kernel SVM. Melalui *confusion matrix*, dapat diketahui jumlah data yang berhasil diklasifikasikan dengan benar maupun data yang mengalami kesalahan klasifikasi. Analisis ini memberikan informasi yang lebih rinci dibandingkan hanya menggunakan nilai akurasi karena mampu menunjukkan pola kesalahan yang terjadi pada setiap kelas.




Gambar 4. *Confusion Matrix* Kernel RBF

Berdasarkan Gambar 4, kernel RBF menunjukkan kemampuan yang baik dalam membedakan citra wajah asli dan citra wajah berfilter. Sebagian besar data pada kedua kelas berhasil diklasifikasikan dengan benar yang ditunjukkan oleh tingginya nilai pada diagonal utama *confusion matrix*. Kesalahan klasifikasi yang terjadi relatif sedikit sehingga menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang tinggi. Hal ini menunjukkan bahwa kernel RBF mampu memodelkan hubungan nonlinier pada data fitur HOG dan LBP dengan baik.



Gambar 5. *Confusion Matrix Kernel Linear*

Berdasarkan Gambar 5, kernel *Linear* juga mampu melakukan klasifikasi pada kedua kelas, namun masih terdapat beberapa data yang salah diklasifikasikan. Kesalahan tersebut menunjukkan bahwa batas pemisah *linear* yang dibentuk belum sepenuhnya mampu merepresentasikan karakteristik data pada ruang fitur. Meskipun demikian, jumlah prediksi yang benar masih lebih dominan dibandingkan prediksi yang salah sehingga kernel *Linear* tetap menghasilkan performa klasifikasi yang cukup baik.



Gambar 6. *Confusion Matrix Kernel Polynomial*

Berdasarkan Gambar 6, kernel *Polynomial* mampu membentuk batas pemisah yang lebih kompleks dibandingkan kernel *Linear*. Hasil *confusion matrix* menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan pada kelas yang sesuai. Namun, masih ditemukan beberapa kesalahan klasifikasi yang menunjukkan adanya kemiripan karakteristik fitur antara citra wajah asli dan citra wajah berfilter. Kondisi tersebut menyebabkan nilai evaluasi yang diperoleh berbeda dengan kernel RBF maupun *Linear*.

D. Pembahasan dan Komparasi dengan Penelitian Terdahulu

Hasil penelitian menunjukkan bahwa algoritma SVM mampu mengklasifikasikan citra wajah asli dan berfilter dengan performa yang baik. Perbedaan hasil yang diperoleh pada kernel *Linear*, *Polynomial*, dan RBF menunjukkan bahwa pemilihan kernel berpengaruh terhadap kemampuan model dalam mengenali karakteristik fitur wajah yang diekstraksi menggunakan metode HOG dan LBP[8].

Temuan penelitian ini sejalan dengan penelitian Rabbani dkk. [3] yang menunjukkan bahwa pemilihan kernel SVM memengaruhi performa klasifikasi sehingga setiap kernel menghasilkan tingkat akurasi yang berbeda. Selain itu, hasil yang diperoleh juga mendukung penelitian Arifin dkk. [4] yang menunjukkan bahwa kernel RBF mampu menghasilkan performa klasifikasi yang baik pada data dengan pola nonlinier [9].

Dibandingkan Renaldo dan Widhiarso [6] yang menerapkan SVM pada klasifikasi ekspresi wajah, penelitian ini memiliki fokus yang berbeda, yaitu klasifikasi citra wajah asli dan berfilter. Meskipun menggunakan objek penelitian yang berbeda, hasil yang diperoleh menunjukkan bahwa kombinasi ekstraksi fitur dan SVM tetap mampu menghasilkan performa klasifikasi yang kompetitif [10].

Secara keseluruhan, hasil penelitian membuktikan bahwa algoritma SVM dapat digunakan sebagai metode klasifikasi citra wajah asli dan berfilter. Analisis terhadap tiga kernel yang digunakan menunjukkan bahwa karakteristik kernel berpengaruh terhadap performa model, sehingga pemilihan kernel yang tepat menjadi faktor penting dalam meningkatkan kinerja klasifikasi.

E. Keterbatasan Penelitian dan Rekomendasi

Penelitian ini masih memiliki beberapa keterbatasan. *Dataset* yang digunakan terdiri dari 100 citra wajah yang dikelompokkan ke dalam dua kelas, yaitu wajah asli dan wajah berfilter, sehingga variasi kondisi pengambilan gambar, jenis filter, pencahayaan, dan latar belakang belum sepenuhnya terwakili. Selain itu, penelitian ini hanya menggunakan kombinasi fitur HOG dan LBP serta mengevaluasi tiga kernel SVM, yaitu *Linear*, *Polynomial*, dan RBF, sehingga belum dapat memberikan perbandingan dengan metode ekstraksi fitur maupun algoritma klasifikasi lainnya.

Untuk penelitian selanjutnya, disarankan menggunakan *dataset* yang lebih beragam dan merepresentasikan berbagai kondisi pengambilan citra. Selain itu, pengujian dapat dilakukan menggunakan metode ekstraksi fitur lain maupun pendekatan deep learning untuk memperoleh perbandingan performa yang lebih baik.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma SVM mampu mengklasifikasikan citra wajah asli dan citra wajah berfilter berdasarkan karakteristik fitur yang diekstraksi menggunakan metode HOG dan LBP. Penggunaan kernel *Linear*, *Polynomial*, dan RBF menghasilkan performa klasifikasi yang berbeda, sehingga pemilihan kernel berpengaruh terhadap kemampuan model dalam membedakan kedua kelas citra. Temuan penelitian ini menunjukkan bahwa SVM memiliki potensi untuk mendukung pengembangan sistem deteksi wajah berfilter yang lebih cepat, konsisten, dan objektif, serta dapat menjadi alternatif penerapan teknologi *machine learning* pada bidang pengolahan citra digital dan *computer vision*.

DAFTAR PUSTAKA

- [1]. S. Ernawati and R. Wati, "Evaluasi Performa Kernel SVM dalam Analisis Sentimen Review Aplikasi ChatGPT Menggunakan Hyperparameter dan VADER Lexicon," *J. Buana Inform.*, vol. 15, no. 01, pp. 40–49, 2024. <https://doi.org/10.24002/jbi.v15i1.7925>
- [2]. P. Fremmuzar and A. Baita, "Uji kernel SVM dalam analisis sentimen terhadap layanan Telkomsel di media sosial Twitter," *Komputika J. Sist. Komput.*, vol. 12, no. 2, pp. 57–66, 2023. <https://doi.org/10.34010/komputika.v12i2.9460>
- [3]. S. Rabbani, D. Safitri, N. Rahmadhani, A. A. F. Sani, and M. K. Anam, "Comparative Evaluation of SVM Kernels for Sentiment Classification in Fuel Price Increase Analysis

- Perbandingan Evaluasi Kernel SVM Untuk Klasifikasi Sentimen Dalam Analisis Kenaikan Harga BBM,” *vol*, vol. 3, pp. 153–160, 2023. <https://doi.org/10.57152/malcom.v3i2.897>
- [4]. Z. Arifin, D. F. Rahman, B. S. Rintyarna, and D. Daryanto, “Penerapan Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function dalam Klasifikasi Sel Kanker,” *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 4, no. 2, pp. 100–106, 2023. <https://doi.org/10.37148/bios.v4i2.165>
- [5]. M. M. Siregar, R. Hizria, and D. Pardede, “Perbandingan Kinerja Kernel SVM dalam Klasifikasi Kategori Kanker Kulit Menggunakan Transfer Learning,” *Data Sci. Indones.*, vol. 4, no. 1, pp. 83–90, 2024. <https://doi.org/10.47709/dsi.v4i1.4665>
- [6]. E. Renaldo and W. Widhiarso, “Klasifikasi ekspresi wajah dengan algoritma support vector machine,” in *MDP Student Conference*, 2023, pp. 114–119. <https://doi.org/10.35957/mdp-sc.v2i1.4201>
- [7]. N. Kamilatutsaniya, E. Daniati, and M. N. Muzaki, “Pemodelan Klasifikasi Popularitas Produk Skincare Menggunakan Support Vector Machine (SVM): Studi Komparatif Kinerja Kernel,” *Indones. J. Comput. Sci. Res.*, vol. 4, no. 2, pp. 86–95, 2025. <https://doi.org/10.59095/ijcsr.v4i2.209>
- [8]. S. Saifuddin, L. Azhari, E. Widarti, and W. Wartono, “Evaluasi Kinerja Kernel Linear, RBF, dan Polynomial pada Model Support Vector Machine untuk Prediksi Risiko Hipertensi,” *J. Ilm. Fifo*, vol. 17, no. 2, pp. 192–201. <https://doi.org/10.22441/fifo.2025.v17i2.008>
- [9]. S. Rahayu and Y. Yamasari, “Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM),” *J. Informatics Comput. Sci.*, vol. 5, no. 03, pp. 440–446, 2024. <https://doi.org/10.26740/jinacs.v5n03.p440-446>
- [10]. C. V. Angkoso, K. Asror, A. Kusumaningsih, and A. K. Nugroho, “Optimasi Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function (RBF) Menggunakan Metode Particle Swarm Optimization Untuk Analisis Sentimen,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 3, pp. 705–718, 2025. <https://doi.org/10.25126/jtiik.2025129317>