

# Pengaruh *Histogram of Oriented Gradients* Dan *Principal Component Analysis* Terhadap Kinerja *Support Vector Machine* Untuk Deteksi Citra Jalan Berlubang

Hanifatus Sa'diyah Widihasaniputri <sup>1)</sup>\*, Hamid Muhammad Jumasa <sup>2)</sup>, Indri Nurtiyani Hakim <sup>3)</sup>\*

Universitas Muhammadiyah Purworejo <sup>1,2,3)</sup>,  
[hanifatus@umpwr.ac.id](mailto:hanifatus@umpwr.ac.id) <sup>1)</sup>\*, [hamidjumasa@umpwr.ac.id](mailto:hamidjumasa@umpwr.ac.id) <sup>2)</sup>\*, [indri@umpwr.ac.id](mailto:indri@umpwr.ac.id) <sup>3)</sup>\*

## Abstrak

Kerusakan jalan seperti lubang dan permukaan yang tidak rata menjadi salah satu hambatan utama dalam mewujudkan konsep *smart city* yang menekankan efisiensi, keselamatan, dan keberlanjutan. Deteksi lubang jalan yang masih dilakukan secara manual bergantung pada pengamatan manusia, sehingga prosesnya subjektif, memakan waktu, dan kurang efisien. Penelitian ini mengusulkan pendekatan berbasis computer vision dengan mengombinasikan tiga metode, yaitu *Histogram of Oriented Gradients* (HOG) sebagai teknik ekstraksi fitur, *Principal Component Analysis* (PCA) untuk reduksi dimensi, dan *Support Vector Machine* (SVM) sebagai algoritma klasifikasi. Dataset penelitian terdiri atas 681 citra yang diperoleh dari sumber publik Kaggle, kemudian diperluas melalui proses augmentasi menjadi 5.448 citra. HOG digunakan untuk menangkap pola gradien lokal dari setiap gambar, sementara PCA membantu menyederhanakan fitur agar perhitungan lebih cepat dan efisien. Selanjutnya, model SVM digunakan untuk mengklasifikasikan citra jalan normal dan berlubang, dengan evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil eksperimen menunjukkan peningkatan akurasi dari 85,32% menjadi 91,93%, serta peningkatan sekitar 7% pada *precision*, *recall*, dan *F1-score*. Hasil ini membuktikan bahwa kombinasi HOG–PCA–SVM efektif meningkatkan akurasi deteksi jalan berlubang secara otomatis, efisien, dan mendukung penerapan *smart city* yang berkelanjutan.

**Kata kunci:** Deteksi Lubang Jalan, *Histogram of Oriented Gradients*, *Principal Component Analysis*

## Abstract

*[The Effect of Histogram of Oriented Gradients and Principal Component Analysis on the Performance of Support Vector Machine for Pothole Image Detection]* Road damages such as potholes and uneven surfaces pose major obstacles to realizing the *smart city* concept, which emphasizes efficiency, safety, and sustainability. Pothole detection, which is still largely conducted manually, relies on human observation, making the process subjective, time-consuming, and inefficient. This study proposes a computer vision-based approach that combines three methods: *Histogram of Oriented Gradients* (HOG) for feature extraction, *Principal Component Analysis* (PCA) for dimensionality reduction, and *Support Vector Machine* (SVM) as the classification algorithm. The dataset consists of 681 images obtained from the public Kaggle repository, which were augmented to 5,448 images. HOG was used to capture local gradient patterns from each image, while PCA simplified the features to make computations faster and more efficient. The SVM model was then employed to classify normal and pothole road images, with evaluation metrics including *accuracy*, *precision*, *recall*, and *F1-score*. Experimental results showed an accuracy improvement from 85.32% to 91.93%, along with approximately a 7% increase in *precision*, *recall*, and *F1-score*. These findings demonstrate that the combination of HOG–PCA–SVM effectively enhances automatic pothole detection accuracy and efficiency, supporting the implementation of a sustainable *smart city*.

**Keywords:** Pothole Detection, *Histogram of Oriented Gradients*, *Principal Component Analysis*

## 1. PENDAHULUAN

Wilayah perkotaan saat ini mengalami rekonstruksi baru yang melahirkan konsep *smart city*[1]. Konsep *smart city* memadukan konsep infrastruktur modern, konektivitas yang stabil dan

sistem pengelolaan yang cerdas untuk meningkatkan kualitas hidup masyarakat [2][3]. *Smart city* mampu mengoptimalkan sumber daya, menyelaraskan sistem transportasi, dan meningkatkan kualitas pelayanan masyarakat[4][5].

Kerusakan infrastruktur jalan menjadi tantangan terhadap konsep *smart city*. Kerusakan lubang dan permukaan jalan tidak rata menjadikan jalan licin dan berbahaya. Lubang jalan terjadi akibat buruknya kualitas material yang menyebabkan genangan air[6]. Lubang jalan tidak hanya membahayakan keselamatan, tetapi juga meningkatkan biaya perawatan kendaraan, konsumsi bahan bakar, waktu tempuh, serta mempercepat kerusakan ban [7][8]. Sementara itu, berdampak pula di sektor lingkungan, meningkatkan emisi karbon dioksida[9]. Oleh karena itu, perbaikan dan perawatan jalan diperlukan untuk menjaga keamanan dan mengurangi dampak ekonomi dan lingkungan[10].

Cara umum deteksi lubang jalan adalah pemeriksaan visual secara manual oleh insinyur [11]. Pemerintah dari berbagai negara mulai mengalokasikan dana khusus untuk mendeteksi kerusakan jalan[12]. Pemerintah Inggris menganggarkan lebih dari 5 miliar poundsterling atau setara dengan 108,77 triliun rupiah untuk perbaikan jalan hingga tahun 2025[9]. Di San Diego, AS, lebih dari 30.000 lubang diperbaiki setiap tahun. Meskipun demikian, deteksi lubang jalan secara manual memiliki banyak kelemahan seperti memakan waktu, biaya, dan kurang efisien. Selain itu, cara ini sangat bergantung pada penilaian dan pengalaman individu[13][14].

Deteksi otomatis berbasis *computer vision* menjadi salah satu solusi deteksi jalan secara manual, sehingga hemat biaya, meningkatkan keselamatan, dan menjaga kualitas jalan [14]. Perkembangan teknologi *computer vision* dan *machine learning* memicu munculnya berbagai metode deteksi jalan berlubang yang lebih akurat dan efisien. [15].

*Support Vector Machine* adalah model *machine learning* yang populer dan digunakan untuk klasifikasi. SVM bekerja dengan mencari *hyperplane* yang memisahkan titik-titik antar kelas di ruang fitur, dengan menghitung jarak (*margin*) terbesar antara *hyperplane* dengan titik terdekatnya [16][17][18]. Pada konteks analisis sentimen, SVM terbukti unggul dengan akurasi mencapai 96,2%. Model SVM juga efektif untuk dimensi tinggi dan sering digunakan pada pengenalan citra dan deteksi penyakit tanaman[19][20][21]. Meskipun SVM memiliki banyak keunggulan, kebutuhan penyimpanan yang besar dan beban komputasi yang tinggi menjadi tantangan. Pelatihan SVM pada dataset yang besar dan berdimensi tinggi memerlukan kapasitas penyimpanan yang signifikan[22][23] dan beban komputasi yang besar, baik pada fase pelatihan maupun prediksi[22][24][23]. Hal ini disebabkan kompleksitas algoritma yang tinggi dan kebutuhan memori yang besar untuk menyimpan matriks kernel[25][26]. Solusi mengatasi tantangan ini menggunakan teknik reduksi dimensi untuk mengurangi jumlah fitur. Hal ini akan mengurangi beban komputasi dan risiko overfitting [22].

*Principal Component Analysis* (PCA) menjadi teknik reduksi dimensi yang umum digunakan. PCA membantu mengurangi dimensi fitur gambar, sehingga

mempercepat proses pelatihan dan meningkatkan kinerja model *Support Vector Machine* (SVM)[27][28][29]. Metode PCA mereduksi dimensi data gambar melalui tiga tahapan utama. Tahapan pertama, ekstraksi fitur penting dengan menghitung *eigenfaces* dari matriks kovarians gambar pelatihan[30][31]. Kedua, menghapus informasi redundan. PCA membantu menghilangkan korelasi antara variabel statistik dan mempertahankan informasi yang diperlukan[32][33]. Ketiga, peningkatan akurasi dan kecepatan. PCA mengurangi jumlah variabel yang harus diproses, sehingga meningkatkan akurasi dan kecepatan deteksi[30][34].


Efektifitas PCA untuk reduksi dimensi sejalan dengan [35] yang menggabungkan teknik *Local Binary Patterns* (LBP) dengan PCA dan SVM untuk mendeteksi dan mengklasifikasikan retakan pada jalan. Dimensi fitur LBP yang besar disederhanakan menggunakan PCA, meningkatkan akurasi model mencapai 91,91%, yang 6,6% lebih tinggi. Studi [29] memperkuat temuan yang menunjukkan akurasi hingga 99%. Hal ini menunjukkan bahwa PCA secara signifikan meningkatkan kinerja SVM pada aplikasi deteksi citra. PCA terbukti efektif pada deteksi kerusakan mesin [36] dengan mengolah data berdimensi tinggi lebih efisien dibanding SVM tanpa reduksi dimensi. [37] mengeksplorasi CNN untuk mengidentifikasi malaria secara otomatis, akurasi mencapai 91,79% pada data uji.

Upaya untuk meningkatkan hasil deteksi, salah satu strategi yang efisien adalah mengintegrasikan beberapa jenis ekstraksi fitur objek secara spesifik[38][39]. Ekstraksi fitur menggunakan teknik *Histogram of Oriented Gradients* (HOG). HOG memanfaatkan intensitas gradien untuk mengekstraksi fitur lokal dari suatu objek, yang selanjutnya digunakan untuk pengolahan citra[40][41]. Penelitian ini akan melihat pengaruh ekstraksi fitur HOG dan metode reduksi dimensi PCA terhadap model klasifikasi SVM.

## 2. BAHAN DAN METODE

### 2.1 Kerangka dan Tahapan Penelitian

Penelitian diawali dengan studi literatur yang melihat adanya tantangan SVM membutuhkan penyimpanan yang besar dan beban komputasi yang tinggi. Penelitian ini bertujuan melihat pengaruh ekstraksi fitur HOG dan metode reduksi dimensi PCA terhadap model klasifikasi SVM. Setiap tahapan penelitian dijabarkan secara sistematis pada gambar 1 mulai dari identifikasi masalah hingga analisis hasil penelitian.



Gambar 1. Tahapan Penelitian

Gambar 1 merupakan tahapan penelitian yang telah dilakukan.

### 2.1.1 Identifikasi Masalah

Permasalahan yang menjadi sorotan penelitian ini adalah bagaimana meningkatkan kinerja SVM melalui ekstraksi fitur HOG dan metode reduksi dimensi PCA.

### 2.1.2 Pengumpulan Data

Penelitian ini diawali dengan pengumpulan data sekunder melalui dataset publik kaggle yang disusun oleh Atulya Kumar melalui tautan <https://www.kaggle.com/atulyakumar98/datasets>. Data set terdiri dari 681 citra dengan ekstensi setiap citra adalah ".jpg". Tabel 1 menyajikan detail dataset citra dan detail nama kelas pada citra jalan berlubang dan jalan normal.

**Tabel 1** Detail Dataset

| Nama Kelas | Gambar Citra                                                                       |
|------------|------------------------------------------------------------------------------------|
| Potholes   |   |
| Normal     |  |

### 2.1.3 Preprocessing Data

Untuk mengoptimalkan tahap pemodelan, diperlukan tahap *preprocessing data* sehingga model klasifikasi menghasilkan kinerja yang baik. Tahapan *preprocessing* meliputi:

1. Resizing : tahapan gambar di ubah ke ukuran 224x224 piksel untuk menyamakan ukuran citra agar seragam
2. Augmentasi : dilakukan peningkatan variasi data agar data lebih beragam tanpa perlu tambahan data baru[42][43]. Proses augmentasi data dilakukan dengan menerapkan 7 transformasi, yaitu rotasi +15° dan -15°, flip vertikal, shear, Gaussian blur, warp shift, dan peningkatan kecerahan. Setiap gambar asli menghasilkan tujuh versi tambahan, sehingga jumlah data meningkat delapan kali lipat menjadi 5448 citra.
3. Normalisasi Piksel: Untuk mempercepat proses pelatihan dan stabilitas model[44], nilai piksel dinormalisasi ke skala 0 sampai 1 sehingga akurasi klasifikasi dapat meningkat

### 2.1.4 Ekstraksi Fitur HOG

*Histogram of Oriented Gradients* (HOG) berfokus pada penggambaran objek secara lokal dengan memanfaatkan arah dan intensitas gradien dari sebuah gambar. Prinsip kerja HOG didasarkan pada asumsi bahwa bentuk dan struktur objek dapat dikenali melalui pola distribusi arah gradien intensitas atau kontur, tanpa perlu mengetahui posisi gradien secara spesifik. Metode ini membentuk deskripsi citra melalui histogram orientasi gradien pada area-area lokal, yang

menggambarkan seberapa sering arah gradien tertentu muncul di setiap bagian gambar.[40], [41]

### 2.1.5 Evaluasi Model

Evaluasi dilakukan dengan menggunakan confusion matrix untuk melihat sebaran model dalam melakukan prediksi yang didalamnya mencakup berapa jumlah benar prediksi dan jenis kesalahan yang dilakukan. Selain *confusion matrix*, evaluasi dilakukan menggunakan metrik seperti akurasi, presisi, recall, dan F1-score untuk menilai kinerja model klasifikasi.

### 2.1.6 Analisis dan Pembahasan

Analisis dan pembahasan difokuskan pada kinerja SVM sebelum dan sesudah penerapan PCA, serta perbandingan dengan CNN VGG16 dan Logistic Regression melalui evaluasi metrik yang dilakukan.

### 2.2 Principal Component Analysis

*Principal Component Analysis* (PCA) dikenal dengan metode statistik multivariat yang efektif untuk menangani data dimensi tinggi dengan mengekstraksi fitur utama, sehingga mempercepat proses pelatihan model neural network[45][46][47].

Dataset berukuran  $n \times m$  dengan  $n$  sebagai observasi dan  $m$  sebagai variabel. Pada PCA, langkah awal menghitung matriks kovarians menggunakan persamaan (1), Menentukan nilai eigen dan eigenvector dari matrik kovarians menggunakan persamaan (2) dan (3). Menghitung kontribusi varians dan kontribusi kumulatif tiap komponen utama berdasarkan nilai eigen dengan persamaan (4) dan (5)[48][49].

$$\text{Cov}(x_j, x_k) = \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)}{n-1} \quad (1)$$

$$\det(C - \lambda I) = 0 \quad (2)$$

$$(C - \lambda I) = 0 \quad (3)$$

$$p_l = \frac{\lambda_l}{\sum_{l=1}^m \lambda_l} \text{ dimana } l < m, \lambda_1 > \lambda_2 > \dots > \lambda_m \quad (4)$$

$$pk = \sum_{l=1}^m p_l \quad (5)$$

### 2.3 Support Vector Machine

Pendekatan *Structural Risk Minimization* (SRM) menjadi landasan pada model SVM. Cara kerja SVM mencari garis pemisah (*hyperplane*) terbaik yang memisahkan dua kelas pada ruang input. Untuk menemukannya, SVM menghitung margin, yaitu jarak antara data terdekat dari masing-masing kelas ke *hyperplane* menggunakan persamaan (6) [50][51].

$$f(x_d) = \sum_{i=1}^n \alpha_i y_i x_i d + b \quad (6)$$

### 2.4 Confusion Matrix

Fokus *confusion matrix* untuk mengevaluasi hasil klasifikasi model berdasarkan nilai *accuracy*, *precision*, *recall*, dan *f1-score*. Hal ini menunjukkan seberapa baik model mampu mengenali jalan berlubang dengan tepat. *Confusion matrix* sering digunakan untuk pengolahan citra karena kemampuannya memberikan gambaran menyeluruh mengenai performa model [52]. Perhitungan metrik pada *confusion matrix*, seperti *accuracy*, *precision*, *recall*, dan *f1-score*, didasarkan pada empat elemen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) [53].

1. *Accuracy* mengevaluasi seberapa banyak prediksi model yang benar dari seluruh prediksi yang dilakukan oleh model.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. *Precision* menjelaskan perbandingan jumlah deteksi positif yang benar (*True Positives*) dengan total prediksi positif (*True Positives* + *False Positives*).

$$Precision = \frac{TP}{TP + FP}$$

3. *Recall* menggambarkan perbandingan antara jumlah deteksi positif yang benar (*True Positives*) dengan total data positif sebenarnya (*True Positives* + *False Negatives*).

$$Recall = \frac{TP}{TP + FN}$$

4. *F1-Score* adalah nilai gabungan dari *Precision* dan *Recall* yang digunakan untuk menilai keseimbangan antara keduanya.

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Evaluasi Model Support Vector Machine (SVM)

Evaluasi awal dilakukan pada model *Support Vector Machine* (SVM) untuk deteksi citra jalan berlubang. Pada evaluasi awal model, digunakan data asli yang belum diseimbangkan atau belum di terapkan teknik ekstraksi fitur *Histogram of Oriented Gradients* (HOG) dan teknik dimensi reduksi *Principal Component Analysis* (PCA). Secara ringkas, Tabel 2 menyajikan hasil kinerja model klasifikasi SVM menggunakan *Confusion matrix*.

**Tabel 2.** *Confusion Matrix* Model SVM

| Model | <i>Confusion Matrix</i> |     |    |    |
|-------|-------------------------|-----|----|----|
|       | TP                      | TN  | FP | FN |
| SVM   | 454                     | 476 | 87 | 73 |

Berdasarkan *confusion matrix* pada tabel 2, model SVM berhasil mengenali 454 citra lubang jalan secara benar (*True Positive*) dan 476 citra jalan normal secara tepat (*True Negative*). Namun, masih terdapat 87 citra jalan normal yang salah diklasifikasikan sebagai lubang jalan (*False Positive*) serta 73 citra lubang jalan yang tidak terdeteksi dan diklasifikasikan sebagai jalan normal (*False Negative*). Hasil ini menunjukkan bahwa meskipun model SVM memiliki kemampuan klasifikasi yang cukup baik, namun masih terjadi kesalahan deteksi terutama pada kondisi citra dengan tekstur atau pencahayaan yang mirip antara jalan berlubang dan jalan normal.

Setelah dilakukan evaluasi terhadap *confusion matrix*, selanjutnya dilakukan evaluasi terhadap metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Tabel 3 menyajikan perbandingan matrik evaluasi model.

**Tabel 3.** Perbandingan Matrik Evaluasi Model

| Mode<br>l | Metrik Evaluasi      |                  |               |                      |
|-----------|----------------------|------------------|---------------|----------------------|
|           | <i>Accura<br/>cy</i> | <i>Precision</i> | <i>Recall</i> | <i>F1-<br/>Score</i> |
| SVM       | 0.85                 | 0.87             | 0.85          | 0.86                 |

Tabel 3 menunjukkan evaluasi kinerja model *Support Vector Machine* (SVM) berdasarkan *accuracy* (akurasi), *precision*, *recall*, dan *F1-score*. Dari metrik tersebut menunjukkan performa yang konsisten dan akurat terhadap deteksi citra jalan normal dan citra jalan berlubang. Akurasi model sebesar 0.85 berarti 85% citra diklasifikasikan dengan benar, sementara *precision* 0.87 menunjukkan 87% dari prediksi positif adalah benar; *recall* 0.85 berarti 85% kasus positif yang ada berhasil dideteksi. *F1-score* 0.86 menekankan adanya keseimbangan yang baik antara kemampuan model mendeteksi dan meminimalisir kesalahan klasifikasi.

#### 3.2 Analisis Keterbatasan Model SVM

Meskipun menunjukkan kinerja deteksi jalan berlubang yang baik, model SVM yang dilatih tanpa ekstraksi fitur. Hal ini berdampak pada pengenalan pola tepi dan tekstur khas lubang jalan. Karena hanya mengandalkan nilai piksel asli, model SVM gagal menangkap informasi spasial dan orientasi gradien. Akibatnya, kemampuan generalisasi model menjadi terbatas saat menghadapi variasi kondisi pencahayaan dan sudut pandang citra yang berbeda-beda.

#### 3.3 Pengaruh HOG dan PCA terhadap Model SVM

##### 3.3.1 Hasil Confusion Matrix

Untuk mengatasi keterbatasan yang ada, penelitian ini mencoba menerapkan teknik ekstraksi fitur *Histogram of Oriented Gradients* (HOG) dan teknik reduksi dimensi *Principal Component Analysis* (PCA) sebelum deteksi citra menggunakan SVM. Kombinasi ini bertujuan menghasilkan representasi fitur yang lebih informatif dan efisien secara komputasi. Tabel 4 menunjukkan perbandingan *Confusion Matrix* terhadap model SVM dan pengaruh HOG dan PCA terhadap klasifikasi SVM.


**Tabel 4.** Perbandingan *Confusion Matrix*

| Model       | <i>Confusion Matrix</i> |     |    |    |
|-------------|-------------------------|-----|----|----|
|             | FP                      | FN  | TP | TN |
| SVM         | 454                     | 476 | 87 | 73 |
| SVM+HOG+PCA | 482                     | 520 | 43 | 45 |


Berdasarkan *confusion matrix* pada Tabel 4, penerapan ekstraksi fitur HOG dan dimensi reduksi PCA pada model SVM menunjukkan peningkatan kinerja klasifikasi yang signifikan dibandingkan model SVM tanpa teknik penyeimbang. Model SVM yang diterapkan HOG dan PCA berhasil mengenali 520 citra normal secara benar (*True Negative*) dan 482 citra lubang jalan secara tepat (*True Positive*). Jumlah kesalahan klasifikasi juga menurun cukup signifikan, yaitu hanya 43 citra normal yang salah dikenali sebagai lubang jalan (*False Positive*) dan 45 citra lubang jalan yang tidak terdeteksi (*False Negative*). Jika dibandingkan dengan model SVM tanpa HOG dan PCA, terjadi peningkatan deteksi benar sebesar 6,17% pada kelas pothole dan 9,24% pada kelas normal, serta penurunan kesalahan klasifikasi masing-masing 50,57% untuk *False Positive* dan 38,36% untuk *False Negative*. Hasil ini membuktikan bahwa penerapan HOG-PCA-SVM mampu meningkatkan kemampuan

model untuk membedakan citra jalan normal dan berlubang secara lebih akurat dan efisien.

Untuk menyajikan gambaran yang lebih detail mengenai performa klasifikasi, gambar 2 menyajikan evaluasi *confusion matrix* model SVM tanpa penerapan HOG dan PCA, sedangkan gambar 3 *confusion matrix* untuk model SVM setelah penerapan HOG dan PCA.



Gambar 2. Evaluasi SVM tanpa HOG dan PCA



Gambar 3. Evaluasi SVM dengan HOG dan PCA

### 3.3.2 Metrik Evaluasi Model

Evaluasi lanjutan dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score* yang ditunjukkan pada Tabel 5.

Tabel 5. Perbandingan Metrik Evaluasi

| Mode            | Metrik Evaluasi |           |        |          |
|-----------------|-----------------|-----------|--------|----------|
|                 | Accuracy        | Precision | Recall | F1-Score |
| SVM             | 0.853           | 0.87      | 0.85   | 0.86     |
| SVM + HOG + PCA | 0.919           | 0.92      | 0.92   | 0.92     |
| Selisih         | 6.61%           | 7.0%      | 7.0%   | 7.0%     |

Hasil tabel 5 menunjukkan bahwa model SVM dengan HOG dan PCA mampu meningkatkan kinerja model secara signifikan dibandingkan model SVM

biasa. Akurasi meningkat sebesar 6,61% (dari 0.853 menjadi 0.919), dan peningkatan serupa sekitar 7% juga terjadi pada *precision*, *recall*, serta *F1-score*. Hal ini membuktikan bahwa penerapan HOG dan PCA mampu meningkatkan model SVM, melalui peningkatan akurasi deteksi citra jalan normal dan berlubang.

## 4. KESIMPULAN

Penerapan HOG (*Histogram of Oriented Gradients*) sebagai fitur ekstraksi dan PCA (*Principal Component Analysis*) sebagai dimensi reduksi pada model SVM (*Support Vector Machine*) berhasil meningkatkan akurasi dari 85,32% menjadi 91,93%, atau naik sebesar 6,61%. Lebih lanjut, pada nilai *precision*, *recall*, dan *F1-score* masing-masing meningkat sekitar 7%. HOG berperan penting dalam mengekstraksi fitur citra berbasis tepi dan tekstur, sementara PCA berfungsi mereduksi dimensi fitur hasil ekstraksi HOG, sehingga proses pelatihan menjadi lebih efisien dan stabil. Kombinasi keduanya membuat model SVM lebih akurat, konsisten, dan tahan terhadap variasi pencahayaan maupun bentuk citra.

## 5. DAFTAR PUSTAKA

- [1] M. A. Gaikwad, A. Kannao, D. Gawande, P. Gite, S. Pandey, and T. Mahato, "Road Condition Improvement in Smart Cities Using IoT," *Int. Res. J. Eng. Technol.*, pp. 1906–1908, 2020, [Online]. Available: [www.irjet.net](http://www.irjet.net).
- [2] A. K. Pandey, V. Palade, R. Iqbal, T. Maniak, C. Karyotis, and S. Akuma, "Convolution neural networks for pothole detection of critical road infrastructure," *Comput. Electr. Eng.*, vol. 99, pp. 1–20, 2022, doi: 10.1016/j.compeleceng.2022.107725.
- [3] D. Chen, N. Chen, X. Zhang, and Y. Guan, "Real-Time Road Pothole Mapping Based on Vibration Analysis in Smart City," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 15, pp. 6972–6984, 2022, doi: 10.1109/JSTARS.2022.3200147.
- [4] N. Ma *et al.*, "Computer vision for road imaging and pothole detection: a state-of-the-art review of systems and algorithms," *Transp. Saf. Environ.*, vol. 4, no. 4, pp. 1–16, 2022, doi: 10.1093/tse/tdac026.
- [5] S. B. Arpit Kumar Bhatt, "AI ENABLED ROAD HEALTH MONITORING SYSTEM FOR SMART CITIES," *Easy Chair*, 2022.
- [6] G. S. T. & P. A. G. kale Vishal. L. Solanke, Darshan. D. Patil, Aniket. S. Patkar, "Analysis of Existing Road Surface on the Basis of Pothole Characteristics," *Glob. J. Res. Eng. E Civ. Struct. Eng.*, vol. 19, no. 3, 2019.
- [7] N. J. Ashaari Muhamad, M. E. Rana, V. A. Hameed, and H. K. Tripathy, "Machine Learning Combined with Thresholding - A Blended Approach to Potholes Detection," *ASSIC 2022 - Proc. Int. Conf. Adv. Smart*,



- Secur. Intell. Comput.*, no. November 2022, 2022, doi: 10.1109/ASSIC55218.2022.10088310.
- [8] Y. Safyari, M. Mahdianpari, and H. Shiri, "A Review of Vision-Based Pothole Detection Methods Using Computer Vision and Machine Learning," *Sensors*, vol. 24, no. 17, 2024, doi: 10.3390/s24175652.
- [9] B. News, "Earmark Fuel Duty Money for Pothole Repairs—Councils," *BBC News*, 2923. <https://www.bbc.com/news/uk-66481761> (accessed Aug. 12, 2023).
- [10] M. D. Matouq, Y., Manasreh, D., & Nazzal, "AI-Driven Approach for Automated Real-Time Pothole Detection, Localization, and Area Estimation," *Transp. Res. Rec.*, vol. 2678, no. 11, pp. 2018–2031, 2024, doi: <https://doi.org/10.1177/03611981241246993>.
- [11] R. Fan and M. Liu, "Road Damage Detection Based on Unsupervised Disparity Map Segmentation," *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 11, pp. 4906–4911, 2020, doi: 10.1109/TITS.2019.2947206.
- [12] Y. M. Kim, Y. G. Kim, S. Y. Son, S. Y. Lim, B. Y. Choi, and D. H. Choi, "Review of Recent Automated Pothole-Detection Methods," *Appl. Sci.*, vol. 12, no. 11, pp. 1–15, 2022, doi: 10.3390/app12115320.
- [13] C. Koch, K. Georgieva, V. Kasireddy, B. Akinci, and P. Fieguth, "A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure," *Adv. Eng. Informatics*, vol. 29, no. 2, pp. 196–210, 2015, doi: 10.1016/j.aei.2015.01.008.
- [14] S. S. Park, V. T. Tran, and D. E. Lee, "Application of various yolo models for computer vision-based real-time pothole detection," *Appl. Sci.*, vol. 11, no. 23, 2021, doi: 10.3390/app112311229.
- [15] C. Saisree and D. K. U, "Pothole Detection Using Deep Learning Classification Method," *rocedia Comput. Sci.*, vol. 218, no. C, pp. 2143–2152, 2023, doi: <https://doi.org/10.1016/j.procs.2023.01.190>.
- [16] X. Zhang, "Support Vector Machines," in *Encyclopedia of Machine Learning and Data Mining*, NICTA, Australian National University, Canberra, ACT, Australia: Springer Science+Business Media, 2017, pp. 1214–1220.
- [17] X. Qu, L. Bai, and H. You, "Fast processing in support vector machine for large-scaled data set," in *Lecture Notes in Electrical Engineering*, 2012, vol. 113 LNEE, pp. 171–176, doi: 10.1007/978-94-007-2169-2\_20.
- [18] P. Bohra and H. Palivela, "Understanding and formulation of various kernel techniques for suport vector machines," in *2015 IEEE International Conference on Computational Intelligence and Computing Research, ICCIC 2015*, 2016, doi: 10.1109/ICCIC.2015.7435804.
- [19] H. Al Kaddouri *et al.*, "Optimization of Hyperparameters for SVM Classification of Citrus Diseases Using Grid Search and Cross-Validation," in *Lecture Notes in Electrical Engineering*, 2025, vol. 1306, pp. 489–497, doi: 10.1007/978-981-96-0644-3\_44.
- [20] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, "A comprehensive survey on support vector machine classification: Applications, challenges and trends," *Neurocomputing*, vol. 408, pp. 189–215, 2020, doi: 10.1016/j.neucom.2019.10.118.
- [21] Z. Ma, L. T. Yang, and Q. Zhang, "Support Multimode Tensor Machine for Multiple Classification on Industrial Big Data," *IEEE Trans. Ind. Informatics*, vol. 17, no. 5, pp. 3382–3390, 2021, doi: 10.1109/TII.2020.2999622.
- [22] I.-J. Li, J.-L. Wu, and C.-H. Yeh, "A fast classification strategy for SVM on the large-scale high-dimensional datasets," *Pattern Anal. Appl.*, vol. 21, no. 4, pp. 1023–1038, 2018, doi: 10.1007/s10044-017-0620-0.
- [23] I. Durdanovic *et al.*, "Massive SVM parallelization using hardware accelerators," in *Scaling up Machine Learning: Parallel and Distributed Approaches*, vol. 9780521192, NEC Labs America, Princeton, NJ, United States: Cambridge University Press, 2011, pp. 127–147.
- [24] R. Zhang and Y. Liu, "Research on development and application of support vector machine - Transformer fault diagnosis," in *ACM International Conference Proceeding Series*, 2018, pp. 262–268, doi: 10.1145/3305275.3305328.
- [25] D. D. Nguyen, K. Matsumoto, Y. Takishima, and K. Hashimoto, "Condensed vector machines: Learning fast machine for large data," *IEEE Trans. Neural Networks*, vol. 21, no. 12, pp. 1903–1914, 2010, doi: 10.1109/TNN.2010.2079947.
- [26] E. Sadrfaridpour, K. Palmer, and I. Safro, "AML-SVM: Adaptive Multilevel Learning with Support Vector Machines," in *Proceedings - 2020 IEEE International Conference on Big Data, Big Data 2020*, 2020, pp. 788–797, doi: 10.1109/BigData50022.2020.9378010.
- [27] H. Abdi and L. J. Williams, "Principal component analysis," *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 2, no. 4, pp. 433–459, 2010, doi: 10.1002/wics.101.
- [28] E. Endri, A. Sheta, and H. Turabieh, "Road damage detection utilizing convolution neural network and principal component analysis,"

- Int. J. Adv. Comput. Sci. Appl.*, vol. 11, no. 6, pp. 670–678, 2020, doi: 10.14569/IJACSA.2020.0110682.
- [29] A. K. M. Jobayer Al Masud, S. T. Sharin, K. F. T. Shawon, and Z. Zaman, “Pothole Detection Using Machine Learning Algorithms,” in *2021 15th International Conference on Signal Processing and Communication Systems, ICSPCS 2021 - Proceedings*, 2021, doi: 10.1109/ICSPCS53099.2021.9660216.
- [30] A. Gupta, S. Wazir, A. K. Mahto, and S. I. Alam, “Facial Recognition Using Principal Component Analysis,” in *Artificial Intelligence & Blockchain in Cyber Physical Systems: Technologies & Applications*, Jamia Hamdard, New Delhi, India: CRC Press, 2023, pp. 1–259.
- [31] X. Wang, W. Huang, C. Jin, M. Hu, and F. Ren, “Facial expression recognition based on the optimal matching of multi-feature and multi-classifier,” *Guangdian Gongcheng/Opto-Electronic Eng.*, vol. 43, no. 3, pp. 73–79, 2016, doi: 10.3969/j.issn.1003-501X.2016.03.012.
- [32] F. Han, J. Zhu, B. Zhang, and F. Duan, “Study of defect feature dimension reduction based on principal component analysis,” in *Proceedings of 2nd International Conference on Computer Science and Network Technology, ICCSNT 2012*, 2012, pp. 1367–1371, doi: 10.1109/ICCSNT.2012.6526175.
- [33] F. Badakhshan Farahabadi, K. F. Vajargah, and R. Farnoosh, “Dimension Reduction Big Data Using Recognition of Data Features Based on Copula Function and Principal Component Analysis,” *Adv. Math. Phys.*, vol. 2021, 2021, doi: 10.1155/2021/9967368.
- [34] L. Wang, Y. Wang, G. Wang, and J. Jia, “Near-field sound source localization using principal component analysis–multi-output support vector regression,” *Int. J. Distrib. Sens. Networks*, vol. 16, no. 4, 2020, doi: 10.1177/1550147720916405.
- [35] C. Chen, H. Seo, C. H. Jun, and Y. Yang, “Pavement crack detection and classification based on fusion feature of LBP and PCA with SVM,” *Int. J. Pavement Eng.*, vol. 23, no. 9, pp. 3274–3283, 2022, doi: 10.1080/10298436.2021.1888092.
- [36] J. Guo, T. Li, and Y. Li, “SVM Based on Gaussian and Non-Gaussian Double Subspace for Fault Detection,” *IEEE Access*, vol. 9, pp. 66519–66530, 2021, doi: 10.1109/ACCESS.2021.3075273.
- [37] S. Hanifatus, D. Chirzah, W. Kurniawan, and A. Maulana, “Analisis Performa Convolutional Neural Networks pada Deteksi Penyakit Malaria Berbasis Citra Mikroskopis,” vol. 8, pp. 111–117, 2025.
- [38] G. H. Chen *et al.*, “Detection of Highway Pavement Damage Based on a CNN Using Grayscale and HOG Features,” *Sensors*, vol. 22, no. 7, pp. 1–10, 2022, doi: 10.3390/s22072455.
- [39] K. Li, C. Zou, S. Bu, Y. Liang, J. Zhang, and M. Gong, “Multi-modal feature fusion for geographic image annotation,” *Pattern Recognit.*, vol. 73, pp. 1–14, 2018, doi: 10.1016/j.patcog.2017.06.036.
- [40] A. W. O. Gama, P. V. J. A. Gunawan, and K. Darmaastawan, “HOG Feature Extraction in Optimizing FK-NN and CNN for Image Identification of Rice Plant Diseases,” *J. Appl. Data Sci.*, vol. 6, no. 3, pp. 1611–1626, 2025, doi: 10.47738/jads.v6i3.722.
- [41] A. Saini, N. S. Gill, P. Gulia, A. K. Tiwari, P. Maratha, and M. A. Shah, “Smart crop disease monitoring system in IoT using optimization enabled deep residual network,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–21, 2025, doi: 10.1038/s41598-025-85486-1.
- [42] D. A. Prastita, A. Setiawan, and I. F. Ashari, “Analisis Perbandingan Metode Convolutional Neural Network (CNN) untuk Deteksi Warna pada Objek,” *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 821–830, 2025, doi: 10.47065/bulletincsr.v5i4.617.
- [43] T. B. Sasongko, H. Haryoko, and A. Amrullah, “Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 4, pp. 763–768, 2023, doi: 10.25126/jtiik.2024106583.
- [44] Moh Mario Subagio, Mulyani Satya Bhakti, Achmad Yusuf Yulestiono, and Anggraini Puspita Sari, “Perbandingan Kinerja Metode Convolutional Neural Network (CNN) dan VGG-16 dalam Klasifikasi Rambu Lalu Lintas,” *J. Mhs. Tek. Inform.*, vol. 3, no. 2, pp. 79–87, 2024, doi: 10.35473/jamastika.v3i2.3361.
- [45] B. Rahmani, S. Javadi, and S. M. H. Shahdany, “Evaluation of aquifer vulnerability using PCA technique and various clustering methods,” *Geocarto Int.*, vol. 36, no. 18, pp. 2117–2140, 2021, doi: 10.1080/10106049.2019.1690057.
- [46] Y. Ling, Q. Yue, C. Chai, Q. Shan, D. Hei, and W. Jia, “Nuclear accident source term estimation using Kernel Principal Component Analysis, Particle Swarm Optimization, and Backpropagation Neural Networks,” *Ann. Nucl. Energy*, vol. 136, p. 107031, 2020, doi: 10.1016/j.anucene.2019.107031.
- [47] M. Abdipour, M. Younessi-Hmazekhanlu, S. H. R. Ramazani, and A. hassan omidi, “Artificial neural networks and multiple linear regression as potential methods for modeling seed yield of safflower (*Carthamus tinctorius* L.),” *Ind. Crops Prod.*, vol. 127, no. November 2018, pp. 185–194, 2019, doi:

- 10.1016/j.indcrop.2018.10.050.
- [48] L. N. Desinaini, A. Mualimah, D. C. R. Novitasari, and M. Hafiyusholeh, "Application of Fuzzy K-Nearest Neighbor (FKNN) to Detect the Parkinson's Disease," *Inpr. Indones. J. Pure Appl. Math.*, vol. 1, no. 1, 2019, doi: 10.15408/inprime.v1i1.12827.
- [49] M. Musfiroh, D. C. R. Novitasari, P. K. Intan, and G. G. Wisnawa, "Penerapan Metode Principal Component Analysis (PCA) dan Long Short-Term Memory (LSTM) dalam Memprediksi Prediksi Curah Hujan Harian," *Build. Informatics, Technol. Sci.*, vol. 5, no. 1, pp. 1–11, 2023, doi: 10.47065/bits.v5i1.3114.
- [50] A. I. Putri, Y. Syarif, P. Jayadi, F. Arrazak, and F. N. Salisah, "Implementation of Decision Tree and Support Vector Machine (SVM) Algorithm for Stunting Risk Prediction," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. October, pp. 349–357, 2023.
- [51] W. S. Dharmawan, "Komparasi Algoritma Klasifikasi Svm-Pso Dan C4.5-Pso Dalam Prediksi Penyakit Jantung," *J. Inform. Manaj. dan Komput.*, vol. 13, no. 2, p. 31, 2021, doi: 10.36723/juri.v13i2.301.
- [52] A. T. Akbar, S. Saifullah, and H. Prapcoyo, "Klasifikasi Ekspresi Wajah Menggunakan Covolutional Neural Network," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 6, pp. 1399–1412, 2024, doi: 10.25126/jtiik.2024118888.
- [53] S. Bahri, A. Sunyoto, and M. P. Kurniawan, "Klasifikasi Hama Pada Daun Sawi Menggunakan Convolutional Neural Network (CNN) Dengan Algoritma Xcaption dan Optimasi Adam," *J. Electr. Eng. Comput.*, vol. 6, no. 2, pp. 359–370, 2024, doi: 10.33650/jeeecom.v6i2.9529.