



DOI: <https://doi.org/10.38035/jemsi.v7i4>
<https://creativecommons.org/licenses/by/4.0/>

Klasifikasi Cacat Permukaan Keramik Menggunakan *Logistic Regression* dan SVM Berbasis CNN

Inggrid Nindia Aprila Palupi¹, Budiyan Mariyadi², Imam Yuadi³, Taufik Roni Sahroni⁴

¹Universitas Airlangga, Surabaya, Indonesia, inggrid.nindia.aprilia-2024@pasca.unair.ac.id

²Universitas Muhammadiyah Bandung, Bandung, Indonesia, budiyan.mariyadi@umbandung.ac.id

³Univeristas Airlangga, Surabaya, Indonesia, imam.yuadi@fisip.unair.ac.id

⁴Binus University, Jakarta, Indonesia, taufik@binus.edu

Corresponding Author: inggrid.nindia.aprilia-2024@pasca.unair.ac.id¹

Abstract: Classification in detecting surface defects in ceramic tiles is an important step in ensuring product quality in the manufacturing industry. Accurate classification is indispensable to improve the quality of production and reduce human factor errors. This study aims to accurately detect and classify types of defects with both 2D and 3D textures. The proposed method uses Logistic Regression and is compared to the Support Vector Machine. In this study, 133 defect type data was used taken using a smartphone camera with an angle of 45°. The training process used 66% of the data trained with the Inception V3, VGG-16 and VGG-19 models then 34% of the defect type data for testing. Logistic Regression and Support Vector Machine with Inception V3 provides the best classification results with an accuracy and precision of 0.99 with the ability to classify 100% of defect types such as lumps, holes, peeling, cracks with 2D textures. With Inception V3, 6.9 and 2.1 seconds and VGG-19 required training and testing times of 53.8 and 5.36 seconds. Meanwhile, the Support Vector Machine with Inception V3 requires 6.6 and 4.7 seconds of testing and training time, and VGG-19 requires 10.1 and 4.7 seconds of training and testing.

Keywords: Classification, Logistic Regression, Support Vector Machine, Ceramic surface defects, Accuracy, Precision.

Abstrak: Klasifikasi dalam mendeteksi cacat permukaan pada ubin keramik merupakan langkah penting dalam memastikan kualitas produk di industri manufaktur. Klasifikasi yang akurat sangat diperlukan untuk meningkatkan kualitas hasil produksi dan mengurangi kesalahan faktor manusia. Penelitian ini bertujuan untuk deteksi dan klasifikasi secara akurat pada jenis cacat baik yang bertekstur 2D dan 3D. Metode yang diusulkan dengan menggunakan *Logistic Regression* dan dibandingkan dengan *Support Vector Machine*. Dalam Penelitian ini menggunakan 133 data jenis cacat yang diambil menggunakan kamera *smartphone* dengan sudut 45°. Proses pelatihan menggunakan 66% data yang dilatih dengan model *Inception V3*, *VGG-16* dan *VGG-19* kemudian 34% data jenis cacat untuk pengujian. *Logistic Regression* dan *Support Vector Machine* dengan *Inception V3* memberikan hasil klasifikasi terbaik dengan akurasi dan presisi 0,99 dengan kemampuan untuk klasifikasi 100% jenis cacat seperti gompal, lubang, terkelupas, retak dengan tekstur 2D. Sedangkan *VGG-19* dapat melakukan klasifikasi

100% pada jenis cacat gelembung dengan tekstur 3D. Waktu pelatihan dan pengujian *Logistic Regression* dengan *Inception V3* 6,9 dan 2,1 detik dan VGG-19 membutuhkan waktu pelatihan dan pengujian 53,8 dan 5,36 detik. Sedangkan *Support Vector Machine* dengan *Inception V3* membutuhkan waktu pelatihan dan pengujian 6,6 dan 4,7 detik, sedangkan VGG-19 membutuhkan waktu pelatihan dan pengujian 10,1 dan 4,7 detik.

Kata Kunci: Klasifikasi, *Logistic Regression*, *Support Vector Machine*, Cacat permukaan Keramik, Akurasi, Presisi.

PENDAHULUAN

Industri keramik lantai menghadapi tantangan besar dalam menjaga mutu produk. Permukaan keramik rentan mengalami cacat seperti retakan halus, bintik, pori, goresan, dan variasi glasir, yang bila tidak terdeteksi secara tepat bisa menyebabkan produk ditolak, biaya produksi meningkat, dan citra kualitas menurun (Laveda-Martínez et al., 2025)(Wang & Zhang, 2025). Inspeksi manual masih banyak dilakukan di lapangan, tetapi metode ini rawan terhadap kelelahan operator, penilaian subjektif, dan inkonsistensi antar operator, terutama saat volume produksi tinggi (Cumbajin et al., 2023). Oleh karena itu, kebutuhan terhadap sistem otomasi inspeksi visual yang cepat, akurat, dan stabil menjadi sangat mendesak (Bai et al., 2024)(Ohemu, 2021).

Seiring kemajuan deep learning dan computer vision, banyak penelitian menerapkan *Convolutional Neural Network* (CNN) untuk deteksi cacat permukaan di berbagai material (Jha & Babiceanu, 2023). *Deep CNN-based visual defect detection* meninjau berbagai arsitektur CNN untuk inspeksi optik otomatis (Jha & Babiceanu, 2023). Model CNN mampu mengekstraksi fitur spasial yang kompleks tanpa rekayasa fitur manual, dan telah banyak digunakan dalam industri metal, kayu, keramik, dan beton (Karimi et al., 2024). Namun, pelatihan end-to-end CNN memerlukan dataset besar dan infrastruktur komputasi berat, yang kadang tidak feasible di industri berskala menengah. Selain itu deteksi cacat permukaan masih berbasis cacat permukaan dua dimensi. Sementara di Industri variasi cacat permukaan terdapat variasi cacat permukaan 3 dimensi (Diao et al., 2025).

Untuk mengatasi keterbatasan tersebut, strategi *hybrid* menggunakan model *pretrained* CNN sebagai *feature extractor* dan menerapkan algoritma klasik seperti *Support Vector Machine* (SVM) atau *Logistic Regression* (LR) pada ruang fitur mulai mendapatkan perhatian. Penelitian (Kilci & Koklu, 2025) memanfaatkan *Inception V3* untuk ekstraksi fitur, kemudian menguji LR dan SVM sebagai pengklasifikasi, menemukan bahwa LR menghasilkan akurasi tertinggi (83,9 %) dibanding SVM (78,4 %) dalam klasifikasi cacat panel surya. Di domain medis, penelitian (Kaur et al., 2025) menunjukkan kombinasi CNN dan SVM efektif dalam prediksi penyakit paru-paru. Sedangkan dalam konteks deteksi objek pekerja real-time, (Chen et al., 2025) memadukan *Inception V3* dan SVM untuk meningkatkan akurasi deteksi.

Secara teoritis, SVM unggul dalam menangani data berdimensi tinggi dengan margin optimasi dan dapat memperlakukan kasus non-linear melalui kernel (misalnya RBF) (Kareem et al., 2024). Teknik SVM juga relatif *robust* terhadap *overfitting* dalam ruang fitur tinggi jika parameter disetel dengan baik. Dalam penelitian terbaru, (Baldomero-Naranjo et al., 2021) mengajukan metode SVM *robust* yang sekaligus melakukan seleksi fitur dan deteksi *outlier* lewat formulasi *ramp loss* dan batas anggaran fitur. Model semacam ini bisa sangat bermanfaat bila terdapat fitur “noise” atau fitur kurang relevan dari CNN. Sedangkan LR dikenal karena kesederhanaan, interpretabilitas (Caba, 2023), dan komputasi ringan, memungkinkan inferensi cepat dalam sistem produksi. Dalam domain manufaktur, beberapa eksperimen *wafer defect classification* menunjukkan LR mampu menghasilkan akurasi 86,9 % (Mat Jizat et al., 2021).


Tren penggunaan *transfer learning* dalam *defect detection* sekitar 83 % studi deteksi permukaan menggunakan model CNN *pretrained* sebagai titik awal. Survey arsitektur dan tren *defect detection* mengindikasikan bahwa sementara CNN dominan, penggunaan kombinasi metode klasik (seperti SVM) tetap relevan dalam skenario data terbatas atau kebutuhan latensi rendah (Cumbajin et al., 2023)

Berdasarkan latar belakang di atas, penelitian ini memilih pendekatan *hybrid* ekstraksi fitur menggunakan model CNN (VGG-16, VGG-19, *Inception V3*) yang telah terlatih (*pretrained*) (Hussain et al., 2024), kemudian menerapkan *Logistic Regression* dan SVM pada vektor fitur untuk klasifikasi jenis cacat. Alasan utama pemilihan metode ini adalah (1) efisiensi komputasi dibanding melatih ulang CNN penuh (Sun, 2026), (2) kemampuan SVM dan LR dalam memodelkan batas keputusan di ruang fitur tinggi (Kazemi, 2024), (3) kebutuhan latensi rendah dalam produksi, dan (4) interpretabilitas model LR untuk analisis kesalahan. Pendekatan ini juga memungkinkan kompatibilitas dengan *pipeline* industri karena ukuran model dan kebutuhan sumber daya relatif rendah (Tahirovi, 2023).

Tujuan utama penelitian ini adalah (1) mengevaluasi kemampuan tiga *backbone* CNN (VGG-16, VGG-19, *Inception V3*) dalam menghasilkan fitur representatif untuk klasifikasi cacat keramik, (2) membandingkan performa SVM dan LR dalam mengenali jenis cacat dengan tekstur 2D atau 3D berdasarkan fitur tersebut, serta (3) mengusulkan sistem otomatis inspeksi visual yang *viable* untuk integrasi di lini produksi keramik. Dengan demikian, penelitian ini diharapkan berkontribusi pada upaya otomatisasi mutu di industri keramik dan memperkuat landasan teoretis penggunaan *hybrid* CNN dan *classifier* klasik dalam diagnosis cacat visual.

METODE

Pada penelitian ini dilakukan observasi sampel data ke produsen keramik dan eksperimen dalam melakukan ekstraksi data. Langkah langkah penelitian dapat dilihat pada gambar 1.



Gambar 1. Tahapan dalam penelitian


Persiapan Alat dan Bahan

Dalam proses pengambilan gambar keramik membutuhkan peralatan dan bahan dengan spesifikasi seperti terlihat pada Tabel 1.

Tabel 1. Alat dan Bahan Penelitian

No	Alat dan Bahan	Spesifikasi
1	Kamera	Redmi 12 Mega pixel
2	Lampu	LED 3 x 10 watt
3	Keramik	Bermotif dimensi 20x20
4	CPU Komputer	IntelCore I5 M460 RAM 16GB Graphics 8GB
5	Monitor	14 inch
6	Software	Orange 3.38

Dengan menggunakan alat dan bahan tersebut, dilakukan pengambilan gambar keramik pada kondisi normal tanpa cacat dan cacat. Skema pengambilan gambar keramik dilakukan dengan skema pada Gambar 2.



Gambar 2. Skema Pengambilan Citra Keramik

Pengambilan Data Citra

Pada proses ini merupakan pengumpulan data. Keramik polos berukuran 20 x 20 di letakkan di atas meja dengan posisi yang rata. Lampu di atur sebanyak 3 buah untuk memenuhi pencahayaan pada proses pengambilan gambar. Kemudian kamera di dihidupkan untuk mengambil gambar dengan membentuk sudut 45° terhadap permukaan keramik. Hasil pengambilan gambar langsung terkoneksi dengan perangkat komputer untuk melihat hasilnya. Kemudian hasil pengambilan gambar permukaan keramik dilakukan pre processing, latihan dan pengujian menggunakan software orange 3.38.

Sampel Jenis Cacat Keramik

Keramik yang digunakan sebagai sampel yaitu keramik satu motif dengan permukaan yang halus. Ada 5 jenis cacat keramik yang sering terjadi di industri, dan menjadi data untuk dilakukan klasifikasi jenis cacat pada penelitian ini. Masing masing cacat diambil 20 sampel gambar dengan kondisi cacat yang berbeda seperti terlihat pada tabel 2. Jumlah semua sampel untuk data set pelatihan dan pengujian 132 data.

Tabel 2. Jenis Cacat Keramik

No	Jenis Cacat	Deskripsi
1	Gompal	Gompal pada bagian sisi atau sudut keramik

		
2	Gelembung	Lapisan permukaan yang menonjol ke atas
		
3	Terkelupas	Lapisan glasir yang mengelupas
		
4	Lubang Jarum	Lubang kecil pada permukaan glasir
		
5	Retak	Retak kecil pada bagian lapisan glasir
		

Ekstraksi Fitur

Gambar jenis cacat pada permukaan keramik yang sudah di-*capture* diimpor ke dalam *software* menggunakan orange dengan terlebih dahulu membaut arsitektur modelnya, kemudian dilakukan ekstraksi fitur dari jenis cacat keramik. Model ekstraksi yang digunakan yaitu *Inception V3*, *VGG-16* dan *VGG-19*.

Proses Klasifikasi

Berdasarkan fitur yang diperoleh dari proses ekstraksi, kemudian dilakukan pelatihan dan pengujian menggunakan model *Logistic Regression* dan *Support Vector Machine* (SVM). Sehingga diperoleh hasil klasifikasi yang akurat.


Analisa Hasil dan Pembahasan

Pada tahap ini dilakukan analisa hasil proses klasifikasi menggunakan model *Logistic Regression* dan *Support Vector Machine* (SVM) kemudian dilakukan pembahasan terhadap akurasi dalam melakukan klasifikasi jenis cacat pada permukaan keramik.

HASIL DAN PEMBAHASAN


Arsitektur model klasifikasi


Pada Gambar 3 merupakan arsitek model *Logistic Regression* dan *Support Vector Machine* (SVM). Model tersebut digunakan untuk melakukan ekstraksi fitur, pelatihan dan pengujian. Proses *Image Embedding* dilakukan untuk mengubah data gambar cacat keramik menjadi representasi numerik. Data ini digunakan untuk analisis klasifikasi. Dalam ekstraksi fitur *Inception V3*, setiap gambar di rubah menjadi ukuran 299x299x3 pixel (panjang, lebar, warna rgb) yang kemudian direpresentasikan dalam bentuk vektor berdimensi tinggi sehingga dapat menangkap karakteristik pola, tekstur, dan bentuk.




Gambar 3. Arsitektur model klasifikasi *Logistic Regression* dan *Support Vector Machine* (SVM)


Ekstraksi fitur *Inception V3* menghasilkan vektor dengan dimensi 2048. Selain itu model VGG-16 dan VGG-19 digunakan untuk ekstraksi fitur dengan dimensi 4096. Hasil ekstraksi fitur untuk dimensi ukuran, lebar dan tinggi dapat dilihat pada Gambar 4.






Gambar 4. Distribusi probabilitas fitur ukuran, lebar, tinggi ekstraksi *Inception V3*





Gambar 5. Distribusi probabilitas fitur ukuran, lebar, tinggi dengan ekstraksi VGG-16



Gambar 6. Distribusi probabilitas fitur ukuran, lebar, tinggi dengan ekstraksi VGG-19

Hasil Pelatihan dan Pengujian *Logistic Regression* dan *Support Vector Machine* (SVM)

Hasil ekstraksi fitur merupakan inputan dalam melakukan pelatihan dan pengujian *Logistic Regression* dan *Support Vector machine*. Hal ini dapat dilihat pada Gambar 7. Pembagian data set untuk pelatihan sebesar 66% dan 34% untuk pengujian. Parameter yang diperoleh dari pelatihan dan pengujian adalah sebagai berikut:

- a. Akurasi yang merupakan persentasi prediksi dari total data

$$Accuracy = \frac{Prediksi\ benar}{Jumlah\ sampel} \quad (1)$$


- b. Presisi yang merupakan proporsi prediksi yang benar benar positif

$$Precision = \frac{True\ positive(TP)}{TP+False\ Positive(FP)} \quad (2)$$


- c. Recall (sensitivity) yang merupakan data positif yang teridentifikasi dengan benar

$$Recall = \frac{True\ positive}{TP + False\ Negative(FP)} \quad (3)$$


- d. AUC-ROC (*Area Under the Curve*) yang merupakan kemampuan mengukur model untuk membedakan antara kelas. Semakin tinggi semakin baik.



(a)



(b)



(c)

Gambar 7. Hasil test dan score model Logistic Regression dan SVM a) Inception V3 b) VGG-16 c) VGG-19


Evaluasi model *Logistic Regression* dengan *Inception V3* pada Gambar 7 dibutuhkan waktu pelatihan (*Training Time*) 6,9 detik, waktu pengujian (*Test time*) 2,1 detik. Sedangkan akurasi klasifikasi (CA) dan presisi 0,99. Model *VGG-16* pada gambar 8 dibutuhkan waktu pelatihan (*Training Time*) 64,5 detik, waktu pengujian (*Test time*) 5,8 detik. Sedangkan akurasi klasifikasi (CA) 0.913 dan 0,927 presisi. Sedangkan model *VGG-19* pada gambar 9 dibutuhkan waktu pelatihan (*Training Time*) 53,8 detik, waktu pengujian (*Test time*) 5,36 detik. Sedangkan akurasi klasifikasi (CA) dan presisi 0,94.

Evaluasi model SVM dengan *Inception V3* pada Gambar 7 dibutuhkan waktu pelatihan (*Training Time*) 6,64 detik, waktu pengujian (*Test time*) 4,7 detik. Sedangkan akurasi klasifikasi (CA) dan presisi 0,98. Model *VGG-16* pada gambar 8 dibutuhkan waktu pelatihan (*Training Time*) 9,85 detik, waktu pengujian (*Test time*) 5,3 detik. Sedangkan akurasi


klasifikasi (CA) dan presisi 0,97. Model *VGG-19* pada gambar 9 dibutuhkan waktu pelatihan (*Training Time*) 10,1 detik, waktu pengujian (*Test time*) 4,7 detik. Sedangkan akurasi klasifikasi (CA) dan presisi 0,98.

Hasil Klasifikasi *Logistic Regression*


Hasil klasifikasi *Logistic Regression* berdasarkan jenis cacat permukaan keramik dapat dilihat pada gambar 8.



(a)



(b)




(c)


Gambar 8. Hasil klasifikasi model *Logistic Regression* dengan ekstraksi fitur a) *Inception V3* b) *VGG-16* c) *VGG-19*

Hasil Klasifikasi *Support Vector Machine (SVM)*


Hasil klasifikasi *Support Vector Machine (SVM)* berdasarkan jenis cacat permukaan keramik dapat dilihat pada gambar 9.



(a)



(b)



(c)

Gambar 9. Hasil klasifikasi model SVM dengan ekstraksi fitur a) *Inception V3* b) *VGG-16* c) *VGG-19*

Pembahasan

Tekstur permukaan keramik yang kompleks berbentuk ruang menjadi tantangan dalam melakukan klasifikasi secara akurat. Pada proses pelatihan menggunakan *backpropagation neural network* untuk jenis cacat permukaan dengan tekstur gelembung (dalam ruang 3D) cenderung diklasifikasikan sebagai lubang dan glasir yang menggunakan ekstraksi fitur *Gray Level Co-occurrence Matrix (GLCM)* (Mariyadi et al., 2021), sedangkan *Logistic Regression* (LR) dengan model *VGG-19* dapat melakukan klasifikasi 100% sebagai cacat permukaan gelembung pada gambar 8c). Tapi pada jenis cacat gompal, retak, lubang, keramik normal (tanpa cacat) dapat diklasifikasikan 100% menggunakan dengan *Inception V3* pada gambar 8a) dan 8b). Hal ini terjadi karena LR tidak hanya menghasilkan prediksi kelas, tetapi juga probabilitas untuk setiap kelas (Zhang et al., 2022), sehingga model lebih fleksibel dalam menangkap hubungan kompleks, termasuk dalam ruang tiga dimensi, di mana probabilitas sering kali memberikan wawasan tambahan dibandingkan hanya *hard classification*.

Probabilitas hasil biner berdasarkan kombinasi linier dari input fitur. Fungsi sigmoid digunakan untuk memetakan nilai keluaran kedalam rentang 0 hingga 1. Dengan menggunakan persamaan 4.

$$P(y = 1/x) = \frac{1}{1+e^{-z}}, \text{ dimana } z = W^T X + b \quad (4)$$

Dengan :

W : Vektor Bobot

X : Vektor fitur input

b : Bias

Probabilitas yang dihasilkan dibandingkan dengan ambang batas standar 0,5 untuk menghasilkan label kelas, menggunakan persamaan 5.

$$\begin{aligned} \text{Jika } P\left(y = \frac{1}{x}\right) &\geq 0,5, \text{ kelas positif (1)} \\ \text{Jika } P\left(y = \frac{1}{x}\right) &\leq 0,5, \text{ kelas negatif (0)} \end{aligned} \quad (5)$$

Untuk meminimalkan nilai bobot yang besar digunakan *L2 regularization*. Kemudian model dilatih untuk menemukan bobot W yang optimal. Pada model LR pelatihan dan pengujian dilakukan dengan *cross validation* sebanyak 10 *fold*, dan pengulangan 10 kali. Pengaturan *fold* yang semakin besar mempengaruhi parameter pelatihan dan pengujian diantaranya yaitu akurasi. Jumlah *fold* 10 merupakan yang optimal.

VGG-19 mempunyai kemampuan menangkap informasi spasial suatu bentuk secara detail hal ini dapat dilihat dari hasil ekstraksi fitur pada gambar 6. yang menunjukkan distribusi fitur pada dimensi ukuran, lebar dan tinggi, sedangkan VGG-16 tidak memberikan hasil fitur yang lengkap pada gambar 5. VGG-19 dapat memisahkan kelas data dengan baik pada jenis cacat gelembung. Lapisan awal *convolutional* menangkap detail sederhana (tepi dan struktur) sedangkan lapisan koneksi menangkap pola kompleks yang terkait dengan pola objek ruang gelembung. Selain itu pengambilan gambar cacat dengan pemberian sudut (Pardo et al., 2019) memberikan informasi terkait detail fitur pada cacat permukaan gelembung, sehingga dapat diekstraksi pada proses *image embedding*.

Pada model SVM, jenis cacat gelembung dapat melakukan klasifikasi secara penuh 100%, menggunakan ekstraksi VGG-19 pada gambar 15, begitu juga dengan jenis cacat yang lain baik itu gompal, lubang, retak dapat diklasifikasi 100% menggunakan *inception V3*. Hal ini karena model SVM memerlukan pengaturan kernel untuk menangani data yang non linier. Jenis cacat gelembung merupakan bentuk dan pola yang kompleks, sehingga pemilihan kernel yang tepat menjadi penting. Jika kernel kurang tepat, SVM gagal menangkap pola cacat gelembung dengan tepat. Pengaturan kernel menggunakan *linier* memberikan hasil klasifikasi yang paling akurat, jika dibandingkan dengan *polynomial*, *RBF* dan *sigmoid*. Selain itu SVM sangat sensitif terhadap *outlier*, terutama pada titik titik data dekat *hyperplane* mempengaruhi posisi secara signifikan. Pada cacat gelembung dengan distribusi outlier, SVM mungkin menghasilkan *hyperplane* yang kurang optimal.

SVM menemukan *hyperplane* (garis atau bidang) yang memisahkan kelas data secara maksimal. Hasil ekstraksi fitur baik menggunakan *inception v3* maupun VGG-19 dinormalisasi untuk memastikan semua berada pada skala yang sama karena model SVM sensitif terhadap jarak. Pada proses pelatihan, margin antara *hyperplane* dan *support vector* di maksimalkan dengan menggunakan persamaan 6.

$$\min \frac{1}{2} ||W||^2 + C \sum \xi_i \dots \quad (6)$$

Dengan :

W : Vektor Bobot

ξ : Parameter (kesalahan)

C : Parameter regulasi

Titik data yang paling dekat dengan *hyperplane* menentukan *hyperplane* yang optimal. Dimana margin dikontrol oleh konstanta C. nilai C yang besar margin kecil dan lebih fokus pada klasifikasi yang benar. Pada model SVM nilai C yang digunakan 1, parameter kesalahan (ξ) = 0,1 serta kernel linier dihitung menggunakan persamaan 7.

$$K = x.y \quad (7)$$

Dengan:

K : Kernel liner

x,y : Vektor data (fitur)

Akurasi klasifikasi *Logistic Regression Inception V3* mencapai 0,991 dibanding dengan dengan support vector machine 0,983 dapat dilihat pada tabel 3.

Tabel 3. Perbandingan hasil *Logistic Regression* dan *Support Vector Machine*

Model	Feature Extraction	AUC	Classification Accuracy (CA)	F1	Precision	Recall	MCC
<i>Logistic Regression</i>	<i>Inception V3</i>	1.000	0.991	0.991	0.991	0.978	0.990
	VGG-16	0.985	0.913	0.915	0.927	0.913	0.897
	VGG-19	0.990	0.935	0.936	0.944	0.935	0.922
<i>Support Vector Machine</i>	<i>Inception V3</i>	0.997	0.983	0.983	0.983	0.946	0.979
	VGG-16	0.990	0.967	0.967	0.970	0.967	0.961
	VGG-19	0.996	0.978	0.978	0.980	0.978	0.974

Kemampuan mengukur keandalan klasifikasi kelas positif (*precision*) *logistic regression* hampir sama dibandingkan dengan *precision* SVM. Selain itu kemampuan model *logistic regression* mendeteksi semua kasus positif yang ditunjukkan oleh *recall* 0,03 lebih besar dari pada *support vector machine*. hal ini terlihat dari kemampuan dalam membedakan kelas positif dan kelas negatif yang berkisar antar 0 dan 1 yang ditunjukkan oleh rata-rata *ROC AUC* mencapai 1. Sementara untuk model VGG-16 dan VGG-19 untuk rata-rata akurasi berada pada level di atas 0,9.

KESIMPULAN

Pada penelitian ini, klasifikasi jenis cacat pada permukaan keramik dengan metode *Logistic Regression* dan *Support Vector Machine* (SVM) dengan *Inception V3* memberikan informasi yang akurat dalam melakukan klasifikasi pada jenis cacat permukaan pada ruang geometri 2D. Sedangkan model ekstraksi dengan VGG-19 memberikan informasi yang akurat dalam melakukan klasifikasi pada jenis cacat permukaan pada ruang 3D. Tetapi waktu pelatihan dan pengujian pada SVM baik itu menggunakan *Inception V3* dan VGG-19 lebih cepat dibandingkan dengan *Logistic Regression*. Sehingga kombinasi ini diperlukan untuk mendapatkan hasil klasifikasi yang akurat dan presisi.

REFERENSI

- Bai, J., Wu, D., Shelley, T., Schubel, P., Twine, D., Russell, J., Zeng, X., & Zhang, J. (2024). *A Comprehensive Survey on Machine Learning Driven Material Defect Detection: Challenges, Solutions, and Future Prospects*. <http://arxiv.org/abs/2406.07880>
- Baldomero-Naranjo, M., Martínez-Merino, L. I., & Rodríguez-Chía, A. M. (2021). A robust SVM-based approach with feature selection and outliers detection for classification problems. *Expert Systems with Applications*, 178(1995), 1–38. <https://doi.org/10.1016/j.eswa.2021.115017>
- Caba, A. B. (2023). *Mathematical Approach in Image Classification using Regression*. 732–733. <https://doi.org/10.1186/cc2401>.
- Chen, J., Xiong, H., Zhou, S., Wang, X., Lou, B., Ning, L., Hu, Q., Tang, Y., & Gu, G. (2025). A Hybrid Deep Learning and Improved SVM Framework for Real-Time Railroad Construction Personnel Detection with Multi-Scale Feature Optimization. *Sensors*, 25(7). <https://doi.org/10.3390/s25072061>
- Cumbajin, E., Rodrigues, N., Costa, P., Miragaia, R., Frazão, L., Costa, N., Fernández-caballero, A., Carneiro, J., Buruberri, L. H., & Pereira, A. (2023). *A Systematic Review on*

- Deep Learning with CNNs Applied to Surface Defect Detection*. 1–29.
- Diao, J., Wei, H., Zhou, Y., & Diao, Z. (2025). A Deep Learning-Based Algorithm for Ceramic Product Defect Detection. *Applied Sciences (Switzerland)*, 15(12), 1–19. <https://doi.org/10.3390/app15126641>
- Hussain, T., Hong, J., & Seok, J. (2024). *A Hybrid Deep Learning and Machine Learning-Based Approach to Classify Defects in Hot Rolled Steel Strips for Smart Manufacturing*. 1–21. <https://doi.org/10.32604/cmc.2024.050884>
- Jha, S. B., & Babiceanu, R. F. (2023). Deep CNN-based visual defect detection: Survey of current literature. *Computers in Industry*, 148, 103911. <https://doi.org/10.1016/j.compind.2023.103911>
- Kareem, I., Ali, S. F., Bilal, M., & Hanif, M. S. (2024). Exploiting the features of deep residual network with SVM classifier for human posture recognition. *PLoS ONE*, 19(12 December), 1–26. <https://doi.org/10.1371/journal.pone.0314959>
- Karimi, N., Mishra, M., & Lourenço, P. B. (2024). Deep learning-based automated tile defect detection system for Portuguese cultural heritage buildings. *Journal of Cultural Heritage*, 68, 86–98. <https://doi.org/10.1016/j.culher.2024.05.009>
- Kaur, S., Gupta, S., Gupta, D., Juneja, S., Nauman, A., Khan, M., Husain, I., Islam, A., & Mallik, S. (2025). High-accuracy lung disease classification via logistic regression and advanced feature extraction techniques. *Egyptian Informatics Journal*, 29(December 2024), 100596. <https://doi.org/10.1016/j.eij.2024.100596>
- Kazemi, M. (2024). Support vector machine in ultrahigh-dimensional feature space. *Journal of Statistical Computation and Simulation*, 94(3), 517–535. <https://doi.org/10.1080/00949655.2023.2263128>
- Kilci, O., & Koklu, M. (2025). *4 th International Conference on Trends in Advanced MACHINE LEARNING-BASED DETECTION OF SOLAR PANEL SURFACE DEFECTS USING DEEP FEATURES FROM*. July.
- Laveda-Martínez, A., García-de-la-Puente, N. P., García-Torres, F., Israelsen, N. M., Bang, O., Brouczek, D., Benson, N., Colomer, A., & Naranjo, V. (2025). *Defect Segmentation in OCT scans of ceramic parts for non-destructive inspection using deep learning*. <http://arxiv.org/abs/2510.00745>
- Mariyadi, B., Fitriyani, N., & Sahroni, T. R. (2021). 2D Detection Model of Defect on the Surface of Ceramic Tile by an Artificial Neural Network. *Journal of Physics: Conference Series*, 1764(1). <https://doi.org/10.1088/1742-6596/1764/1/012176>
- Mat Jizat, J. A., P.P. Abdul Majeed, A., Ahmad, A. F., Taha, Z., & Yuen, E. (2021). Evaluation of the machine learning classifier in wafer defects classification. *ICT Express*, 7(4), 535–539. <https://doi.org/10.1016/j.icte.2021.04.007>
- Ohemu, M. F. (2021). *DEVELOPMENT OF AUTOMATED CERAMIC TILES SURFACE DEFECT DETECTION AND CLASSIFICATION SYSTEM*. 8(8), 200–208.
- Pardo, C. N., Sabri, L. M., & Awwaluddin, M. (2019). No Title. *Jurnal Geodesi Undip; Volume 9, Nomor 1, Tahun 2020*. <https://doi.org/10.14710/jgundip.2020.26181>
- Sun, Z. (2026). *Parts Surface Defect Detection Algorithm Based on Improved YOLOv8s*. <https://doi.org/10.1002/eng2.70569>
- Tahirovi, E. (2023). *Interpretability and Explainability of Logistic Regression Model for Breast Cancer Detection*. 3(Icaart), 161–168. <https://doi.org/10.5220/0011627600003393>
- Wang, B. S., & Zhang, L. (2025). *Deep Learning for Ceramic Surface Defect Inspection : A State-of-the-Art Survey*. 14, 1–14. <https://doi.org/10.4416/JCST2025-00011>
- Zhang, P., Wang, R., & Xiu, N. (2022). Neurocomputing Multinomial logistic regression classifier via l q ; 0 -proximal Newton algorithm. *Neurocomputing*, 468, 148–164. <https://doi.org/10.1016/j.neucom.2021.10.005>