



Classification of Insulator Conditions Using Logistic Regression and Support Vector Machine with Image Analysis Based on VGG-16, VGG-19, and Inception V3

Klasifikasi Kondisi Isolator Menggunakan Logistic Regression dan Support Vector Machine dengan Analisis Citra Berbasis VGG-16, VGG-19, dan Inception V3

Aris Purwaningtyas^{1*}, Imam Yuadi²

¹Master's Program in Human Resource Development, Postgraduate School,
Universitas Airlangga, Indonesia

²Department of Information and Library Science, Faculty of Social and Political Sciences,
Universitas Airlangga, Indonesia

E-Mail: ¹aris.purwaningtyas-2025@pasca.unair.ac.id, ²imam.yuadi@fisip.unair.ac.id

Received Mar 29th 2026; Revised May 08th 2026; Accepted May 28th 2026; Available Online Jun 26th 2026

Corresponding Author: Aris Purwaningtyas

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

The reliability of power systems largely depends on the condition of insulators, which are critical components that prevent electrical leakage. Insulator failures can lead to major power outages. Although Unmanned Aerial Vehicle (UAV)-based inspections have been widely adopted, visual assessment is still performed manually, making it subjective, inconsistent, and time-consuming. This study proposes an automated image-based insulator condition classification pipeline using the Orange Data Mining platform. Three pre-trained Deep Convolutional Neural Network (DCNN) models VGG-16, VGG-19, and Inception V3 were employed as feature extractors to generate high-level feature representations, while Logistic Regression and Support Vector Machine (SVM) were used as classifiers to distinguish between normal and contaminated insulators. The dataset comprised 168 ceramic and glass insulator images collected through UAV-based field inspections. Model performance was evaluated using 5-fold stratified cross-validation to maintain balanced class distributions across all folds. Experimental results demonstrated that the VGG-19 + Logistic Regression combination achieved the best performance, with an accuracy (CA) of 96.4%, an AUC of 0.986, and a Matthews Correlation Coefficient (MCC) of 0.929, while reducing the false positive rate to only 3.6%. These findings demonstrate the effectiveness of the hybrid DCNN-machine learning approach for automated early detection of insulator defects.

Keywords: *Deep Learning, Image Classification, Insulator, Logistic Regression, Predictive Maintenance, SVM, VGG.*

Abstrak

Keandalan sistem ketenagalistrikan sangat bergantung pada kondisi isolator sebagai komponen yang mencegah kebocoran arus listrik, karena rusaknya dapat memicu gangguan hingga pemadaman berskala luas. Meskipun inspeksi menggunakan Unmanned Aerial Vehicle (UAV) semakin banyak diterapkan, analisis visual masih dilakukan secara manual sehingga cenderung subjektif, tidak konsisten, dan memerlukan waktu yang lama. Penelitian ini mengembangkan sistem klasifikasi kondisi isolator berbasis citra menggunakan platform Orange Data Mining. Model pre-trained Deep Convolutional Neural Network (DCNN), yaitu VGG-16, VGG-19, dan Inception V3, dimanfaatkan sebagai feature extractor, sedangkan Logistic Regression dan Support Vector Machine (SVM) digunakan sebagai algoritma klasifikasi untuk membedakan isolator normal dan terkontaminasi. Dataset terdiri atas 168 citra isolator keramik dan kaca yang diperoleh melalui inspeksi lapangan menggunakan drone. Evaluasi dilakukan menggunakan 5-fold stratified cross-validation untuk menjaga distribusi kelas pada setiap fold. Hasil menunjukkan bahwa kombinasi VGG-19 dan Logistic Regression memberikan performa terbaik dengan akurasi 96,4%, AUC 0,986, dan Matthews Correlation Coefficient (MCC) 0,929, serta menurunkan false positive menjadi 3,6%. Temuan ini menunjukkan efektivitas pendekatan hybrid DCNN-machine learning untuk deteksi dini kondisi isolator secara otomatis.

Kata Kunci: *Deep Learning, Isolator, Klasifikasi Citra, Logistic Regression, Pemeliharaan Prediktif, SVM, VGG*



1. PENDAHULUAN

Sistem ketenagalistrikan merupakan infrastruktur kritis yang menopang seluruh aktivitas modern, mulai dari industri hingga layanan kesehatan. Salah satu komponen vital dalam sistem ini adalah isolator, yang berfungsi mencegah kebocoran arus listrik dari konduktor ke struktur penyangga tower transmisi [1]. Kegagalan isolator dapat disebabkan oleh akumulasi kontaminan seperti debu, garam, dan polutan industri. Hal ini merupakan salah satu penyebab utama gangguan pada jaringan transmisi. Kerusakan isolator yang tidak terdeteksi secara dini dapat mengakibatkan flashover, lonjakan tegangan, kerusakan peralatan, hingga pemadaman listrik berskala luas yang berdampak signifikan [2]. Kondisi lingkungan dengan tingkat populasi tinggi mempercepat laju degradasi isolator, sehingga pemantauan kondisi secara rutin menjadi kebutuhan operasional yang sangat mendesak [3].

Inspeksi konvensional yang dilakukan oleh petugas di lapangan memiliki keterbatasan dalam hal efisiensi, cakupan geografis, dan objektivitas penilaian. Perkembangan teknologi *Unmanned Aerial Vehicle* (UAV) membuka peluang untuk akuisisi data citra isolator secara efisien di sepanjang jalur transmisi yang sulit dijangkau [4]. Namun, analisis data citra dalam volume besar masih memerlukan pendekatan otomatis yang andal. Di sinilah Convolutional Neural Network (CNN) berperan krusial. CNN adalah arsitektur *Deep Learning* yang dirancang khusus untuk memproses data berbentuk grid, seperti citra, dengan kemampuan mengekstrak fitur hierarkis secara otomatis, mulai dari tepi dan tekstur sederhana hingga pola semantik yang kompleks [5]. Liu et al. [6] mencatat bahwa otomatisasi berbasis *Deep Learning* menjadi kunci untuk mengatasi kesenjangan antara kapasitas pengumpulan data UAV dan kemampuan analisis manusia. Kemampuan ini menjadikan CNN sebagai tulang punggung sebagian besar sistem klasifikasi citra modern.

Sejumlah penelitian terdahulu telah membuktikan efektivitas CNN dalam inspeksi komponen kelistrikan. Liu et al. (2023) [2] melakukan tinjauan komprehensif terhadap lebih dari 100 studi deteksi cacat isolator berbasis *Deep Learning* dan menyimpulkan bahwa arsitektur CNN seperti ResNet dan VGG secara konsisten mencapai akurasi di atas 85% untuk klasifikasi kondisi isolator dalam berbagai skenario lingkungan. Das, L et al. (2023) [7] mengembangkan sistem identifikasi kerusakan isolator jaringan transmisi menggunakan citra aerial dan melaporkan akurasi hingga 89% dengan arsitektur *Deep Learning* berbasis *transfer learning*. Nejadbogar et al. (2022) [8] mengusulkan *framework Deep Learning* baru untuk pemantauan isolator dari citra UAV dan berhasil mencapai F1-score di atas 90% dengan mengintegrasikan mekanisme perhatian ke dalam arsitektur CNN standar. Tan dan Hu (2022) [9] secara khusus meneliti deteksi cacat permukaan pada isolator porselen dengan CNN berbasis *Deep Learning* dan melaporkan akurasi 93% setelah mengoptimalkan strategi augmentasi data untuk mengatasi keterbatasan *dataset*. Vigneshwaran et al. (2023) [10] mengembangkan sistem *dual-input* VGG CNN untuk mengenali lokasi lapisan polusi pada isolator polimer 11 kV dalam jaringan smart grid dan mencapai akurasi 95% dengan memanfaatkan kombinasi fitur visual dan termal. Zhang et al. [11] mengembangkan sistem deteksi isolator berbasis *Deep Learning* pada citra lapangan dengan akurasi kompetitif, sedangkan Haiba dan Ellwagad [12] membuktikan bahwa jaringan saraf tiruan konvensional juga mampu mengklasifikasikan isolator keramik yang cacat dengan tingkat akurasi yang memadai. Maduako et al. [13] mengkaji penerapan *Deep Learning* untuk berbagai jenis kesalahan komponen pada jaringan transmisi dan menyimpulkan bahwa pendekatan berbasis CNN dapat mengenali beragam pola kerusakan.

Meskipun hasil penelitian-penelitian tersebut menjanjikan, terdapat kesenjangan penelitian yang signifikan. Pertama, sebagian besar studi mengimplementasikan CNN secara *end-to-end* dengan pelatihan bobot dari awal (*from scratch*) atau *fine-tuning* penuh, yang membutuhkan sumber daya komputasi yang besar serta keahlian pemrograman yang tinggi. Kedua, studi komparatif sistematis mengenai efektivitas kombinasi beragam ekstraktor fitur DCNN (VGG-16, VGG-19, Inception V3) dengan algoritma klasifikasi tradisional (Logistic Regression, SVM) pada satu *platform* visual terintegrasi masih sangat terbatas. Ketiga, hampir tidak ada penelitian yang mengeksplorasi implementasi solusi inspeksi isolator melalui *platform* no-code/low-code yang dapat diakses langsung oleh praktisi utilitas listrik tanpa latar belakang *data science* yang mendalam.

Berdasarkan kesenjangan tersebut, penelitian ini mengembangkan *pipeline* klasifikasi kondisi isolator berbasis citra yang memanfaatkan kekuatan *transfer learning* dari model DCNN *pre-trained* sebagai ekstraktor fitur, dikombinasikan dengan algoritma klasifikasi *machine learning* tradisional yang efisien secara komputasional, serta diimplementasikan sepenuhnya dalam *platform* visual *Orange Data Mining*. Kebaruan penelitian ini terletak pada tiga aspek, yaitu (1) studi komparatif sistematis enam kombinasi model (tiga ekstraktor fitur $\times$ dua classifier) pada *dataset* citra isolator nyata dari inspeksi UAV; (2) demonstrasi bahwa akurasi $>90\%$ dapat dicapai tanpa pelatihan CNN *end-to-end* yang mahal; dan (3) validasi potensi *Orange Data Mining* sebagai *platform* pemeliharaan prediktif yang aksesibel bagi utilitas listrik dengan sumber daya komputasi dan keahlian pemrograman yang terbatas.

2. METODE PENELITIAN

Bagian ini menyajikan tinjauan literatur terkait algoritma yang digunakan dan penjelasan metodologi penelitian secara menyeluruh.

2.1. Tinjauan Literature

Deep Convolutional Neural Network (DCNN) dengan arsitektur *pre-trained* telah menjadi standar *de facto* dalam *transfer learning* untuk klasifikasi citra. VGG-16 dan VGG-19, yang dikembangkan oleh Simonyan dan Zisserman, adalah arsitektur CNN dengan kedalaman 16 dan 19 layer berbobot yang dikenal karena kesederhanaan dan konsistensi desainnya, serta menggunakan filter konvolusi berukuran 3×3 secara bertingkat [14]. Kekuatan arsitektur VGG terletak pada kemampuannya menangkap fitur hierarkis yang kaya, mulai dari tekstur lokal hingga representasi semantik secara global. *Layer fully connected fc2* pada VGG menghasilkan *feature vector* berdimensi 4096 yang kaya informasi, sehingga menjadi pilihan populer sebagai ekstraktor fitur dalam studi klasifikasi komponen kelistrikan. Shah et al. (2023) [14] membandingkan performa Inception V3, VGG-16, VGG-19, CNN, dan ResNet-50 untuk deteksi penyakit tanaman padi dan menemukan bahwa VGG-16 dan VGG-19 memberikan performa yang stabil dan konsisten, meskipun Inception V3 unggul dalam akurasi secara keseluruhan. Vigneshwaran et al. (2023) [10] juga memvalidasi keunggulan arsitektur VGG untuk klasifikasi kondisi isolator polimer dalam konteks smart grid. Zhai et al. [15] sebelumnya telah menunjukkan bahwa fitur berbasis saliency dari permukaan isolator dapat diekstrak secara efektif untuk mendeteksi kerusakan. Hal ini menjadi dasar bagi pendekatan deteksi berbasis fitur visual yang digunakan dalam studi-studi berikutnya.


Inception V3, dikembangkan oleh Szegedy et al., merupakan arsitektur CNN generasi ketiga dari keluarga Inception (GoogLeNet) yang menggunakan modul Inception multi-skala untuk mengekstrak fitur pada berbagai resolusi secara paralel. Pendekatan multi-scale processing ini memungkinkan Inception V3 menangkap detail visual yang lebih halus dengan efisiensi komputasional yang lebih baik dibandingkan dengan VGG [16]. Mujahid et al. (2021) [16] mendemonstrasikan superioritas Inception V3 dibandingkan dengan arsitektur lain untuk tugas klasifikasi citra medis yang kompleks, dengan akurasi mencapai 95,3% pada *dataset pneumonia X-ray*. Kemampuan Inception V3 dalam menangkap pola multiskala sangat relevan untuk deteksi kontaminasi isolator, di mana kerusakan dapat bermanifestasi dalam berbagai skala visual, dari noda lokal kecil hingga perubahan warna permukaan yang menyeluruh. Kumar et al. (2022) [17] mengembangkan model *hybrid VI-NET* yang menggabungkan keunggulan VGG dan Inception V3, dan melaporkan peningkatan akurasi yang signifikan dibandingkan dengan menggunakan salah satu arsitektur saja untuk tugas *copy-move forgery detection*.

Dari sisi algoritma klasifikasi, Logistic Regression merupakan model linear generatif yang terbukti efektif untuk klasifikasi biner dan multikelas ketika fitur input telah melalui ekstraksi yang komprehensif. Keunggulan Logistic Regression terletak pada interpretabilitasnya yang tinggi, waktu pelatihan yang cepat, dan ketahanannya terhadap *overfitting* pada ruang fitur berdimensi tinggi dengan regularisasi yang tepat [7]. Das et al. (2023) [7] memvalidasi efektivitas Logistic Regression sebagai model deteksi anomali untuk inspeksi isolator jaringan listrik, menekankan pentingnya MCC sebagai metrik evaluasi utama untuk menangani ketidakseimbangan kelas. Support Vector Machine (SVM) adalah algoritma *supervised learning* yang mencari *hyperplane* pemisah optimal dengan margin maksimum di ruang fitur berdimensi tinggi. Penggunaan fungsi kernel, khususnya *Radial Basis Function* (RBF), memungkinkan SVM menangkap batas keputusan non-linear yang kompleks dalam data fitur hasil ekstraksi DCNN [9]. Tan dan Hu (2022) [9] secara spesifik mendemonstrasikan efektivitas SVM dengan kernel RBF untuk mengklasifikasikan cacat permukaan isolator porselen. Hasil penelitian menunjukkan performa yang kompetitif terutama pada skenario *dataset* dengan distribusi kelas tidak merata. Yin et al. [18] mengonfirmasi bahwa gabungan ekstraksi fitur otomatis dengan classifier konvensional menghasilkan sistem deteksi defect yang efisien untuk lingkungan industri.

Namun, penelitian-penelitian tersebut memiliki beberapa keterbatasan yang menjadi motivasi bagi penelitian ini. Liu et al. (2024) [2] dan Ahmed et al. (2021) [1] mengimplementasikan CNN *end-to-end* yang membutuhkan GPU kelas tinggi dan keahlian *deep learning* yang mendalam, sehingga sulit direplikasi oleh praktisi utilitas. Nejadbougar et al. (2022) [8] menggunakan *framework* kustom yang tidak tersedia sebagai *platform* siap pakai. Kumar et al. (2022) [17] meneliti domain yang berbeda (deteksi pemalsuan citra), sehingga validasinya dalam konteks inspeksi isolator masih terbatas. Tan dan Hu (2022) [9] serta Vigneshwaran et al. (2023) [10] hanya mengeksplorasi satu arsitektur CNN tanpa studi komparatif yang sistematis. Dari keterbatasan-keterbatasan ini, penelitian ini mengisi kesenjangan dengan mengusulkan *pipeline* terintegrasi dalam *platform* visual *Orange Data Mining* yang memungkinkan studi komparatif sistematis antarmodel sekaligus menjamin aksesibilitas implementasi bagi utilitas listrik.

2.2. Alur Penelitian

Kerangka kerja penelitian ini dirancang secara sistematis melalui enam tahapan utama yang saling berkaitan, sebagaimana diilustrasikan pada Gambar 1: (1) *Data collection*, (2) *Data preprocessing*, (3) *Deep feature extraction*, (4) *Classification*, (5) *Model Evaluation*, dan (6) *Results and analysis*. Pendekatan ini memastikan reproduktibilitas dan validitas ilmiah dari seluruh proses. Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.3. Data collection

Dataset penelitian ini diperoleh dari inspeksi lapangan di gardu induk dan jaringan transmisi menggunakan *drone inspection*. Sebanyak 168 citra isolator keramik dan isolator kaca dikumpulkan dengan variasi kondisi lingkungan yang beragam, meliputi perbedaan sudut pengambilan gambar, intensitas cahaya, dan latar belakang. Seluruh citra kemudian dianotasi dan dikategorikan ke dalam dua kelas kondisi, yaitu normal (84 citra) dan terkontaminasi (84 citra), sehingga *dataset* memiliki distribusi kelas yang seimbang. Kelas normal mencakup isolator dalam kondisi bersih tanpa akumulasi kontaminan yang signifikan, sementara kelas terkontaminasi mencakup isolator dengan akumulasi debu, garam, lumpur, atau polutan industri yang dapat menyebabkan *flashover*. Keseimbangan *dataset* ini penting untuk memastikan validitas evaluasi model menggunakan metrik seperti MCC yang sensitif terhadap distribusi kelas.

2.4. Data preprocessing

Setelah akuisisi, seluruh citra menjalani tahap *preprocessing* untuk memastikan keseragaman format dan kualitas data. Normalisasi ukuran dilakukan dengan mengubah resolusi setiap citra menjadi 4000×3000 piksel. Augmentasi data diterapkan secara selektif untuk meningkatkan keberagaman data latih dan ketahanan model terhadap variasi kondisi lapangan. Teknik augmentasi yang diterapkan meliputi rotasi ± 30 derajat untuk mensimulasikan variasi sudut kamera *drone*, *flipping* horizontal dan vertikal untuk mengatasi invariansi orientasi, serta *adjustment brightness* $\pm 20\%$ untuk mensimulasikan variasi kondisi pencahayaan di lapangan.

2.5. Deep feature extraction

Data gambar kemudian diekstraksi menggunakan tiga model *pre-trained* DCNN yaitu VGG-16, VGG-19, dan inception V3.

VGG-16 adalah arsitektur CNN dengan 16 layer berbobot yang terdiri dari 13 layer konvolusi dan 3 *Layer fully connected*, diakhiri dengan *layer softmax* untuk klasifikasi ImageNet. Dalam penelitian ini, embedding diekstraksi dari layer fc2 (*fully connected* kedua) sebelum *layer softmax*, menghasilkan *feature vector* berdimensi 4096 per citra. Layer fc2 dipilih karena mampu menangkap representasi semantik tingkat tinggi yang relevan untuk klasifikasi kondisi isolator, sebagaimana telah divalidasi dalam berbagai studi deteksi komponen kelistrikan [1]. *Feature vector* berdimensi 4096 ini kemudian menjadi input untuk algoritma klasifikasi.

VGG-19 merupakan pengembangan VGG-16 dengan penambahan tiga layer konvolusi, menghasilkan total 19 layer berbobot. Kedalaman tambahan ini memungkinkan model mempelajari representasi fitur yang lebih kompleks dan hierarkis. Berbeda dari VGG-16, embedding pada VGG-19 diekstraksi dari *layer flatten* setelah blok konvolusi terakhir, menghasilkan *feature vector* yang mempertahankan informasi spasial yang penting untuk mendeteksi distribusi kontaminasi lokal pada permukaan isolator [9].

Inception V3 merupakan arsitektur CNN generasi ketiga dari keluarga GoogLeNet yang menggunakan modul inception paralel untuk memproses citra pada berbagai skala secara simultan. Modul

inception menggabungkan konvolusi berukuran 1×1 , 3×3 , dan 5×5 dalam satu layer, memungkinkan model menangkap fitur pada berbagai tingkat detail. Inception V3 juga menggunakan konvolusi yang difaktorkan (*factorized convolutions*) untuk meningkatkan efisiensi komputasional. Kemampuan *multi-scale processing* ini sangat sesuai untuk mendeteksi kontaminasi isolator yang dapat bermanifestasi dalam berbagai skala visual, dari granular kecil hingga area yang luas [16].

2.6. Classification

Feature vector yang dihasilkan dari tahap feature extraction selanjutnya digunakan sebagai input proses klasifikasi dengan menggunakan algoritma *machine learning*, yaitu Logistic Regression dan SVM.

Logistic Regression diimplementasikan sebagai model baseline untuk klasifikasi biner kondisi isolator (normal dan terkontaminasi). Model ini memetakan kombinasi linear dari *feature vector* DCNN ke dalam nilai probabilitas menggunakan fungsi sigmoid:

$$P(Y = 1 | X) = \frac{1}{1+e^{-z}}, z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1)$$

di mana β_0 adalah intercept, β_1 hingga β_n adalah bobot fitur yang dipelajari dari data, dan x_1 hingga x_n adalah komponen *feature vector* DCNN, dan e adalah bilangan natural Euler ($\approx 2,71828$). Jika $P(Y = 1 | X) \geq 0,5$, isolator diklasifikasikan sebagai terkontaminasi, sebaliknya dinyatakan normal.

Implementasi menggunakan pendekatan multinomial dengan optimizer L-BFGS dan regularisasi L2 (parameter $C = 1,0$) untuk mencegah *overfitting* pada ruang fitur berdimensi tinggi. Das et al. (2023) memvalidasi efektivitas Logistic Regression sebagai model deteksi anomali untuk inspeksi isolator, dan menekankan pentingnya MCC sebagai metrik evaluasi utama untuk menangani ketidakseimbangan kelas. Keunggulan utama Logistic Regression terletak pada interpretabilitasnya yang tinggi, waktu pelatihan yang cepat, serta ketahanannya terhadap *overfitting* melalui regularisasi yang tepat.

SVM diimplementasikan dengan fungsi kernel *Radial Basis Function* (RBF) yang terbukti efektif untuk menangkap pola non-linear dalam data fitur berdimensi tinggi hasil ekstraksi DCNN. Fungsi kernel RBF diformulasikan pada persamaan 2.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2)$$

di mana K adalah fungsi kernel yang mengukur kesamaan antara dua data point x_i dan x_j dalam ruang fitur berdimensi tinggi, $\|x_i - x_j\|^2$ adalah kuadrat dari jarak Euclidean antara kedua data point tersebut, dan γ (gamma) adalah parameter yang mengontrol lebar fungsi kernel atau seberapa jauh pengaruh satu data point latih terhadap batas keputusan. Nilai gamma yang kecil berarti pengaruhnya meluas jauh, sedangkan nilai yang besar membatasi pengaruhnya hanya pada area sekitar data point. Parameter C (*cost*) dan gamma dioptimalkan menggunakan grid search dengan validasi silang 5-fold untuk menemukan konfigurasi terbaik.

2.7. Model Evaluation

Evaluasi performa seluruh kombinasi model dilakukan menggunakan skema validasi silang 5-fold stratified, di mana *dataset* dibagi menjadi lima subset dengan proporsi kelas yang seimbang di setiap subset. Proses ini diulang lima kali dengan setiap subset berperan sebagai data uji sekali, sehingga seluruh data digunakan untuk pengujian. Metrik evaluasi yang digunakan mencakup *Classification Accuracy* (CA) sebagai proporsi prediksi yang benar terhadap total prediksi, *Area Under the ROC Curve* (AUC) sebagai ukuran kemampuan diskriminasi model terhadap kedua kelas secara keseluruhan, *F1-Score* sebagai harmonic mean antara precision dan recall, serta *Matthews Correlation Coefficient* (MCC) sebagai metrik utama karena kemampuannya memberikan evaluasi yang seimbang, bahkan pada *dataset* dengan distribusi kelas yang tidak merata [7]. Analisis hasil dilakukan secara komprehensif melalui dua pendekatan. Pertama, analisis confusion matrix dilakukan untuk mengidentifikasi pola misklasifikasi spesifik dan menghitung tingkat *false positive* serta *false negative* pada setiap kelas. Kedua, perbandingan antarmodel dilakukan menggunakan uji signifikansi statistik berbasis AUC untuk menentukan apakah perbedaan performa antarmodel signifikan secara praktis.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 168 citra isolator keramik dan kaca yang diperoleh dari kegiatan inspeksi lapangan menggunakan *drone* di sejumlah lokasi gardu induk dan jaringan transmisi. *Dataset* dibagi secara seimbang menjadi dua kelas, yaitu 84 citra isolator dalam kondisi normal dan 84 citra isolator dalam kondisi terkontaminasi. Kelas normal mencakup isolator dengan permukaan bersih tanpa akumulasi kontaminan yang berarti, sementara kelas terkontaminasi mencakup isolator yang mengalami penumpukan debu, garam, lumpur, atau polutan industri pada permukaannya. Keseimbangan

distribusi kelas ini disengaja untuk memastikan validitas evaluasi model, khususnya pada metrik *Matthews Correlation Coefficient* (MCC) yang sensitif terhadap ketimpangan distribusi kelas [7]. Variasi kondisi pengambilan citra yang meliputi perbedaan sudut kamera, intensitas cahaya, dan latar belakang tetap dipertahankan agar model terpapar pada kondisi lapangan yang representatif.

3.2. Ekstraksi Fitur

Setiap citra diproses melalui tiga model Deep Convolutional Neural Network (DCNN) *pre-trained* untuk menghasilkan representasi fitur tingkat tinggi. Seluruh bobot model dibekukan (frozen) selama proses ekstraksi sehingga tidak ada pembaruan parameter pada model backbone. Pendekatan ini merupakan keunggulan utama *transfer learning* berbasis ekstraksi fitur dibandingkan dengan *fine-tuning* penuh, yaitu kebutuhan komputasi yang jauh lebih rendah tanpa mengorbankan kualitas representasi fitur yang dihasilkan.

VGG-16 menghasilkan *feature vector* berdimensi 4.096 dari layer fc2, yang dipilih karena kemampuannya menangkap representasi semantik tingkat tinggi yang relevan untuk membedakan kondisi permukaan isolator [1]. VGG-19 menghasilkan *feature vector* dari layer *flatten* setelah blok konvolusi terakhir, yang mempertahankan informasi spasial terkait distribusi kontaminasi lokal [9]. Inception V3 menghasilkan multi-scale *feature vector* melalui layer global average pooling setelah blok Inception terakhir. Kemampuan multi-scale processing yang memproses fitur secara paralel menggunakan konvolusi 1×1, 3×3, dan 5×5 menjadikannya sangat sesuai untuk mendeteksi kontaminasi yang bervariasi pada skala visual [16].

3.3. Hasil Evaluasi dan Analisis Kinerja Model

Berdasarkan hasil pengujian enam kombinasi model yang terdiri dari tiga ekstraktor fitur berbasis *Deep Learning* (VGG-16, VGG-19, dan Inception V3) dengan dua classifier (Logistic Regression dan Support Vector Machine), diperoleh variasi performa yang signifikan antar kombinasi. Evaluasi dilakukan menggunakan sejumlah metrik komprehensif, meliputi *Classification Accuracy* (CA), Area Under Curve (AUC), F1-Score, *Matthews Correlation Coefficient* (MCC), Confusion Matrix (TP, FN, FP, TN), serta *False positive Rate* (FP Rate), sehingga penilaian tidak hanya bergantung pada satu indikator tunggal yang dapat menyesatkan pada kondisi distribusi kelas tertentu. Hasil evaluasi dirangkum secara terintegrasi dalam Tabel 1 untuk memudahkan perbandingan antarkombinasi model secara komprehensif.

Tabel 1. Hasil Evaluasi Terintegrasi: Metrik Kinerja dan Confusion Matrix Enam Kombinasi Model

Ekstraktor Fitur	Classifier	CA (%)	AUC	F1	MCC	Confusion Matrix				FP Rate (%)
						TP	FN	FP	TN	
VGG-16	Logistic Regression	92,3	0,975	0,923	0,845	78	6	7	77	8,33
VGG-16	SVM	86,9	0,959	0,869	0,741	77	7	15	69	17,9
VGG-19	Logistic Regression	96,4	0,986	0,964	0,929	81	3	3	81	3,6
VGG-19	SVM	91,1	0,971	0,911	0,911	77	7	8	76	9,5
Inception V3	Logistic Regression	92,9	0,979	0,929	0,857	75	9	4	80	4,8
Inception V3	SVM	92,3	0,980	0,923	0,847	74	10	5	79	6,0

Keterangan: TP = True Positive (terkontaminasi terdeteksi benar); FN = False Negative (terkontaminasi tidak terdeteksi); FP = False positive (normal salah terdeteksi); TN = True Negative (normal terdeteksi benar); FP Rate = $FP/(FP+TN) \times 100\%$

Kombinasi VGG-19 dengan Logistic Regression menunjukkan performa tertinggi di antara seluruh model yang diuji, dengan nilai CA sebesar 96,4%, AUC 0,986, F1-Score 0,964, MCC 0,929, serta FP Rate terendah sebesar 3,6%. Tingginya nilai MCC pada model ini mengindikasikan kualitas klasifikasi yang seimbang antara kelas positif dan negatif, bukan sekadar akurasi yang tinggi secara artifisial akibat ketidakseimbangan distribusi kelas. Keunggulan VGG-19 dibandingkan dengan VGG-16 dapat dikaitkan dengan kedalaman arsitekturnya yang lebih besar, yakni 19 lapisan konvolusional, yang memungkinkan ekstraksi representasi fitur visual yang lebih hierarkis dan diskriminatif. Temuan ini sejalan dengan Shah et al. [14] yang menyimpulkan bahwa VGG-19 secara konsisten menghasilkan performa lebih tinggi dibandingkan dengan VGG-16 pada tugas klasifikasi citra karena kapasitas representasionalnya yang lebih besar, serta dengan Vigneshwaran et al. [10] yang berhasil menerapkan arsitektur VGG pada klasifikasi kondisi isolator polimer dengan akurasi tinggi menggunakan pendekatan *dual-input*.

Di sisi lain, VGG-16 dengan classifier SVM mencatatkan performa terendah di antara seluruh model, dengan CA 86,9% dan FP Rate sebesar 17,9%. Nilai FP Rate yang tinggi ini memiliki implikasi praktis yang serius dalam konteks inspeksi infrastruktur kelistrikan, karena berarti hampir satu dari lima isolator yang sebenarnya dalam kondisi normal akan diklasifikasikan secara keliru sebagai rusak. Das et al. [7] dan Li et al. [5] menegaskan bahwa minimisasi *false positive* merupakan prioritas utama dalam sistem inspeksi otomatis pada jaringan transmisi, mengingat biaya tindak lanjut inspeksi fisik di lapangan sangat tinggi. Senada

dengan hal tersebut, Tan dan Hu [9] serta Odo [4] menekankan bahwa optimasi sistem berbasis *Deep Learning* tidak seharusnya berfokus semata pada akurasi keseluruhan, melainkan juga pada presisi deteksi guna mereduksi alarm palsu yang dapat membebani operasional jaringan. Mahapatra et al. [19] menambahkan bahwa alarm palsu yang berulang dapat mengikis kepercayaan operator pada sistem otomatis.

Inception V3 dengan kedua classifier menunjukkan performa yang kompetitif namun tidak mampu melampaui VGG-19, dengan CA berkisar antara 92,3% hingga 92,9%. Kesetaraan performa antara Logistic Regression dan SVM pada Inception V3 dengan selisih CA hanya 0,6%, mengindikasikan bahwa arsitektur ini kurang sensitif terhadap pemilihan classifier pada konteks *dataset* yang digunakan. Kondisi ini dapat dijelaskan oleh karakteristik modul inception yang mengutamakan efisiensi komputasi melalui konvolusi paralel, bukan kedalaman representasi murni. Mujahid et al. [16] mencatat bahwa Inception V3 menunjukkan efektivitas tinggi pada *dataset* medis berskala besar, namun pada *dataset* domain spesifik berukuran lebih terbatas seperti citra aerial isolator, arsitektur berbasis kedalaman murni seperti VGG-19 cenderung menghasilkan fitur yang lebih spesifik-domain. Pernyataan ini diperkuat oleh Liu et al. [2] dan Nejadbouggar et al. [8] yang menyimpulkan bahwa kedalaman arsitektur model merupakan faktor determinan dalam deteksi defek isolator berbasis *Deep Learning*.

Secara umum, terdapat pola konsisten bahwa Logistic Regression mengungguli SVM pada seluruh ekstraktor fitur yang diujikan. Fenomena ini dapat dijelaskan oleh karakteristik ruang fitur yang dihasilkan oleh ekstraktor berbasis CNN dimana fitur *Deep Learning* cenderung telah terpisah secara linear dalam ruang laten berdimensi tinggi, sehingga classifier linear seperti Logistic Regression sudah memadai untuk memisahkan kelas tanpa memerlukan transformasi kernel yang menjadi keunggulan SVM. Selain itu, Logistic Regression menunjukkan stabilitas optimasi yang lebih baik pada ruang fitur bervolume tinggi dibandingkan dengan SVM yang sensitif terhadap pemilihan hyperparameter. Hal ini selaras dengan temuan Kumar et al. [17] yang mengembangkan model *hybrid* berbasis VGG dan Inception V3 dan menyimpulkan bahwa kombinasi *transfer learning* dengan classifier sederhana secara linear dapat menghasilkan akurasi optimal tanpa kompleksitas komputasi berlebih. Ahmed et al. [1] juga mengonfirmasi bahwa pendekatan berbasis fitur *Deep Learning* dengan classifier konvensional mampu mencapai performa inspeksi yang tinggi pada kondisi citra aerial yang bervariasi.

Berdasarkan keseluruhan analisis di atas, kombinasi VGG-19 sebagai ekstraktor fitur dan Logistic Regression sebagai classifier merupakan konfigurasi optimal yang direkomendasikan untuk diimplementasikan dalam sistem inspeksi isolator otomatis berbasis citra. Model ini tidak hanya unggul pada seluruh metrik evaluasi kuantitatif, tetapi juga memiliki FP Rate terendah yang menjamin keandalan praktis dalam skenario deployment nyata pada jaringan transmisi daya listrik.

3.4. Diskusi

Dari keseluruhan data pada Tabel 1, tiga temuan utama dapat disintesis secara sistematis. Pertama, pemilihan ekstraktor fitur berbasis DCNN terbukti memberikan dampak yang jauh lebih determinan terhadap performa sistem klasifikasi dibandingkan dengan pemilihan algoritma klasifikasi. Hal ini tercermin dari rentang variasi CA antarekstraktor fitur yang mencapai hingga 9,5 poin (86,9% pada VGG-16 dengan SVM dan 96,4% pada VGG-19 dengan Logistic Regression), sementara pergantian classifier pada ekstraktor yang sama hanya menghasilkan variasi sebesar 1,1% hingga 5,4%. VGG-19 secara konsisten mengungguli VGG-16 pada kedua classifier dengan peningkatan CA sebesar 4,1–4,2 poin dan penurunan FP Rate yang signifikan, dari 8,33% menjadi 3,6% pada Logistic Regression dan dari 17,9% menjadi 9,5% pada SVM. Keunggulan ini dapat dikaitkan dengan kapasitas representasional VGG-19 yang lebih tinggi akibat penambahan tiga lapisan konvolusional dibandingkan dengan VGG-16, yang memungkinkan model menangkap fitur tekstural dan struktural pada tingkat abstraksi yang lebih dalam. Nejadbouggar et al. [8] menjelaskan bahwa kedalaman arsitektur konvolusional secara langsung memengaruhi kemampuan model dalam membedakan pola degradasi halus pada permukaan isolator dari citra udara, sementara Shah et al. [14] mengonfirmasi bahwa VGG-19 secara konsisten mengungguli VGG-16 pada tugas klasifikasi citra domain spesifik karena kapasitas ekstraksi fitur hierarkisnya yang lebih kaya. Adapun Inception V3 menunjukkan performa yang kompetitif dengan CA berkisar antara 92,3% hingga 92,9%, namun tidak mampu melampaui VGG-19 pada konfigurasi Logistic Regression. Karakteristik modul Inception yang mengutamakan efisiensi komputasi melalui konvolusi paralel multiskala, menjadikan arsitektur ini lebih adaptif pada *dataset* berskala besar, sedangkan pada *dataset* domain spesifik berukuran terbatas, arsitektur berbasis kedalaman sekuensial seperti VGG-19 cenderung menghasilkan representasi fitur yang lebih spesifik domain dan diskriminatif [16].

Kedua, Logistic Regression secara konsisten mengungguli SVM dalam metrik CA dan MCC di seluruh arsitektur DCNN yang diuji, dengan selisih CA berkisar antara 0,6% pada Inception V3 hingga 5,4% pada VGG-16, dan selisih MCC antara 0,010 pada Inception V3 hingga 0,104 pada VGG-16. Temuan ini selaras dengan Das et al. [7] yang memvalidasi keunggulan Logistic Regression dengan regularisasi L2 untuk deteksi anomali isolator pada ruang fitur berdimensi tinggi, dengan argumen bahwa fitur yang diekstrak oleh lapisan konvolusional cenderung telah terpisah secara linear di ruang laten, sehingga classifier linear sudah

memadai tanpa memerlukan transformasi kernel yang menjadi keunggulan SVM. Dalam konteks pemeliharaan prediktif infrastruktur kelistrikan, metrik CA dan MCC lebih relevan sebagai dasar pemilihan model dibandingkan dengan AUC semata, karena keduanya mencerminkan kinerja aktual model pada ambang keputusan yang digunakan secara operasional. Hal ini ditegaskan oleh Tan dan Hu [9] yang menyatakan bahwa evaluasi sistem deteksi defek isolator harus mempertimbangkan profil kesalahan secara menyeluruh, bukan hanya performa pada kurva ROC yang mengasumsikan ambang keputusan yang bergerak. Lebih lanjut, konsistensi antara ranking MCC dan ranking FP Rate yang ditemukan dalam penelitian ini, di mana model dengan MCC tertinggi secara bersamaan memiliki FP Rate terendah, memperkuat relevansi MCC sebagai metrik evaluasi utama, sebagaimana direkomendasikan oleh Ahmed et al. [1] yang mengemukakan bahwa MCC merupakan indikator paling representatif untuk menilai keandalan sistem inspeksi visual berbasis kecerdasan buatan karena kemampuannya memperhitungkan seluruh sel confusion matrix secara proporsional dan simetris.

Ketiga, seluruh enam kombinasi model yang diuji memenuhi ambang batas minimum kelayakan implementasi di atas 85% yang ditetapkan oleh Liu et al. [2] sebagai syarat minimum bagi sistem inspeksi isolator berbasis *Deep Learning* untuk dapat dipertimbangkan dalam deployment lapangan. Konfigurasi terbaik, yakni VGG-19 dengan Logistic Regression, bahkan melampaui persyaratan akurasi di atas 90% yang ditetapkan untuk sistem pemeliharaan prediktif tingkat lanjut, sekaligus memvalidasi efektivitas pendekatan *hybrid DCNN-machine learning* secara keseluruhan. Nejadbougar et al. [8] memvalidasi bahwa sistem inspeksi isolator berbasis *Deep Learning* yang mencapai F1-Score di atas 90% dari citra UAV layak diimplementasikan dalam kondisi lapangan nyata, dan konfigurasi terbaik dalam penelitian ini memenuhi kriteria tersebut dengan F1-Score 0,964 dan AUC 0,986 mengindikasikan kemampuan diskriminasi yang sangat tinggi terhadap kondisi normal dan abnormal isolator. Vigneshwaran et al. [10] dan Li et al. [5] secara bersamaan menegaskan bahwa sistem berbasis *Deep Learning* dengan akurasi di atas 90% dan FP Rate di bawah 5% memiliki kesiapan implementasi yang memadai untuk mendukung operasi pemeliharaan jaringan transmisi secara otomatis, dan model VGG-19 dengan Logistic Regression dalam penelitian ini memenuhi kedua kriteria tersebut secara simultan dengan CA 96,4% dan FP Rate 3,6%. Dengan demikian, hasil penelitian ini tidak hanya memvalidasi kelayakan teknis pendekatan *hybrid DCNN-machine learning*, tetapi juga memberikan kontribusi empiris terhadap pemilihan konfigurasi arsitektur yang optimal untuk sistem inspeksi isolator otomatis berbasis citra aerial, sejalan dengan arah riset terkini yang dirangkum oleh Liu et al. [2] dan Odo [4] mengenai pentingnya evaluasi multidimensi dalam pengembangan sistem inspeksi infrastruktur kelistrikan yang dapat diandalkan secara operasional. Maduako et al. [13] menambahkan bahwa validasi pada data lapangan nyata seperti yang dilakukan dalam penelitian ini dapat meningkatkan tingkat kepercayaan hasil dibandingkan dengan pengujian pada data benchmark generik.

3.5. Implikasi terhadap Sistem Pemeliharaan Prediktif

Konfigurasi optimal yang diperoleh, yaitu VGG-19 sebagai ekstraktor fitur dan Logistic Regression sebagai classifier, memiliki potensi implementasi yang nyata dalam sistem pemeliharaan prediktif jaringan transmisi. Pendekatan *hybrid DCNN-machine learning* ini tidak memerlukan GPU kelas tinggi untuk pelatihan karena seluruh bobot DCNN dibekukan dan hanya Logistic Regression yang dilatih dari data, sehingga memungkinkan implementasinya pada perangkat edge computing berkapasitas menengah di ruang kontrol gardu induk.

Dari aspek ekonomi, penurunan FP Rate dari 17,9% (VGG-16) menjadi 3,6% (VGG-19) berarti dalam skala inspeksi 1.000 isolator, sistem ini hanya menghasilkan 36 alarm palsu dibandingkan dengan 179 alarm palsu dengan VGG-16. Hal ini berpotensi menghemat biaya inspeksi lapangan yang tidak perlu. Tim pemeliharaan dapat memprioritaskan isolator yang benar-benar membutuhkan penanganan dengan lebih akurat, sehingga alokasi sumber daya dapat dioptimalkan secara lebih efektif.

Meskipun demikian, penelitian ini memiliki keterbatasan yang perlu diakui. Ukuran *dataset* (168 citra) masih tergolong kecil untuk memvalidasi generalisasi model pada berbagai jenis, merek, dan kondisi lingkungan isolator yang lebih beragam. Integrasi data dari berbagai sumber, seperti pengukuran partial discharge atau data termal dari sensor inframerah, berpotensi meningkatkan akurasi dan keandalan sistem secara substansial serta menjadi arah penelitian yang perlu dieksplorasi lebih lanjut.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengevaluasi kerangka kerja otomatis untuk klasifikasi kondisi isolator berbasis citra menggunakan *platform Orange Data Mining* dengan pendekatan *transfer learning*. Dari evaluasi sistematis enam kombinasi model menggunakan validasi silang 5-fold stratified pada *dataset* 168 citra isolator lapangan, diperoleh beberapa kesimpulan utama. Konfigurasi terbaik adalah kombinasi VGG-19 sebagai ekstraktor fitur dengan Logistic Regression sebagai classifier, yang mencapai akurasi 96,4%, AUC 0,986, MCC 0,929, dan berhasil menekan *false positive* hingga hanya 3,6%. Hal ini memenuhi persyaratan akurasi >90% untuk implementasi pemeliharaan prediktif. Logistic Regression secara konsisten mengungguli SVM, hal ini menjadikannya pilihan classifier yang lebih sesuai untuk kasus

ini. Seluruh 6 kombinasi model memenuhi ambang batas kelayakan implementasi >85%, membuktikan efektivitas pendekatan *hybrid DCNN-machine learning* secara keseluruhan.

Kelebihan utama penelitian ini meliputi: (1) demonstrasi bahwa akurasi >90% dapat dicapai melalui ekstraksi fitur DCNN tanpa *fine-tuning end-to-end* yang membutuhkan GPU kelas tinggi; (2) implementasi pada platform visual Orange Data Mining yang dapat diakses oleh praktisi utilitas tanpa keahlian pemrograman; (3) pengurangan false positive yang signifikan (dari 17,9% menjadi 3,6%) yang berimplikasi langsung pada penghematan biaya inspeksi lapangan; dan (4) studi komparatif sistematis yang memberikan panduan konkret untuk pemilihan konfigurasi model yang optimal.

Namun, penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Pertama, ukuran *dataset* (168 citra) relatif kecil; generalisasi model ke berbagai jenis dan merek isolator, serta kondisi lingkungan yang lebih beragam, memerlukan *dataset* yang lebih besar [20]. Kedua, tahap ekstraksi fitur DCNN masih membutuhkan sumber daya komputasi yang cukup signifikan, yang dapat menjadi tantangan pada perangkat edge dengan kapasitas terbatas. Ketiga, sistem ini hanya mengandalkan data citra visual. Integrasi dengan data sensor lain seperti Partial Discharge (PD) berpotensi meningkatkan akurasi dan keandalan sistem secara substansial.

REFERENSI

- [1] M. F. Ahmed, J. C. Mohanta, and A. Sanyal, "Inspection and identification of transmission line insulator breakdown based on *Deep Learning* using aerial images," *Electric Power Systems Research*, vol. 211, Oct. 2022, doi: 10.1016/j.epsr.2022.108199.
- [2] J. Liu, M. M. Hu, J. Y. Dong, and X. Lu, "Summary of insulator defect detection based on *Deep Learning*," Nov. 01, 2023, *Elsevier Ltd.* doi: 10.1016/j.epsr.2023.109688.
- [3] H. de Santos and M. Sanz-Bobi, "A *machine learning* approach for condition monitoring of high voltage insulators in polluted environments," *Electric Power Systems Research*, vol. 220, Jul. 2023, doi: 10.1016/j.epsr.2023.109340.
- [4] A. Odo, S. McKenna, D. Flynn, and J. B. Vorstius, "Aerial Image Analysis Using *Deep Learning* for Electrical Overhead Line Network Asset Management," *IEEE Access*, vol. 9, pp. 146281–146295, 2021, doi: 10.1109/ACCESS.2021.3123158.
- [5] D. Li, X. Wang, J. Zhang, and Z. Ji, "Automated *Deep Learning* system for power line inspection image analysis and processing: Architecture and design issues," *Global Energy Interconnection*, vol. 6, no. 5, pp. 614–633, Oct. 2023, doi: 10.1016/j.gloi.2023.10.008.
- [6] X. Liu, X. Miao, H. Jiang, and J. Chen, "Data analysis in visual power line inspection: An in-depth review of *Deep Learning* for component detection and fault diagnosis," Jan. 01, 2020, *Elsevier Ltd.* doi: 10.1016/j.arcontrol.2020.09.002.
- [7] L. Das, B. Gjorgiev, and G. Sansavini, "An improved anomaly detection model for automated inspection of power line insulators," *Eng. Appl. Artif. Intell.*, vol. 158, Oct. 2025, doi: 10.1016/j.engappai.2025.111431.
- [8] R. Rahimi Nejadbougar, E. Ghanbari Parmehr, A. Afary, and S. Mavaddati, "A new *Deep Learning framework* for intelligent aerial monitoring of power transmission line insulators," *Eng. Appl. Artif. Intell.*, vol. 161, Dec. 2025, doi: 10.1016/j.engappai.2025.112290.
- [9] L. Tan and Y. Hu, "Accurate Detection and *Classification* of Surface Defects in Electric Porcelain Insulators Based on *Deep Learning* Intelligent Algorithms," in *Procedia Computer Science*, Elsevier B.V., 2025, pp. 582–588. doi: 10.1016/j.procs.2025.04.248.
- [10] B. Vigneshwaran *et al.*, "Recognition of pollution layer location in 11 kV polymer insulators used in smart power grid using *dual-input* VGG Convolutional Neural Network," *Energy Reports*, vol. 7, pp. 7878–7889, Nov. 2021, doi: 10.1016/j.egy.2020.12.044.
- [11] J. Zhang, T. Xiao, M. Li, and Y. Zhou, "Deep-Learning-Based Detection of Transmission Line Insulators," *Energies (Basel)*, vol. 16, no. 14, Jul. 2023, doi: 10.3390/en16145560.
- [12] A. S. Haiba and A. Eliwa Gad, "Artificial neural network analysis for *Classification* of defected high voltage ceramic insulators," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-51860-8.
- [13] I. Maduako *et al.*, "*Deep Learning* for component fault detection in electricity transmission lines," *J. Big Data*, vol. 9, no. 1, Dec. 2022, doi: 10.1186/s40537-022-00630-2.
- [14] S. R. Shah, S. Qadri, H. Bibi, S. M. W. Shah, M. I. Sharif, and F. Marinello, "Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease," *Agronomy*, vol. 13, no. 6, Jun. 2023, doi: 10.3390/agronomy13061633.
- [15] Y. Zhai, D. Wang, M. Zhang, J. Wang, and F. Guo, "Fault detection of insulator based on saliency and adaptive morphology," *Multimed. Tools Appl.*, vol. 76, no. 9, pp. 12051–12064, May 2017, doi: 10.1007/s11042-016-3981-2.
- [16] M. Mujahid, F. Rustam, R. Álvarez, J. Luis Vidal Mazón, I. de la T. Díez, and I. Ashraf, "Pneumonia *Classification* from X-ray Images with Inception-V3 and Convolutional Neural Network," *Diagnostics*, vol. 12, no. 5, May 2022, doi: 10.3390/diagnostics12051280.

- [17] S. Kumar, S. K. Gupta, M. Kaur, and U. Gupta, "VI-NET: A *hybrid* deep convolutional neural network using VGG and inception V3 model for copy-move forgery *Classification*," *J. Vis. Commun. Image Represent.*, vol. 89, Nov. 2022, doi: 10.1016/j.jvcir.2022.103644.
- [18] X. Yin, Y. Zuo, and G. Fu, "Design of intelligent detection method for electricity transmission line equipment defect based on data mining algorithm," *International Journal of Thermofluids*, vol. 24, Nov. 2024, doi: 10.1016/j.ijft.2024.100814.
- [19] U. Mahapatra, M. A. Rahman, M. R. Islam, M. A. Hossain, M. R. I. Sheikh, and M. J. Hossain, "Adversarial training-based robust model for transmission line's insulator defect *Classification* against cyber-attacks," *Electric Power Systems Research*, vol. 245, Aug. 2025, doi: 10.1016/j.epsr.2025.111585.
- [20] J. Y. Lim, K. M. Lim, C. P. Lee, and Y. X. Tan, "A review of few-shot image *Classification*: Approaches, *datasets* and research trends," Oct. 07, 2025, *Elsevier B.V.* doi: 10.1016/j.neucom.2025.130774.