

BAB II

LANDASAN TEORI

2.1 Panel Surya dan Jenis Kecacatan

Sistem fotovoltaik (PV) merupakan teknologi pembangkit listrik tenaga surya yang mengonversi energi cahaya menjadi energi listrik. Dalam beberapa dekade terakhir, sistem ini semakin menempati posisi strategis dalam penyediaan energi terbarukan yang berkelanjutan. Ilustrasi pada Gambar 2.1 memperlihatkan gambaran mengenai pembangkit listrik tenaga surya (*solar power plant*).




Gambar 2.1 *Solar power plant*

Ilustrasi tersebut menjadi basis pemahaman terhadap potensi permasalahan yang muncul sepanjang siklus operasional. Secara umum, pemeliharaan modul diklasifikasikan menjadi tiga kategori, yaitu preventif, korektif, dan prediktif (Abubakar dkk., 2021). Pemeliharaan preventif meliputi inspeksi terjadwal, servis, pengencangan konektor, serta pembersihan modul guna mencegah kegagalan, meskipun berpotensi menambah biaya kunjungan, strategi ini menekan resiko gangguan dini. Pemeliharaan korektif biasa dilakukan setelah muncul gangguan

memerlukan biaya perbaikan dan *downtime*. Sementara itu, pemeliharaan prediktif memanfaatkan data operasi untuk memproyeksikan potensi kegagalan sehingga intervensi dapat dijadwalkan secara proaktif.

Sepanjang siklus hidup, mulai dari manufaktur, pemasangan, hingga operasi, panel surya mengalami berbagai tekanan lingkungan dan mekanik yang berdampak pada degradasi performa pembangkitan listrik. Studi melaporkan penurunan pembangkitan tahunan pada kisaran 3,6–18,9% serta penurunan efisiensi sistem sekitar 0,5–1% yang dipengaruhi faktor lingkungan, kelistrikan, dan operasional (Thakfan & Bin Salamah, 2024). Keragaman gangguan tersebut dipetakan melalui taksonomi kecacatan yang ditunjukkan pada Gambar 2.2.




Gambar 2.2 Jenis kecacatan pada panel surya (Thakfan & Bin Salamah, 2024)

Jenis cacat dari perspektif sifat/lingkungan, cacat dapat berupa fisik/struktural (retakan, delaminasi, korosi, *discoloration*), kelistrikan (*mismatch*, kegagalan dioda *bypass*, gangguan DC/AC), serta lingkungan (*hotspots*, *partial shading*, ketidakseragaman iradiasi, *snail trails*, dan *soiling*). Dari dimensi temporal, cacat dibedakan menjadi berkala/temporer seperti bayangan sesaat atau debu musiman, permanen seperti korsleting atau retak berat yang memerlukan perbaikan segera,

dan awal/progresif seperti degradasi sel yang memburuk seiring waktu. Sementara itu, berdasarkan lokasi subsistem, cacat dapat terjadi pada modul PV, elektronika daya, atau komponen keseimbangan sistem (BOS) inverter dan pengontrol muatan.

Kecerdasan buatan telah mulai digunakan secara dalam berbagai aspek sistem panel surya. Pemanfaatan kecerdasan buatan dalam O&M PV mencakup lima area utama sebagaimana ditunjukkan pada Gambar 2.3.



Gambar 2.3 Area pemanfaatan AI dalam sistem PV surya (Thakfan & Bin Salamah, 2024)

Peran AI dalam optimalisasi kinerja sistem PV surya dapat dicapai dengan menyesuaikan area pemanfaatan berikut:

- a. *Performance Optimization*, optimalisasi kinerja sistem PV secara dinamis, menyesuaikan sudut panel mengikuti perubahan musiman (Liu dkk., 2023).


- b. *Energy Generation Forecasting*, peramalan produksi energi melalui analisis pola cuaca dan data historis, seperti tutupan awan, kelembaban, curah hujan, tekanan udara, suhu, dan kecepatan angin (Scott dkk., 2023).
- c. *Defect and Fault Detection*, deteksi dan diagnosis cacat pada panel surya, meningkatkan keandalan sistem dengan deteksi dini sebelum kerusakan lebih parah untuk memperpanjang umur pakai PV (Meribout dkk., 2023).
- d. *Energy Management System*, menyeimbangkan permintaan–pasokan serta mengendalikan penyimpanan/koneksi jaringan (Smadi dkk., 2024).
- e. *Modelling and Simulation*, membantu merancang dan menguji konfigurasi baru sistem PV dengan memprediksi kinerja sehingga mengoptimalkan desain sistem dan meningkatkan efisiensi (Assareh dkk., 2023).

Dalam konteks penelitian ini, pilar ketiga yaitu *defect and fault detection* berbasis citra menjadi fokus penelitian ini. Kecacatan panel surya sulit diperoleh dari data elektrik saja karena sangat memakan waktu dan biaya, terlebih untuk skala utilitas. Klasifikasi cacat melalui data citra memberikan informasi yang lebih kaya terhadap berbagai kondisi kecacatan. Diagnosis terhadap potensi kerusakan dapat dilakukan, sehingga intervensi korektif maupun preventif dapat direncanakan lebih efektif. Mekanisme ini tidak hanya meningkatkan keandalan sistem, tetapi juga berkontribusi terhadap pengurangan *downtime*, penurunan biaya pemeliharaan, serta perpanjangan umur pakai modul surya secara keseluruhan.

2.2 Klasifikasi Gambar

Klasifikasi gambar merupakan salah satu tugas dalam bidang visi komputer, sebuah subdisiplin dari ilmu komputer yang berfokus pada pengembangan

algoritma untuk mengenali, memahami, dan menginterpretasikan informasi visual dari citra maupun video. Tujuan utamanya adalah membuat komputer dapat meniru sebagian kemampuan penglihatan manusia dalam mengenali pola visual (Szeliski, 2022). Perbedaan mendasar antara cara manusia memproses visual dan cara komputer melakukan klasifikasi gambar diilustrasikan pada Gambar 2.4.



Gambar 2.4 Perbedaan visual manusia dan visi komputer


Manusia mengandalkan persepsi holistik melalui pengalaman inderawi, sedangkan komputer memerlukan pemrosesan berbasis fitur seperti warna, bentuk, tekstur, maupun intensitas cahaya yang kemudian diterjemahkan ke dalam representasi numerik. Teknik komputer bekerja melalui pemrosesan berulang terhadap data visual untuk menemukan pola yang membedakan satu kategori dengan kategori lain. Beberapa tugas umum dalam visi komputer antara lain klasifikasi gambar, deteksi objek, segmentasi, *pattern recognition*, serta *edge detection* (Huang dkk., 2023).

Secara khusus, klasifikasi gambar bertujuan untuk mengelompokkan citra ke dalam kategori berdasarkan kesamaan fitur visual yang diekstraksi dari data. Proses ini mendasari kemampuan sistem untuk mengenali dan membedakan gambar ke

dalam kategori tertentu berdasarkan persamaan dan fiturnya. Tugas klasifikasi gambar melakukan analisis keseluruhan pada sebuah gambar.

2.3 *Transfer Learning*

Transfer learning merupakan pendekatan dalam *machine learning* dan *deep learning* yang memanfaatkan pengetahuan dari model yang telah dilatih pada tugas atau domain tertentu untuk diaplikasikan pada tugas lain yang berbeda namun masih memiliki keterkaitan (Alzubaidi dkk., 2021). *Transfer learning* relevan dalam bidang visi komputer, mengingat pelatihan model dari nol membutuhkan jumlah data dan sumber daya komputasi yang sangat besar. Gambar 2.5 memperjelas konsep *transfer learning*.



Gambar 2.5 Konsep *transfer learning* (Alzubaidi dkk., 2021)

Transfer learning dalam klasifikasi gambar dilakukan dengan menggunakan model yang telah dilatih pada dataset berskala besar seperti ImageNet, yang berisi jutaan citra dengan ribuan kelas (Tan dkk., 2018). Model pra-latih ini kemudian


dimanfaatkan kembali untuk domain target dengan data yang relatif lebih terbatas. Pendekatan ini dapat meningkatkan kinerja model sekaligus mempercepat proses pelatihan, karena bobot awal model sudah mengandung representasi visual umum yang kuat dari data latih sebelumnya.

Konsep hubungan antara guru-murid merupakan analogi untuk menjelaskan konsep *transfer learning*. Langkah pertama adalah memperoleh pengetahuan mendalam tentang subjek (Alzubaidi dkk., 2021; Pan, 2016). Serupa dengan konsep tersebut, jaringan dilatih menggunakan volume data yang besar, dan mempelajari bias serta bobot selama proses pelatihan. Bobot-bobot tersebut kemudian ditransfer ke jaringan yang berbeda untuk melatih ulang atau menguji model baru yang serupa. Dengan demikian, model baru dapat menggunakan bobot *pre-trained* tanpa harus melakukan pelatihan dari awal.

Pada *transfer learning*, model yang telah dilatih sebelumnya dengan dataset besar seperti ImageNet digunakan sebagai dasar (*base model*). Lapisan-lapisan model awal tersebut dibekukan (*freeze*), bobotnya tidak diubah selama proses pelatihan berikutnya. Selanjutnya, lapisan-lapisan baru ditambahkan di atas model yang telah dilatih sebelumnya dan hanya lapisan-lapisan baru tersebut yang dilatih kembali. Model awal bertindak sebagai *extractor* fitur, mengekstrak fitur-fitur penting dari dataset baru, sementara lapisan-lapisan baru belajar untuk mengklasifikasikan fitur-fitur tersebut berdasarkan tugas spesifik yang diberikan (Q. Yang dkk., 2020). Inception, Xception, VGG, dan Resnet merupakan beberapa contoh model *pre-trained* yang dapat digunakan untuk *transfer learning* (Hosna dkk., 2022).

2.4 Convolutional Neural Network (CNN)

CNN merupakan jenis *neural network* yang umumnya digunakan dalam pengolahan data citra dan merupakan salah satu yang paling terkenal. CNN memiliki kemampuan untuk memproses data berdimensi tinggi seperti gambar dan video. Prinsip kerja CNN mirip dengan *neural network* pada umumnya, dengan perbedaan utama menggunakan kernel 2 dimensi atau dimensi tinggi pada setiap unit dalam lapisan CNN untuk menjalankan proses konvolusi. Selanjutnya, CNN menggunakan berbagai parameter untuk mengurangi jumlah parameter agar lebih mudah dipelajari. Keluaran dari lapisan konvolusi disebut sebagai *feature map* yang mendeskripsikan ciri-ciri unik dari citra. Lapisan konvolusi terdiri dari filter yang berfungsi melakukan proses konvolusi pada matriks citra masukan. CNN melibatkan beberapa lapisan seperti pada Gambar 2.6, antara lain *convolution layer*, *pooling layer*, dan *fully connected layer*.



Gambar 2.6 Convolutional Neural Network (CNN) (Yuliany dkk., 2022)


Berdasarkan Gambar 2.6 mengenai CNN berikut penjelasannya

1. Feature Learning/Feature Extration Layer

Feature Extraction Layer merupakan tahap dimana citra di ubah menjadi fitur-fitur numerik proses yang dapat merepresentasikan citra tersebut.

a. Convolutional Layer

Tujuan proses konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra input. Konvolusi menghasilkan transformasi linear dari data input sesuai informasi spasial dalam data tersebut. Bobot pada layer ini menentukan kernel konvolusi yang dapat diatur berdasarkan input pada CNN. *Convolution layer* menggunakan filter pada setiap citra masukan. Filter ini berupa matriks 2 dimensi dengan ukuran 5×5 , 3×3 atau 1×1 . Proses *Convolution layer* dengan menggunakan filter akan menghasilkan *feature map* yang kemudian akan ditambahkan *activation function*. Adapun proses operasi *convolution layer* terdapat pada Gambar 2.7.




Gambar 2.7 Operasi pada *convolution layer* (Alzubaidi dkk., 2021)

Berdasarkan Gambar 2.7, konvolusi merujuk pada penerapan filter (hijau) ke seluruh input. Parameter filter yang digunakan mencakup ukuran filter (f) sebesar 3×3 pergeseran filter (s) sebanyak 1, dan *padding* (p) dengan jumlah 0. Nilai dalam filter berkisar antara -1 hingga 1, nilai ini digunakan untuk menentukan hasil konvolusi, seperti efek ketajaman, *blur*, *grayscale*, *sharpen*, dan sebagainya. Bidang input (merah) adalah gambar yang akan mengalami konvolusi, di mana angka dalam setiap piksel

mencerminkan matriks dari gambar tersebut. Pada kotak kuning menunjukkan hasil konvolusi dari gambar tersebut. Proses konvolusi pada data citra bertujuan untuk mengekstrak fitur dari citra masukan (Alzubaidi dkk., 2021).

b. *Pooling Layer*

Pooling Layer memiliki peran dalam menerima input dari fungsi aktivasi dan mengurangi jumlah parameter. Layer ini sering disebut sebagai *subsampling* atau *downsampling*, yang mengurangi dimensi dari *feature map* tanpa kehilangan informasi krusial di dalamnya. Dua jenis *pooling layer* yang umum digunakan adalah *max pooling* dan *average pooling*. Adapun untuk proses *pooling* terdapat pada Gambar 2.8.



Gambar 2.8 *Pooling layer* (Alzubaidi dkk., 2021)


Berdasarkan Gambar 2.8 proses *pooling layer* terdapat 2 yaitu *max pooling* dan *average pooling*. *Max pooling* mendapatkan nilai maksimum dari matriks input berdasarkan hasil operasi 'dot' dari *convolution layer*. Sedangkan *average pooling* mengambil nilai rata-rata dari matriks hasil operasi konvolusi

2. Lapisan Klasifikasi

Lapisan ini terbentuk dari sejumlah lapisan yang berisi neuron yang terhubung sepenuhnya (*fully connected*) dengan lapisan lainnya. Lapisan ini menerima input dari *output layer* pada bagian pembelajaran fitur yang kemudian di proses dengan mengaplikasikan proses *flatten* dan menambahkan beberapa *hidden layer* pada proses *fully connected* untuk menghasilkan keluaran berupa akurasi klasifikasi dari setiap kelas.

a. *Flatten*

Matriks hasil konvolusi dan *max pooling* akan melalui proses *flatten* sebelum masuk ke dalam layer *fully connected* dimana setiap citra akan diubah menjadi vektor. Adapun untuk proses *flatten* terdapat pada Gambar 2.9.




Gambar 2.9 Proses *flatten* (Alzubaidi dkk., 2021)

Hasil keluaran dari proses *flatten* akan menjadi masukan pada proses *fully connected layer*. Proses perubahan matriks menjadi *vector* diterapkan agar sesuai dengan format masukan pada layer *neural network*.

b. *Fully connected layer*

Lapisan *fully connected layer* adalah lapisan dalam jaringan saraf tiruan yang memiliki *neuron* aktivasi yang terkoneksi satu sama lain dari lapisan sebelumnya. Neuron-neuron dikonversi menjadi bentuk satu dimensi sebelum

dihubungkan ke semua neuron pada lapisan sepenuhnya terhubung. Proses lapisan sepenuhnya terhubung ini dilakukan untuk memproses data dengan tujuan klasifikasi. Adapun untuk *fully connected layer* terdapat pada Gambar 2.10.




Gambar 2.10 *Fully connected layer* (Alzubaidi dkk., 2021)

Pada Gambar 2.10 menjelaskan mengenai *fully connected layer*. Proses ini berbeda dengan neuron pada lapisan konvolusional yang hanya terhubung dengan suatu area tertentu dari input, neuron pada lapisan sepenuhnya terhubung terkoneksi secara menyeluruh.

2.5 Visual Geometry Group (VGG)

VGG adalah salah satu arsitektur CNN yang diterapkan untuk pengolahan citra. Model ini dikembangkan oleh Karen Simonyan dan Andrew Zisserman. Adapun arsitektur VGG16 dan VGG19 terdapat pada Gambar 2.11.



Gambar 2.11 Arsitektur VGG16 dan VGG19 (Marcella dkk., 2022)

Gambar 2.11 mengenai arsitektur dari VGG16 dan VGG19. Perbedaan dari VGG16 dan VGG19 ini terdapat pada jumlah lapisannya. Pada VGG16 terdiri dari total 16 layer, dengan 13 layer konvolusi dan 3 layer *fully connected*. Keunggulan VGG16 terletak pada homogenitas arsitekturnya yang secara konsisten menerapkan konvolusi 3×3 dan pooling 2×2 dari awal hingga akhir. Sedangkan pada VGG19 mengadopsi pendekatan bahwa semakin banyak lapisan, semakin baik akurasi model. Dengan 19 layer, termasuk 16 layer konvolusi dan 3 layer *fully connected*, VGG19 menyediakan representasi gambar yang lebih kompleks, mengurangi potensi kesalahan dalam pemrosesan gambar menggunakan CNN (Marcella dkk., 2022).

2.6 Dekomposisi Kelas

Dekomposisi kelas merupakan pendekatan yang cara memecah kelas yang heterogen menjadi subkelas yang lebih homogen. Gagasan dasar metode ini adalah bahwa data dalam satu kelas sering kali tidak sepenuhnya seragam. Sebagai contoh, dalam domain citra, satu label kelas dapat mencakup variasi bentuk, tekstur, atau kondisi pencahayaan yang berbeda. Variasi tersebut dapat menyebabkan representasi fitur antar kelas menyulitkan model dalam melakukan klasifikasi

secara tepat. Secara matematis, ruang fitur yang diperoleh dari ekstraksi fitur direpresentasikan sebagai matriks A , sedangkan label kelas awal direpresentasikan sebagai L . Proses dekomposisi dilakukan untuk membagi setiap kelas L ke dalam beberapa sub-kelas homogen. Setiap data dalam kelas asli akan dipetakan ke subkelas terdekat berdasarkan jarak kuadrat *Euclidean*. Hasil dari proses dekomposisi ini adalah dataset baru B , di mana setiap kelas pada dataset awal A telah terbagi ke dalam beberapa sub-kelas. Label kelas pada dataset baru ditandai dengan $C = \{l_{11}, l_{12}, \dots, l_{1k}, l_{22}, \dots, l_{2k}, l_{ck}, \dots\}$.

Dengan demikian, dekomposisi kelas bertujuan untuk meningkatkan keterpisahan antar kelas dengan cara menyederhanakan kompleksitas dalam satu kelas (Abbas dkk., 2021b). Metode PCA digunakan untuk mereduksi dimensi dataset sebelum di-*cluster* menggunakan K-Means. Algoritma K-Means bekerja dengan membagi himpunan data menjadi kluster. Tahapan pada algoritma K-Means adalah sebagai berikut:

- a. Membuat partisi sebanyak k cluster yang berisi sampel acak kemudian perhitungkan centroid cluster dengan cara memilih salah satu k -point secara acak sebagai center.
- b. Hitung jarak antar objek dengan center menggunakan persamaan Euclidean Distance. Euclidean distance adalah perhitungan untuk menentukan jarak dari 2 buah titik. Persamaan Euclidean Distance:

$$d_{ij} = \sqrt{\sum_{k=1}^p \{x_{ik} - x_{jk}\}^2} \quad (2.1)$$

Dimana:

d_{ij} = jarak antar objek i dengan j

p = dimensi data

x_{ik} = koordinat objek i pada dimensi k

x_{jk} = koordinat objek j pada dimensi k

- c. Masukkan tiap objek ke segmen terdekat.
- d. Lakukan pengukuran kembali tiap kali terdapat perubahan segmen.
- e. Ulangi langkah hingga objek dalam tiap segmen tidak mengalami perubahan.

2.7 Silhouette Score

Silhouette Score merupakan salah satu metode evaluasi *clustering* yang digunakan untuk mengukur kualitas hasil pengelompokan berdasarkan kedekatan antar data dalam satu cluster (*intra-cluster*) dan keterpisahan antar cluster yang berbeda (*inter-cluster*). Metode ini tidak memerlukan label kelas sehingga sesuai digunakan pada pendekatan *unsupervised learning* seperti K-Means *clustering*. *Silhouette Score* dihitung dengan dua komponen utama untuk setiap data ke- i , yaitu:

- a. *Intra-cluster distance* $a(i)$, yaitu rata-rata jarak data ke- i terhadap seluruh data lain dalam cluster yang sama.
- b. *Nearest inter-cluster distance* $b(i)$, yaitu rata-rata jarak data ke- i terhadap data pada cluster lain yang paling dekat.

Nilai *silhouette* untuk setiap data ke- i dirumuskan sebagai berikut:

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (2.2)$$

Dimana:

$s(i)$ = rata-rata nilai dari seluruh data

$a(i) = \text{intra-cluster distance}$

$b(i) = \text{nearest inter-cluster distance}$

Nilai *silhouette* berada pada rentang $[-1, 1]$ dengan interpretasi berikut:

- a. Nilai mendekati 1 menunjukkan bahwa data sangat sesuai dengan cluster-nya dan memiliki jarak yang jauh dari cluster lain.
- b. Nilai negatif mengindikasikan bahwa data lebih dekat dengan cluster lain dibandingkan cluster tempat data tersebut berada.

Nilai *silhouette* untuk keseluruhan dataset diperoleh dengan menghitung rata-rata nilai $s(i)$ dari seluruh data.

2.8 Confusion matrix

Confusion matrix berisi informasi tentang klasifikasi yang berhasil diprediksi dengan benar dan salah. Parameter evaluasi ini digunakan sebagai nilai perbandingan dari masing-masing model untuk mendapatkan model sistem yang optimal. Nilai-nilai dihasilkan dari parameter uji sebagai berikut (Alzubaidi dkk., 2021) :

- a. Akurasi (Akurasi)

Akurasi adalah rasio prediksi benar (positif dan negatif) terhadap keseluruhan data. Nilai dari akurasi yang diperoleh dari rumus yaitu

$$Accuracy = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (2.3)$$

Dimana:

TP = *true positif*

TN = *true negative*

FP = *false positif*

FN = *false negative*

b. *F1-score*

F1-score adalah kalkulasi evaluasi yang menggabungkan hasil dari *recall* dan presisi. Pada situasi tertentu, ketika *recall* dan presisi dapat memiliki bobot yang berbeda. Rumus *f1-score*, yaitu:

$$F1\ Score = 2 \times \frac{(Recall \times Precision)}{(Recall + Precision)} \times 100 \quad (2.4)$$

2.9 Penelitian Terkait

Penelitian mengenai peningkatan kinerja klasifikasi citra telah mengalami perkembangan, terutama dengan diterapkannya *deep learning*. Berbagai studi telah mengeksplorasi pendekatan mulai dari klasifikasi berbasis statistik, hingga teknik yang memanfaatkan CNN dan *transfer learning*. Dalam konteks penelitian ini, pengembangan model dengan pemanfaatan informasi subkelas diterapkan dengan tujuan untuk tidak hanya untuk performa klasifikasi, tetapi juga mengatasi permasalahan misklasifikasi kelas. *Transfer learning* diterapkan dengan model yang telah dilatih sebelumnya pada dataset skala besar, memungkinkan *transfer* pengetahuan yang lebih efisien ke dataset target. Pengetahuan dari hasil pemetaan subkelas digunakan untuk memperkuat klasifikasi kelas utama dalam kerangka VGG19-SATL. Untuk memahami kontribusi dan perbandingan antara penelitian-penelitian terdahulu, Tabel 2.1 berikut mencakup hasil ringkasan temuan dan perkembangan penelitian-penelitian yang relevan terkait pendekatan *transfer learning* dalam klasifikasi citra.

Tabel 2.1 *State of the art* penelitian

Penulis	Algoritma/ Pendekatan	Dataset	Akurasi	Kontribusi Utama
(Jasim & Atia, 2023)	ResNet + DenseNet + MLP	CIFAR-10, Sign-Traffic	97,45%, 99,45%	<i>Transfer learning</i> meningkatkan akurasi hingga 3% dibanding metode lain.
(Ledmaoui dkk., 2024)	VGG16	<i>Solar Panel Defect Dataset</i>	91,46%	Deteksi anomali panel fotovoltaik dengan dilengkapi PyQt5 untuk antarmuka ramah pengguna.
(Zhang dkk., 2023)	Model TL-ResNet50, VGG19, dan AlexNet	<i>Steel surface defects: (a) crazing; (b) inclusion; (c) patches; (d) pitted surface; (e) roll-in scale; (f) scratches.</i>	Model TL-ResNet50 mencapai akurasi keseluruhan 99,4% pada set pengujian dan menunjukkan kemampuan identifikasi yang baik dengan GradCAM++ untuk fitur cacat.	Prapemrosesan gambar yang cacat, membaginya ke dalam set pelatihan dan verifikasi, mengekstraksi informasi fitur menggunakan TL-ResNet50, dan menggunakan Grad-CAM++ untuk menjelaskan logika pengenalan model.
(Naik & Rudra, 2024)	ShuffleNet + QCNN	<i>Arecanut X-ray</i>	97,72%	Model QCNN mengungguli CNN dalam <i>transfer learning</i> .
(Gogoi & Begum, 2022)	<i>Progressive 3-Layered CNN</i>	CIFAR 10, CIFAR 100, CALTECH 101	CALTECH101 (95,39%), CIFAR100 (96,47%), CIFAR10 (98,79%)	TL + <i>fine-tuning</i> dengan <i>progressive resizing</i> dan <i>split train strategy</i> meningkatkan akurasi CNN.

(Abascal dkk., 2021)	U-Net	CT KiTS19	U-Net-P yang mendasarkan pelatihan pada data proyeksi, menghasilkan gambar dengan kualitas lebih baik dibandingkan dengan <i>Regularisasi-Gauss-Newton</i> (RGN).	DL strategi dalam tomografi (CT) memanfaatkan U-Net dan TL Sim2Real, memungkinkan model yang dilatih pada data sintetis (yang dihasilkan dari phantom numerik).
(Z. Li dkk., 2022)	DHTL	<i>Glass dan LCD coating</i>	Metode yang diusulkan mencapai kinerja terbaik dengan presisi, <i>recall</i> , dan skor f1 tertinggi, serta <i>loss</i> terendah.	<i>Hybrid transfer learning</i> dengan bayesian hirarkis untuk latar belakang yang halus dan $L2,1 + L1$ -norm untuk representasi dimensi rendah anomali
(Abbas dkk., 2021)	4S-DT ResNet, GoogleNet, VGG19	<i>Chest X-ray image</i>	97.54% pada 4S-DT ResNet	4S-DT memanfaatkan dekomposisi kelas untuk menyederhanakan struktur data pada gambar rontgen dada yang tidak berlabel
(Zoubir dkk., 2022)	VGG16	<i>Bridges defects (cracks, spalling, efflorescence, and non-defective)</i>	Skema (c) memberikan hasil terbaik, dengan akurasi pengujian sebesar 97,13% (tertinggi di antara ketiga skema).	Model memanfaatkan tiga skema pembelajaran berbeda dalam jumlah lapisan yang dilatih ulang: Skema (a) Hanya lapisan klasifikasi yang dilatih ulang. (b): Lapisan klasifikasi dan lapisan konvolusi

				terakhir yang dilatih ulang. (c): Lapisan klasifikasi dan dua lapisan konvolusional terakhir yang dilatih ulang. Teknik interpretasi menghasilkan peta lokalisasi yang menyoroti area cacat.
(Saleh, 2024)	Xception, InceptionV3, VGG16, VGG19, ResNet50, ResNet152V2	Dataset X-ray industri dari perusahaan ban global: 23.366 citra (3.366 cacat, 20.000 normal), 15 jenis cacat, klasifikasi biner	94,75% (Xception) Validasi: 95%	Sistem inspeksi visual otomatis yang dirancang khusus untuk mengidentifikasi dan mengklasifikasikan cacat pada permukaan veneer kayu dengan menggunakan pendekatan jaringan syaraf tiruan berbasis wilayah yang lebih cepat (faster R-CNN)
(Wan dkk., 2021)	VGG19	NEU <i>surface dataset</i>	Akurasi mencapai 97,8% diuji pada dataset campuran, mencakup dataset permukaan NEU beserta dataset yang dikembangkan dalam penelitian.	Peningkatan untuk deteksi cacat permukaan baja strip menggabungkan metode proyeksi skala abu-abu, menyaring area bebas cacat, cacat tepi palsu, dan interferensi pencahayaan, memungkinkan ekstraksi fitur cacat aktual yang lebih baik.

(Rahman dkk., 2021)	VGG (VGG-19 and VGG-16), GoogLeNet (Inception-v3, Xception), <i>residual network</i> (ResNet50)	<i>solar cells (cracked, uncracked)</i>	Metode <i>ensemble</i> mencapai akurasi tertinggi masing-masing 96,97% dan 97,06% untuk panel surya monokristalin dan polikristalin.	Mengeksplorasi arsitektur CNN yang telah dilatih sebelumnya untuk menentukan pembelajaran transfer dalam klasifikasi praktis dan menyajikan analisis komparatif di antara berbagai model dengan <i>ensemble</i> berdasarkan akurasi, presisi, skor fl dan AUC-ROC.
(Rudro dkk., 2024)	InceptionV3-Net	<i>Solar Panel Defect Segmentation and Classification Dataset</i>	Model yang diusulkan mencapai akurasi sebesar 98,34%, akurasi pengujian sebesar 94,35% dengan nilai fl sebesar 0,94, presisi sebesar 0,94, dan Recall sebesar 0,94.	Arsitektur yang diusulkan menerapkan basis InceptionV3 dengan bobot ImageNet, disempurnakan dengan lapisan konvolusi, <i>squeeze-and-excitation</i> (SE), <i>residual connections</i> , dan <i>global average pooling</i> . Model mencakup dua <i>dense layer</i> dengan LeakyReLU dan normalisasi batch, diakhiri dengan lapisan output <i>softmax</i> .

(Abbas dkk., 2020)	DeTraC AlexNet, VGG16, GoogleNet, ResNet	<i>real chest X-ray images, histological images of human colorectal cancer, digital mammograms</i>	99.8% dengan ResNet dan 99.6% dengan GoogleNet	TL berbasis dekomposisi kelas untuk meningkatkan akurasi klasifikasi citra medis. Model ini meningkatkan akurasi, sensitivitas, dan spesifisitas dibandingkan model CNN standar.
--------------------	--	--	--	--

Berdasarkan Tabel 2.1 yang merangkum penelitian terkait selama lima tahun terakhir (2020–2024), *transfer learning* efektif mengurangi beban komputasi serta menangani permasalahan kebutuhan data pelatihan yang banyak. Namun, penerapan *transfer learning* dalam klasifikasi CNN tidak selalu dapat beradaptasi dengan baik terhadap setiap dataset. Penurunan performa klasifikasi terjadi dan model mengalami kesulitan dalam menggeneralisasi data baru karena adanya perbedaan karakteristik dataset. Sebagai respons terhadap permasalahan tersebut, penelitian ini mengusulkan pendekatan dengan pemanfaatan informasi subkelas yang dirancang agar lebih adaptif terhadap dataset. Pendekatan ini melakukan *transfer learning* dari model prelatih dengan pembelajaran multitugas yang melibatkan subkelas, sehingga diharapkan dapat meningkatkan performa klasifikasi dan stabilitas hasil klasifikasi kondisi panel surya.

Gambaran mengenai matriks penelitian tercantum dalam Tabel 2.2 yang merupakan perbandingan berbagai pendekatan penelitian terdahulu terkait dengan permasalahan penelitian.

Tabel 2.2 Matriks penelitian

Penelitian	<i>Transfer Learning</i> (TL)	<i>TL + Fine Tuning</i>	Dekomposisi	Augmentasi	Objek Dataset
(Jasim & Atia, 2023)	✓	-	-	✓	lampu lalu lintas
(Ledmaoui dkk., 2024)	✓	-	-	-	<i>solar panel defect</i>
(Zhang dkk., 2023)	✓	✓	-	✓	kecacatan baja
(Naik & Rudra, 2024)	✓	-	-	-	medis
(Gogoi & Begum, 2022)	✓	✓	-	-	CIFAR, CALTECH
(He & Chen, 2021)	✓	-	-	-	<i>hyperspectral</i>
(Abascal dkk., 2021)	✓	✓	-		medis
(Z. Li dkk., 2022)	✓	✓	✓	-	gelas dan LCD <i>coating</i>
(Abbas dkk., 2021)	✓	✓	✓	✓	medis
(Zoubir dkk., 2022)	✓	✓	-	✓	keretakan jembatan
(Saleh, 2024)	✓	✓	-	-	Kecacatan ban
(Wan dkk., 2021)	✓	✓	-	-	kecacatan strip baja
(Rahman dkk., 2021)	✓	✓	-	✓	<i>solar panel defect</i> (binary)
(Rudro dkk., 2024)	✓	-	-	✓	<i>solar panel defect</i>
(Abbas dkk., 2020)	✓	✓	✓	-	medis
Penelitian ini	✓	✓	✓	✓	<i>solar panel defect</i>

Penelitian-penelitian dalam lima tahun terakhir menunjukkan bahwa *transfer learning* menjadi pendekatan dominan dalam tugas klasifikasi citra, terutama pada kasus dengan data terbatas. Mayoritas studi, seperti yang dilakukan oleh (Jasim & Atia, 2023; Ledmaoui et al., 2024; Naik & Rudra, 2024), memanfaatkan arsitektur

CNN pra-latih seperti ResNet, DenseNet, ShuffleNet, dan VGG untuk meningkatkan akurasi sekaligus mengurangi beban pelatihan dari nol. Pendekatan TL terbukti menghasilkan performa tinggi mulai dari citra medis hingga cacat material industri. Namun, TL sangat dipengaruhi oleh kesesuaian karakteristik antara dataset sumber (misalnya ImageNet) dan dataset target, sehingga tidak selalu optimal ketika domain target memiliki variasi kelas kompleks.

Beberapa penelitian melakukan *fine-tuning* pada layer tertentu untuk menyesuaikan representasi fitur dengan domain baru. Studi seperti yang dilakukan oleh (Zhang et al., 2023) dan (Gogoi & Begum, 2022) menunjukkan bahwa *fine-tuning* mampu meningkatkan ekstraksi fitur tingkat tinggi sehingga model lebih mudah beradaptasi terhadap cacat atau anomali yang memiliki pola visual kompleks. Sementara itu, pendekatan lain mencoba memperkaya representasi fitur melalui augmentasi data, seperti pada penelitian (Wan et al., 2021) dan (Zoubir et al., 2022) yang memanfaatkan augmentasi dan *preprocessing* khusus untuk meningkatkan kemampuan model dalam menghadapi kondisi citra yang bervariasi. Studi lain memperkenalkan dekomposisi kelas untuk menangkap variasi internal dalam satu kelas utama yang diterapkan oleh (Abbas et al., 2021b) menunjukkan bahwa memecah kelas menjadi subkategori dapat menyederhanakan struktur data dan membantu model mempelajari pola yang lebih halus.

Berdasarkan kajian tersebut, meskipun *transfer learning*, *fine-tuning*, augmentasi data, dan dekomposisi kelas masing-masing memberikan kontribusi penting tetapi pendekatan-pendekatan tersebut belum sepenuhnya mampu mencapai performa yang selalu stabil dan optimal pada dataset dengan variasi

visual dengan ukuran data sangat terbatas. Padahal, subkelas dari dekomposisi kelas berpotensi dimanfaatkan bukan hanya sebagai pemecahan struktur data, tetapi juga sebagai mekanisme pembelajaran tambahan yang memperkaya pemahaman model terhadap variasi internal. Dengan demikian, terdapat kesenjangan penelitian (*research gap*) terkait bagaimana memanfaatkan informasi subkelas secara eksplisit dalam kerangka *transfer learning* untuk meningkatkan kemampuan generalisasi model. Maka penelitian ini memperluas metode yang ada dengan menambahkan jalur klasifikasi subkelas sebagai tugas pendamping saat pelatihan, sehingga model tidak hanya belajar membedakan kelas utama, tetapi juga memahami informasi lebih kaya berupa variasi internal di dalamnya. Dengan cara ini, SATL diharapkan dapat meningkatkan stabilitas dan akurasi klasifikasi citra kecacatan panel surya sekaligus memberikan kontribusi baru terhadap pengembangan teknik klasifikasi gambar yang dirancang untuk menangani keterbatasan data, tingkat variasi visual yang tinggi, serta kebutuhan generalisasi model pada kondisi citra dunia nyata