

BAB I

PENDAHULUAN

1.1 Latar Belakang

Adopsi pembangkit listrik tenaga surya melonjak tajam dan menjadi penopang utama penambahan kapasitas energi terbarukan dunia. Kapasitas fotovoltaik (PV) kumulatif dunia mencapai 1,6 TW pada akhir 2023, naik dari 1,2 TW pada 2022, sepanjang 2024. Pembangkit listrik tenaga surya tetap memimpin penambahan kapasitas dan diproyeksikan akan mendominasi hingga 2030 (*Snapshot 2024 - IEA-PVPS*). Di sisi hulu, peningkatan kapasitas manufaktur modul surya yang besar memicu penurunan harga secara tajam akibat kelebihan produksi manufaktur sehingga mendorong akses lebih mudah dan adopsi surya yang lebih luas di berbagai negara. Perluasan kapasitas memperbesar kebutuhan *operations & maintenance* (O&M) panel surya. Lapangan yang perlu dipantau menjadi semakin banyak agar produksi listrik tetap optimal. Di Indonesia, ambisi nasional menempatkan panel surya sebagai tulang punggung transisi energi. Rencana Umum Ketenagalistrikan Nasional (RUKN) 2025–2060 menargetkan 108,7 GW kapasitas surya atau sekitar 24,6% bauran listrik (*Indonesia's 108.7 GW Solar Goal Needs Industry Plan: IESR*)

Secara operasional, panel surya rentan mengalami penurunan pembangkitan listrik tahunan pada kisaran 3,6–18,9% serta degradasi sistem sekitar 0,5–1% (Thakfan & Bin Salamah, 2024). Kerugian akibat penurunan pembangkitan listrik tenaga surya berdampak nyata pada aspek finansial, terlebih untuk kontinuitas suplai energi bersih. Praktik O&M pada Pembangkit Listrik Tenaga Surya (PLTS)

mulanya hanya bertumpu mulanya hanya bertumpu pada pengujian elektrik lapangan seperti *I-V curve tracing*, pengukuran isolasi yang memerlukan kunjungan lapangan, instrumentasi khusus, serta waktu henti tertentu. Dalam PLTS skala utilitas yang besar, pendekatan tersebut memakan biaya, waktu, dan tenaga ahli yang sangat besar (Thakfan & Bin Salamah, 2024). Seiring berkembangnya *computer vision*, pendekatan berbasis citra menjadi alternatif yang memungkinkan inspeksi tanpa kontak, non-destruktif, dan lebih cepat untuk *screening* awal kondisi panel surya.

Pada ranah algoritmik, *Convolutional Neural Network* (CNN) menjadi tulang punggung dalam berbagai bidang analisis citra. Sejak keberhasilan CNN dalam kompetisi ImageNet, berbagai varian dikembangkan untuk meningkatkan akurasi, efisiensi parameter, dan kemampuan generalisasi model (Chai dkk., 2021; Gorai dkk., 2025). Dalam konteks kondisi dan kecacatan panel surya, beberapa studi menerapkan *transfer learning* untuk klasifikasi. (Ledmaoui dkk., 2024) menerapkan VGG16 dengan *transfer learning* dan mencapai akurasi 91,46%. (Rahman dkk., 2021) menerapkan *ensemble* dari beberapa arsitektur seperti VGG19, InceptionV3, dan ResNet50 untuk klasifikasi retakan panel surya. (Rudro dkk., 2024) menggunakan arsitektur berbasis InceptionV3 dengan modifikasi *residual connections* yang meningkatkan presisi pada segmentasi kecacatan panel surya. Pendekatan serupa juga banyak digunakan pada domain inspeksi visual lainnya, seperti deteksi cacat pada baja dan *veneer* kayu, dengan memanfaatkan *transfer learning* berbasis ResNet50, VGG19, dan AlexNet (Urbonas dkk., 2020; Zhang dkk., 2023). Berbagai strategi dilakukan untuk meningkatkan performa

klasifikasi, seperti melatih kembali beberapa lapisan konvolusional terakhir (Zoubir dkk., 2022), teknik augmentasi yang lebih kaya seperti *progressive resizing* (Gogoi & Begum, 2022), penggunaan Grad-CAM++ untuk interpretabilitas model (Zhang dkk., 2023) hingga adopsi struktur model yang ringan (Naik & Rudra, 2024). Meskipun menunjukkan hasil yang menjanjikan, beberapa penelitian mencatat misklasifikasi antar kondisi yang berbeda serta permasalahan ketidakseimbangan distribusi data (Chowdhury dkk., 2024; Yu & Pei, 2024). Temuan ini mengindikasikan bahwa representasi fitur yang dipelajari model masih memiliki ruang untuk ditingkatkan. Dalam konteks klasifikasi kondisi panel surya, (Ledmaoui dkk., 2024) dengan VGG16 mencatat adanya misklasifikasi model sulit membedakan beberapa jenis kondisi panel surya. *Transfer learning* memperlakukan setiap kondisi sebagai satu kelas utama tanpa mempertimbangkan variasi visual yang muncul di dalam kelas. Padahal, variasi visual di dalam kelas berpotensi mengandung informasi tambahan yang dapat dimanfaatkan untuk memperkaya proses pembelajaran model. Gagasan untuk memanfaatkan struktur internal kelas sejalan dengan pendekatan dekomposisi kelas oleh (Abbas dkk., 2020) yang memecah kelas besar berdasarkan pola distribusi fitur untuk representasi yang lebih diskriminatif.

Berdasarkan uraian tersebut, penelitian ini mengusulkan pengembangan model klasifikasi kondisi panel surya berbasis *transfer learning* VGG19 dengan pemanfaatan informasi subkelas melalui pembelajaran tugas ganda yang kemudian disebut *Subclass-Aware Transfer Learning* (VGG19-SATL). VGG19 dipilih sebagai *natural progression* dari VGG16, dengan arsitektur yang lebih dalam untuk

ekstraksi fitur hierarkis dan representasinya yang sangat dekat dengan CNN. Inti dari pendekatan yang diusulkan adalah mengintegrasikan informasi subkelas hasil dekomposisi ke dalam proses *transfer learning*. Setiap kelas utama dikelompokkan ke dalam beberapa subkelas berdasarkan pola visual yang muncul di dalam kelas tersebut. Selama proses pelatihan, informasi subkelas dimanfaatkan sebagai tugas tambahan sehingga model terdorong untuk mempelajari representasi fitur yang lebih informatif.

Penelitian bertujuan untuk mengkaji sejauh mana pemanfaatan informasi subkelas sebagai sinyal tambahan dalam kerangka pembelajaran tugas ganda dapat meningkatkan performa klasifikasi kondisi panel surya. Dengan demikian, penelitian ini tidak hanya mengisi celah riset terkait pemanfaatan struktur internal kelas dalam klasifikasi citra, tetapi juga memberikan kontribusi praktis bagi tim O&M yang membutuhkan sistem *screening* panel surya.

1.2 Rumusan Masalah

Berdasarkan uraian pada latar belakang, rumusan masalah yang diangkat pada penelitian ini sebagai berikut:

- a. Bagaimana mengembangkan model klasifikasi kondisi panel surya berbasis *transfer learning* dengan pemanfaatan informasi subkelas sehingga menghasilkan performa klasifikasi yang optimal?
- b. Bagaimana pengaruh strategi pembelajaran dengan pemanfaatan informasi terhadap performa klasifikasi kondisi panel surya?

1.3 Tujuan Penelitian

Tujuan penelitian ini dispesifikasikan berdasarkan rumusan masalah yang telah dibuat sebagai berikut:

- a. Mengembangkan model klasifikasi kondisi panel surya berbasis *transfer learning* yang memanfaatkan informasi subkelas melalui pembelajaran tugas ganda.
- b. Mengevaluasi pengaruh pemanfaatan informasi subkelas terhadap performa klasifikasi kondisi panel surya.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi akademis dengan memperkaya referensi metodologis dalam pengembangan *transfer learning* pada inspeksi visual panel surya. Pendekatan yang diusulkan diharapkan dapat menjadi alternatif strategi untuk meningkatkan representasi fitur dan tahan terhadap misklasifikasi antar kelas, serta menjadi dasar bagi penelitian lanjutan dalam domain klasifikasi kecacatan panel surya berbasis citra. Secara praktis, penelitian ini menawarkan rancangan model klasifikasi yang berpotensi membantu inspeksi tim O&M, terutama pada PLTS skala utilitas, dalam proses *screening* awal, prioritas perbaikan, dan pemantauan kondisi panel secara rutin, serta menjadi dasar bagi pengembangan alat bantu pemeliharaan panel surya pada lingkungan operasional. Pendekatan yang diusulkan berpotensi dikembangkan lebih lanjut ke dalam bidang lain yang memiliki karakteristik serupa serta membuka peluang kolaborasi lintas bidang seperti energi, manufaktur, dan lingkungan.

1.5 Batasan Masalah

Penelitian ini memiliki batasan-batasan masalah sebagai berikut:

- a. Ruang lingkup dataset yang digunakan dalam penelitian yaitu *Solar Panel Images Clean and Faulty Images* yang tersedia di repositori Kaggle. Eksperimen tidak mencakup pengumpulan atau penggunaan dataset tambahan maupun data lapangan lainnya.
- b. Penelitian ini berfokus pada eksplorasi dan evaluasi model klasifikasi dengan pemanfaatan informasi subkelas, tidak mencakup tahap pengembangan menyeluruh sistem atau integrasi model ke dalam lingkup perangkat nyata.
- c. Arsitektur yang digunakan adalah VGG19 dengan bobot awal (*pre-trained weights*) dari ImageNet, sebagai dasar untuk eksperimen strategi pembelajaran yang diusulkan.
- d. Evaluasi performa model difokuskan pada metrik *f1-score* sebagai metrik utama, dengan akurasi sebagai metrik pendukung, dengan tambahan *confusion matrix*, kurva pelatihan, serta efisiensi komputasi yang ditinjau dari hubungan antara performa model dan waktu pelatihan.
- e. Seluruh eksperimen dilakukan dalam lingkungan komputasi berbasis GPU NVIDIA Tesla T4 pada Google Collaboratory menggunakan framework TensorFlow 2.14 dan Keras. Penelitian ini tidak menguji performa model pada hardware atau sistem produksi lainnya.

1.6 Sistematika Penulisan

Sistematika penulisan penelitian ini disesuaikan dengan panduan penulisan Tugas Akhir yang diterbitkan oleh Universitas Siliwangi dengan terdiri dari lima BAB sebagai berikut:

BAB I PENDAHULUAN

BAB I menguraikan latar belakang penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian baik secara akademis maupun praktis, batasan masalah, dan sistematika penulisan penelitian yang memberikan struktur keseluruhan dokumen Tugas Akhir.

BAB II LANDASAN TEORI

BAB II menyajikan tinjauan pustaka berupa landasan teori yang menjadi dasar penelitian yang berhubungan dengan permasalahan yang akan diteliti serta *state-of-the art methods* terkait penelitian. Bab ini juga mengidentifikasi *research gap* yang menjadi dasar pengembangan metode yang diusulkan.

BAB III METODOLOGI

BAB III menjelaskan tentang metodologi secara komprehensif mencakup kerangka penelitian mulai dari studi literatur, strategi pelatihan, evaluasi model, hingga penarikan kesimpulan.

BAB IV HASIL DAN PEMBAHASAN

BAB IV memaparkan hasil eksperimen dan analisis terhadap temuan penelitian. Pembahasan meliputi konfigurasi model, hasil dan analisis dinamika pelatihan model untuk setiap eksperimen, perbandingan antar

eksperimen yang dilakukan, analisis *confusion matrix*, evaluasi waktu pelatihan *vs* akurasi, perbandingan dengan *state-of-the-art* dari penelitian terdahulu, serta analisis *threats to validity* untuk keandalan hasil penelitian

BAB V KESIMPULAN DAN SARAN

BAB V menyajikan kesimpulan atas seluruh rangkaian penelitian yang telah dilakukan dengan memaparkan keunggulan dan kekurangan penelitian serta saran untuk penelitian lanjutan untuk memperbaiki kekurangan pada penelitian yang telah dilakukan pada penelitian ini.