


BAB II

METODOLOGI

3.1 Peta Jalan Penelitian

Spesifikasi dari setiap lapisan dalam penelitian ini ditandai dengan kotak berwarna merah pada Gambar 3.1.



Gambar 3.1 Roadmap penelitian (AIS Universitas Siliwangi, 2024)


Berdasarkan Gambar 3.1, penelitian yang diangkat dalam tugas akhir ini merupakan bagian dari peta jalan penelitian Artificial Intelligence Siliwangi (AIS) beririsan dengan Kelompok Keahlian dan Sistem Cerdas (KK-ISI), dan Kelompok Keahlian Jaringan, Keamanan dan Forensik Digital (KK-JKF).

Penelitian ini berada pada jalur pengembangan *Computer Vision* dan *Classification & Clustering System* yang tergolong dalam lapisan *Applied Application* dan *Basic Application* di dalam *Intelligent Informatics*. Fokus utama penelitian adalah pada penerapan *Deep Learning* sebagai fondasi teknis untuk membangun sistem klasifikasi. Lebih lanjut, penelitian ini mendukung *Knowledge-Based and Intelligent Learning System*, dengan menitikberatkan pada aspek pemahaman citra. Dengan demikian, penelitian ini tidak hanya mendukung arah pengembangan riset dalam pembelajaran model klasifikasi, tetapi juga bertujuan menghasilkan aplikasi praktis dalam otomasi inspeksi dan pemeliharaan panel surya yang scalable dan efisien.

3.2 Tahapan Penelitian


Penelitian dimulai dengan studi literatur hingga penarikan kesimpulan.

Rangkaian tahapan dalam penelitian ini dapat dilihat pada Gambar 3.2.



Gambar 3.2 Tahapan penelitian

Tujuan penelitian direpresentasikan menggunakan *Fishbone Diagram* (Shinde dkk., 2018) untuk mengidentifikasi faktor-faktor utama yang memengaruhi implementasi pengembangan model klasifikasi kondisi panel surya. Elemen pendukung tersebut dipetakan pada Gambar 3.3.



Gambar 3.3 *Fishbone diagram*

Bagian “ekor” dari diagram merepresentasikan objek penelitian, yaitu kecacatan panel surya. Sementara bagian “kepala” diarahkan pada tujuan penelitian, yaitu pengembangan model klasifikasi kondisi panel surya. Adapun “tulang” dari diagram terdiri dari:

- Environment Research*, ruang lingkup penelitian difokuskan pada bidang *computer vision* dan *deep learning*, khususnya pada masalah klasifikasi kondisi panel surya.
- Material*, data yang digunakan adalah *Solar Panel Images Clean and Faulty Images* yang mencakup citra kondisi panel surya.

- c. *Measurement*, tahap yang melibatkan evaluasi dengan metrik evaluasi.
- d. *Machine*, perangkat keras dan perangkat lunak yang digunakan berupa Google Colaboratory, GPU, serta pustaka *deep learning* (TensorFlow/Keras).
- e. *Methods*, inti yang digunakan penelitian berupa VGG19 dan *Subclass-Aware Transfer Learning* yang mengintegrasikan informasi subkelas melalui *multitask learning*.
- f. *Manpower*, peran peneliti dalam merancang, mengimplementasikan, serta melakukan evaluasi model dengan metrik akurasi.

3.2.1 Studi Literatur

Tahap pertama dilakukan dengan mengumpulkan dan mempelajari *survey paper* yang berkaitan dengan penelitian yang dilakukan. Selanjutnya, dilakukan pengumpulan *technical paper* untuk membangun pemahaman terhadap lingkungan *state-of-the-art* yang mendukung jalannya penelitian ini. Proses ini bertujuan untuk memperoleh pemahaman mengenai perkembangan teknologi, kerangka kerja konseptual, dan metode-metode yang telah digunakan, serta mengidentifikasi kesenjangan yang akan diisi oleh penelitian ini. Seluruh referensi yang digunakan berasal dari sumber terindeks untuk validitas kajian.

3.2.2 Akuisisi Data


Dataset yang digunakan merupakan dataset publik yang diperoleh dari Kaggle *Solar Panel Images Clean and Faulty Images*. Dataset terdiri dari kumpulan gambar yang merepresentasikan berbagai kondisi panel surya. Dataset bersifat komprehensif, namun ketidakseimbangan jumlah citra pada setiap kelas ditemukan yang disebabkan oleh keterbatasan jumlah data dari beberapa kondisi kerusakan

relatif jarang terdokumentasikan. Dataset digunakan juga dalam penelitian di bidang klasifikasi kecacatan panel surya (Ledmaoui et al., 2024). Riwayat penggunaan dataset menunjukkan tingkat reliabilitas sekaligus memperkuat relevansi dataset sebagai basis penelitian ilmiah.

3.2.3 Pra-pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk menyiapkan dataset sebelum digunakan dalam pelatihan model dengan tujuan meningkatkan kualitas data. Langkah-langkah diambil meliputi penyesuaian ukuran (*resize*), normalisasi nilai piksel, pembagian dataset latih dan validasi, serta augmentasi ringan, seperti rotasi acak dan *flipping* untuk keragaman data latih.

Sebagai bagian dari upaya memperkaya informasi yang dapat dipelajari model, dekomposisi kelas dilakukan untuk menangkap variasi internal pada setiap kelas melalui pembentukan subkelas. Gambar 3.4 merupakan ilustrasi proses dekomposisi kelas.



Gambar 3.4 Proses dekomposisi

Fitur visual diekstrak menggunakan *pretrained model*. Keluaran dari proses ini berupa vektor fitur yang merepresentasikan informasi visual dari citra. Vektor ini


kemudian direduksi dimensinya menggunakan *Principal Component Analysis* (PCA) untuk mempertahankan informasi penting sekaligus mengurangi *noise* dan redundansi yang terdapat pada fitur asli. Reduksi dimensi membuat proses *clustering* lebih efisien. Setelah itu, fitur yang telah direduksi diklaster menggunakan K-Means, sehingga dapat menghasilkan label subkelas. Proses inisialisasi pada algoritma K-Means dilakukan dengan K-Means++ untuk mengatasi kelemahan inisialisasi acak (*random initialization*). Inisialisasi acak sering kali menempatkan pusat klaster (centroid) pada posisi yang saling berdekatan secara stokastik, mengakibatkan konvergensi yang lambat dan hasil pengelompokan yang tidak konsisten. Sebaliknya, K-Means++ menggunakan mekanisme distribusi peluang berbasis jarak, di mana setiap centroid berikutnya dipilih secara selektif dari titik data yang memiliki jarak kuadrat terjauh dari centroid yang telah ada. Pendekatan ini membuat persebaran centroid awal lebih representatif di seluruh ruang fitur, sehingga meningkatkan stabilitas dan akurasi pembentukan subkelas. Nilai K optimal untuk setiap kelas dievaluasi menggunakan *silhouette score* yang menilai sejauh mana data cocok dengan kluster yang ditetapkan, dengan nilai berkisar dari -1 hingga 1. Prosedur penentuan K optimal dilakukan sebagai berikut:

- a. Menentukan rentang kandidat K yang diuji ($K=2$ hingga $K=N$, berdasarkan domain knowledge perkiraan variasi internal visual dan ukuran data).
- b. Melakukan clustering K-Means pada fitur hasil PCA untuk setiap kandidat K.
- c. Menghitung *silhouette score* untuk setiap K.
- d. Menetapkan nilai K optimal dengan *silhouette score* tertinggi.

Dengan pendekatan ini, nilai K optimal ditentukan secara sistematis berdasarkan performa model *clustering*, sehingga setiap subkelas dapat merepresentasikan variasi internal kelas secara maksimal. Subkelas yang terbentuk kemudian digunakan sebagai tugas tambahan dalam *multitask*, untuk membantu model mempelajari fitur minoritas tanpa menurunkan performa pada kelas utama.

3.2.4 Pemodelan

Tahap ini bertujuan untuk mengembangkan model klasifikasi kondisi panel surya berbasis *transfer learning* dengan pemanfaatan informasi subkelas. Pendekatan ini dirancang untuk meningkatkan kemampuan model membedakan variasi visual antar kondisi panel surya. VGG19 dipilih sebagai arsitektur basis dengan pertimbangan arsitektur VGG relatif sederhana karena representasinya sangat dekat dengan konsep CNN memudahkan analisis kontribusi SATL secara eksplisit, tanpa kompleksitas tambahan dari arsitektur seperti *skip connections*. VGG19 juga merupakan *natural progression* dari VGG16 dengan tiga lapisan konvolusi tambahan yang memungkinkan ekstraksi fitur hierarkis yang lebih dalam. Proses pengembangan model mencakup penyesuaian layer pada arsitektur dasar dan integrasi jalur keluaran tambahan untuk subkelas, seperti yang ditunjukkan pada Gambar 3.5.



Gambar 3.5 Pengembangan model usulan (VGG19-SATL)

Integrasi informasi subkelas dilakukan pada bagian *head* klasifikasi model. Model dikonfigurasi dengan dua jalur keluaran yaitu *main head* untuk prediksi kelas utama, dan *subclass head* untuk prediksi subkelas hasil dekomposisi. Kedua jalur dilatih secara simultan menggunakan fungsi *loss* gabungan, sehingga sinyal pembelajaran dari subkelas dapat memperkaya representasi fitur dan mendukung generalisasi model. Beberapa layer *fully connected* (FC) di bagian akhir VGG19 diganti dengan FC baru yang sesuai dengan jumlah kelas utama dan subkelas untuk menyesuaikan dengan dataset panel surya

Jalur tambahan ini berperan sebagai mekanisme *knowledge enrichment* yang membantu *backbone* belajar fitur-fitur diskriminatif lebih detail, yang selanjutnya ditransfer ke klasifikasi kelas utama (Liu et al., 2025). Dengan rancangan ini, model tidak hanya berfokus pada label kelas utama, tetapi juga memanfaatkan variasi visual di dalam tiap kelas melalui subkelas.

3.2.5 Pelatihan

Tahap pelatihan model dilakukan untuk mengoptimalkan jaringan saraf sehingga model mampu melakukan klasifikasi secara akurat. Dalam penelitian ini, digunakan dua skenario pelatihan, yang dikonfigurasi untuk mengisolasi pengaruh dekomposisi kelas dan *multitask* terhadap performa model. Konfigurasi skenario pelatihan model ditunjukkan pada Tabel 3.1.

Tabel 3.1. Skenario pelatihan model

Skenario	Dekomposisi	<i>Multitask</i>	Output
Baseline (VGG19-Only)	-	-	<i>Main Head</i>
VGG19-SATL	✓	✓	<i>Main + Sub Head</i>

Pelatihan model memanfaatkan VGG19 yang telah dilatih sebelumnya pada dataset ImageNet. Skenario pertama digunakan sebagai *baseline*, yaitu pelatihan model VGG19 dengan *transfer learning* tanpa dekomposisi kelas dan tanpa *multitask learning*. Pada skenario VGG19-SATL, model memiliki dua jalur keluaran, yaitu *main head* untuk prediksi kelas utama dan *sub head* untuk prediksi subkelas. Kedua tugas tersebut dilatih secara simultan menggunakan fungsi *loss* gabungan dengan pembobotan antara *loss* kelas utama dan *loss* subkelas (Shi et al., 2025). Pendekatan ini dirancang untuk memberikan sinyal pembelajaran tambahan dari subkelas yang diharapkan dapat mendukung proses pembelajaran model pada tugas klasifikasi kelas utama.

3.2.6 Evaluasi

Tahap evaluasi bertujuan mengukur efektivitas pendekatan VGG19-SATL terhadap klasifikasi kecacatan panel surya dan membandingkan performa model antara skenario. Proses evaluasi menggunakan metrik dari Keras API dengan

persamaan pada subbab 2.7 untuk mengukur akurasi prediksi model. Kurva akurasi dan *loss* dianalisis selama pelatihan dan validasi untuk setiap skenario. Analisis ini digunakan untuk memantau kemampuan model dalam mempelajari pola visual serta mendeteksi potensi *overfitting* atau *underfitting*. Kinerja model difokuskan pada metrik *f1-score* sebagai metrik utama, dengan akurasi digunakan sebagai metrik pendukung. Hasil evaluasi model VGG19-SATL dibandingkan dengan *baseline* (VGG19-Only). Analisis tambahan dilakukan menggunakan *confusion matrix*, kurva pembelajaran, serta efisiensi komputasi yang ditinjau dari hubungan antara performa model dan waktu pelatihan.

Confusion matrix digunakan untuk memvisualisasikan distribusi prediksi benar dan salah antar kelas. Analisis ini membantu mengidentifikasi kelas yang berpotensi mengalami misklasifikasi serta menilai kemampuan model dalam membedakan variasi visual pada subkelas.

3.2.7 Penarikan Kesimpulan

Tahap penarikan kesimpulan dilakukan untuk merangkum hasil penelitian secara menyeluruh. Kesimpulan dari tahap ini memberikan informasi terkait sejauh mana tujuan penelitian telah tercapai, implikasi metode yang diusulkan terhadap pengembangan model klasifikasi kondisi panel surya, serta arah penelitian selanjutnya yang dapat dilakukan untuk mengatasi keterbatasan yang ada.