

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

2.1.1. Penelitian tentang Deteksi Cacat Pada Kendaraan

Penelitian terkait deteksi cacat permukaan dan ketidaksesuaian cat kendaraan berbasis citra telah berkembang pesat seiring meningkatnya pemanfaatan teknik pemrosesan citra dan *Machine Learning* dalam inspeksi visual otomotif. Jiang et al. [16] menunjukkan bahwa *Convolutional Neural Networks* (CNN) mampu meningkatkan akurasi pendeteksian cacat cat mobil melalui klasifikasi citra berbasis fitur visual. Pendekatan ini efektif dalam mengenali cacat permukaan yang bersifat eksplisit, seperti goresan dan penyok. Namun demikian, penelitian tersebut masih terbatas pada kondisi cacat yang tampak secara visual, sehingga tidak mampu mengidentifikasi perubahan yang telah melalui proses perbaikan dan pengecatan ulang, di mana perbedaan visual menjadi jauh lebih halus.

Pendekatan serupa dikembangkan oleh Kamani et al. [17] dengan mengombinasikan pengukuran *local variance* (VAR) dan metode *One-Against-All Support Vector Machine* (OAA-SVM) untuk meningkatkan stabilitas deteksi cacat terhadap rotasi citra. Meskipun sistem ini menunjukkan ketahanan terhadap variasi orientasi citra, fokus penelitian masih terbatas pada deteksi cacat fisik, tanpa mempertimbangkan perubahan pola warna atau tekstur mikro yang muncul akibat proses pengecatan ulang kendaraan.

Sementara itu, Zhang et al. [18] mengembangkan algoritma *MobileNet-SSD* yang dioptimalkan untuk mendeteksi cacat cat permukaan kendaraan dengan efisiensi inferensi yang lebih baik. Meskipun model ini unggul dari sisi komputasi, sistem tersebut tetap dirancang untuk mendeteksi cacat eksplisit dan belum mampu menganalisis perbedaan halus antara cat pabrik dan cat hasil pengecatan ulang, yang memerlukan analisis tekstur dan distribusi warna secara lebih mendalam.

Secara keseluruhan, penelitian-penelitian pada subbab ini menegaskan bahwa pendekatan berbasis Deep Learning dan pemrosesan citra sangat efektif

untuk mendeteksi cacat permukaan kendaraan yang bersifat eksplisit, seperti goresan, retak, dan penyok. Namun, fokus utama penelitian masih terbatas pada cacat visual yang mudah diamati secara kasat mata. Perubahan lapisan cat akibat proses pengecatan ulang, yang umumnya tidak menimbulkan cacat fisik yang jelas dan hanya memunculkan perbedaan visual yang sangat halus, belum menjadi perhatian utama. Kondisi ini menunjukkan adanya celah penelitian terkait keterbatasan metode deteksi cacat konvensional dalam mengidentifikasi status cat ulang kendaraan.

2.1.2. Penelitian Perbandingan Antara Machine Learning dan Deep Learning

Perbandingan antara pendekatan *Machine Learning* tradisional dan *Deep Learning* dalam klasifikasi citra telah banyak dikaji untuk menilai efektivitas, kebutuhan data, serta kompleksitas komputasi masing-masing metode. Farid Naufal et al. [19] melakukan analisis komparatif antara beberapa algoritma *Machine Learning* seperti SVM dan *K-Nearest Neighbor* dengan arsitektur *Deep Learning* berbasis CNN pada klasifikasi citra Sistem Isyarat Bahasa Indonesia (SIBI). Hasil penelitian menunjukkan bahwa CNN mampu mencapai akurasi yang lebih tinggi ketika jumlah data latih mencukupi, namun memerlukan sumber daya komputasi yang lebih besar serta proses pelatihan yang lebih kompleks. Sebaliknya, algoritma *Machine Learning* tradisional masih menunjukkan performa yang kompetitif pada skenario dataset terbatas dengan waktu komputasi yang lebih efisien.

Pendekatan serupa juga dikaji oleh Lv et al. [20] yang menekankan bahwa *Deep Learning* unggul dalam mengekstraksi fitur secara otomatis tanpa memerlukan proses *handcrafted feature extraction*. Meskipun demikian, penelitian tersebut mengungkap bahwa performa model *Deep Learning* sangat bergantung pada ketersediaan data dalam jumlah besar dan kualitas anotasi yang konsisten. Dalam kondisi data terbatas, model *Machine Learning* yang mengandalkan fitur statistik dan tekstur yang dirancang secara eksplisit masih dapat memberikan hasil klasifikasi yang stabil dan mudah diinterpretasikan. Hal ini menunjukkan adanya kompromi antara fleksibilitas representasi fitur pada *Deep Learning* dan efisiensi

serta interpretabilitas pada *Machine Learning*.

Studi komparatif yang lebih luas dilakukan oleh Wang et al. [21] dengan membandingkan berbagai algoritma klasifikasi citra berbasis tradisional *Machine Learning* dan *Deep Learning* pada beberapa dataset standar. Temuan penelitian ini menunjukkan bahwa CNN secara umum unggul pada dataset berskala besar dan kompleks, sedangkan metode seperti SVM dan *Random Forest* tetap kompetitif pada dataset dengan dimensi fitur yang terkontrol dan jumlah sampel yang terbatas. Namun, penelitian tersebut belum secara spesifik mengevaluasi karakteristik citra dengan perbedaan visual yang sangat halus, seperti variasi tekstur mikro dan reflektansi permukaan, sehingga generalisasi hasilnya pada kasus inspeksi visual tertentu masih terbatas.

Hasil yang konsisten juga dilaporkan oleh Karypidis et al. [22] yang membandingkan kinerja tradisional *Machine Learning* dan *Deep Learning* untuk klasifikasi data dan citra. Penelitian ini menegaskan bahwa *Deep Learning* menawarkan keunggulan akurasi pada permasalahan kompleks, tetapi membutuhkan biaya komputasi tinggi dan risiko *overfitting* pada dataset kecil. Sebaliknya, *Machine Learning* tradisional lebih fleksibel untuk diimplementasikan pada sistem dengan keterbatasan data dan sumber daya, serta lebih mudah dikontrol dari sisi pemilihan fitur yang relevan dengan domain permasalahan.

Tinjauan perbandingan antara *Machine Learning* dan *Deep Learning* menunjukkan bahwa CNN dan model *Deep Learning* lainnya unggul pada dataset berskala besar dengan kompleksitas tinggi, tetapi sangat bergantung pada ketersediaan data latih yang melimpah dan sumber daya komputasi yang besar. Sebaliknya, metode *Machine Learning* tradisional seperti SVM tetap kompetitif dan stabil pada kondisi dataset terbatas. Temuan ini mengindikasikan adanya celah penelitian terkait kebutuhan akan pendekatan klasifikasi yang mampu bekerja optimal pada keterbatasan data, khususnya untuk kasus identifikasi cat ulang kendaraan yang umumnya tidak didukung oleh dataset besar.

2.1.3. Penelitian Penggunaan SVM untuk Klasifikasi Citra

SVM telah lama dikenal sebagai metode klasifikasi yang andal dalam tugas-tugas berbasis citra, terutama ketika perbedaan antar kelas bersifat tipis dan sulit diamati secara visual. Tao [23] menunjukkan bahwa SVM dapat bekerja secara efektif ketika dikombinasikan dengan CNN dan *Random Forest* untuk mendeteksi cacat permukaan logam. Meskipun memberikan hasil yang menjanjikan, penelitian ini masih terbatas pada domain material industri dan tidak mengevaluasi karakteristik warna maupun tekstur yang relevan dengan perbedaan lapisan cat kendaraan.

Agarap [24] menunjukkan bahwa integrasi CNN dan SVM mampu menghasilkan margin pemisah yang lebih optimal dibandingkan penggunaan CNN secara mandiri. Namun, penelitian tersebut tidak menguji kasus spesifik seperti identifikasi keaslian cat kendaraan, sehingga tantangan utama berupa variasi warna dan tekstur mikro akibat pengecatan ulang belum terakomodasi. Hal ini menunjukkan bahwa keunggulan teoretis SVM dalam membentuk margin optimal belum sepenuhnya dieksplorasi pada konteks inspeksi cat mobil.

Dalam studi komparatif, Pal et al. [25] membandingkan performa SVM, 2D-CNN, dan Neural Network pada klasifikasi citra remote sensing, dan menemukan bahwa SVM tetap kompetitif pada dataset dengan variasi terbatas. Meskipun demikian, karakteristik citra remote sensing sangat berbeda dengan permukaan cat kendaraan, sehingga hasil penelitian tersebut belum dapat digeneralisasi untuk kasus identifikasi cat asli dan cat ulang.

Pendekatan hibrida lainnya dikemukakan oleh Sharifrazi et al. [26] yang mengombinasikan CNN, SVM, dan Sobel Filter dalam satu arsitektur untuk meningkatkan akurasi deteksi. Hasil penelitian ini menunjukkan bahwa SVM mampu meningkatkan konsistensi klasifikasi fitur visual. Namun, konteks penelitian berada pada citra medis, sehingga tidak mempertimbangkan tantangan unik permukaan cat kendaraan, seperti refleksi cahaya, variasi kilap, dan kondisi pencahayaan yang tidak terkontrol.

Tinjauan luas oleh Chandra dan Bedi [27] menegaskan bahwa SVM unggul dalam menangani dataset berdimensi tinggi dengan jumlah sampel terbatas.

Meskipun demikian, kajian tersebut tidak menyertakan studi khusus terkait identifikasi keaslian cat mobil, sehingga belum menyediakan kerangka implementasi SVM untuk kasus deteksi cat ulang pada kendaraan. Temuan serupa juga disampaikan oleh Hasan et al. [28] yang membandingkan SVM dan CNN pada citra hyperspectral, namun pendekatan hyperspectral tidak umum digunakan dalam inspeksi kendaraan berbasis citra RGB di kondisi nyata.

Dalam konteks inspeksi visual kendaraan, analisis citra umumnya masih mengandalkan data RGB konvensional, di mana perbedaan antara cat asli dan cat ulang tercermin pada tekstur mikro, distribusi warna, dan karakteristik reflektansi permukaan. Variasi pencahayaan lingkungan terbukti secara signifikan memengaruhi representasi warna pada ruang RGB, sehingga menurunkan konsistensi pemisahan kelas visual. Son et al. [29] menunjukkan bahwa transformasi ruang warna dan penerapan algoritma Machine Learning, khususnya SVM, mampu meningkatkan robustness terhadap perubahan iluminasi serta meningkatkan separabilitas kelas pada citra permukaan material. Namun demikian, pendekatan tersebut masih difokuskan pada deteksi komponen atau cacat permukaan material secara umum dan belum secara spesifik diarahkan untuk mengidentifikasi perubahan lapisan cat akibat pengecatan ulang yang tidak selalu menimbulkan cacat visual yang jelas.

Hasil-hasil penelitian terdahulu menguatkan bahwa SVM memiliki keunggulan teoretis dan empiris dalam menangani klasifikasi citra dengan perbedaan antar kelas yang tipis serta jumlah data yang terbatas. Namun, sebagian besar implementasi SVM masih diterapkan pada domain citra medis, material industri, remote sensing, atau hyperspectral yang memiliki karakteristik optik berbeda dengan permukaan cat kendaraan. Faktor-faktor khas pada inspeksi kendaraan, seperti refleksi cahaya, variasi tingkat kilap, dan kondisi pencahayaan yang tidak terkontrol, belum secara spesifik diakomodasi. Hal ini menegaskan adanya celah penelitian terkait keterbatasan generalisasi domain penelitian SVM terhadap karakteristik visual cat kendaraan berbasis citra RGB.

2.1.4. Penelitian Berbasis Segmentasi Citra pada Inspeksi Permukaan Kendaraan

Pendekatan segmentasi citra telah lama digunakan sebagai tahap awal dalam inspeksi visual kendaraan untuk memisahkan area permukaan yang relevan dari latar belakang atau objek lain. Rotaru, Graf, dan Zhang [30] mengusulkan metode segmentasi citra warna pada ruang warna HSI untuk aplikasi otomotif, dengan tujuan meningkatkan pemisahan objek berdasarkan karakteristik hue dan saturation yang lebih stabil terhadap variasi intensitas pencahayaan dibandingkan ruang RGB. Hasil penelitian menunjukkan bahwa segmentasi pada ruang HSI mampu meningkatkan konsistensi deteksi area permukaan kendaraan. Namun, pendekatan ini masih bersifat rule-based dan sangat bergantung pada penentuan ambang batas warna, sehingga kurang adaptif terhadap variasi kondisi lingkungan dan tidak secara eksplisit mengevaluasi perbedaan halus pada tekstur atau lapisan cat akibat proses pengecatan ulang.

Perkembangan metode segmentasi berbasis Deep Learning ditunjukkan oleh Egodawela et al. [31] yang mengembangkan pendekatan segmentasi dan klasifikasi retak permukaan menggunakan arsitektur Deep Learning pada citra hasil inspeksi berbantuan UAV. Penelitian ini menunjukkan bahwa model segmentasi modern mampu mengidentifikasi area cacat permukaan secara presisi tinggi, bahkan pada kondisi citra kompleks. Meskipun demikian, fokus utama penelitian tersebut adalah segmentasi retak struktural pada infrastruktur, bukan pada analisis karakteristik visual permukaan kendaraan seperti distribusi warna, kilap, atau tekstur mikro. Selain itu, ketergantungan pada dataset berskala besar dan kompleksitas komputasi yang tinggi menjadi keterbatasan apabila diterapkan pada sistem inspeksi kendaraan berbasis citra RGB sederhana.

Pendekatan lain dalam inspeksi kendaraan dikemukakan oleh Sukumar et al. [32] melalui pemanfaatan pencitraan 3D untuk inspeksi bagian bawah kendaraan. Sistem ini mengintegrasikan segmentasi dan rekonstruksi 3D untuk mendeteksi anomali fisik pada permukaan kendaraan. Meskipun memberikan representasi geometris yang kaya, pendekatan berbasis 3D imaging memerlukan perangkat keras khusus dan tidak secara langsung menganalisis perbedaan visual pada lapisan cat

kendaraan. Dengan demikian, metode ini kurang relevan untuk konteks identifikasi keaslian cat atau deteksi pengecatan ulang yang umumnya dilakukan menggunakan citra 2D konvensional.

Penelitian-penelitian berbasis segmentasi citra menunjukkan kontribusi signifikan dalam memisahkan area permukaan dan mendeteksi cacat fisik atau objek tertentu pada kendaraan. Namun, pendekatan segmentasi pada dasarnya dirancang untuk memetakan objek atau cacat yang dapat didefinisikan secara spasial. Dalam konteks identifikasi cat ulang, perubahan yang terjadi bersifat intrinsik pada karakteristik lapisan cat, bukan berupa objek cacat yang dapat disegmentasi secara langsung. Oleh karena itu, pendekatan segmentasi visual murni dinilai kurang efektif untuk mendeteksi status cat ulang kendaraan, sehingga membuka celah penelitian terhadap perlunya metode analisis berbasis tekstur dan warna sebagai alternatif yang lebih relevan.

2.2. Celah Penelitian

Berdasarkan tinjauan literatur yang telah dilakukan, dapat disimpulkan bahwa inspeksi visual cat kendaraan berbasis citra telah banyak diteliti, baik menggunakan pendekatan Deep Learning maupun metode klasifikasi klasik. Meskipun demikian, terdapat beberapa kesenjangan penelitian yang belum sepenuhnya terjawab oleh studi-studi terdahulu, yaitu:

1) Fokus penelitian yang masih dominan pada cacat visual eksplisit

Sebagian besar penelitian terdahulu menitikberatkan pada deteksi cacat permukaan seperti goresan, retak, atau penyok, sementara perubahan lapisan cat akibat pengecatan ulang yang sering kali tidak menampilkan cacat visual belum menjadi fokus utama.

2) Ketergantungan metode Deep Learning pada dataset besar

Pendekatan CNN dan model Deep Learning lainnya umumnya membutuhkan jumlah data yang besar dan sumber daya komputasi tinggi, sehingga kurang sesuai untuk kasus identifikasi cat ulang yang sering kali memiliki keterbatasan data.

3) Keterbatasan generalisasi domain penelitian terdahulu terhadap

karakteristik optik kendaraan

Penerapan SVM dan metode hibrida pada penelitian sebelumnya masih terpaku pada domain citra medis, material industri, atau *remote sensing* yang memiliki karakteristik berbeda. Studi-studi tersebut belum mengakomodasi tantangan unik yang spesifik pada inspeksi permukaan cat kendaraan, yaitu pengaruh refleksi cahaya, variasi tingkat kilap (*gloss*), serta kondisi pencahayaan yang tidak terkontrol saat pengambilan citra.

4) Inefektivitas pendekatan segmentasi visual dalam mendeteksi status cat ulang

Meskipun teknik segmentasi berbasis Deep Learning mampu memetakan area cacat fisik secara presisi, pendekatan ini terbukti tidak memadai untuk kasus identifikasi cat ulang. Hal ini dikarenakan pengecatan ulang bukanlah sebuah objek cacat permukaan yang dapat disegmentasi secara langsung, melainkan merupakan perubahan karakteristik lapisan yang memerlukan analisis tekstur dan warna, bukan sekadar pemisahan objek dari latar belakang.

Oleh karena itu, penelitian ini diarahkan untuk mengisi celah tersebut dengan mengembangkan sistem klasifikasi cat asli dan cat ulang berbasis citra RGB menggunakan pendekatan *Machine Learning* yang lebih ringan dan efisien, khususnya dengan memanfaatkan SVM. Pendekatan ini diharapkan mampu memberikan solusi yang relevan, akurat, dan aplikatif dalam konteks inspeksi visual otomotif dengan keterbatasan data dan sumber daya komputasi. Secara lebih jelas, tabel perbandingan antara penelitian terdahulu dapat dilihat pada Tabel 2.1 berikut.

Tabel 2. 1. Tabel Perbandingan Penelitian

Penulis	Aspek 1	Aspek 2	Aspek 3	Aspek 4
Jiang et al. [16]	Berfokus pada goresan dan penyok yang kasat mata	CNN membutuhkan dataset besar	Tidak mempertimbangkan refleksi dan kilap cat kendaraan	Tidak mampu mengidentifikasi cat ulang tanpa cacat visual

Penulis	Aspek 1	Aspek 2	Aspek 3	Aspek 4
Kamani et al. [17]	Deteksi cacat fisik berbasis variasi lokal permukaan	Relatif efisien pada dataset terbatas	Belum mempertimbangkan perubahan warna dan tekstur mikro	tidak menganalisis perubahan lapisan cat
Zhang et al. [18]	Deteksi cacat eksplisit berbasis MobileNet-SSD	Bergantung pada data latih berannotasi	Bergantung pada data latih berannotasi	Segmentasi diarahkan pada cacat fisik
Farid Naufal et al. [19]	Tidak membahas cacat permukaan kendaraan	Menunjukkan CNN unggul pada dataset besar	Domain bahasa isyarat, bukan citra kendaraan	Tidak menggunakan segmentasi
Lv et al. [20]	Tidak fokus pada cacat visual kendaraan	Menegaskan kebutuhan data besar pada Deep Learning	Tidak mempertimbangkan karakteristik optik kendaraan	Tidak membahas segmentasi
Wang et al. [21]	Fokus pada klasifikasi umum	CNN unggul pada dataset besar	Tidak mengkaji domain otomotif	Tidak menggunakan segmentasi
Karypidis et al. [22]	Tidak membahas cacat cat kendaraan	Menyoroti keterbatasan Deep Learning pada data kecil	Domain umum, bukan inspeksi kendaraan	Tidak menerapkan segmentasi
Tao [23]	fokus pada	Kombinasi	domain material	Tidak

Penulis	Aspek 1	Aspek 2	Aspek 3	Aspek 4
	cacat material industri	CNN-SVM masih membutuhkan data cukup besar	logam, bukan otomotif	membahas segmentasi
Agarap [24]	evaluasi umum klasifikasi citra	CNN-SVM tetap kompleks secara komputasi	Tujuan penelitian tidak spesifik pada cat kendaraan	Tidak membahas mengenai klasifikasi mengenai cat ulang
Pal et al. [25]	Hanya berfokus pada klasifikasi objek citra	Menggunakan SVM sehingga ramah terhadap data terbatas	Hanya berfokus pada domain remote sensing	Tidak relevan untuk klasifikasi pada kendaraan
Sharifrazi et al. [26]	Hanya berfokus pada deteksi objek medis	Menggunakan algoritma hibrida yang membutuhkan data besar	Secara keseluruhan penelitian berfokus pada bidang medis	Tidak dapat membandingkan karakteristik cat
Chandra dan Bedi [27]	Hanya berfokus pada teknik klasifikasi gambar	Menekankan keunggulan SVM pada data terbatas	Tidak membahas atau berkaitan dengan otomotif	Belum menyinggung deteksi klasifikasi cat ulang
Hasan et al. [28]	Fokus penelitian dalam	Membutuhkan data khusus dengan	Hyperspectral tidak umum jika di gunakan pada	Tidak membahas atau menyinggung

Penulis	Aspek 1	Aspek 2	Aspek 3	Aspek 4
	klasifikasi citra hyperspectral	dimensi yang luas atau tinggi	lingkup inspeksi kendaraan	identifikasi cat ulang pada kendaraan
Son et al. [29]	Penelitian fokus mendeteksi beton berdasarkan warna	Tidak memerlukan data luas	Penelitian berfokus pada domain konstruksi	Tidak sejalan dengan pendeteksian cat ulang pada kendaraan
Rotaru, Graf, dan Zhang [30]	Segmentasi area permukaan umum	Tidak membahas kebutuhan dataset besar	Terbatas pada pemisahan warna	Segmentasi tidak mampu mendeteksi cat ulang
Egodawe la et al. [31]	Fokus retak struktural eksplisit	Deep Learning bergantung dataset besar	Terbatas hanya deteksi retak	Segmentasi tidak relevan untuk cat ulang
Sukumar et al. [32]	Deteksi anomali fisik kendaraan	Perangkat keras khusus	Fokus geometri, bukan optik cat	Tidak menggunakan segmentasi 2D
Laksono *	fokus pada perbedaan mikro cat asli dan cat ulang	fokus pada perbedaan mikro cat asli dan cat ulang	dirancang khusus untuk karakteristik cat kendaraan	Efektif mendeteksi menggunakan segmentasi warna dan mampu menangkap perbedaan tekstur mikro serta warna

*) Penelitian yang dilakukan

2.3. Landasan Teori


2.3.1. Teori Pemrosesan Citra Digital

Pemrosesan citra digital merupakan teknik komputasi untuk menganalisis dan mengekstraksi informasi dari citra berbasis piksel [33]. Dalam konteks identifikasi cat mobil, teknik ini menyoroti anomali visual seperti perbedaan distribusi warna dan irregularitas tekstur permukaan akibat pengecatan ulang [34]. Proses representasi citra sebagai matriks numerik memudahkan sistem dalam menerapkan transformasi warna, filtrasi, serta ekstraksi fitur. Melalui *feature extraction*, citra permukaan cat dapat dipetakan menjadi vektor numerik yang siap digunakan oleh algoritma pembelajaran mesin. Pemrosesan citra menjadi landasan dasar untuk membangun sistem deteksi otomatis yang objektif dan terukur

2.3.2. Model Warna dalam Analisis Permukaan Cat

Model representasi warna seperti RGB, HSV, dan CIELAB seperti yang ditunjukkan pada Gambar 2.3.2.1 berperan penting dalam menganalisis karakter permukaan cat [35]. RGB (*Red, Green, Blue*) menggambarkan komposisi intensitas tiga kanal warna, namun sensitif terhadap pencahayaan. HSV lebih stabil karena memisahkan hue, saturation, dan value. Sementara itu, CIELAB sering digunakan dalam pengukuran perbedaan warna karena didesain mendekati persepsi visual manusia. Dalam deteksi cat ulang, pemilihan model warna menjadi sangat krusial karena perbedaan warna yang muncul pada permukaan cat asli dan cat ulang sering kali sangat tipis, sehingga diperlukan representasi warna yang lebih stabil terhadap

variasi pencahayaan, seperti HSV [36].




Gambar 2.3.2.1 Model Representasi Warna (a) RGB (b) HSV (c) CIELAB

2.3.3. Teknik Ekstraksi Fitur Visual Berbasis Citra

Teknik ekstraksi fitur visual yang digunakan dalam penelitian ini mencakup fitur warna, tekstur mikro, serta pola gradien yang berfungsi mengonversi citra menjadi representasi numerik sehingga dapat diolah oleh algoritma pembelajaran mesin [37]. Ekstraksi tekstur menggunakan *Local Binary Pattern* (LBP) terbukti efektif dalam mengidentifikasi pola permukaan halus pada material, termasuk variasi kecil yang tidak mudah diamati secara manual [38]. Pemanfaatan fitur warna melalui *color histogram* pada ruang warna HSV memungkinkan sistem mengenali perbedaan distribusi warna antara cat asli dan cat yang telah mengalami pengecatan ulang. Selain itu, penggunaan *Histogram of Oriented Gradients* (HOG) membantu mendeteksi pola gradien dan struktur permukaan yang berkaitan dengan perbedaan kilap atau ketidakteraturan lapisan cat. Kombinasi ketiga metode ini penting untuk meningkatkan kemampuan sistem dalam membedakan cat pabrik dan cat ulang yang umumnya menunjukkan variasi halus pada warna, tekstur, dan karakteristik permukaan. Pada Gambar 2.3.3.1, pemanfaatan fitur warna melalui color histogram pada ruang warna HSV memungkinkan sistem mengenali perbedaan distribusi warna antara cat asli dan cat yang telah mengalami pengecatan ulang dengan penggambaran alur ekstraksi warna seperti pada Gambar 2.3.3.1. Selain itu, penggunaan Histogram of Oriented Gradients (HOG) membantu mendeteksi pola gradien dan struktur permukaan yang berkaitan dengan perbedaan kilap atau

ketidakteraturan lapisan cat. Kombinasi ketiga metode ini penting untuk meningkatkan kemampuan sistem dalam membedakan cat pabrik dan cat ulang yang umumnya menunjukkan variasi halus pada warna, tekstur, dan karakteristik permukaan.



Gambar 2.3.3.1 Alur Ekstraksi Warna

2.3.4. *Machine Learning* dan *Supervised Learning*

Machine Learning merupakan pendekatan komputasi yang memungkinkan sistem membangun fungsi prediktif melalui proses pembelajaran dari data berlabel, di mana hubungan antara fitur masukan dan kelas keluaran dipelajari secara eksplisit. Dalam konteks *Supervised Learning*, model dikonstruksi menggunakan pasangan data input-output sehingga mampu membentuk batas keputusan yang optimal untuk tugas klasifikasi. Kerangka ini menekankan pentingnya representasi fitur yang relevan serta proses pembelajaran terkontrol guna meminimalkan kesalahan generalisasi, khususnya pada permasalahan klasifikasi biner dengan kompleksitas pola yang tinggi [39], [40].

Supervised Learning secara sistematis melibatkan tahapan pelatihan, validasi, dan pengujian untuk memastikan bahwa model tidak hanya akurat pada

data latih, tetapi juga stabil ketika dihadapkan pada data baru. Proses pelatihan digunakan untuk mengestimasi parameter model berdasarkan data berlabel, sedangkan validasi berperan dalam pemilihan hyperparameter dan pengendalian overfitting. Tahap pengujian kemudian digunakan untuk mengevaluasi performa akhir model secara objektif. Pendekatan ini memungkinkan evaluasi kemampuan generalisasi model melalui metrik kuantitatif yang terstandarisasi, sehingga kinerja sistem dapat dianalisis secara empiris dan terukur [40], [41].

Dalam implementasinya, Supervised Learning banyak digunakan untuk memetakan fitur kompleks ke dalam ruang keputusan yang terpisah secara jelas, termasuk pada sistem klasifikasi berbasis SVM. Model SVM memanfaatkan data berlabel untuk membangun hyperplane dengan margin maksimum sebagai pemisah antar kelas, sehingga efektif dalam menangani data berdimensi tinggi dan jumlah sampel terbatas. Pendekatan ini relevan untuk sistem klasifikasi yang membutuhkan ketelitian tinggi dalam membedakan pola yang memiliki perbedaan halus, karena mekanisme pembelajarannya dirancang untuk mencapai keseimbangan antara kompleksitas model dan kemampuan generalisasi [39], [42].

2.3.5. Support Vector Machine (SVM) sebagai Metode Klasifikasi

SVM bekerja dengan mencari hyperplane optimal yang memisahkan dua kelas dengan margin maksimal [43]. SVM unggul dalam menangani data berdimensi tinggi, dataset terbatas, serta mampu memetakan data nonlinear melalui kernel seperti RBF dan polynomial. Untuk mendapatkan kernel RBF dapat dihitung menggunakan persamaan 2.3.5.1. berikut. Aplikasi SVM banyak digunakan dalam inspeksi permukaan, deteksi cacat material, serta klasifikasi citra bertekstur, sehingga relevan digunakan untuk mendeteksi perbedaan halus antara cat asli dan cat ulang. Selain itu, proses klasifikasi dilakukan menggunakan perhitungan berdasarkan persamaan 2.3.5.2, di mana nilai hasil perhitungan menentukan kelas citra, yaitu bernilai negatif untuk kelas Non-Repaint dan bernilai positif untuk kelas Repaint. bernilai negatif maka gambar dapat di kategorikan sebagai kelas Non Repaint dan sebaliknya jika bernilai positif.

$$K(x_i, x_j) = \exp(-\gamma ||x_i - x_j||^2) \quad \text{Persamaan 2.3.5.1}$$

Keterangan:

$K(x_i, x_j)$ = Kernel RBF

x_i = Vektor fitur sampel ke-i

x_j = Vektor fitur sampel ke-j

$|x_i - x_j|^2$ = Jarak Euclidean kuadrat

γ = Parameter Kernel

$\exp(\cdot)$ = Fungsi eksponensial

$$f(x) = \text{sign} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \right) \quad \text{Persamaan 2.3.5.2}$$

Keterangan:

$f(x)$ = Fungsi keputusan

$\text{sign}(\cdot)$ = Fungsi tanda

$\sum_{i=1}^n$ = Operator penjumlahan

n = Jumlah support vector

α_i = Koefisien Lagrange

y_i = Label kelas

$K(x_i, x)$ = Kernel antara data latih dan data uji

b = Bias

2.3.6. Evaluasi Performansi Model Klasifikasi

Evaluasi performansi, yang meliputi Akurasi, *Precision*, *Recall*, *F1-Score*, dan *Confusion Matrix*, digunakan untuk mengukur tingkat efektivitas model klasifikasi. Parameter-parameter tersebut memungkinkan kualitas sistem dianalisis secara objektif serta dibandingkan dengan metode lain, termasuk *Convolutional Neural Network* (CNN) maupun model berbasis *Deep Learning* [36]. Nilai evaluasi diperoleh melalui perhitungan yang didasarkan pada empat komponen utama dalam

Confusion Matrix, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Akurasi didefinisikan sebagai proporsi prediksi yang benar terhadap keseluruhan data uji dan dirumuskan pada persamaan 2.3.6.1.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{Persamaan 2.3.6.1}$$

Selanjutnya, *precision* digunakan untuk mengukur tingkat ketepatan model dalam memprediksi kelas cat ulang, sebagaimana dinyatakan pada persamaan 2.3.6.2. Sementara itu, *recall* atau sensitivitas merepresentasikan kemampuan model dalam mengidentifikasi seluruh sampel cat ulang, yang dirumuskan pada persamaan 2.3.6.3. Untuk memperoleh evaluasi yang lebih seimbang antara *Precision* dan *Recall*, digunakan *F1-Score* sebagai rata-rata harmonis keduanya, sebagaimana ditunjukkan pada persamaan 2.3.6.4. Seluruh metrik evaluasi tersebut dihitung berdasarkan *Confusion Matrix* yang dirumuskan pada persamaan 2.3.6.5 sebagai dasar utama perhitungan. Dengan demikian, sistem deteksi cat asli dan cat ulang dapat dievaluasi secara kuantitatif dan komprehensif, sehingga performansi model SVM yang digunakan dapat dinyatakan reliabel serta dapat dipertanggung jawabkan secara ilmiah.

$$\text{Precision} = \frac{TP}{TP + FP} \quad \text{Persamaan 2.3.6.2}$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad \text{Persamaan 2.3.6.3}$$

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{Persamaan 2.3.6.4}$$

$$\begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix} \quad \text{Persamaan 2.3.6.5}$$

Keterangan:

TP = *True Positive*

TN = *True Negative*

FP = *False Positive*

FN = *False Negative*

