

Data-Driven Anomaly Control Detection for Railroad Lines Using Sobel Filter and VGG-16 Model, Res-Net50, InceptionV3

Deteksi Kontrol Anomali Berbasis Data Untuk Jalur Kereta Api Menggunakan Filter Sobel dan Model VGG-16, Res-Net50, InceptionV3

Adiratna Ciptaningrum¹, R. Akbar Nur Apriyanto^{2*}, Dimas Nur Prakoso³, R. Gaguk Pratama Yudha⁴, M. Erik Echsony⁵

^{1,2,3,4,5}Department of Engineering, Politeknik Negeri Madiun, Indonesia

¹ adiratna@pnm.ac.id, ² akbar@pnm.ac.id, ³ dimasnur@pnm.ac.id, ⁴ gaguk@pnm.ac.id,

⁵erik_sony@pnm.ac.id

**Corresponding Author: adiratna@pnm.ac.id*

ABSTRACT

Rail inspection is essential to ensure the safety and performance of the rail system. In rail inspection, object detection is an important task to locate and identify damage or obstructions on the rail. This research discusses the use of Sobel features on three convolutional neural network (CNN) architectures, namely VGG-16, ResNet50, and InceptionV3 for object detection in rail inspection. The purpose of this research is to improve the accuracy of object detection in rail inspection by utilizing the edge information obtained from the Sobel filter. This research involves several stages, namely collecting rail image data, image processing with the Sobel filter, feature extraction using three CNN architectures, namely VGG-16, ResNet50, and InceptionV3, and evaluating object detection performance using accuracy metrics. The results show that the use of Sobel features in the three CNN architectures can improve the accuracy of object detection in rail inspection. The evaluation results show that the ResNet50 model provides the best performance with detection accuracy reaching 96%, followed by the InceptionV3 model with 90% accuracy, and the VGG-16 model with 90% accuracy. Based on the results of this study, it can be concluded that the use of Sobel features in CNN architecture can improve object detection accuracy in rail inspection. In addition, the ResNet50 model has the best performance compared to the VGG-16 and InceptionV3 models in object detection in rail inspection. This can be a reference in the development of future rail inspection object detection systems.

Keywords: rail inspection; Sobel feature; VGG-16; Res-Net50; InceptionV3.

ABSTRAK

Inspeksi rel sangat penting untuk memastikan keamanan dan kinerja sistem rel kereta api. Dalam inspeksi rel, deteksi objek adalah tugas yang penting untuk menemukan dan mengidentifikasi kerusakan atau halangan pada rel. Dalam penelitian ini membahas penggunaan fitur Sobel pada tiga arsitektur jaringan saraf konvolusional (CNN), yaitu VGG-16, ResNet50, dan InceptionV3 untuk deteksi objek pada inspeksi rel. Tujuan dari penelitian ini adalah untuk meningkatkan akurasi deteksi objek pada inspeksi rel dengan memanfaatkan informasi tepi yang diperoleh dari filter Sobel. Penelitian ini melibatkan beberapa tahap, yaitu pengumpulan data citra rel, pengolahan citra dengan filter Sobel, ekstraksi fitur dengan menggunakan tiga arsitektur CNN, yaitu VGG-16, ResNet50, dan InceptionV3, dan evaluasi performa deteksi objek menggunakan metrik akurasi. Hasil penelitian menunjukkan bahwa penggunaan fitur Sobel pada ketiga arsitektur CNN dapat meningkatkan akurasi deteksi objek pada inspeksi rel. Hasil evaluasi menunjukkan bahwa model ResNet50 memberikan performa terbaik dengan akurasi deteksi mencapai 96%, diikuti oleh model InceptionV3 dengan akurasi 90%, dan model VGG-16 dengan akurasi 90%. Berdasarkan hasil penelitian ini, dapat disimpulkan bahwa penggunaan fitur Sobel pada arsitektur CNN dapat meningkatkan akurasi deteksi objek pada inspeksi rel. Selain itu, model ResNet50 memiliki performa terbaik

dibandingkan dengan model VGG-16 dan InceptionV3 dalam deteksi objek pada inspeksi rel. Hal ini dapat menjadi acuan dalam pengembangan sistem deteksi objek pada inspeksi rel di masa depan.

Kata kunci: inspeksi rel; fitur Sobel; VGG-16; Res-Net50; InceptionV3.

1. PENDAHULUAN

Inspeksi rel kereta adalah proses untuk memeriksa dan mengevaluasi kondisi rel kereta secara visual dan/atau menggunakan peralatan khusus untuk mendeteksi kerusakan atau keausan yang dapat mempengaruhi keamanan dan kinerja rel kereta. Inspeksi rel kereta dilakukan secara rutin oleh operator rel kereta, inspektur rel kereta, atau personel pemeliharaan untuk memastikan bahwa rel kereta berada dalam kondisi yang aman dan efektif. Adapun terdapat beberapa teknik dan peralatan yang paling umum digunakan dalam inspeksi rel kereta, diantaranya inspeksi visual, pemeriksaan dengan kereta inspeksi, pemeriksaan dengan ultrasonik, dan pemeriksaan dengan infrared (Jiang, J., et al., 2019). Inspeksi rel kereta yang teratur dan cermat sangat penting untuk memastikan keamanan dan efisiensi operasi rel kereta. Setiap kerusakan atau keausan yang ditemukan harus segera diperbaiki atau diganti untuk menghindari bahaya kecelakaan dan kerusakan pada kereta dan kargo yang diangkut.

Namun, teknik dan peralatan yang digunakan untuk inspeksi masih dirasa belum optimum. Oleh karenanya dibutuhkan teknik inspeksi menggunakan visi komputer (Chen, Y., et al., 2019).

Inspeksi rel kereta menggunakan visi komputer adalah teknik yang menggabungkan image processing, analisis gambar, dan kecerdasan buatan untuk memeriksa kondisi rel kereta secara otomatis dan akurat. Teknik ini memanfaatkan kamera atau sensor yang terpasang pada kereta inspeksi atau pada jaringan rel kereta untuk mengambil gambar atau video rel kereta, kemudian gambar tersebut dianalisis oleh sistem visi komputer untuk mendeteksi kerusakan atau keausan pada rel. Inspeksi rel kereta menggunakan visi komputer dapat memberikan banyak manfaat seperti penghematan waktu dan biaya, meningkatkan efisiensi operasi rel kereta, dan meningkatkan akurasi deteksi kerusakan atau keausan pada rel kereta. Namun demikian, teknik ini juga memiliki beberapa tantangan, seperti variasi kondisi cahaya atau lingkungan, deformasi pada rel kereta, atau kebisingan pada gambar atau video. Oleh karena itu, teknik ini memerlukan penyesuaian dan pengujian yang cermat untuk menghasilkan hasil yang akurat dan dapat diandalkan (Dutta, S., et al., 2018).

Terdapat banyak penelitian terkait inspeksi kereta menggunakan visi komputer yang telah dilakukan oleh para peneliti. Beberapa contohnya adalah *"Real-Time Detection and Classification of Railroad Track Defects Using Deep Learning"* oleh (Ahmad Salman Khan, et al., 2018), penelitian ini memanfaatkan teknik deep learning untuk mendeteksi dan mengklasifikasikan kerusakan pada rel kereta secara real-time. Selanjutnya *"Intelligent Railway Track Inspection System based on Deep Learning and Image Processing"* oleh (YanJun Chen, et al., 2019), penelitian ini memanfaatkan teknik deep learning dan image processing untuk mendeteksi dan mengklasifikasikan kerusakan pada rel kereta secara otomatis dan akurat.

Kemudian *"Automated Inspection System for Railroad Switches using Machine Vision"* oleh (Sasan Bakhtiari, 2018). Penelitian ini memanfaatkan sistem machine vision untuk mengidentifikasi kerusakan pada jalan rel kereta, terutama pada bagian persimpangan rel. Dan *"Automatic Track Inspection System Based on Computer Vision and Image Processing"* oleh (Jingxian Li, et al., 2020). Penelitian ini memanfaatkan teknik computer vision dan image processing untuk mendeteksi kerusakan pada rel kereta dan mengklasifikasikannya dalam berbagai kategori seperti retak, korosi, dan keausan. Penelitian-penelitian ini menunjukkan potensi besar dari penggunaan visi komputer dalam inspeksi rel kereta, yang dapat meningkatkan keamanan dan efisiensi operasi kereta api serta mengurangi biaya inspeksi

secara signifikan. Pada penelitian ini, peneliti akan menggunakan kombinasi anisotropic filtering dan Res-Net50 untuk inspeksi visual.

2. METODE PENELITIAN

Pada penelitian ini digunakan kombinasi filter Sobel dan Res-Net50 untuk mendapatkan akurasi yang optimum.

2.1 ANALISIS WARNA

Pada umumnya, citra rel kereta memiliki warna yang kompleks dan beragam, terutama jika ada kerak, karat, atau kotoran lainnya. Oleh karena itu, analisis warna dapat membantu membedakan dan mengidentifikasi area yang perlu diperbaiki atau dibersihkan (Li, J., 2020). Beberapa teknik analisis warna yang dapat digunakan dalam inspeksi rel kereta yaitu dengan cara mengambil ruang warna. Dalam analisis warna RGB, setiap piksel pada citra dinyatakan dalam bentuk triplet (R, G, B), di mana R, G, dan B masing-masing mewakili nilai intensitas warna pada kanal merah, hijau, dan biru pada piksel tersebut. Rata-rata nilai RGB pada sebuah citra dapat dihitung dengan menggunakan persamaan berikut :

$$R_{avg} = \frac{(\sum R)}{N} \quad (1)$$

$$G_{avg} = \frac{(\sum G)}{N} \quad (2)$$

$$B_{avg} = \frac{(\sum B)}{N} \quad (3)$$

Dimana $\sum R$, $\sum G$, dan $\sum B$ masing-masing merupakan total nilai intensitas warna pada kanal merah, hijau, dan biru pada seluruh piksel pada citra, dan N merupakan jumlah piksel pada citra. Selanjutnya untuk histogram warna pada sebuah citra dapat dihitung dengan menghitung jumlah kemunculan setiap nilai intensitas warna pada masing-masing kanal R, G, dan B. Sebagai contoh, histogram warna pada kanal merah dapat dihitung dengan menggunakan persamaan berikut :

$$H(R) = [h_1, h_2, h_3, \dots, h_n] \quad (4)$$

Di mana h_i merupakan jumlah piksel pada citra yang memiliki nilai intensitas warna pada kanal merah sebesar i, dan n merupakan jumlah nilai intensitas warna yang mungkin pada kanal merah (yaitu, 256 pada citra dengan kedalaman warna 8 bit per kanal).

2.2 ANALISIS FITUR

Analisis fitur adalah salah satu teknik dalam pengolahan citra dan visi komputer yang dapat digunakan untuk inspeksi rel. Dalam hal ini, fitur dapat diartikan sebagai karakteristik atau atribut yang dimiliki oleh citra yang dapat diukur atau dihitung. Fitur ini kemudian dapat digunakan untuk mengidentifikasi objek atau bagian dari objek pada citra (Sivaraman, N., 2019).

A. FITUR SOBEL

Tepi pada rel dapat dideteksi dengan menggunakan filter tepi, seperti filter Sobel. Sobel filter merupakan salah satu jenis filter pada pengolahan citra yang digunakan untuk deteksi tepi pada citra. Filter ini menggunakan kernel sobel, yaitu matriks 3x3 atau 5x5, untuk memperoleh nilai gradien pada setiap piksel pada citra. Gradien ini digunakan untuk mendeteksi perbedaan intensitas warna antara piksel yang bersebelahan, sehingga memungkinkan untuk mengidentifikasi lokasi tepi pada citra.

Dalam aplikasinya pada inspeksi rel, sobel filter dapat digunakan untuk mendeteksi keretakan atau perubahan bentuk pada rel. Filter ini dapat bekerja pada citra grayscale

maupun citra berwarna. Pada citra grayscale, sobel filter akan menghasilkan citra dengan piksel-piksel yang memiliki nilai gradien, yang dapat digunakan untuk menandai lokasi tepi pada citra. Sedangkan pada citra berwarna, sobel filter perlu diterapkan pada masing-masing kanal warna (R, G, B) terlebih dahulu sebelum digabungkan kembali menjadi citra berwarna.

$$G_x = [[-1, 0, 1], [-2, 0, 2], [-1, 0, 1]] \quad (6)$$

$$G_y = [[-1, -2, -1], [0, 0, 0], [1, 2, 1]] \quad (7)$$

Gradien pada sumbu x (G_x) dan sumbu y (G_y) pada masing-masing piksel kemudian dapat dihitung dengan mengalikan kernel sobel tersebut dengan nilai intensitas pada masing-masing piksel, dan menjumlahkan hasil perkalian tersebut. Dengan demikian, untuk setiap piksel pada citra, dapat dihitung nilai gradien pada sumbu x (G_x) dan sumbu y (G_y), serta nilai gradien total (G_{mag}) dengan menggunakan rumus berikut :

$$G_x = \sum(G_x * I) \quad G_y = \sum(G_y * I) \quad G_{mag} = \sqrt{G_x^2 + G_y^2} \quad (8)$$

Di mana I merupakan nilai intensitas pada piksel tersebut. Setelah mendapatkan nilai gradien pada setiap piksel, maka dapat dilakukan thresholding atau segmentasi untuk menandai lokasi tepi pada citra, yang kemudian dapat digunakan untuk deteksi keretakan atau perubahan bentuk pada rel.

B. TRANSFORMASI HSV

Pada inspeksi rel, HSV Transform dapat digunakan untuk memisahkan komponen warna pada citra rel. Misalnya, hue dapat digunakan untuk mendeteksi perubahan warna pada rel, sedangkan saturation dapat digunakan untuk memisahkan rel dari latar belakang dengan kemurnian warna yang lebih tinggi.

Setelah melakukan analisis fitur pada citra rel, transformasi warna HSV dapat digunakan untuk membantu memperbaiki hasil deteksi dan memperbaiki performa dari algoritma deteksi inspeksi rel.

Salah satu cara untuk menggunakan transformasi warna HSV adalah dengan mengisolasi fitur rel dari latar belakang. Dengan mengubah citra asli ke mode warna HSV, peneliti dapat mengambil komponen nilai (value) yang lebih tinggi untuk menekankan objek yang lebih terang dan meminimalkan bagian latar belakang yang lebih gelap. Hal ini dapat membantu dalam memisahkan rel dari latar belakang yang berbeda dalam citra dan meningkatkan akurasi deteksi. Transformasi HSV (Hue, Saturation, Value) dapat dijelaskan dengan persamaan berikut:

$$H' = H/60, \text{ untuk nilai } H \text{ dalam rentang } 0 - 360 \text{ derajat} \quad (9)$$

$$C = V * S \quad (10)$$

$$X = C * (1 - |H' \bmod 2 - 1|) \quad (11)$$

$$m = V - C \quad (12)$$

- jika H' berada di rentang $[0,1)$, maka $(R,G,B) = (C,X,0)$
- jika H' berada di rentang $[1,2)$, maka $(R,G,B) = (X,C,0)$
- jika H' berada di rentang $[2,3)$, maka $(R,G,B) = (0,C,X)$
- jika H' berada di rentang $[3,4)$, maka $(R,G,B) = (0,X,C)$
- jika H' berada di rentang $[4,5)$, maka $(R,G,B) = (X,0,C)$
- jika H' berada di rentang $[5,6)$, maka $(R,G,B) = (C,0,X)$

- $(R,G,B) = (R+M,G+M,B+M)$, dengan M =maksimum dari nilai R , G , dan B

Dalam persamaan ini, H adalah hue (warna) dalam derajat, S adalah saturation (kemurnian warna) dalam persentase, dan V adalah value (intensitas warna) dalam persentase juga. C adalah chroma, yaitu intensitas warna tanpa memperhitungkan nilai V . X adalah variabel antara 0 dan C yang bergantung pada nilai H' . m adalah nilai minimum dari nilai R , G , dan B , yang menentukan tingkat kecerahan warna. Dalam praktiknya, transformasi HSV sering digunakan untuk mempermudah analisis warna pada citra, terutama ketika tidak diperlukan informasi spesifik mengenai intensitas cahaya atau kecerahan objek. Dalam penggunaan transformasi warna HSV untuk deteksi inspeksi rel, penting untuk memilih range nilai Hue, Saturation, dan Value yang tepat untuk mengidentifikasi rel. Hal ini tergantung pada variasi warna rel yang digunakan dalam kereta api dan kondisi pencahayaan pada saat pengambilan citra.

C. DETEKSI SUDUT (*HARRIS CORNER DETECTION*)

Teknik *corner detection* atau deteksi sudut dapat digunakan dalam inspeksi rel untuk menemukan titik-titik sudut pada citra rel. Deteksi sudut sangat penting dalam pengolahan citra karena sudut pada citra sering kali merepresentasikan objek atau fitur yang penting dalam citra. Deteksi sudut dapat dilakukan dengan beberapa algoritma, salah satunya adalah Harris Corner Detection. Algoritma ini menghitung perbedaan intensitas di sekitar setiap piksel pada citra dan memperhitungkan perubahan intensitas di beberapa arah. Hasilnya adalah lokasi sudut pada citra. Adapun persamaan deteksi sudut :

$$M = \sum(x,y) w(x,y) [I_x(x,y)^2 I_x(x,y)I_y(x,y)] [I_x(x,y)I_y(x,y)I_y(x,y)^2] \quad (13)$$

Deteksi sudut dengan Harris Corner Detection dapat membantu dalam inspeksi rel dengan mendeteksi titik sudut pada citra rel. Misalnya, sudut pada rel dapat merepresentasikan perubahan arah atau tikungan rel. Dengan deteksi sudut, kita dapat mengukur sudut dan menemukan lokasi titik sudut pada citra rel untuk mendapatkan informasi yang berguna dalam inspeksi rel.

D. FITUR SIFT

Titik-titik penting pada rel dapat dideteksi dengan menggunakan detektor titik-titik, seperti SIFT. Titik-titik ini kemudian dapat digunakan untuk melakukan pencocokan citra dan identifikasi keausan pada rel. Metode ini dapat mengekstraksi fitur dari citra yang tidak terpengaruh oleh perubahan skala, rotasi, dan translasi.

SIFT bekerja dengan cara membangun skala piramida dari citra dan menghitung fitur kepadatan spasial (*spatial density*) untuk setiap level skala. Kemudian, titik-titik kepadatan spasial tersebut digunakan untuk menentukan fitur-fitur lokal yang dapat dikenali (*recognizable local features*) dengan cara membangun gambar-tampilan (*image descriptor*) dari lingkaran sub-piksel di sekitar setiap titik tersebut.

Dalam tahap deteksi fitur, SIFT menggunakan metode Difference of Gaussian (DoG) untuk menemukan titik-titik kepadatan spasial yang mewakili fitur-fitur pada citra. Kemudian, pada tahap pemilihan orientasi utama, SIFT menggunakan histogram gradien orientasi untuk menentukan orientasi utama dari setiap fitur yang telah ditemukan pada tahap sebelumnya. Pada tahap deskripsi fitur, SIFT menghitung histogram gradien orientasi dari lingkaran sub-piksel di sekitar setiap titik fitur yang telah ditemukan. Adapun persamaan DoG :

$$DoG(x,y,\sigma) = G(x,y,k\sigma) - G(x,y,\sigma) \quad (14)$$

Dimana :

- (x, y) adalah koordinat piksel
- σ adalah ukuran filter Gauss
- k adalah faktor skala yang menentukan ukuran filter Gauss pada level yang berbeda
- DoG adalah perbedaan antara dua citra Gaussian

Hasil ekstraksi fitur SIFT dapat digunakan dalam berbagai aplikasi, seperti pencocokan gambar, deteksi objek, dan rekonstruksi 3D. Dalam konteks inspeksi rel, metode SIFT dapat digunakan untuk mendeteksi dan mengekstraksi fitur-fitur pada rel, seperti titik-titik sudut, palang rel, atau benda-benda lainnya yang terdapat pada rel.

2.3 AUGMENTASI

Pada proses augmentasi data termasuk teknik untuk membuat variasi pada dataset yang ada dengan tujuan meningkatkan keanekaragaman data yang digunakan untuk melatih model deep learning. Dengan menghasilkan variasi pada data, model dapat belajar dari data yang lebih beragam dan lebih umum sehingga lebih mampu mengenali pola dan fitur pada data baru yang belum pernah dilihat sebelumnya. Dalam deep learning, augmentasi data sangat penting untuk meningkatkan performa model dan mencegah overfitting pada dataset yang kecil.


Pada penelitian ini proses augmentasi data digunakan beberapa penggunaan generator yang meliputi Test Generator, VGG-16 Generator, Res-Net50 Generator, dan InceptionV3 Generator. Fungsi generator ini dapat digunakan untuk menghasilkan data augmentasi secara tak terbatas dengan mengubah data asli secara acak menggunakan teknik augmentasi data yang telah ditentukan. Hal ini sangat berguna ketika data latih terbatas dan memerlukan variasi data yang lebih banyak.

2.4 PEMODELAN MENGGUNAKAN DEEP LEARNING

Pemodelan menggunakan VGG-16, Res-Net50, dan InceptionV3 adalah teknik deep learning yang populer digunakan untuk tugas-tugas pengolahan citra.

A. VGG-16

VGG-16 merupakan arsitektur deep learning yang memiliki 16 lapisan konvolusi dan menggunakan filter berukuran kecil (3x3) pada setiap lapisan untuk mengekstraksi fitur-fitur gambar. VGG-16 mampu memproses gambar dengan baik dan dapat mengenali banyak kelas objek yang berbeda.



Gambar 1. Arsitektur VGG-16 untuk deteksi inspeksi rel dengan teknik transfer learning.

Pada inspeksi rel, arsitektur VGG-16 Gambar 1 dapat digunakan untuk melakukan deteksi kerusakan pada rel dengan mengenali fitur-fitur kerusakan pada gambar rel. VGG-16 dapat

dilatih dengan dataset gambar rel yang telah diberi label untuk mengenali berbagai jenis kerusakan seperti retak, korosi, atau perubahan bentuk pada rel. Dengan menggunakan teknik transfer learning, VGG-16 dapat diadaptasi untuk tugas-tugas inspeksi rel dengan dataset yang relatif kecil.

Arsitektur VGG-16 terdiri dari 16 lapisan (layer) yang terdiri dari lapisan konvolusi (convolutional layer), lapisan aktivasi ReLU, dan lapisan pooling. Pada dasarnya, arsitektur VGG-16 dirancang untuk mengenali objek dalam citra yang berbeda-beda dan kompleks. Oleh karena itu, VGG-16 dapat digunakan untuk deteksi inspeksi rel dengan mengajarkan jaringan untuk membedakan rel dari latar belakang pada citra. Berikut adalah arsitektur VGG-16 secara umum:

- Lapisan input: memproses citra masukan dengan ukuran 224 x 224 piksel dan 3 channel warna (RGB).
- Lapisan konvolusi: melakukan ekstraksi fitur dari citra masukan menggunakan beberapa filter konvolusi dengan ukuran 3x3 piksel dan stride 1. Setiap lapisan konvolusi diikuti oleh lapisan aktivasi ReLU yang melakukan non-linearitas pada hasil konvolusi.
- Lapisan pooling: melakukan downsampling pada hasil konvolusi untuk mengurangi ukuran representasi fitur. VGG-16 menggunakan max pooling dengan ukuran 2x2 piksel dan stride 2.
- Lapisan Fully Connected (FC): melakukan klasifikasi objek dengan menghubungkan semua fitur yang diekstraksi oleh konvolusi dan pooling. VGG-16 memiliki 3 lapisan FC yang masing-masing memiliki 4096 neuron.
- Lapisan output: menghasilkan probabilitas kelas objek pada citra masukan. VGG-16 memiliki lapisan output dengan 1000 neuron, yang masing-masing merepresentasikan 1 kelas objek.

Untuk deteksi inspeksi rel, jaringan VGG-16 dapat dilatih dengan menggunakan dataset citra rel yang telah dilabeli (*labeled dataset*). Pada tahap pelatihan, bobot (*weight*) jaringan CNN diatur sedemikian rupa untuk memaksimalkan akurasi klasifikasi pada dataset pelatihan. Pada tahap pengujian, jaringan CNN dapat digunakan untuk mengklasifikasikan citra rel dalam dataset yang belum pernah dilihat sebelumnya.


Namun, karena ukuran dataset citra rel terbatas, terkadang perlu dilakukan teknik augmentasi data (data augmentation) untuk meningkatkan variasi citra dan memperbaiki kinerja jaringan CNN. Teknik augmentasi data dapat berupa rotasi, pergeseran, pembalikan (flip), dan lainnya.

Dalam keseluruhan, VGG-16 dapat digunakan untuk deteksi inspeksi rel dengan mengajarkan jaringan untuk membedakan rel dari latar belakang pada citra. Namun, karena arsitektur VGG-16 memiliki jumlah parameter yang sangat besar, pelatihan jaringan dapat memakan waktu dan sumber daya yang besar.

B. RES-NET50

Untuk menggunakan Res-Net50 untuk deteksi objek pada inspeksi rel, pertama-tama kita perlu melakukan pelabelan data dengan memberikan label pada objek-objek yang ada pada gambar. Selanjutnya, kita dapat melatih model Res-Net50 menggunakan data yang telah dilabeli tersebut dengan menggunakan teknik transfer learning. Dalam transfer learning, kita dapat menggunakan model Res-Net50 yang telah dilatih pada dataset yang lebih besar seperti

ImageNet, dan kemudian kita tinggal menyesuaikan kembali parameter-parameter model tersebut dengan data yang kita miliki pada inspeksi rel.




Gambar 2. Arsitektur Res-Net50 untuk deteksi inspeksi rel.

Setelah model Res-Net50 dilatih, kita dapat menggunakannya untuk melakukan deteksi objek pada gambar inspeksi rel. Proses deteksi objek pada Res-Net50 dilakukan dengan cara melakukan perhitungan pada matriks konvolusi yang mengambil informasi tentang fitur-fitur pada gambar, dan kemudian menghasilkan prediksi tentang objek apa yang terdapat pada gambar tersebut. Hasil deteksi objek tersebut kemudian dapat ditampilkan pada output model sebagai kotak yang menunjukkan lokasi objek pada gambar.

C. INCEPTIONV3

InceptionV3 didasarkan pada konsep "modul Inception", yang menggunakan beberapa filter konvolusi dengan ukuran dan dilatasi yang berbeda untuk menangkap fitur pada berbagai skala. Modul Inception memungkinkan model untuk menggabungkan informasi dari fitur-fitur yang ditangkap pada berbagai skala dan menyelesaikan masalah ketergantungan pada skala yang sering terjadi pada model deep learning.

Selain modul Inception, InceptionV3 juga menggunakan teknik seperti regularisasi L2 dan dropout untuk mencegah overfitting pada model. Model ini juga menggunakan pre-training pada dataset ImageNet untuk memperoleh fitur-fitur yang dapat digunakan pada tugas deteksi objek pada inspeksi rel.



Gambar 3. Arsitektur InceptionV3 untuk deteksi inspeksi rel.

Dalam praktiknya, penggunaan InceptionV3 untuk deteksi objek pada inspeksi rel dapat dilakukan dengan mentraining model menggunakan dataset gambar rel yang sudah diannotasi dengan label objek-objek yang ingin dideteksi. Setelah model dilatih, model dapat digunakan untuk melakukan deteksi objek pada gambar rel baru dengan menghitung probabilitas keberadaan objek yang diinginkan pada tiap lokasi gambar.

3. HASIL DAN PEMBAHASAN


Pada penelitian ini, peneliti membagi kategori data yang ada pada Tabel 1 yang meliputi train sample, val sample, dan test sample. Masing-masing digunakan untuk kelas defect dan non-defect.

Tabel 1: Jumlah Sampel Data Defect dan Non-Defect


No.	Defect	Jumlah Sampel	Non-Defect	Jumlah Sampel
1.	Train Sample	150	Train Sample	150
2.	Val Sample	31	Val Sample	31
3.	Test Sample	11	Test Sample	11

Source : Analysed from the primary source.


Didapatkan hasil dari ruang warna RGB dari defect dan non-defect disertai histogram ruang warna dari RGB. Tiap kondisi defect maupun non-defect direpresentasikan ke dalam ruang warna RGB untuk mengekstrak informasi warna dari suatu gambar dalam bentuk nilai numerik.



Gambar 4. Analisis intensitas melalui histogram ruang warna pada warna Red.




Gambar 5. Analisis intensitas melalui histogram ruang warna pada warna Green.




Gambar 6. Analisis intensitas melalui histogram ruang warna pada warna Blue.

Analisis warna dan fitur Sobel saling terkait dalam inspeksi rel. Analisis warna dapat membantu mengidentifikasi bagian-bagian rel yang berbeda dengan memperhatikan perbedaan warna, sementara fitur Sobel digunakan untuk menemukan tepi atau perbedaan intensitas yang dapat membantu memperjelas fitur pada bagian-bagian tersebut. Kombinasi kedua teknik ini dapat memberikan informasi yang lebih lengkap dan akurat mengenai kondisi rel dan potensi kerusakan yang mungkin terjadi.

Analisis tepi dengan Sobel filter dapat menghasilkan gambar dengan tepian yang lebih tajam dan jelas, sehingga mempermudah deteksi objek pada gambar. Sobel filter mampu mendeteksi garis dan tepi pada gambar rel dengan baik, terutama pada garis-garis lurus seperti rel yang terlihat pada gambar berikut.



Gambar 7. Analisis tepi menggunakan fitur Sobel pada rel defect.




Gambar 8. Analisis tepi menggunakan fitur Sobel pada rel non-defect.


Hasil dari analisis fitur Sobel pada inspeksi rel dapat dilihat pada gambar yang menunjukkan bagian dari rel kereta yang diidentifikasi sebagai tepi oleh fitur Sobel. Tepi-tepi tersebut dapat memberikan informasi mengenai keadaan permukaan rel seperti adanya retakan atau kerusakan pada rel.

Namun demikian, analisis fitur Sobel juga memiliki beberapa kelemahan. Salah satu kelemahan tersebut adalah kepekaan terhadap noise pada gambar. Oleh karena itu, perlu dilakukan pemrosesan lanjutan seperti filtering untuk mengurangi noise pada gambar sebelum dilakukan analisis fitur Sobel. Selain itu, analisis fitur Sobel hanya dapat memberikan informasi mengenai tepi pada gambar, sehingga perlu dilakukan analisis fitur lain seperti analisis warna atau analisis tekstur untuk memberikan informasi yang lebih lengkap mengenai keadaan rel kereta.

Setelah dilakukan fitur Sobel untuk analisis tepi pada citra rel kereta, selanjutnya dilakukan transformasi HSV untuk analisis warna. Transformasi HSV dilakukan untuk memperoleh informasi mengenai hue, saturation, dan value pada setiap piksel pada citra rel kereta.



Gambar 9. Transformasi HSV pada rel yang mengalami defect.



Gambar 10. Transformasi HSV pada rel yang non-defect.

Hasil dari transformasi HSV menunjukkan bahwa terdapat perbedaan warna antara rel yang normal dan rusak. Rel yang rusak umumnya memiliki nilai hue yang lebih rendah dan saturation yang lebih tinggi dibandingkan rel yang normal. Hal ini dapat dijadikan sebagai ciri atau fitur untuk melakukan inspeksi rel kereta secara otomatis menggunakan teknik visi komputer. Pada pembahasan selanjutnya, dilakukan integrasi antara fitur Sobel untuk analisis tepi dan transformasi HSV untuk analisis warna guna memperoleh hasil yang lebih akurat dalam inspeksi rel kereta.

Selanjutnya untuk deteksi sudut atau corner sangat penting dalam inspeksi rel karena dapat membantu dalam identifikasi lokasi cacat atau kerusakan pada rel. Dalam penelitian ini, dilakukan deteksi corner menggunakan metode Harris Corner setelah dilakukan fitur Sobel dan transformasi HSV. Setelah dilakukan fitur Sobel, gambar hasil ditingkatkan untuk meningkatkan kontrasnya. Kemudian, dilakukan transformasi HSV untuk mengubah ruang warna dari RGB ke HSV, di mana komponen Value (V) dari ruang warna HSV digunakan untuk meningkatkan kontras gambar. Hasil transformasi ini digunakan sebagai input untuk deteksi sudut dengan metode Harris Corner.



(a)



(b)

Gambar 11. Deteksi sudut (corner) pada bagian rel defect (a) rel defect keseluruhan; (b) rel defect ketika diperbesar.



(a)



(b)

Gambar 12. Deteksi sudut (corner) pada bagian rel non-defect (a) rel non-defect keseluruhan; (b) rel non-defect ketika diperbesar.

Hasil deteksi sudut menunjukkan bahwa metode Harris Corner berhasil mengidentifikasi sudut-sudut yang terdapat pada rel dengan baik. Sudut-sudut tersebut dapat digunakan sebagai titik acuan untuk mendeteksi dan memetakan kerusakan pada rel. Dalam pembahasan, dijelaskan bahwa penggunaan fitur Sobel dan transformasi HSV dapat meningkatkan kualitas hasil deteksi corner pada gambar rel. Selain itu, dijelaskan pula beberapa kendala yang dihadapi dalam proses deteksi corner, seperti noise pada gambar dan kepekaan parameter deteksi sudut.

Dalam keseluruhan, hasil dan pembahasan deteksi sudut setelah dilakukan fitur Sobel dan transformasi HSV pada inspeksi rel menunjukkan bahwa penggunaan metode Harris Corner dapat membantu dalam identifikasi lokasi kerusakan pada rel dengan lebih efektif. Namun, perlu dilakukan pengaturan parameter deteksi sudut secara tepat untuk menghindari false positive atau false negative pada deteksi sudut.

Setelah dilakukan deteksi sudut menggunakan algoritma Harris corner, dilakukan ekstraksi fitur menggunakan algoritma *Scale-Invariant Feature Transform* (SIFT) pada setiap titik sudut yang terdeteksi. Hasil dari ekstraksi fitur SIFT adalah deskripsi fitur yang mewakili ciri khas dari masing-masing titik sudut.

Deskripsi fitur SIFT terdiri dari 128 dimensi, yang merepresentasikan keunikan dari setiap titik sudut. Deskripsi fitur ini dapat digunakan untuk melakukan pencocokan atau matching antara citra rel yang sedang diuji dengan citra rel yang telah disimpan pada database. Dengan menggunakan teknik pencocokan yang tepat, dapat dilakukan identifikasi kerusakan pada rel dengan tingkat akurasi yang tinggi.



Gambar 13. Fitur SIFT pada rel defect.



Gambar 14. Fitur SIFT pada rel non-defect.


Namun, perlu diperhatikan bahwa penggunaan fitur SIFT pada citra rel juga memiliki kelemahan, yaitu sensitivitas terhadap perubahan rotasi, skala, dan transformasi affine pada citra. Oleh karena itu, perlu dilakukan preprocessing terlebih dahulu pada citra sebelum dilakukan ekstraksi fitur SIFT untuk mengurangi efek dari perubahan tersebut.

3.1 ANALISIS PERFORMA PEMODELAN MENGGUNAKAN DEEP LEARNING


A. ANALISIS PERFORMA VGG-16

Untuk menganalisis performa model akurasi VGG-16 pada deteksi objek inspeksi rel, dapat dilakukan dengan memplot grafik akurasi dan loss dari model. Grafik akurasi menunjukkan seberapa akurat model dalam memprediksi objek, sedangkan grafik loss

menunjukkan seberapa baik model belajar dari data. Berikut adalah hasil grafik akurasi dan loss dari model VGG-16 pada deteksi objek inspeksi rel.



Gambar 15. Model akurasi pada VGG-16.




Gambar 16. Model loss pada VGG-16.


Dari grafik di atas, dapat dilihat bahwa akurasi model naik secara bertahap selama proses pelatihan dan mencapai akurasi sekitar 90% setelah sekitar 20 epoch. Sedangkan loss model turun secara bertahap selama pelatihan dan mencapai loss sekitar 0.3 setelah sekitar 20 epoch.

B. ANALISIS PERFORMA VGG-16

Untuk analisis performa model ResNet50 pada deteksi objek inspeksi rel, dapat dilihat dari grafik model akurasi dan model loss berikut ini.



Gambar 17. Model akurasi pada Res-Net50.




Gambar 18. Model loss pada Res-Net50.

Berdasarkan grafik Gambar 17, dapat dilihat bahwa model ResNet50 pada deteksi objek inspeksi rel memiliki akurasi yang meningkat dengan cepat pada awal epoch dan mencapai titik puncaknya pada sekitar epoch 15-20, dengan akurasi mencapai sekitar 96%. Namun, setelah itu akurasi cenderung stagnan dan tidak mengalami peningkatan yang signifikan. Sementara itu, model loss menurun dengan cepat pada awal epoch dan terus menurun hingga mencapai titik minimum pada sekitar epoch 25-30, dengan nilai loss mencapai sekitar 0.05. Setelah itu, loss cenderung stagnan dan tidak mengalami penurunan yang signifikan.


Berdasarkan grafik Gambar 18, dapat disimpulkan bahwa model ResNet50 pada deteksi objek inspeksi rel memiliki performa yang baik dengan akurasi mencapai 96% dan nilai loss yang rendah. Namun, ada kemungkinan bahwa model tersebut sudah mengalami overfitting pada sekitar epoch 15-20, mengingat akurasi tidak mengalami peningkatan yang signifikan setelah itu. Oleh karena itu, perlu dilakukan evaluasi lebih lanjut terhadap performa model, seperti dengan menggunakan metrik precision, recall, dan F1-score, untuk memastikan bahwa model tersebut memang memiliki performa yang baik dalam deteksi objek pada inspeksi rel.

C. ANALISIS PERFORMA INCEPTIONV3

Untuk analisis performa model InceptionV3 pada inspeksi rel, perlu dilihat grafik model akurasi dan model loss. Grafik model akurasi pada Gambar 19 menunjukkan seberapa baik model dapat memprediksi label yang benar selama pelatihan dan validasi, sedangkan grafik model loss menunjukkan seberapa baik model meminimalkan kesalahan prediksi selama pelatihan dan validasi.



Gambar 19. Model akurasi pada InceptionV3.



Gambar 20. Model loss pada InceptionV3.

Berdasarkan grafik model akurasi pada Gambar 19 dan model loss pada Gambar 20 yang diperoleh dari pelatihan model InceptionV3 pada dataset inspeksi rel, terlihat bahwa model berhasil mencapai akurasi sekitar 95% pada data pelatihan dan sekitar 90% pada data validasi setelah beberapa epoch. Sedangkan, model loss pada data pelatihan dan data validasi mengalami penurunan secara bertahap seiring dengan peningkatan epoch.

Hal ini menunjukkan bahwa model InceptionV3 berhasil mengenali pola dan fitur yang berkaitan dengan inspeksi rel dengan baik, dan mampu memprediksi label dengan akurasi yang cukup tinggi. Namun, peningkatan epoch juga dapat meningkatkan overfitting pada

model, sehingga perlu dilakukan evaluasi lebih lanjut untuk mengevaluasi performa model pada data uji.

4. KESIMPULAN

Pada inspeksi rel, deteksi objek dapat dilakukan dengan menggunakan beberapa arsitektur deep learning, seperti VGG-16, Res-Net50, dan InceptionV3. Pada penelitian ini, fitur Sobel digunakan untuk mengekstraksi fitur tepi dari gambar rel, kemudian fitur ini diolah oleh masing-masing arsitektur deep learning untuk mendeteksi objek pada gambar. Dalam penggunaan fitur Sobel, hasil yang didapat cukup menjanjikan dalam mengekstraksi fitur tepi pada gambar rel. Selain itu, penggunaan transformasi HSV pada fitur Sobel dapat meningkatkan deteksi sudut dan corner pada gambar rel.

Untuk penggunaan arsitektur deep learning, hasil yang didapat menunjukkan bahwa Res-Net50 memiliki akurasi yang lebih baik sebesar 96% dibandingkan dengan VGG-16 sebesar 90% dan InceptionV3 sebesar 90%. Namun, ketiga arsitektur deep learning tersebut memberikan hasil yang cukup memuaskan dalam mendeteksi objek pada gambar rel. Kesimpulannya, penggunaan fitur Sobel dan arsitektur deep learning merupakan metode yang efektif untuk deteksi objek pada inspeksi rel. Penggabungan kedua metode tersebut dapat meningkatkan performa deteksi objek pada gambar rel dan memberikan hasil yang lebih akurat.

REFERENSI

- Bakhtiari, S., & Kwan, A. C. W. "Automated Inspection System for Railroad Switches Using Machine Vision". *International Journal of Advanced Computer Science and Applications* (2018). 9(8), 65-70.
- Chen, Y., Xu, Z., Li, L., Zhu, C., & Wu, Y. "Intelligence Railway Track Inspection System Based on Deep Learning and Image Processing" (2019). *Measurement*, 136, 401-411.
- Cheng, G., Han, J., Zhang, Y., & Yu, T. "Detecting Vehicles in UAV Images With Deep Learning : A Benchmark Dataset and A Comparative Study" (2019). *IEEE Transactions on Geoscience and Remote Sensing*, 57(10), 7784-7798
- Dutta, S., Jain, S., & Gupta, N. "Railway Track Anomaly Detection using Computer Vision Techniques". (2018). 6th International Symposium on Computational and Business Intelligence (ISCBI) (pp. 62-66). Vancouver, BC, Canada: IEEE.
- Jiang, J., Sun, C., Liu, Z., & Zhu, W. "Object Detection Algorithm Based on Improved ResNet50". *Journal of Physics: Conference Series* (2019), 1256(4), 042014 .
- Khan AS, Bilal HSM. "Real-time Detection and Classification of Railroad Track Defects Using Deep Learning". 15th International Bhurban Conference on Applied Science and Technology (IBCAST); (2018) Jan 9-13; Islamabad, Pakistan. IEEE : 2018. P.545-50.
- Khan AS, Bilal H.S.M., & Khan, M. K. "Automatic Railroad Track Inspection Using Deep Learning and Image Processing" (2019). *IEEE 22nd International Multi-Topic Conference (INMIC)* (pp.1-6).
- Li, J., Liu, X., Zhang, L., Wang, Y., Zhang, S., Wang, Y.,... & Chen, Y. "Automatic Track Inspection System Based on Computer Vision and Image Processing" (2020). *IEEE Access*, 8, 79496-79509.
- Sudip Paul, Tuhin Sarkar, et al. "Intelligent Railway Inspection Using Machine Vision and Deep Learning" (2020). *Proceedings of The International Conference on Machine Learning, Big Data, Cloud, and Parallel Computing (COMITCon)*.
- Sivaraman, N., Balakrishnan, K. M., & Kandasamy, A. "Automated Railway Track Inspection Using Edge Detection Techniques". (2019). 5th International Conference on Advanced Computing & Communication Systems (ICACCS) (pp. 1526-1530). IEEE.
- Sivaraman, N., Balakrishnan, K. M., & Kandasamy, A. "Real-Time Detection of Rail Track Anomalies using Edge Detection Techniques". (2019). 5th International Conference on Advanced Computing & Communication Systems (ICACCS) (pp. 136-141). IEEE.