

Deteksi Baut Kereta Api Menggunakan *Artificial Intelligence*

Firman¹, Helfy Susilawati *², Ginaldi Ari Nugroho³

¹⁻³Teknik Elektro, Universitas Garut

E-mail: firmanfardiansyah2592@gmail.com¹, helfy.susilawati@uniga.ac.id², ginaldi.ari@uniga.ac.id³

Abstrak. Baut merupakan salah satu komponen vital dalam struktur rel kereta api karena berfungsi sebagai pengencang antar komponen rel. Kondisi baut yang tidak layak dapat menimbulkan risiko kecelakaan serius. Saat ini, pengecekan kondisi baut masih dilakukan secara manual oleh petugas yang berjalan menyusuri rel. Metode ini rentan terhadap kesalahan manusia dan tidak terdokumentasi secara sistematis. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis baut kereta api menggunakan model *deep learning* SSD ResNet50 V1. Dataset yang digunakan terdiri dari 200 gambar hasil ekstraksi video, dengan 183 gambar untuk pelatihan dan 17 gambar untuk pengujian. Hasil pelatihan menunjukkan nilai presisi sebesar 92,64% dan *recall* sebesar 64,87%. Penelitian ini merupakan langkah awal dalam pengembangan sistem *monitoring* cerdas untuk infrastruktur rel kereta api.

Kata kunci: Deteksi objek; Baut kereta api; *Deep learning*; SSD ResNet50

Abstract. Bolts are one of the most critical components in railway track systems as they secure rail parts together. Faulty or loose bolts pose significant risks to railway safety. Currently, bolt inspections are manually conducted by operators walking along the track, which is prone to human error and lacks systematic documentation. This research proposes an automated bolt detection system using the SSD ResNet50 V1 deep learning model. The dataset consists of 200 images extracted from video footage, with 183 images for training and 17 for testing. The results show a precision score of 92.64% and a recall score of 64.87%. This study serves as a foundational step toward the development of intelligent monitoring systems for railway infrastructure.

Keywords: Bolt Railway; Object Detection; SSD ResNet50; Deep Learning

1. Pendahuluan

Kereta api merupakan salah satu alat transportasi yang dapat dipergunakan oleh banyak orang. Kereta api merupakan salah satu transportasi darat yang dinilai efisien dan untuk meningkatkan pelayanan [1]. Moda transportasi kereta api merupakan salah satu moda angkutan umum yang memiliki beberapa kelebihan di antaranya adalah kepastian waktu berangkat dan waktu sampai tujuan, serta merupakan moda transportasi darat yang bebas dari kemacetan [2]. Salah satu bagian penting dari moda transportasi kereta api adalah rel kereta api. Rel kereta api merupakan jalur tempat kereta api bergerak. Salah satu elemen pada rel kereta api adalah baut. Baut merupakan salah satu elemen penghubung yang banyak digunakan dalam dunia industri untuk kereta api, menara turbin angin, dan struktur bangunan [3]. Baut

pada rel kereta api digunakan untuk mengencangkan rel ke bantalan rel dan menjaganya tetap pada tempatnya, sehingga memberikan kestabilan dan dukungan bagi jalur rel [4].

Mengingat pentingnya komponen baut pada rel kereta api, untuk menjaga kondisi baut kereta api dalam keadaan baik, saat ini dilakukan pengecekan setiap harinya [5]. Pada pagi hari, petugas ditugaskan untuk menyusuri rel kereta api [6]. Proses penyusuran rel kereta api ini dilakukan dengan cara berjalan menyusuri rel atau menggunakan kendaraan yang sudah dimodifikasi agar dapat berjalan di rel kereta api [6]. Penyusuran jalur rel ini bertujuan untuk melakukan pengecekan kondisi jalur rel kereta api, salah satunya adalah pengecekan kondisi baut kereta api.

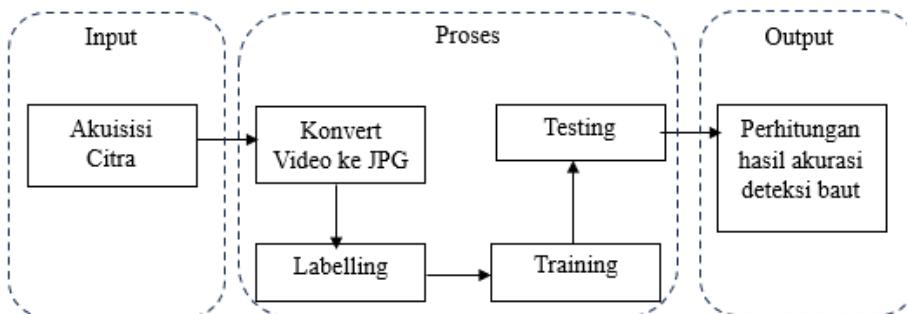
Pengecekan kondisi baut kereta api yang masih menggunakan cara manual menjadi kurang efektif dikarenakan perbedaan persepsi dalam mendefinisikan kondisi baut. Selain itu, pencatatan terkait kondisi baut di rel kereta api juga belum dilakukan [7]. Oleh karena itu, diperlukan penelitian yang dapat meminimalisir hal tersebut.

Penelitian mengenai rel kereta api sudah banyak dilakukan, di antaranya adalah sistem prediksi pemeliharaan kereta api untuk sistem kereta metro yang menggunakan algoritma pengelompokan untuk mengidentifikasi probabilitas tingkat intervensi dengan mengategorikan intervensi pemeliharaan ke dalam tiga tingkat probabilitas: rendah, sedang, dan tinggi [8]. Terdapat juga penelitian untuk meningkatkan teknologi kontrol lalu lintas yang aman pada perlintasan kereta api digital, yang memaparkan ide teknologi kontrol kereta api yang terhubung dengan lingkungan dan komponen di sekitarnya, seperti palang pintu dan lampu [9]. Selain penelitian pada kereta api, terdapat pula penelitian mengenai deteksi kelelahan operator pada rel kereta api [10]. Terkait penelitian mengenai jalur rel kereta api, ada penelitian yang mendekripsi cacat pada rel menggunakan CNN [7] dan penelitian yang menggunakan metode *Edge Detection* [9]. Penelitian retakan rel juga dilakukan dengan menggunakan *Deep Learning* dengan metode transformasi Gabor [10]. Penelitian-penelitian sebelumnya menunjukkan bahwa telah banyak dikembangkan berbagai metode inspeksi otomatis, mulai dari analisis getaran, *thermografi* inframerah, pemantauan akustik, citra multispektral, robot inspeksi bergerak, sistem berbasis UAV, *digital twin*, metode LSTM untuk deteksi kelainan, *vision-based bolt-tightening monitoring*, hingga kombinasi sensor cerdas dan IoT untuk pemantauan kondisi rel serta pendekatan *augmented reality* untuk dokumentasi inspeksi [11], [12], [13], [14], [15].

2. Metode

2.1 Diagram Blok

Penelitian ini menggunakan pendekatan berbasis *computer vision* dengan tahapan: (1) akuisisi citra, (2) konversi video ke gambar, (3) pelabelan data, (4) pelatihan model, dan (5) pengujian.



Gambar 1. Blok Diagram Penelitian

2.2 Akuisisi dan Preprocessing Data

Data diperoleh melalui perekaman video menggunakan kamera ponsel, kemudian diekstrak menjadi 200 frame gambar berformat JPG. Dari jumlah tersebut, sebanyak 183 gambar digunakan untuk pelatihan dan 17 gambar untuk pengujian. Proses pelabelan objek dilakukan secara manual menggunakan aplikasi *labelling* dengan menambahkan *bounding box* pada objek baut yang muncul di setiap gambar.

2.3 Pelatihan Model

Model yang digunakan dalam penelitian ini adalah SSD (*Single Shot Detector*) dengan *backbone* ResNet50 V1. Pelatihan dilakukan selama 2.000 langkah (*steps*) menggunakan parameter *learning rate* sebesar 0,004, *batch size* sebanyak 4, dan jumlah *epoch* sebanyak 50. Proses pelatihan dijalankan di lingkungan Anaconda dengan Python versi 3.9, TensorFlow versi 2.10, dan didukung oleh GPU NVIDIA RTX 3050.

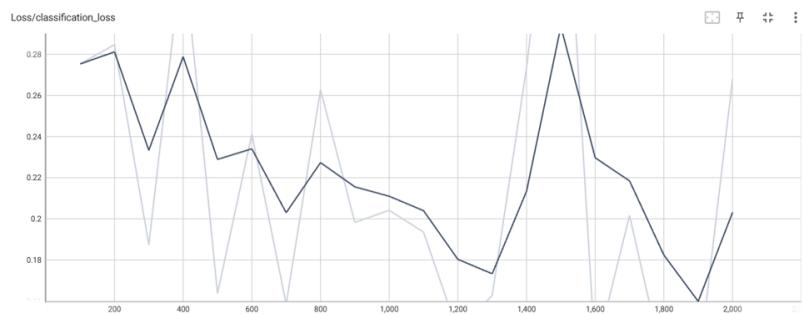
2.4 Strategi Tambahan

Mengingat keterbatasan jumlah data, digunakan beberapa teknik augmentasi seperti rotasi, *flipping*, dan penyesuaian kontras untuk meningkatkan keragaman data pelatihan. Di masa mendatang, direncanakan pengumpulan *dataset* yang lebih besar dan bervariasi, serta eksplorasi model deteksi lain seperti YOLOv5 guna memperoleh hasil deteksi yang lebih optimal.

3. Hasil dan Pembahasan

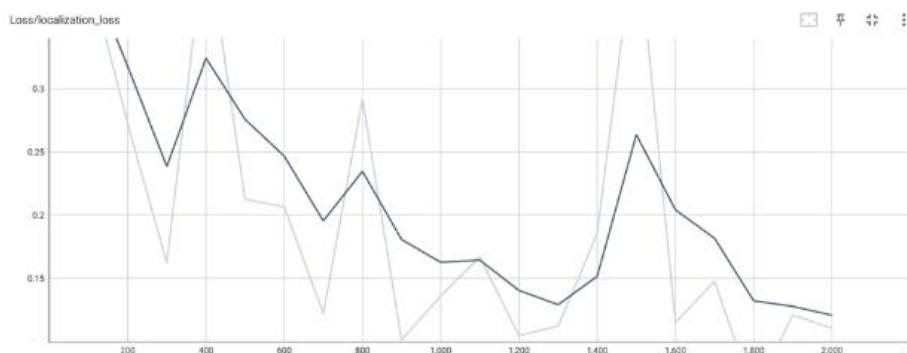
3.1 Hasil Penelitian

Berdasarkan hasil penelitian dengan menggunakan 183 *dataset* data *training*, data untuk *classification loss training* dapat dilihat pada Gambar 3. *Classification loss* merupakan fungsi yang melatih klasifikasi untuk menentukan jenis objek target.



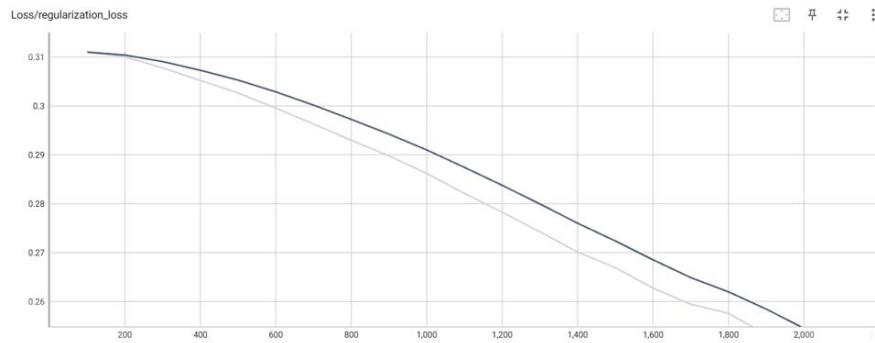
Gambar 3. Classification Loss Training

Gambar 4 menunjukkan *localization loss* pada saat proses *training* dengan menggunakan 183 *dataset*. *Localization loss* adalah fungsi untuk melatih *bounding box* yang diprediksi dengan nilai sebenarnya.



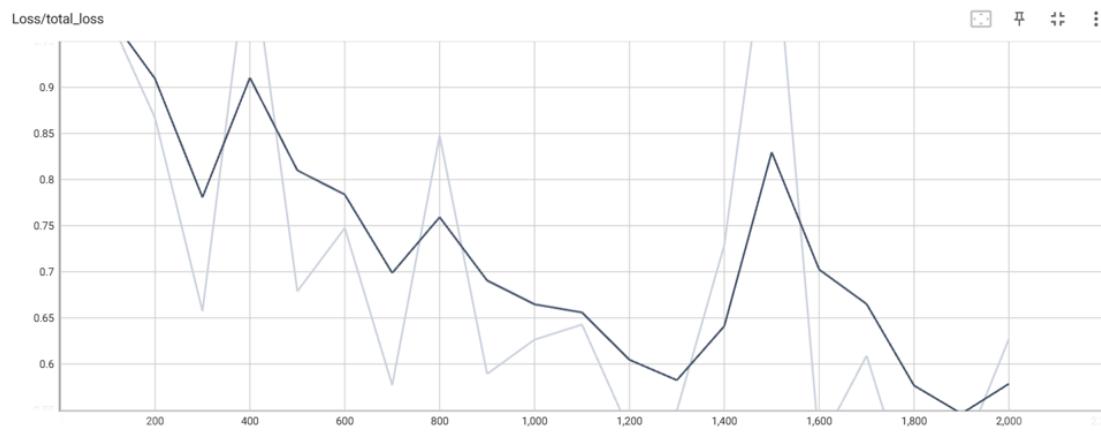
Gambar 4. Localization Loss

Gambar 5 menunjukkan *regularization* pada proses *training* dengan menggunakan 183 *dataset*. *Regularization loss* merupakan fungsi yang digunakan untuk mencegah terjadinya *overfitting* dan meningkatkan generalisasi jaringan syaraf. Nilai *regularization loss* pada proses *training* dapat dilihat pada Gambar 5.



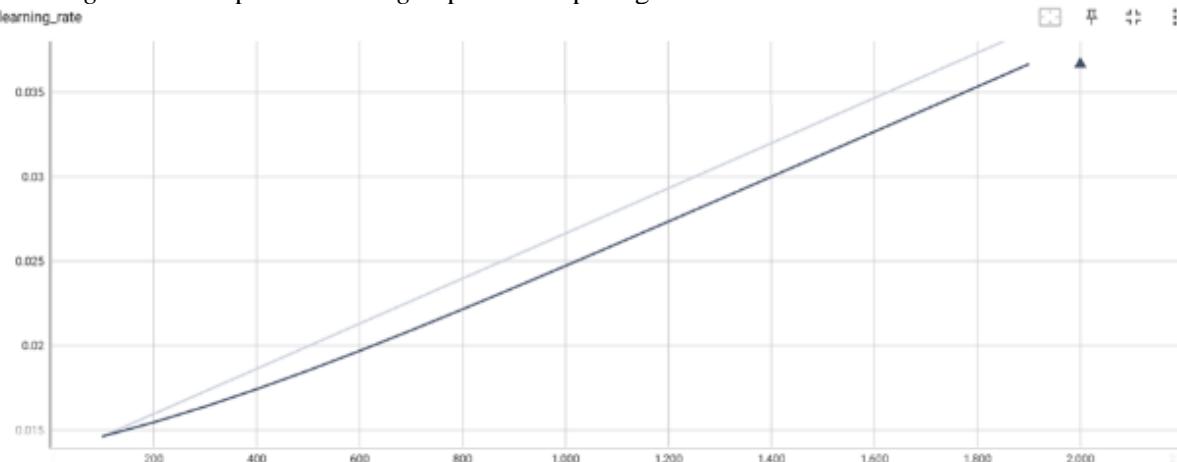
Gambar 5. Regularization Loss

Total *loss* pada proses *training* dapat dilihat pada Gambar 6. Total *loss* merupakan rata-rata dari ketiga *loss* yang diukur. Sedangkan *Learning Rate* merupakan *hyperparameter* yang digunakan untuk mengatur seberapa besar perubahan parameter model yang terjadi selama proses pelatihan.



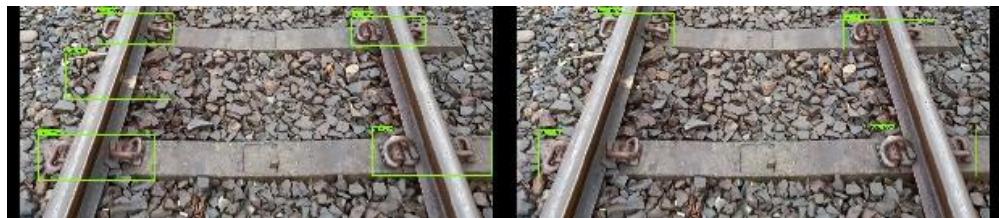
Gambar 6. Total Loss

Learning rate untuk proses *training* dapat dilihat pada gambar 7.

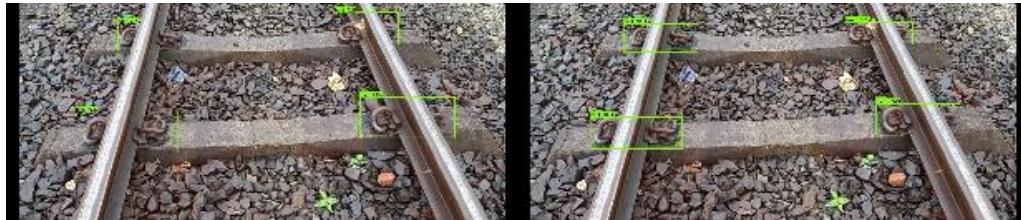


Gambar 7. Learning Rate

Hasil deteksi objek dapat dilihat pada Gambar 8 dan Gambar 9.

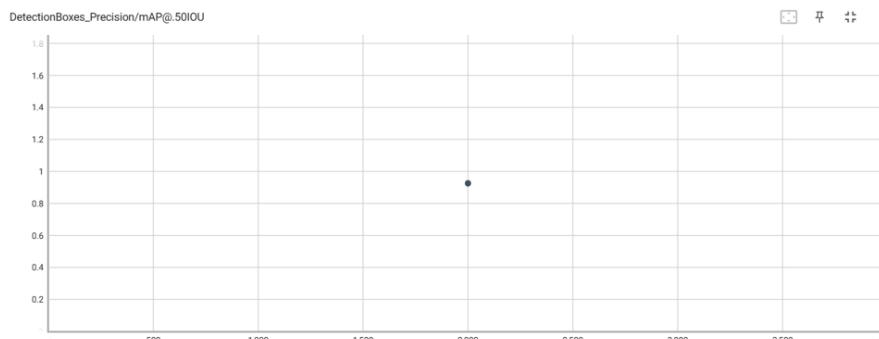


Gambar 8. Gambar hasil deteksi objek baut



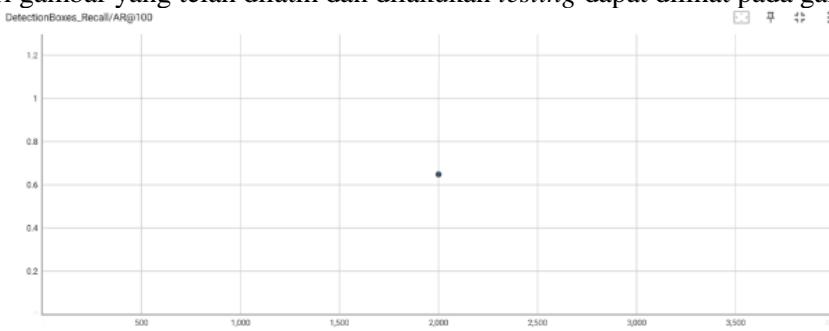
Gambar 9. Gambar hasil deteksi objek baut

Hasil presisi dari gambar yang telah dilatih dan dilakukan *testing* dapat dilihat pada gambar 10.



Gambar 10. Hasil presisi deteksi objek baut

Hasil *recall* dari gambar yang telah dilatih dan dilakukan *testing* dapat dilihat pada gambar 11.



Gambar 11. Hasil *recall* deteksi objek baut

3.2 Pembahasan

Dengan menggunakan 183 dataset *training* sebanyak 2.000 *num step* dapat diketahui pada Gambar 3 mendapatkan hasil 0,2 untuk classification loss, pada Gambar 4 mendapatkan hasil 0,07 untuk localization loss, dan pada Gambar 5 mendapatkan hasil 0,4 untuk total loss. Sedangkan pada Gambar 6 mendapatkan hasil 0,065 dengan 1.800 *num step*.

Pada proses testing yang ditunjukkan pada Gambar 7 dan Gambar 8 menunjukkan sistem sudah dapat mengenali baut yang terdapat pada rel kereta api. Masih terdapat kesalahan pengenalan pada awalnya yang dinyatakan sebagai baut akan tetapi dalam kondisi nyatanya lokasi tersebut tidak terdapat

baut. Pada testing selanjutnya diketahui bahwa sistem sudah dapat mengenali posisi baut dengan baik dan benar.

Nilai *precision* dari *testing* yang telah dilakukan memiliki nilai 92,64%, di mana *precision* merupakan rasio prediksi *true* positif yang dibandingkan dengan keseluruhan hasil yang diprediksi positif. Sedangkan nilai *recall* mendapatkan hasil 64,87%, di mana *recall* merupakan perbandingan prediksi *true* positif dibandingkan dengan keseluruhan data yang benar positif. *Precision* dan *recall* yang dihitung menggunakan 2.000 *num step*. Berdasarkan data di atas, nilai *precision* yang didapatkan tinggi akan tetapi untuk nilai *recall* cenderung kurang tinggi.

4. Kesimpulan

Penelitian ini berhasil mengembangkan prototipe sistem deteksi baut rel kereta api berbasis *computer vision* menggunakan model SSD ResNet50 V1. Sistem ini menunjukkan akurasi tinggi dalam *precision* namun masih memiliki kekurangan pada *recall*. Dengan pengembangan lebih lanjut, sistem ini berpotensi menjadi bagian penting dalam pemeliharaan prediktif rel kereta api.

5. Referensi

- [1] N. Effendy, A. L. M, E. A. S. T. F, T. I. Panji, and S. B. Ningsih, “Penggunaan Bigdata Transportasi Berpotensi Meningkatkan Efisiensi Sistem Transportasi Kota,” vol. 7, no. 11, pp. 162–166, 2023.
- [2] H. Yang, C. Han, N. Zhang, J. Wang, Q. Chen, and J. Liu, “Sustainable Stability Control of Roof Anchorage Blind Zone in Coal Roadway Bolt Support : Mechanisms and Strategies,” 2025.
- [3] M. V. Sensor, “Multi-source Visual Sensor,” 2020.
- [4] B. T. Philo, “Bolt assembly integral to track stability: an overview,” *Int. J. Railw. Technol.*, vol. 5, no. 3, pp. 45–60, 2016.
- [5] J. G. Provan and F. Cook, “The role of rail transportation in achieving sustainability at regional scale,” *J. Rail Transp. Plan. Manag.*, vol. 2, no. 1–2, pp. 90–100, 2012.
- [6] A. K. Singh and S. Ray, “Design and optimization of railway track fasteners,” *J. Mech. Des.*, vol. 134, no. 3, p. 31002, Mar. 2012.
- [7] X. Zhang, J. Liu, and M. Wu, “Rail surface defect detection using convolutional neural networks,” *Measurement*, vol. 135, pp. 701–710, Oct. 2019.
- [8] T. Y. Lee and C. C. Wang, “Operator fatigue detection in railway systems: a review,” *J. Safety Res.*, vol. 63, pp. 23–31, 2018.
- [9] D. P. L. Scott and J. D. Mumford, “Edge detection methods for railway track crack identification,” *J. Nondestruct. Eval.*, vol. 36, no. 2, pp. 1–9, Jun. 2017.
- [10] S. K. Gupta and P. K. Mishra, “Deep learning for rail crack detection using Gabor transformation,” *IEEE Access*, vol. 7, pp. 121234–121245, 2019.
- [11] P. Q. Li, H. Q. Liu, and C. Zhu, “Vibration-based bolt loosening detection in railway tracks,” *Mech. Syst. Signal Process.*, vol. 104, pp. 180–190, Sep. 2018.
- [12] A. S. Agarwal and M. K. Singh, “Infrared thermography for bolt condition monitoring,” *Nondestruct. Test. Eval.*, vol. 33, no. 4, pp. 312–321, 2018.
- [13] C. Chen and Y. Liu, “Multispectral imaging for rail defect detection,” *Autom. Constr.*, vol. 102, pp. 110–118, Jul. 2019.
- [14] T. Nakamura, K. Sato, and Y. Fujita, “Real-time detection of railway track anomalies using LSTM networks,” *Transp. Res. Part C Emerg. Technol.*, vol. 102, pp. 216–228, Nov. 2019.
- [15] F. Zhao and Y. Zhou, “Vision-based automatic bolt-tightening monitoring system for railways,” *Meas. Sci. Technol.*, vol. 31, no. 12, p. 125302, 2020.