

Analisis Keausan Kawat *Trolley* Dan Suhu Pada Sistem Catenary Kereta Listrik Berbasis Pemrosesan Citra

1st Dermawan Setiananda
Fakultas Teknik Elektro

Telkom University
Bandung, Indonesia
dermawans@student.telkomuniversity.
ac.id

2nd Dr. Eng Ahmad Sugiana, S.Si.,
M.T.

Fakultas Teknik Elektro
Telkom University
Bandung, Indonesia
sugianaa@telkomuniversity.ac.id

3rd Kharisma Bani Adam, S.T., M.T.,
Ph.D.

Fakultas Teknik Elektro
Telkom University
Bandung, Indonesia
kharismaadam@telkomuniversity.ac.id

Abstrak — Sistem Catenary, khususnya kawat *trolley* pada kereta listrik, rentan terhadap keausan dan fluktuasi suhu yang mempengaruhi efisiensi serta keamanan operasional. Menggantikan inspeksi manual yang kurang efisien, penelitian ini menawarkan solusi berbasis pemrosesan citra. Kami memanfaatkan kamera Termal Flir One Gen 3 dan kamera Z Cam E2 untuk mengumpulkan data kawat *Trolley*, kemudian menganalisis menggunakan algoritma Convolutional Neural Network (CNN) untuk mendeteksi *arcing* (percikan listrik) dan keausan. Hasil pengujian menunjukkan kamera termal Flir One Gen 3 memiliki akurasi rata-rata 99,80% dalam pengukuran suhu. Model CNN yang kami latih berhasil mendeteksi *arcing* yang diusulkan dengan menggabungkan tiga model transfer learning: VGG16, ResNet50, dan VGG16-Alt dengan hasil eksperimen menunjukan bahwa model *ensemble* mencapai akurasi 94.83%. Selain itu juga, untuk analisis keausan kawat *Trolley* dengan dua arsitektur CNN dibandingkan: EfficientNetB0 dengan optimasi khusus deteksi kontur kawat *Trolley* mencapai akurasi 87.2% dan *ensemble* ResNet50 mencapai 87.48% melalui 5-Fold Cross Validation.

Kata Kunci: keausan, suhu, sistem catenary, kereta listrik, pemrosesan citra, Convolutional Neural Network (CNN). kata

I. PENDAHULUAN

Kereta Rel Listrik (KRL) merupakan sarana transportasi yang menggunakan energi listrik dari saluran listrik aliran atas dan telah menjadi pilihan populer untuk perjalanan jarak menengah. Sistem pantograf-katenari berfungsi untuk mentransmisikan energi listrik dari sistem katenari ke kereta [1]. Kualitas transmisi ini bergantung pada gaya kontak antara pantograf dan kawat kontak dari katenari. Sistem pantograf-katenari mudah mengalami kerusakan karena sering terkena cuaca dan gesekan, yang dapat menyebabkan keausan, percikan api, atau kerusakan kawat *trolley*. Strip kontak yang aus akibat bersentuhan dengan *Overhead Contact line* (OCL) akan menurunkan kinerja pengumpulan arus. Penelitian sebelumnya mencapai akurasi 90% menggunakan *Support Vector Machine* (SVM) untuk mendeteksi kerusakan sistem pantograf-katenari [2]. Namun, metode pemeliharaan manual terbatas pada deteksi visual

yang memakan waktu dan tidak efisien, sehingga diperlukan metode image processing untuk analisis yang akurat dan tepat waktu [3]. Metode deteksi keausan terbagi menjadi dua kategori: kontak dan non-kontak [4]. Metode kontak menggunakan sensor serat optik pada kepala kolektor pantograf [5], namun memerlukan modifikasi yang berdampak pada kinerja dinamis. Alternatif metode non-kontak seperti pemantauan berbasis ultrasonik telah dipertimbangkan [6]. Metode deteksi yang ada masih mengacu pada skema manual [7] dan hanya dirancang untuk kondisi statis, belum divalidasi dalam kondisi dinamis saat kereta bergerak [8]. Penelitian ini mengusulkan sistem pemantauan menggunakan kamera termal untuk merekam kondisi kawat *trolley* yang diproses dengan mikrokomputer Raspberry Pi 4. Sistem ini menggunakan image processing dan algoritma *Convolution Neural Networks* (CNN) untuk menganalisis suhu kawat *trolley* dan mendeteksi area dengan suhu tinggi yang menandakan keausan atau masalah pada komponen.

II. KAJIAN TEORI

A. Kereta Rel Listrik (KRL)

Kereta Rel Listrik (KRL) menggunakan tenaga listrik untuk menggerakkan motornya dengan sumber DC (600 V - 3000 V) atau AC (15 kV/16,7 Hz dan 25 kV/50 Hz). Terdapat dua tipe pantograf yaitu diamond shaped dan single-arm yang berfungsi mengalirkan listrik dari sumber atas ke motor [9]. Perkembangan teknologi membuat KRL beralih dari motor DC ke motor AC. Motor DC menggunakan DC-DC converter (chopper) untuk pengaturan tegangan yang efisien [10]. Motor AC dipilih karena dapat mencapai kecepatan lebih tinggi dan mengatasi masalah gangguan arus pendek yang sering terjadi pada motor DC [9].

B. Elektrik *Arcing*

Arcing listrik terjadi ketika arus listrik mengalir melalui udara atau gas antara dua konduktor, biasanya karena kegagalan isolasi atau hubung singkat yang menghasilkan

busur listrik sangat panas dengan suara keras dan cahaya sehingga menyebabkan kerusakan serius [10]. Arc flash adalah ledakan api listrik yang terjadi karena korsleting atau hubungan pendek pada sistem kelistrikan. Tanda-tandanya meliputi percikan api, suara ledakan keras, dan panas ekstrem. Arc flash terjadi karena *arcing-fault* atau bolted fault yang menimbulkan plasma busur listrik dan melepas energi berbahaya [11]. Fenomena arc flash menghasilkan tembaga yang mengembang hingga 67.000 kali lipat, uap tembaga beracun, logam cair dengan suhu mencapai 35.000°F (19.400°C), gelombang tekanan, dan gelombang suara di atas 140 desibel [12].

C. Convolution Neural Network (CNN)

Analisis suhu dan keausan adalah indikator penting sebagai pemantauan kondisi kawat *trolley* dan CNN telah digunakan sebagai teknik deep learning yang efektif dalam analisis citra dengan kemampuan otomatis mempelajari fitur-fitur dari data citra [13]. CNN terdiri dari lapisan utama yang mengekstraksi dan memproses data dari gambar, dengan lapisan konvolusi sebagai lapisan pertama dengan mengekstrak fitur dasar seperti tepi, sudut, dan tekstur menggunakan kernel atau filter [14],[15].

Penelitian ini mengimplementasikan tiga arsitektur CNN yang berbeda untuk mengoptimalkan performa deteksi. Arsitektur VGG16 memiliki struktur 16-layer yang terdiri dari 13-layer konvolusi dan 3 layer fully connected, menggunakan filter berukuran 3x3 dengan pola peningkatan jumlah filter secara bertahap dari 64, 128, 256, hingga 512 filter [16]. Arsitektur ResNet50 menggunakan 50-layer dengan 49-layer konvolusi dan 1 layer fully connected yang diorganisir dalam lima tahap menggunakan bottleneck design dan Batch Normalization [17]. Sementara itu, arsitektur EfficientNetB0 menerapkan prinsip *compound scaling* yang menskalakan tiga dimensi jaringan secara bersamaan dengan persamaan kedalaman $d = \alpha^{\phi}$, lebar $w = \beta^{\phi}$, dan resolusi $r = \gamma^{\phi}$ dengan batasan $\alpha \times \beta^2 \times \gamma^2 \approx 2$ [18]. Fungsi Loss Function VGG16 dihitung dengan:

$$L = -\left(\frac{1}{N}\right) \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (1)$$

Tanda negatif didepan rumus memberikan nilai untuk probabilitas antara 0 dan 1. Hal ini karena, *loss* yang besar akan diprediksikan salah dan ketika *loss*nya kecil prediksinya benar [19].

III. METODE


Penelitian ini mengembangkan sistem pemantauan kondisi kawat *trolley* pada infrastruktur kereta listrik melalui pendekatan teknologi pemrosesan citra dan deep learning. Metodologi yang diterapkan mencakup pengembangan sistem terintegrasi yang mampu mendeteksi dua aspek kritis yaitu kondisi keausan kawat *trolley* dan fenomena *arcing* yang terjadi akibat kenaikan suhu berlebih. Sistem dirancang dengan mempertimbangkan kebutuhan operasional di lapangan, efisiensi pemrosesan data, dan akurasi deteksi yang tinggi untuk mendukung program pemeliharaan prediktif pada infrastruktur kereta listrik.

Pendekatan penelitian ini mengintegrasikan hardware dan software dalam satu kesatuan sistem. Pada sisi hardware,

penelitian menggunakan kombinasi sensor termal dan kamera visual yang dioptimalkan untuk kondisi operasional kereta listrik. Sementara pada sisi software, penelitian mengimplementasikan algoritma *Convolution Neural Network* dengan menggunakan tiga arsitektur transfer learning.

A. Desain Sistem Perangkat Lunak


Penelitian ini merancang sistem pemantauan kondisi keausan dan suhu pada kawat *trolley* catenary menggunakan pemrosesan citra. Sistem menggunakan dua jenis dataset: citra termal untuk deteksi *arcing* (1.092 gambar) menggunakan kamera FLIR One Gen 3, dan citra visual untuk analisis keausan kawat *trolley* (519 gambar) menggunakan kamera Z CAM E2. Proses dimulai dengan akuisisi data di Training Center KAI Bandung. Setelah data terkumpul, sistem melakukan pemilihan jenis analisis berdasarkan dataset. Untuk deteksi *arcing*, sistem memproses dataset termal, sedangkan untuk deteksi keausan, sistem memproses dataset visual. Berikut diagram alir keseluruhan sistem pada Gambar 1.



GAMBAR 1

FlowChart Keseluruhan Sistem


Setelah data terkumpul, sistem melakukan pemilihan jenis analisis berdasarkan dataset yang akan diproses, memungkinkan sistem untuk mengoptimalkan *preprocessing* dan *training* model sesuai dengan karakteristik masing-masing jenis data. Berikut merupakan *FlowChart* Sub Sistem *Training* pada Gambar 2:



GAMBAR 2
FlowChart Subsistem Training

Pada Gambar 2 komponen perangkat keras yang digunakan dalam sub-sistem *training* meliputi kamera termal FLIR One Gen 3, Z CAM E2, Raspberry Pi 4, dan display LCD. Kamera berfungsi sebagai sarana pengambilan data, sedangkan mikrokomputer berperan sebagai unit pengolahan data yang mengumpulkan informasi dalam folder dataset.

Arsitektur perangkat lunak dirancang dengan menggunakan Raspberry Pi4 sebagai unit pemrosesan utama yang mengintegrasikan seluruh komponen sistem. Untuk memberikan gambaran tentang alur kerja sistem, desain perangkat lunak divisualisasikan melalui blok diagram yang ditunjukkan pada Gambar 3:



GAMBAR 3
Blok Diagram

Berdasarkan diagram blok pada Gambar 3, desain perangkat lunak mengimplementasikan alur kerja dimulai dari tahap input hingga output hasil analisis. Pada tahap input, sistem

menerima dua jenis data yaitu image of sparks yang diperoleh dari thermal camera dan *trolley wire* yang diambil melalui Z CAM E2.

B. Preprocessing Data

Sistem *preprocessing* dirancang dengan pendekatan yang disesuaikan berdasarkan karakteristik dari masing-masing jenis dataset yang digunakan. Dataset termal memerlukan normalisasi intensitas pixel di rentang $[0,1]$, rescaling gambar ke ukuran standar 224×224 pixel. Sementara itu, dataset visual mengimplementasikan *preprocessing* yang berbeda dengan menggunakan CLAHE (*Contrast Limited Adaptive Histogram Equalization*) untuk meningkatkan kontras citra, intelligent wire contour detection untuk memfokuskan analisis pada kawat *trolley*.

Teknik augmentasi data untuk dataset termal mencakup random horizontal flip (50% probabilitas), random rotation ($\pm 36^\circ$), random zoom ($\pm 15\%$), random contrast ($\pm 15\%$), random brightness ($\pm 10\%$), random translation ($\pm 10\%$), dan gaussian noise ($\sigma = 0.01$). Untuk dataset visual Z Cam E2, augmentasi meliputi horizontal flipping (60% probabilitas), rotasi ($\pm 5^\circ$), dan penyesuaian brightness-contrast dengan parameter yang disesuaikan untuk mempertahankan karakteristik kawat *trolley*.

C. Konfigurasi Training

Model *ensemble arcing* menggunakan two-stage *training* dengan feature *extraction* dan fine-tuning. Konfigurasi *callback* meliputi EarlyStopping (patience 8-10 epochs), ReduceLROnPlateau (factor 0.3-0.5), dan ModelCheckpoint untuk menyimpan bobot terbaik.

Untuk model keausan, EfficientNetB0 dilatih selama 35 epochs sedangkan ResNet50 *ensemble* memerlukan 120 epochs. Model EfficientNetB0 menggunakan specialized *preprocessing* dengan wire contour detection, sedangkan ResNet50 *ensemble* mengimplementasikan selective fine-tuning pada 20-layer terakhir.

Pembagian dataset menggunakan stratified approach dengan rasio 70:15:15:15 untuk *training*, *validation*, dan *testing* pada dataset keausan. Berikut merupakan tabel split dataset keausan pada Tabel 1:

TABEL 1
Split Dataset Keausan

Training	710 Gambar (65%)
Validation	273 Gambar (25%)
Testing	109 Gambar (10%)


Sementara, dataset *arcing* menggunakan rasio 65:25:10 untuk memastikan representasi yang seimbang dari kedua kelas. Berikut merupakan tabel split dataset *arcing* pada Tabel 2:

TABEL 2
Split Dataset Arcing

Training	363 Gambar (70%)
Validation	78 Gambar (15%)
Testing	78 Gambar (15%)


D. Desain Sistem

Desain sistem pemantauan kawat *trolley* dirancang dengan pendekatan terintegrasi yang memanfaatkan dua jenis sensor untuk menganalisis kondisi infrastruktur kereta listrik dari kamera termal dan kamera visual Z Cam E2 untuk memantau interaksi antara pantograf dan *contact line* pada sistem katenari. Berikut merupakan desain sistem pada Gambar 4:



GAMBAR 4
Desain Sistem

Desain sistem pada Gambar 4, mengintegrasikan sistem peringatan dini yang dapat mengidentifikasi obstacle atau gangguan jalur yang dapat mempengaruhi kualitas pengambilan citra. Sementara itu, untuk desain *prototype* generator yang digunakan untuk menghasilkan busur listrik dirancang pada Gambar 5:



GAMBAR 5
Desain *Prototype* Generator Busur Listrik

Pada Gambar 5 Sistem dirancang dalam bentuk *prototype* generator busur listrik untuk menghasilkan eksperimen percikan api yang dikontrol. *Prototype* ini memungkinkan pengumpulan data *arcing* dalam kondisi laboratorium yang aman dan terkontrol. Sistem memiliki satu input berupa kamera termal FLIR One Gen 3, serta dua output yang terdiri dari tampilan grafik hasil analisis dan temperature contact *wire* yang terdeteksi pada setiap titik pengujian.

E. Implementasi dan Testing

Pengujian sistem dilakukan dalam dua tahap: pengujian di laboratorium menggunakan *prototype* generator dan

pengujian lapangan di *Training Center KAI Bandung*. Data *arcing* dikumpulkan melalui eksperimen terkontrol menggunakan *prototype* generator, sedangkan data keausan kawat *trolley* diambil dari infrastruktur eksisting di *Training Center KAI Bandung*.

Sistem terintegrasi menggabungkan kemampuan deteksi *arcing* dan keausan yang memungkinkan analisis komprehensif kondisi kawat *trolley*. Output sistem berupa klasifikasi kondisi (aus/tidak aus, *arcing*/tidak *arcing*) dengan

IV. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan sistem terintegrasi untuk pemantauan kondisi kawat *trolley* pada infrastruktur kereta listrik melalui implementasi pemrosesan citra dan deep learning. Sistem yang dikembangkan mampu melakukan deteksi terhadap dua aspek yaitu fenomena *arcing* dan kondisi keausan kawat *trolley* dengan tingkat akurasi yang tinggi. Hasil pengujian menunjukkan bahwa pendekatan *ensemble method* pada deteksi *arcing* mencapai akurasi 94,83%, sedangkan sistem deteksi keausan kawat *trolley* menggunakan arsitektur CNN mencapai akurasi 87,48%.

A1. Implementasi Deteksi *Arcing*

Sistem deteksi *arcing* diimplementasikan menggunakan dataset termal yang terdiri dari 1.092 gambar dengan klasifikasi 'ARCING' dan 'TIDAK ARCING'. Dataset dibagi menggunakan rasio 65:25:10 untuk *training*, *validation*, dan *testing* guna memastikan representasi yang seimbang dari kedua kelas. Tahap *preprocessing* meliputi normalisasi intensitas pixel ke rentang [0,1], rescaling gambar ke ukuran standar 224x224 pixel, dan implementasi teknik data augmentation. Konfigurasi augmentasi deteksi *arcing* terdapat pada Tabel 3:


TABEL 3
Data Augmentasi Deteksi *Arcing*

No	Data Augmentasi	Keterangan
1	Random Horizontal Flip	50% probabilitas
2	Random Rotation	$\pm 36^\circ$
3	Random Zoom	$\pm 15\%$
4	Random Contrast	$\pm 15\%$
5	Random Brightness	$\pm 10\%$
6	Random Translation	$\pm 10\%$ horizontal/vertikal
7	Gaussian Noise	$\sigma = 0.01$ (simulasi derau sensor termal)

A2. Arsitektur *Ensemble* Model Deteksi *Arcing*

Implementasi deteksi *arcing* menggunakan pendekatan *ensemble method* yang menggabungkan tiga arsitektur CNN berbeda yaitu VGG16, ResNet50, dan VGG16-Alternative. Setiap arsitektur dipilih berdasarkan karakteristik dalam mendeteksi pola *arcing* pada citra termal, dengan VGG16 sebagai baseline, ResNet50 untuk pembelajaran fitur kompleks dengan residual connections, dan VGG16-Alt sebagai variasi untuk memberikan hasil yang berbeda pada

ensemble. Berikut merupakan hasil *validation accuracy* pada ketiga individual model tertera pada Gambar 6:



GAMBAR 6


Validation Accuracy Individual Model

Model VGG16 menunjukkan performa terbaik pada individual dengan *validation accuracy* 89,34%, diikuti ResNet50 dengan 87,13%, dan VGG16-Alt dengan 68,01%. *Ensemble* method mengimplementasikan weighted voting berdasarkan *validation accuracy* dengan formula:

$$P_{ens} = 0.365 \times P_{VGG16} + 0.356 \times P_{ResNet50} + 0.278 \times P_{VGG16-Alt} \quad (2)$$

A3. Hasil Evaluasi *Ensemble*

Model *ensemble* berhasil mencapai *test accuracy* 94,83% dengan peningkatan 5,49% dibandingkan model individual terbaik. Performa *ensemble* menunjukkan precision 98,11%, recall 91,23%, dan F1-Score 94,55%. Berikut merupakan grafik *ensemble* dengan perbandingan dari individual models pada Gambar 7:



GAMBAR 7


Grafik *Ensemble* vs Individual Models

Ensemble model yang terlihat bahwa pada Gambar 7 berhasil mencapai target. *Ensemble* model dengan hasil *test accuracy*

94.83%. Hasil ini menunjukkan peningkatan +5.49% dari model individual terbaik dari (VGG16).

A.4. Hasil dan Prediksi dari Deteksi *Arcing*


Analisis *confusion matrix* mengonfirmasi kemampuan model dalam mengklasifikasikan kondisi *arcing* dengan 58 true positives, 52 true negatives, 1 false negative, dan 5 false positives dari total 116 sampel *testing*.



GAMBAR 8

Confusion matrix *Ensemble*

Hasil evaluasi pada sampel *testing* menunjukkan bahwa model *ensemble* mampu melakukan deteksi busur listrik dengan tingkat kepercayaan yang tinggi. Analisis prediksi pada 9 sampel representatif menunjukkan keberhasilan model dalam mengidentifikasi kondisi *arcing* dengan *confidence score* yang bervariasi dari 0,606 hingga 0,958, mengindikasikan *robustness* sistem dalam berbagai kondisi operasional, yang tertera pada Gambar 8:



GAMBAR 8

Hasil dan Prediksi dari Deteksi *Arcing*

Secara keseluruhan, hasil pengujian ini mengindikasikan bahwa model *ensemble* ini umumnya mampu melakukan deteksi busur listrik dengan baik. Kemampuan ini ditunjukkan dengan banyaknya true positive dan true negative. Namun, pada false negative beberapa sampel menunjukkan bahwa model memiliki keterbatasan dan kegagalan dalam mengidentifikasinya.

TABEL 4
Perbandingan Model Dataset Kawat Trolley

Model	Accuracy	Precision	Recall	F1-Score
EfficientNetB0	87.2%	89.1%	89.1%	89.1%
ResNet50 (Fold 1)	81.73%	92.0%	75.4%	82.9%
ResNet50 (Fold 2)	85.58%	84.9%	91.8%	88.2%
ResNet50 (Fold 3)	80.77%	88.1%	78.7%	83.1%
ResNet50 (Fold 4)	84.62%	87.2%	85.3%	86.2%
ResNet50 (Fold 5)	87.40%	89.7%	88.1%	88.9%
ResNet50 (Ensemble)	87.48%	89.3%	87.1%	88.2%

B1. Implementasi Deteksi Keausan Kawat Trolley

Sistem deteksi keausan kawat *trolley* menggunakan dataset visual yang terdiri dari 519 gambar dengan distribusi 305 sampel kategori "AUS" dan 214 sampel kategori "TIDAK AUS". Dataset dibagi menggunakan stratified approach dengan rasio 70:15:15:15 untuk *training*, *validation*, dan *testing*.

Implementasi *preprocessing* menggunakan dua pendekatan berbeda yaitu *intelligent wire contour detection* untuk mengisolasi kawat dari elemen latar belakang yang kompleks, dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras citra. Algoritma *wire contour detection* mengintegrasikan *edge detection*, *morphological operations*, dan *region of interest extraction* yang diformulasikan sebagai:

$$I_{proc}=ROI_{extrc}\left(morph_{ops}\left(edge_{detect}(I_{input})\right)\right) \quad (3)$$

Berikut merupakan implementasi dari *wire contour detection* pada Gambar 9:



GAMBAR 9
Original vs Wire Contour Detection

Teknik CLAHE diimplementasikan dengan pembagian gambar menjadi grid 8×8 tiles dengan $Clip_{limit} = 3.0$ untuk mencegah over-enhancement, dan menghasilkan peningkatan yang kontras pada area *trolley wire*.

B2. Perbandingan Arsitektur Model

Penelitian mengimplementasikan dua pendekatan arsitektur yaitu EfficientNetB0 sebagai lightweight classifier dan ResNet50 *ensemble* sebagai deep feature extractor. EfficientNetB0 dengan total 4.877.988 parameter memberikan keseimbangan optimal antara kompleksitas model dan efisiensi komputasional untuk dataset berukuran 519 gambar. Berikut merupakan perbandingan hasil *training* EfficientNetB0 dengan ResNet50 menggunakan 5-Fold tertera pada Tabel 4:

Model EfficientNetB0 dilatih selama 35 epochs dan mencapai *test accuracy* 87,2% dengan metrik performa yang seimbang yaitu *precision* 89,1%, *recall* 89,1%, dan F1-score 89,1%. Sementara itu, implementasi ResNet50 *ensemble* menggunakan 5-fold cross-validation dengan selective fine-tuning pada 20-layer terakhir untuk adaptasi dari ImageNet ke karakteristik kawat *trolley*.


5-Fold Cross Validation memberikan hasil pola yang bervariasi untuk memahami model. Hal ini mengindikasikan bahwa tingkat stabilitas yang memadai, mengingat ukuran dataset kawat *trolley* yang tersedia.

B3. Hasil Ensemble ResNet50

ResNet50 *ensemble* menunjukkan peningkatan performa dari 84,01% (rata-rata individual models) menjadi 87,48% dengan improvement sebesar 3,47%. Metode *ensemble* menggunakan sample averaging dari output probabilitas kelima model fold yang diformulasikan sebagai: (4)

$$Pred_{Ensemble} = \frac{Model_1 + Model_2 + Model_3 + Model_4 + Model_5}{5}$$


Dinamika pembelajaran model *ensemble* selama fase *training* disajikan dalam Gambar 10:



GAMBAR 10
Grafik Model Accuracy


Pada Gambar 10 menunjukkan model proses learning yang bertahap tetapi fluktuatif. Training *accuracy* (garis biru) dengan hasil 55% dan secara bertahap naik stabil hingga 67-

70%. *Validation accuracy* (garis merah) menunjukkan pola yang tidak stabil dengan hasil tertinggi 79% pada epoch ke-8. Untuk melengkapi analisis Learning Curve, monitoring *Loss Function* menjadi komponen penting dalam memahami proses optimasi model deep learning. Penurunan *loss* yang stabil dan konsisten antara *training* dan *validation* set menunjukkan kemampuan generalisasi yang baik. Karakteristik *Loss Function* selama pelatihan model *ensemble* disajikan dalam Gambar 11:



GAMBAR 11
Model Loss Overtime

Pada Gambar 11 merupakan grafik *loss* yang menggambarkan seberapa besar “kesalahan” yang dibuat oleh model. Kedua garis (*training loss* biru dan *validation loss* merah) menunjukkan penurunan yang konsisten dari 6.9 menjadi 6.2-6.3. Hal ini mandakan bahwa, model benar-benar belajar dan semakin akurat dalam membedakan kawat *trolley* aus dan tidak aus. Hasil *training* individual model dari Fold 1, Fold 2, Fold 3, Fold 4 dan Fold 5. Dari ke 5-Fold tersebut akan dilakukan *ensemble* model ResNet50 dengan hasil grafik tertera pada Gambar 12.




GAMBAR 12
Grafik Ensemble Model

Pada Gambar 12 menunjukkan perbandingan antara dua pendekatan berbeda pada model ResNet50. Titik kiri menunjukkan performa rata-rata dari 5 model individual yang menghasilkan akurasi 84%. Titik kanan menunjukkan hasil ketika kelima model tersebut digabungkan menjadi *ensemble*, mencapai akurasi 87.5%.


B4. Evaluasi *Confusion matrix*

Analisis *confusion matrix* pada dataset *testing* menunjukkan bahwa dari 78 data *test*, model berhasil memberikan prediksi benar pada 68 kasus dengan akurasi 87,2%. Distribusi hasil mencakup 27 *true negatives* (kawat tidak aus), 41 *true positives* (kawat aus), 5 *false positives* (prediksi aus padahal normal), dan 5 *false negatives* (melewatkan kawat yang sebenarnya aus). Berikut merupakan hasil *confusion matrix* pada Gambar 13:



GAMBAR 13
Confusion matrix

Selanjutnya, visualisasi prediksi model pada 9 sampel representatif yang menunjukkan kemampuan sistem dalam mengidentifikasi kondisi keausan dengan confidence score yang bervariasi, yang tertera pada Gambar 14:



GAMBAR 14
Visualisasi Hasil Model Predictions Kawat Trolley

Dapat dilihat pada Gambar 14 model berhasil memprediksi dengan benar kawat normal pada kondisi pencahayaan yang jelas dan kawat aus pada background yang kompleks, mengindikasikan robustness sistem dalam berbagai kondisi lingkungan operasional.

B5. Analisis Terintegrasi untuk *Framework Maintenance*

Implementasi sistem terintegrasi menunjukkan hubungan yang saling melengkapi antara deteksi *arc*ing dan keausan dalam framework maintenance katenari. Keausan kawat *trolley* merupakan proses degradasi fisik bertahap yang menyebabkan pengurangan luas penampang kontak antara kawat *trolley* dan pantograf.

Kontak yang tidak sempurna dapat menimbulkan fenomena *arc*ing ketika listrik melompat melewati celah udara antara pantograf dan kawat *trolley*. *Arc*ing menghasilkan panas yang dapat mencapai ribuan derajat celsius, yang dapat dideteksi menggunakan thermal imaging. Fenomena *arc*ing berfungsi sebagai indikator dini adanya keausan yang telah mencapai level kritis.

Penelitian ini membuktikan bahwa kombinasi deteksi *arc*ing (94,83% *accuracy*) dan keausan (87,48% *accuracy*) memberikan framework maintenance yang komprehensif. Sistem dapat memberikan *early warning* pada tahap keausan melalui monitoring fisik kawat dan konfirmasi kondisi kritis melalui deteksi thermal *arc*ing sebelum terjadi kegagalan sistem.

V. KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa model Convolutional Neural Network (CNN) dengan efektif digunakan untuk mendeteksi *arc*ing melalui eksperimen laboratorium maupun kejadian keausan pada kawat *trolley* berdasarkan data citra Termal dan Z cam E2. Model CNN menunjukkan keberhasilan dalam klasifikasi untuk mendeteksi keausan pada kawat *trolley* dengan membandingkan dua pendekatan deep learning EfficientNetB0 mencapai akurasi 87.2%, sementara ResNet50 *ensemble* mencapai 87.48% melalui teknik model averaging, yang membuktikan efektivitas metode ini untuk identifikasi kondisi aus tanpa memerlukan kontak langsung atau inspeksi manual. Sementara itu, deteksi *arc*ing menggunakan pemrosesan citra termal CNN dengan menggabungkan tiga model transfer learning dari VGG16, ResNet50, dan VGG16-Alt menunjukkan bahwa model *ensemble* dapat mencapai akurasi 94.83%, yang secara signifikan mengungguli model individual terbaik (89.34% akurasi validasi) sebesar 5.49%. Hal tersebut menunjukkan bahwa, pola suhu akibat loncatan listrik dapat dikenali. Secara keseluruhan, pemanfaatan citra termal dan CNN ini berpotensi menggantikan metode konvensional sebagai sistem monitoring yang lebih efektif, sehingga meningkatkan efisiensi dalam mendeteksi potensi kegagalan dini pada kawat *trolley* kereta listrik.

REFERENSI

- [1] G. Militaru, M. Panoiu, and C. Panoiu, "Real-time detecting deformation on pantograph contact strip based on image processing technique," *J. Phys. Conf. Ser.*, vol. 2714, no. 1, 2024, doi: 10.1088/1742-6596/2714/1/012008.
- [2] S. Barmada, M. Raugi, M. Tucci, and F. Romano, "Arc detection in pantograph-catenary systems by the use of support vector machines-based classification," *IET Electr. Syst. Transp.*, vol. 4, no. 2, pp. 45–52, 2014, doi: 10.1049/iet-est.2013.0003.
- [3] K. M. Na, K. Lee, and H. Kim, "Condition Monitoring of Railway Pantograph Using R-CNN and Image Processing," *J. Electr. Eng. Technol.*, vol. 18, no. 3, pp. 2407–2416, 2023, doi: 10.1007/s42835-022-01229-6.
- [4] D. Zhang, S. Gao, L. Yu, G. Kang, D. Zhan, and X. Wei, "A Robust Pantograph-Catenary Interaction Condition Monitoring Method Based on Deep Convolutional Network," *IEEE Trans. Instrum. Meas.*, vol. 69, no. 5, pp. 1920–1929, 2020, doi: 10.1109/TIM.2019.2920721.
- [5] P. Boffi *et al.*, "Optical fiber sensors to measure collector performance in the pantograph-catenary interaction," *IEEE Sens. J.*, vol. 9, no. 6, pp. 635–640, 2009, doi: 10.1109/JSEN.2009.2020244.
- [6] F. Alonge, M. Branciforte, and F. Motta, "A novel method of distance measurement based on pulse position modulation and synchronization of chaotic signals using ultrasonic radar systems," *IEEE Trans. Instrum. Meas.*, vol. 58, no. 2, pp. 318–329, 2009, doi: 10.1109/TIM.2008.2003309.
- [7] X. W. Song, L. Wang, T. Xu, L., & Song, "Fault Tree Analysis of Pantograph Type Current Collector Based on Ontology Modeling," *Key Eng. Mater.*, vol. 693, 2016, [Online]. Available: 10.4028/www.scientific.net/KEM.693.1371
- [8] Y. Han, Z. Liu, Y. Lyu, K. Liu, C. Li, and W. Zhang, "Deep learning-based visual *ensemble* method for high-speed railway catenary clevis fracture detection," *Neurocomputing*, vol. 396, pp. 556–568, Jul. 2020, doi: 10.1016/J.NEUCOM.2018.10.107.
- [9] O. Futsal, "BAB II TINJAUAN PUSTAKA 2.1 Kereta Rel Listrik (KRL)." Accessed: Dec. 26, 2024. [Online]. Available: https://www.academia.edu/41188085/BAB_II_TINJAUAN_PUSTAKA_2_1_Kereta_Rel_Listrik_KRL
- [10] Liga Primabaraka, Dimas Anton Asfani, and I Made Yulistya Negara, "Pemodelan Arus *Arc*ing Tegangan Rendah pada Kabel Fleksibel (Serabut) menggunakan Elman Neural Network," *J. Tek. Its*, vol. 5, no. 2, pp. 306–310, 2016.
- [11] A. Sistem, P. Terhadap, and B. Busur, "Analisis sistem proteksi terhadap bahaya busur api (Arc Flash)," 2022.
- [12] "WHAT IS ARC FLASH?" Accessed: Jan. 14, 2024. [Online]. Available: <https://www.progarm.com/what-is-arc-flash/>
- [13] MK Gurucharan, "Basic CNN Architecture: A Detailed Explanation of the 5 Layers in Convolutional Neural Networks." [Online]. Available: <https://www.upgrad.com/blog/basic-cnn-architecture/>
- [14] et al. LeCun, Y., "Gradient-Based Learning Applied to Document Recognition," *Proc. IEEE*, vol. 86, n.
- [15] et al Krizhevsky, A., "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems*, 2025, [Online]. Available: <https://www.upgrad.com/blog/basic-cnn-architecture/>
- [16] A. H. M. Linkon, M. M. Labib, T. Hasan, M.

- Hossain, and M. E. Jannat, "Deep learning in prostate cancer diagnosis and Gleason grading in histopathology images: An extensive study," *Informatics Med. Unlocked*, vol. 24, Jan. 2021, doi: 10.1016/j.imu.2021.100582.
- [17] V. Sharma and N. Singh, "Deep Convolutional Neural Network with ResNet-50 Learning algorithm for Copy-Move Forgery Detection," *2021 7th Int. Conf. Signal Process. Commun. ICSC 2021*, pp. 146–150, 2021, doi: 10.1109/ICSC53193.2021.9673422.
- [18] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, May 2019, Accessed: Jul. 12, 2025. [Online]. Available: <https://arxiv.org/pdf/1905.11946>
- [19] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, Sep. 2014, Accessed: Jul. 12, 2025. [Online]. Available: <https://arxiv.org/pdf/1409.1556>

