



Deteksi Cacat pada Isolasi Trafo Secara Visual menggunakan Algoritma *Convolutional Neural Network* (CNN)

Alfendio Alif Faudisyah^{1*}, Kristoko Dwi Hartomo², Hindriyanto Dwi Purnomo³

^{1,3} Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Provinsi Jawa Tengah, Indonesia.

² Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Provinsi Jawa Tengah, Indonesia.

article info

Article history:

Received 27 March 2023

Received in revised form

21 July 2023

Accepted 20 August 2023

Available online October 2023

DOI:

<https://doi.org/10.35870/jtik.v7i4.1067>

Keywords:

Transformer Insulation; Image Classification; Convolutional Neural Network.

Kata Kunci:

Isolasi Trafo; Klasifikasi Gambar; Convolutional Neural Network.

abstract

Transformer insulation is a dielectric material that has the function of selling two or more voltage electrical conductors. Damage to the transformer insulation will cause interference with the performance of the transformer so that it can cause the transformer to experience operational failure or even damage. This research builds a system that can classify defective and normal transformer insulation images. The Convolutional Neural Network method is implemented in model building. The research method begins with conducting research planning, dataset collection, data preprocessing, classification of development models, training models, as well as testing and evaluation. Based on the test results with standardized data size 180 x 180 x 3 pixels, it produces an accuracy of 0.9913 for training, 0.9884 for testing, and 1.00 for evaluation. Test results with standardized data size 240 x 240 x 3 pixels produce an accuracy of 0.9798 for training, 0.9651 for testing, and 0.94 for evaluation. Based on the research that has been done, shows that differences in data standardization can affect the results of the model performance.

abstract

Isolasi trafo adalah bahan dielektrik yang memiliki fungsi untuk memisahkan dua atau lebih penghantar listrik yang bertegangan. Kerusakan pada isolasi trafo akan menyebabkan gangguan kinerja trafo sehingga dapat membuat trafo mengalami kegagalan operasi atau bahkan kerusakan. Penelitian ini membangun suatu sistem yang dapat mengklasifikasikan gambar isolasi trafo cacat dan normal. Metode Convolutional Neural Network diimplementasikan dalam pembuatan model. Metode penelitian dimulai dengan melakukan perencanaan penelitian, pengumpulan dataset, preprocessing data, pembangunan model klasifikasi, training model, serta testing dan evaluasi. Berdasarkan hasil uji dengan standarisasi data ukuran 180 x 180 x 3 piksel menghasilkan accuracy 0.9913 untuk training, 0.9884 untuk testing, dan 1.00 untuk evaluasi. Hasil uji dengan standarisasi data ukuran 240 x 240 x 3 piksel menghasilkan accuracy 0.9798 untuk training, 0.9651 untuk testing, dan 0.94 untuk evaluasi. Berdasarkan penelitian yang telah dilakukan menunjukkan bahwa perbedaan standarisasi data dapat memengaruhi hasil dari performa model.

Corresponding Author. Email: alfendialiff@gmail.com ^{1}.

1. Latar Belakang

Transformator atau lebih sering disebut trafo merupakan komponen yang berfungsi untuk mengubah arus listrik dari satu atau lebih rangkaian listrik ke rangkaian listrik lain tanpa mengubah sistem frekuensi melalui gandengan magnet. Fungsi kerja trafo ini menggunakan prinsip induksi elektromagnetik [1]. Dengan bertambahnya beban, trafo selalu mengalami peningkatan suhu dan arus. Kerusakan atau bahkan ledakan dapat terjadi ketika suhu di dalam ruang trafo terlalu tinggi [2]. Salah satu cara untuk mendeteksi kerusakan trafo adalah dengan mengetahui kondisi dari isolasi trafo apakah dalam keadaan yang baik atau mengalami masalah. Isolasi trafo adalah bahan dielektrik yang memiliki fungsi untuk memisahkan dua atau lebih penghantar listrik yang bertegangan, seperti antara *coil* dengan tangki trafo [3]. Ada beberapa jenis isolasi yang digunakan pada trafo. Jenis isolasi yang digunakan pada penelitian ini adalah *pressboard*. Isolasi *pressboard* dibuat menggunakan bahan *pulp* kayu yang keseluruhannya terbuat dari bahan nabati alami dengan tingkat kimia paling murni [4]. Kerusakan pada isolasi trafo akan menyebabkan gangguan kinerja trafo sehingga dapat membuat trafo mengalami kegagalan operasi atau bahkan kerusakan [5].


Dengan pesatnya perkembangan teknologi informasi, dapat menjadi solusi dari permasalahan di atas. Salah satu metode yang bisa digunakan untuk mengetahui kondisi isolasi trafo adalah klasifikasi gambar. Tujuan dari penelitian ini adalah untuk membangun suatu sistem yang dapat dengan cepat dan akurat mengklasifikasikan gambar isolasi trafo cacat dan normal menggunakan algoritma *Convolutional Neural Network* (CNN). Hasil dari analisis klasifikasi gambar dapat diperoleh informasi mengenai kondisi isolasi trafo apakah dalam keadaan baik atau tidak. Dengan mengetahui kondisi dari isolasi trafo dapat digunakan untuk mendeteksi lebih dini kerusakan pada trafo serta meminimalisir terjadinya penyimpangan atau kegagalan dari kinerja trafo. Klasifikasi gambar adalah suatu proses untuk membedakan kelas data gambar dengan tujuan untuk memprediksi kelas gambar tanpa mengetahui labelnya [6]. Metode yang digunakan untuk klasifikasi gambar isolasi trafo cacat dan normal adalah

Convolutional Neural Network (CNN). CNN adalah salah satu metode *deep learning* yang mampu memberikan hasil signifikan mengenai pengenalan objek gambar [7]. *Deep learning* merupakan sub bidang dari *machine learning* yang berbasis jaringan syaraf tiruan [8]. Metode CNN banyak digunakan dalam pemrosesan gambar karena memiliki akurasi yang tinggi dan lebih baik dalam pengenalan gambar visual [9]. Metode CNN dapat diimplementasikan dalam klasifikasi gambar isolasi trafo cacat dan normal, sehingga peneliti ingin membangun suatu sistem menggunakan metode CNN yang dapat digunakan untuk melakukan deteksi cacat pada isolasi trafo.

Dalam penelitian ini, dataset isolasi trafo cacat didapatkan dari [10], sedangkan dataset isolasi trafo normal dikumpulkan dengan cara *web scraping*. Dari dataset yang diperoleh kemudian dilakukan *preprocessing* data yaitu dengan augmentasi data, standarisasi data, dan membagi dataset menjadi data *training* dan *testing*. Pada penelitian ini dilakukan pengujian dari perbedaan 2 standarisasi data yaitu menggunakan ukuran data gambar 180 x 180 x 3 piksel dan ukuran data gambar 240 x 240 x 3 piksel. Evaluasi model klasifikasi dilakukan dengan menggunakan *confusion matrix*. Penelitian mengenai kegagalan trafo pernah dilakukan sebelumnya, seperti yang dilakukan oleh [11], melakukan pemantauan kondisi trafo dengan menggunakan uji *Dissolved Gas Analysis* (DGA). Dalam penelitian tersebut, dengan melakukan identifikasi jenis dan jumlah gas yang terlarut dalam minyak dapat diperoleh informasi mengenai kegagalan trafo.

2. Metode Penelitian

Metode penelitian dalam penelitian ini dilakukan dalam 6 langkah. Metode penelitian dimulai dengan melakukan perencanaan penelitian, pengumpulan dataset isolasi trafo, *preprocessing* data, pembangunan model klasifikasi menggunakan CNN, proses *training* model klasifikasi, dan yang terakhir adalah *testing* dan evaluasi untuk menguji dan melihat kualitas model klasifikasi. Alur metode penelitian dapat dilihat pada diagram di gambar 1.




Gambar 1. Alur metode penelitian

Perencanaan Penelitian

Perencanaan penelitian ini dilakukan dengan tahap mengidentifikasi permasalahan yang dihadapi, studi literatur, dan analisis penyelesaian untuk mengatasi permasalahan. Peneliti mendapati bahwa kegagalan atau kerusakan trafo dapat dideteksi lebih dini dengan mengidentifikasi kondisi pada isolasi trafo. Permasalahan tersebut dapat diselesaikan dengan menerapkan algoritma *deep learning* yaitu CNN. Dengan dibangunnya sistem klasifikasi gambar dapat mengefisiensi pekerjaan yang ada.

Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini terdapat 2 kelas, yaitu data gambar isolasi trafo cacat dan normal. Total dataset yang dikumpulkan adalah 18 gambar. Dataset isolasi trafo cacat diambil dari [10]. Dataset isolasi trafo normal dikumpulkan dengan cara *web scraping* dengan mempertimbangkan jenis isolasi trafo cacat, sehingga data yang diambil adalah sama yaitu isolasi jenis *pressboard*. *Web scraping* merupakan teknik memperoleh data dari sebuah *website* secara otomatis dan cepat [12]. Dataset yang diambil yaitu gambar dengan pemotretan tegak lurus dengan isolasi. Contoh dataset dari tiap kelas dapat dilihat pada gambar 2.




Gambar 2. Contoh Dataset

Preprocessing Data

Preprocessing data yang dilakukan dalam penelitian ini adalah augmentasi data, standarisasi data, dan membagi dataset ke dalam 2 bagian, yaitu data *training* dan *testing*. Augmentasi data merupakan suatu proses memodifikasi data gambar sehingga gambar asli

dapat berubah bentuk dan posisi [13]. Tujuan augmentasi data adalah untuk memperbanyak dataset dan menghindari terjadinya *overfitting*. Augmentasi data yang digunakan terdiri dari *crop*, *translation*, *rotate*, *scale*, *flip*, *blur*, *posterize*, *sharpen*, *color*, *contrast*, *brightness*, dan *resize*. Jumlah total dataset hasil augmentasi adalah 432 gambar. Contoh dataset hasil augmentasi dari tiap kelas dapat dilihat pada gambar 3. Perbandingan jumlah dataset awal dan hasil augmentasi dari setiap kelas dapat dilihat pada tabel 1.



Gambar 3. Contoh dataset hasil augmentasi

Tabel 1. Jumlah dataset awal dan augmentasi dari setiap kelas

Kelas	Jumlah Dataset Awal	Jumlah Dataset Augmentasi	Total
Cacat	9	216	225
Normal	9	216	225

Setelah dilakukan augmentasi data, langkah selanjutnya adalah melakukan standarisasi data. Tujuan standarisasi data adalah untuk memodifikasi data sedemikian rupa dan menjadikannya lebih stabil [14]. Standarisasi data dilakukan dengan mengubah ukuran data gambar. Pada penelitian ini dilakukan pengujian dari perbedaan 2 standarisasi data yaitu menggunakan ukuran data gambar 180 x 180 x 3 piksel dan ukuran data gambar 240 x 240 x 3 piksel. Langkah selanjutnya yaitu melakukan pembagian dataset ke dalam 2 bagian, yaitu *training* dan *testing*. Pembagian dataset untuk *training* 80% dan untuk *testing* 20%, sehingga jumlah dataset *training* adalah 346 gambar dan *testing* adalah 86 gambar.

Pembangunan model klasifikasi

Pada tahap ini dilakukan pembangunan model klasifikasi dengan menerapkan algoritma *deep learning* yaitu CNN. Model klasifikasi dibangun dan dijalankan menggunakan bahasa pemrograman Python dan *library* TensorFlow serta Keras dengan GPU sebagai *runtime*. TensorFlow adalah kerangka kerja untuk membuat model *machine learning*, khususnya *neural network*. TensorFlow dikembangkan oleh Google pada tahun 2015 [15]. Keras adalah *Application Programming Interface* (API) yang ditulis dengan Python dan dapat berjalan di atas TensorFlow. Keras memungkinkan pengguna untuk melatih dan menganalisis *neural network* [16]. Arsitektur model CNN pada pembangunan model klasifikasi dapat dilihat pada tabel 2.

Tabel 2. Arsitektur model CNN (standarisasi data 180 x 180 x 3 piksel)

<i>Layer (type)</i>	<i>Output Shape</i>	<i>Activation Function</i>
<i>rescaling (Rescaling)</i>	(None, 180, 180, 3)	
<i>conv2d (Conv2D)</i>	(None, 180, 180, 16)	ReLU
<i>max_pooling2d (MaxPooling2D)</i>	(None, 90, 90, 16)	
<i>conv2d_1 (Conv2D)</i>	(None, 90, 90, 32)	ReLU
<i>max_pooling2d_1 (MaxPooling2D)</i>	(None, 45, 45, 32)	
<i>conv2d_2 (Conv2D)</i>	(None, 45, 45, 64)	ReLU
<i>max_pooling2d_2 (MaxPooling2D)</i>	(None, 22, 22, 64)	
<i>flatten (Flatten)</i>	(None, 30976)	
<i>dense (Dense)</i>	(None, 128)	ReLU
<i>dense_1 (Dense)</i>	(None, 2)	

Tabel 3. Arsitektur model CNN (standarisasi data 240 x 240 x 3 piksel)

<i>Layer (type)</i>	<i>Output Shape</i>	<i>Activation Function</i>
<i>rescaling (Rescaling)</i>	(None, 240, 240, 3)	
<i>conv2d (Conv2D)</i>	(None, 240, 240, 16)	ReLU
<i>max_pooling2d (MaxPooling2D)</i>	(None, 120, 120, 16)	
<i>conv2d_1 (Conv2D)</i>	(None, 120, 120, 32)	ReLU
<i>max_pooling2d_1 (MaxPooling2D)</i>	(None, 60, 60, 32)	
<i>conv2d_2 (Conv2D)</i>	(None, 60, 60, 64)	ReLU
<i>max_pooling2d_2 (MaxPooling2D)</i>	(None, 30, 30, 64)	
<i>flatten (Flatten)</i>	(None, 57600)	
<i>dense (Dense)</i>	(None, 128)	ReLU
<i>dense_1 (Dense)</i>	(None, 2)	

Training

Pada tahap ini dilakukan *training* dan penyetelan parameter pada model klasifikasi yang telah dibangun. Dataset yang digunakan untuk proses *training* adalah dataset hasil augmentasi sebesar 80% atau jumlah dataset 346 gambar. Data *training* merupakan data yang digunakan sebagai acuan untuk membuat model klasifikasi [17]. Penyetelan parameter dilakukan dengan tujuan untuk mengetahui pengaruh parameter terhadap performa yang dihasilkan. Parameter *training* pada pembangunan model klasifikasi dapat dilihat pada tabel 3.

Tabel 3. Parameter *training*

Parameter	Deskripsi
<i>Batch size</i>	32
<i>Epoch</i>	10
<i>Optimizer</i>	<i>Adam</i>
<i>Learning rate</i>	0.001
<i>Beta 1</i>	0.9
<i>Beta 2</i>	0.999
<i>Epsilon</i>	1e-07
<i>Amsgrad</i>	<i>False</i>
<i>Loss function</i>	<i>Sparse Categorical Cross-Entropy</i>

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Recall + Precision} \quad (4)$$

Testing dan Evaluasi

Testing dilakukan untuk menguji model dengan data baru. Dataset yang digunakan untuk proses *testing* adalah dataset hasil augmentasi sebesar 20% atau jumlah dataset 86 gambar. Data *testing* merupakan data yang digunakan untuk menguji performa model klasifikasi [17]. Evaluasi dilakukan untuk melihat baik atau tidaknya kualitas dan efektivitas dari model klasifikasi. Evaluasi dilakukan menggunakan *confusion matrix*. *Confusion matrix* merupakan suatu struktur tabel tertentu yang digunakan untuk mengukur kinerja model *machine learning* dengan pendekatan *supervised learning* [18]. Struktur tabel *confusion matrix* dapat dilihat pada tabel 4.

Tabel 4. *Confusion matrix*

		<i>Predicted/Classified Class</i>			
		<i>Positive</i> (1)	<i>Negative</i> (0)		
<i>Confusion Matrix</i>	<i>Positive</i>	TP	(True	FN	(False
	(1)	<i>Positive</i>	<i>Negative</i>		
	<i>Negative</i>	FP	(False	TN	(True
	(0)	<i>Positive</i>	<i>Negative</i>		

Keterangan:

TP = Data positif yang terklasifikasi benar

TN = Data negatif yang terklasifikasi salah

FP = Data negatif yang terklasifikasi benar


FN = Data positif yang terklasifikasi salah

Pada penelitian ini *confusion matrix* digunakan untuk mendapatkan nilai *accuracy*, *precision*, *recall*, dan F1-score. Rumus *confusion matrix* untuk menghitung *accuracy*, *precision*, *recall*, dan F1-score adalah sebagai berikut.


3. Hasil dan Pembahasan

Penelitian ini mendeteksi cacat pada isolasi trafo menggunakan algoritma *Convolutional Neural Network* (CNN). Dataset terbagi menjadi 2 kelas yaitu isolasi cacat dan normal. Dataset yang digunakan adalah dataset hasil augmentasi berjumlah 432 gambar yang terdiri dari 216 gambar untuk masing-masing kelas. Pembagian dataset dilakukan dengan perbandingan 80% untuk *training* dan 20% untuk *testing*. Dataset terbagi menjadi 2 pengujian yaitu dataset yang menggunakan standardisasi data ukuran 180 x 180 x 3 piksel dan 240 x 240 x 3 piksel.

Model klasifikasi dibangun dengan menerapkan algoritma *deep learning* yaitu CNN, dijalankan menggunakan bahasa pemrograman Python, dan menggunakan *library* TensorFlow serta Keras. Parameter *training* yang diujikan yaitu *batch size* terdiri dari 32, *epoch* terdiri dari 10, *optimizer* yang digunakan Adam, dan *loss function* yang digunakan *Sparse Categorical Cross-Entropy*. Hasil *training* standardisasi data ukuran 180 x 180 x 3 piksel menghasilkan *accuracy* 0.9913 dan *loss* 0.0349, sedangkan standardisasi data ukuran 240 x 240 x 3 piksel menghasilkan *accuracy* 0.9798 dan *loss* 0.0586. Hasil *testing* standardisasi data ukuran 180 x 180 x 3 piksel menghasilkan *accuracy* 0.9884 dan *loss* 0.0419, sedangkan standardisasi data ukuran 240 x 240 x 3 piksel menghasilkan *accuracy* 0.9651 dan *loss* 0.1480. Grafik nilai *training accuracy* dan *loss* dapat dilihat pada gambar 4 dan 5.





Gambar 4. Grafik nilai *training accuracy* dan *loss* (standardisasi data 180 x 180 x 3 piksel)





Gambar 5. Grafik nilai *training accuracy* dan *loss* (standardisasi data 240 x 240 x 3 piksel)

Berdasarkan gambar 4 dan 5, performa model yang menggunakan standardisasi data ukuran 180 x 180 x 3 piksel menunjukkan hasil *accuracy* yang lebih tinggi dan *loss* yang lebih rendah. Adapun contoh hasil prediksi model klasifikasi pada data *testing* untuk tiap gambar isolasi trafo dapat dilihat pada tabel 5 dan 6.

Tabel 5. Contoh hasil prediksi (standardisasi data 180 x 180 x 3 piksel)

Gambar	Label/Kelas	Prediksi
	Cacat	Cacat
	Normal	Normal

Tabel 6. Contoh hasil prediksi (standardisasi data 240 x 240 x 3 piksel)

Gambar	Label/Kelas	Prediksi
	Cacat	Cacat
	Normal	Normal

Berdasarkan tabel 5 dan 6, dapat dilihat bahwa model sudah dapat melakukan prediksi dengan benar, baik untuk model yang menggunakan standardisasi data ukuran 180 x 180 x 3 ataupun 240 x 240 x 3. Hasil uji model klasifikasi menggunakan data *training* dan data *testing* dilakukan evaluasi menggunakan *confusion matrix*. Hasil pengujian model dapat dilihat pada tabel 7 dan 8.

Tabel 7. Hasil pengujian (standardisasi data 180 x 180 x 3 piksel)

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Cacat	1.00	1.00	1.00
Normal	1.00	1.00	1.00

Tabel 8. Hasil pengujian (standardisasi data 240 x 240 x 3 piksel)

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Cacat	0.90	1.00	0.95
Normal	1.00	0.85	0.92

Berdasarkan tabel 7 dan 8, pengujian model menggunakan *confusion matrix* menghasilkan nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas. Hasil evaluasi standardisasi data ukuran 180 x 180 x 3 piksel menghasilkan nilai rata-rata 1.00 untuk *precision*, 1.00 untuk *recall*, dan 1.00 untuk *F1-score*. Hasil evaluasi standardisasi data ukuran 240 x 240 x 3 piksel menghasilkan nilai rata-rata 0.95 untuk *precision*, 0.925 untuk *recall*, dan 0.935 untuk *F1-score*. Adapun hasil perhitungan *accuracy* dapat dilihat pada tabel 9.

Tabel 9. Hasil *accuracy* evaluasi

Dataset	<i>Accuracy</i>
Standardisasi data 180 x 180 x 3 piksel	1.00
Standardisasi data 240 x 240 x 3 piksel	0.94

Berdasarkan tabel 9, penelitian dengan menggunakan standardisasi data ukuran 180 x 180 x 3 piksel menghasilkan nilai *accuracy* evaluasi yang lebih tinggi dibanding standardisasi data ukuran 240 x 240 x 3 piksel.

4. Kesimpulan

Berdasarkan penelitian yang dilakukan mengenai deteksi cacat pada isolasi trafo secara visual menggunakan algoritma *Convolutional Neural Network* (CNN), menunjukkan bahwa perbedaan standardisasi data dapat memengaruhi hasil dari performa model. Pada penelitian ini dilakukan pengujian dari perbedaan 2 standardisasi data yaitu menggunakan ukuran data gambar 180 x 180 x 3 piksel dan ukuran data gambar 240 x 240 x 3 piksel. Dataset yang digunakan adalah dataset hasil augmentasi yang berjumlah 432 gambar. Pembagian dataset untuk *training* 80% dan *testing* 20%. Berdasarkan hasil uji dengan standardisasi data ukuran 180 x 180 x 3 piksel menghasilkan *accuracy* 0.9913 untuk *training*, *accuracy* 0.9884 untuk *testing*, dan *accuracy* 1.00 untuk evaluasi. Hasil uji dengan standardisasi data ukuran 240 x 240 x 3 piksel, menghasilkan *accuracy* 0.9798 untuk *training*, *accuracy* 0.9651 untuk *testing*, dan *accuracy* 0.94 untuk evaluasi.

Standardisasi data ukuran 180 x 180 x 3 piksel memiliki hasil yang lebih baik dibanding standardisasi data ukuran 240 x 240 x 3 piksel, baik pada saat *training*, *testing*, ataupun evaluasi.

Berdasarkan hasil penelitian yang telah dilakukan, rekomendasi untuk penelitian selanjutnya adalah melakukan pengujian dengan menggunakan dataset yang lebih luas dan bervariasi untuk memastikan keakuratan model dalam deteksi cacat pada isolasi trafo. Dapat menambah jumlah dataset untuk meningkatkan akurasi model dan melakukan percobaan dengan menggunakan metode *preprocessing* data yang berbeda untuk meningkatkan variasi data. Selain itu, penelitian selanjutnya dapat mencoba menggunakan filter tambahan pada saat proses augmentasi untuk memperoleh data yang lebih bervariasi. Dalam hal penggunaan *Convolutional Neural Network*, peneliti dapat mencoba menggunakan arsitektur yang berbeda dan membandingkan performa dari masing-masing arsitektur. Terakhir, sebaiknya melakukan analisis lebih lanjut terhadap hasil dari performa model untuk memastikan bahwa hasil dari penelitian dapat diterapkan dalam kondisi dunia nyata.

5. Daftar Pustaka

- [1] Harahap, P., Adam, M., & Prabowo, A., 2019. Analisa Penambahan Trafo Sisip Sisi Distribusi 20 Kv Mengurangi Beban Overload Dan Jutah Tegangan Pada Trafo Bl 11 Rayon Tanah Jawa Dengan Simulasi Etap 12.6.0. *RELE (Rekayasa Elektr. dan Energi) J. Tek. Elektro*, 1(2), 62–69. DOI: <https://doi.org/10.30596/rele.v1i2.3002>.
- [2] Dharsni, C., 2019. Test Loop Termokopel Tipe K Dengan Kalibrator Jofra. *J. Ris. Fis. Edukasi dan Sains*, 6(6), 49–53. DOI: <https://doi.org/10.22202/jrfes.2019.v6i2.3571>
- [3] Ondrialdi, R., Situmeang, U., & Zufahri, 2020. Analisis Pengujian Kualitas Isolasi Transformator Daya di PT. Indah Kiat Pulp and Paper Perawang. *SainETIn*, 4(2), 72–81. DOI: <https://doi.org/10.31849/sainetin.v4i2.6288>.

- [4] Rahman, R. A., Paronda, A. H., & Marini, S., 2018. Analisis Pengaruh Kadar Air Terhadap Karakteristik Tegangan Tembus Dan Dielektrik Isolasi Pressboard Tipe B.3.1. *J. Electr. Electron.*, 6(1), 43–52.
- [5] Siregar, S. B., & Rahmadewi, R., 2021. Pengujian Tahanan Isolasi Trafo Tegangan Di Gardu Induk Telukjambe Karawang. *JE-Unisla*, 6(2), 10. DOI: <https://doi.org/10.30736/je-unisla.v6i2.689>.
- [6] Ardiningtyas, Y. E., & Rosa, P. H. P., 2021. Analisis Balancing Data Untuk Meningkatkan Akurasi Dalam Klasifikasi. In *Prosiding Seminar Nasional Aplikasi Sains & Teknologi (SNAST)* (pp. 24–28).
- [7] Malika, M., & Widodo, E., 2022. Implementasi Deep Learning untuk Klasifikasi Gambar Menggunakan Convolutional Neural Network (CNN) pada Batik Sasambo. *Pattimura Proceeding Conf. Sci. Technol.*, pp. 335–340. DOI: <https://doi.org/10.30598/PattimuraSci.2021.KNMX.335-340>.
- [8] Pratiwi, H. A., Cahyanti, M., & Lamsani, M., 2021. Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network. *Sebatik*, 25(1), 124–130. DOI: <https://doi.org/10.46984/sebatik.v25i1.1297>.
- [9] Yuliany, S., & Nur Rachman, A., 2022. Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN). *J. Buana Inform.*, 13(1), 54–65. DOI: <https://doi.org/10.24002/jbi.v13i1.5022>.
- [10] Ji, H., Cui, X., Ren, W., Liu, L., & Wang, W., 2021. Visual inspection for transformer insulation defects by a patrol robot fish based on deep learning. *IET Sci. Meas. Technol.*, 15(7), 606–618. DOI: <https://doi.org/10.1049/smt2.12062>.
- [11] Misto, M., & Haryono, H., 2019. Analisis Gas Terlarut pada Minyak Isolasi sebagai Indikator Kegagalan Transformator Daya dengan Metode Dissolved Gas Analysis. *J. Tek. Elektro dan Komputasi*, 1(2), 99–112. DOI: <https://doi.org/10.32528/elkom.v1i2.3091>.
- [12] Kopravi, M., & Putra, W. S., 2023. Implementasi Web Scraping pada Google Cendekia sebagai Sarana Profiling Penelitian Dosen. *Sci. Tech J. Ilmu Penget. dan Teknol.*, 9(1), 59–72. DOI: <https://doi.org/10.30738/st.vol9.no1.a14188>.
- [13] Mulyana, D. I., & Akbar, A., 2022. Optimasi Klasifikasi Batik Betawi Menggunakan Data Augmentasi Dengan Metode KNN Dan GLCM. *J. Apl. Teknol. Inf. dan Manaj.*, 3(2), 92–101. DOI: <https://doi.org/10.31102/jatim.v3i2.1577>.
- [14] Maharadja, A. N., Maulana, I., & Dermawan, B. A., 2021. Penerapan Metode Regresi Linear Berganda untuk Prediksi Kerugian Negara Berdasarkan Kasus Tindak Pidana Korupsi. *J. Appl. Informatics Comput.*, 5(1), 95–102. DOI: <https://doi.org/10.30871/jaic.v5i1.3184>.
- [15] Iruela, J. R. S., Baca Ruiz, L. G., Tuñon, M. C., & Jiménez, M. D. C. P., 2021. A tensorflow approach to data analysis for time series forecasting in the energy-efficiency realm. *Energies*, 14(13), 1–22. DOI: <https://doi.org/10.3390/en14134038>.
- [16] Chicho, B. T., & Sallow, A. B., 2021. A Comprehensive Survey of Deep Learning Models Based on Keras Framework. *J. Soft Comput. Data Min.*, 2(2), 49–61. DOI: <https://doi.org/10.30880/jscdm.2021.02.02.05>.
- [17] Darwis, D., Siskawati, N., & Abidin, Z., 2021. Penerapan Algoritma Naive Bayes Untuk Analisis Sentimen Review Data Twitter Bmkg Nasional. *J. Tekno Kompak*, 15(1), 131. DOI: <https://doi.org/10.33365/jtk.v15i1.744>.

- [18] Simaiya, S., Lilhore, U. K., Prasad, D., & Verma, D. K., 2021. MRI Brain Tumour Detection & Image Segmentation by Hybrid Hierarchical K-means clustering with FCM based Machine Learning Model. *Ann. Rom. Soc. Cell Biol.*, 25(1), 88–94. Retrieved from <http://annalsofrscb.ro/index.php/journal/article/view/74>.