

Pengenalan Bahasa Isyarat Hijaiyah: Augmentasi Data dengan EfficientnetB7

Tanwir¹, Husain¹, Rifqi Hammad², Andi Sofyan Anas³, Muhammad Azwar³

¹ Program Studi Magister Ilmu Komputer; Universitas Bumigora, Indonesia

² Program Studi Rekayasa Perangkat Lunak; Universitas Bumigora, Indonesia

³ Program Studi Ilmu Komputer; Universitas Bumigora, Indonesia

* Korespondensi: tanwir@universitasbumigora.ac.id

Sitasi: Tanwir, T.; Husain, H.; Hammad, R.; Anas, A. S.; and Azwar, M. (2025). Pengenalan Bahasa Isyarat Hijaiyah: Augmentasi Data dengan EfficientnetB7. JTIM: Jurnal Teknologi Informasi Dan Multimedia, 7(4), 871-880. <https://doi.org/10.35746/jtim.v7i4.728>

Diterima: 19-04-2025

Direvisi: 13-05-2025

Disetujui: 30-05-2025

Abstract: Sign language plays an important role as the primary means of communication for individuals with hearing impairments. This study aims to improve the accuracy of hijaiyah sign language detection through the application of the EfficientNetB7 architecture and data augmentation techniques. The method used, namely the EfficientNetB7 algorithm, was chosen as the base model because of its ability to balance high accuracy with optimal resource utilization by performing data augmentation with rescale, shear, zoom, rotation, and flip horizontal techniques applied to enrich the variation of the original dataset of 6,811 images to 105,615 images. The experimental results show that the combination of EfficientNetB7 and data augmentation produces 99% accuracy on the test data, with consistent performance seen from the confusion matrix and accuracy loss graph for 50 epochs. This study proves that this approach not only improves model generalization but also reduces the risk of overfitting, thus potentially supporting social inclusion through efficient and reliable technology.

Keywords: Data Augmentation; Detection; EfisiennetB7; Hijaiyah Sign Language

Abstrak: Bahasa isyarat memainkan peran penting sebagai alat komunikasi utama bagi individu yang mengalami gangguan pendengaran. Penelitian ini bertujuan untuk meningkatkan akurasi deteksi bahasa isyarat hijaiyah melalui penerapan arsitektur EfficientNetB7 dan teknik augmentasi data. Metode yang digunakan yaitu algoritma EfficientNetB7 dipilih sebagai model dasar karena kemampuannya untuk menyeimbangkan akurasi yang tinggi dengan penggunaan sumber daya yang optimal dengan melakukan augmentasi data dengan teknik *rescale*, *shear*, *zoom*, *rotation*, dan *flip horizontal* diterapkan untuk memperkaya variasi dataset asli sebanyak 6.811 gambar menjadi 105.615 gambar. Hasil eksperimen menunjukkan bahwa kombinasi EfficientNetB7 dan augmentasi data menghasilkan akurasi 99% pada data uji, dengan kinerja yang konsisten terlihat dari matriks kebingungan dan grafik kehilangan akurasi selama 50 *epoch*. Penelitian ini membuktikan bahwa pendekatan ini tidak hanya meningkatkan generalisasi model tetapi juga mengurangi risiko *overfitting*, sehingga berpotensi mendukung inklusi sosial melalui teknologi yang efisien dan andal.

Kata kunci: Augmentasi Data; Bahasa Isyarat Hijaiyah; Deteksi; EfficientnetB7



Copyright: © 2025 oleh para penulis. Karya ini dilisensikan di bawah Creative Commons Attribution-ShareAlike 4.0 International License. (<https://creativecommons.org/licenses/by-sa/4.0/>).

1. Pendahuluan

Bahasa isyarat memainkan peran penting sebagai alat komunikasi utama bagi individu yang mengalami gangguan pendengaran. Kemampuan untuk mendeteksi dan

mengenali bahasa isyarat dengan akurasi tinggi menjadi semakin krusial dalam upaya meningkatkan inklusi sosial bagi komunitas ini [1]. Dalam beberapa tahun terakhir, perkembangan teknologi pengenalan bahasa isyarat telah menunjukkan kemajuan yang signifikan [2], namun tantangan utama dalam pengembangan sistem yang akurat dan andal masih tetap ada [3]. Salah satu tantangan tersebut adalah kebutuhan akan model yang tidak hanya dapat mengenali isyarat dengan presisi tinggi tetapi juga efisien dalam hal penggunaan sumber daya komputasi. Oleh karena itu, penelitian ini berfokus pada penggunaan EfficientNetB7, sebuah arsitektur jaringan saraf konvolusional yang telah terbukti efisien dan kuat dalam pengenalan gambar [4], serta teknik augmentasi data untuk meningkatkan performa model deteksi bahasa isyarat.

Meskipun teknologi pengenalan bahasa isyarat telah mengalami kemajuan, masih terdapat berbagai keterbatasan pada model-model yang ada. Salah satu masalah utama adalah kurangnya akurasi dalam mengenali berbagai variasi bahasa isyarat yang digunakan oleh individu yang berbeda [5]. Model-model sebelumnya sering kali tidak mampu mengatasi perbedaan dalam gaya, kecepatan, dan ekspresi isyarat, yang mengakibatkan hasil deteksi yang tidak konsisten [6]. Selain itu, ketersediaan data yang terbatas dan kurang bervariasi menjadi kendala signifikan dalam melatih model yang robust dan generalis [7]. Keterbatasan data ini membuat model rentan terhadap *overfitting*, sehingga performa pada data uji yang tidak terlihat menjadi kurang optimal. Masalah lainnya adalah terkait efisiensi dan skalabilitas model. Sebagian besar model deteksi bahasa isyarat yang ada membutuhkan sumber daya komputasi yang besar, yang tidak selalu tersedia di perangkat keras yang lebih terbatas, seperti pada perangkat mobile atau sistem tertanam [8]. Oleh karena itu, diperlukan pendekatan yang dapat mengoptimalkan penggunaan sumber daya komputasi tanpa mengorbankan akurasi. Dalam konteks ini, EfficientNetB7 menawarkan solusi potensial karena desainnya yang efisien dalam penggunaan parameter dan daya komputasi, sambil tetap mempertahankan kinerja yang tinggi dalam tugas pengenalan gambar [4].

Penelitian dilakukan oleh [7] membandingkan kinerja beberapa model *pre-trained* CNN (MnetV2, Xception, VGG16, dan ResNet50) untuk klasifikasi bahasa isyarat huruf hijaiyah. Hasil menunjukkan bahwa MnetV2, Xception, dan VGG16 mencapai akurasi 99,85% dalam jumlah *epoch* yang berbeda, sedangkan ResNet50 hanya mencapai akurasi tertinggi 82,12%. Model MnetV2, Xception, dan VGG16 menunjukkan kinerja sempurna pada data uji dengan *precision*, *recall*, *f1-score*, dan *accuracy* sebesar 100%, sementara ResNet50 menunjukkan performa lebih rendah. Penelitian dilakukan oleh [8] metode yang digunakan YOLOV5 untuk mendeteksi bahasa isyarat huruf Hijaiyah, akurasi mencapai 95%, dalam mengenali gerakan tangan yang merepresentasikan huruf Hijaiyah. Dari penelitian sebelumnya tidak melakukan preprocessing citra sebelum pelatihan dan belum menggunakan model EfficientNetB7. Jadi penelitian selanjutnya menambahkan langkah-langkah preprocessing seperti segmentasi citra, augmentasi data seperti rotasi, pemotongan, perubahan kontras dan normalisasi warna untuk meningkatkan kualitas data input.


Penelitian ini bertujuan untuk mengatasi berbagai permasalahan yang dihadapi dalam deteksi bahasa isyarat dengan memanfaatkan arsitektur EfficientNetB7 dan teknik augmentasi data yang inovatif. EfficientNetB7 dipilih sebagai model dasar karena kemampuannya untuk mencapai keseimbangan yang optimal antara akurasi dan efisiensi komputasi [4]. Dengan menggunakan teknik penskalaan yang cermat, EfficientNetB7 dapat menghasilkan model yang lebih kecil namun tetap mempertahankan atau bahkan meningkatkan performa deteksi gambar. Hal ini sangat relevan dalam konteks deteksi bahasa isyarat, di mana efisiensi komputasi merupakan faktor penting terutama pada perangkat keras dengan sumber daya terbatas.

Selain itu, augmentasi data dipilih sebagai salah satu pendekatan utama untuk meningkatkan performa model. Teknik augmentasi data memungkinkan pengayaan

dataset dengan variasi isyarat yang lebih luas, sehingga dapat mengurangi masalah *over-fitting* dan meningkatkan generalisasi model pada data uji yang tidak terlihat [9]. Dengan mengintegrasikan EfficientNetB7 dan teknik augmentasi data, diharapkan penelitian ini dapat memberikan kontribusi signifikan dalam bidang teknologi pengenalan bahasa isyarat dan mendukung inklusi sosial bagi komunitas tuna rungu dan gangguan pendengaran.

2. Bahan dan Metode

Dalam penelitian ini, Metode yang digunakan untuk deteksi adalah EfficientNetB7. Metode dan arsitektur tersebut digunakan untuk deteksi citra Bahasa isyarat hijaiyah. Berikut adalah gambaran umum dari sistem yang akan dirancang dapat dilihat di Gambar 1.




Gambar 1. Alur dari Metode Penelitian

2.1. Dataset

Dataset yang digunakan dalam penelitian ini menggunakan citra bahasa isyarat hijaiyah dengan jumlah gambar sebanyak 6.811 dengan 31 kelas dari : ain, al, alif, ba, dal, dhad, dzal, fa, ghain, ha, hh, jim, kaf, kha, lam, lamalif, mim, nun, qaf, ra, shad, sin, syin, ta, tamar, tha, tsa, wau, ya, zay, zha. Dataset dapat diakses pada tautan berikut <http://bit.ly/40sWUHW>.


Gambar 2 menunjukkan dua jenis visualisasi data: *countplot* (diagram batang) di sebelah kiri dan pie chart (diagram lingkaran) di sebelah kanan. Diagram batang menampilkan jumlah kemunculan dari berbagai kategori dalam dataset, dengan sumbu horizontal berlabel kategori seperti 'ba', 'kha', 'tsa', dan seterusnya, serta sumbu vertikal menunjukkan frekuensi kemunculan. Dari grafik ini, terlihat bahwa kategori 'ba' memiliki frekuensi tertinggi dengan jumlah 255. grafik lingkaran di sebelah kanan menggambarkan persentase distribusi dari kategori yang sama, di mana setiap segmen menunjukkan persentase dari total frekuensi. Kategori dengan persentase 3.74% adalah yang terbesar, sementara yang terkecil adalah 3.05%. Secara keseluruhan, dataset ini terdiri dari berbagai kategori dengan frekuensi kemunculan tertentu, di mana diagram batang memberikan representasi absolut dan diagram lingkaran memberikan representasi proporsional.



Gambar 2. Grafik jumlah dataset dan persentase distribusi kategori sama

2.2. Pre-Processing

Proses pengolahan citra bertujuan meningkatkan kualitas gambar bahasa isyarat hijaiyah, mengurangi risiko *overfitting*, dan mengoptimalkan kinerja model EfficientNetB7[10]. Langkah pertama adalah mengubah ukuran gambar menjadi 200×200 piksel untuk menyamakan dimensi dan memangkas waktu komputasi. Selanjutnya, gambar RGB dikonversi ke skala abu-abu guna mengurangi kompleksitas pemrosesan dan mempercepat eksekusi. Augmentasi data juga diterapkan menggunakan teknik seperti *Re-scale*, *Shear*, *Zoom*, *Rotation*, dan *Flip Horizontal* untuk menciptakan variasi data tambahan tanpa menyalin data asli secara identik[11][9][12]. Kombinasi teknik ini menghasilkan dataset yang lebih beragam dan terstandarisasi, sehingga meningkatkan kemampuan model dalam mengenali pola gerakan tangan secara akurat. Adapun contohnya dapat dilihat pada Gambar 3.




Gambar 3. Hasil Gambar Grayscale; (a). Gambar Sebelum Grayscale, (b). Gambar Setelah Skala Abu-abu

2.3. Desain Model Tranfer Learning EfficientNetB7

Metode EfficientNetB7 biasanya melibatkan beberapa lapisan (*Convusion layer*), termasuk lapisan konvolusional, lapisan penyatuan (*pooling layers*), dan lapisan yang terhubung sepenuhnya (*fully connected*), dalam proses prediksi atau klasifikasi gambar[13]. Proses konvolusi bertanggung jawab untuk mengekstraksi fitur dan memperoleh representasi informatif dari gambar masukan. Fitur-fitur yang diperoleh dari proses konvolusi kemudian dikumpulkan. Proses pengumpulan, yang menggunakan Pengumpulan Maks atau Pengumpulan Rata-rata, diterapkan untuk mengurangi dimensi ruang fitur, sehingga mengurangi waktu komputasi[14]. Ukuran filter yang biasa digunakan pada

proses pooling dengan 7x7. Setelah proses pooling adalah proses *Flatten*, yang mengubah matriks $m \times n$ menjadi vektor masukan satu dimensi [15].

Berbeda dengan arsitektur CNN konvensional yang sering dirancang secara manual dan terpisah-pisah untuk setiap ukuran model, EfficientNetB7 menggunakan pendekatan *compound scaling* yang secara bersamaan mengoptimalkan kedalaman (depth), lebar (width), dan resolusi gambar input secara sistematis. Ini memungkinkan peningkatan akurasi tanpa pertambahan kompleksitas model yang signifikan [4]. Proses kinerja dari metode EfficientNetB7 dapat dilihat pada Gambar 4.



Gambar 4. Proses Kerja Metode EfficientNetB7

2.4. Evaluasi Kinerja Berdasarkan Akurasi

Mengevaluasi kinerja model EfficientNetB7 untuk mendeteksi Bahasa isyarat hijaiyah berdasarkan akurasi. Akurasi digunakan untuk mengevaluasi kemampuan model EfficientNetB7 untuk menentukan kelas hijaiyah dari seluruh dataset Bahasa isyarat hijaiyah. Rumus yang digunakan untuk menghitung akurasi adalah seperti yang ditunjukkan dalam Persamaan (1) [7], [8].

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

Keterangan:

- **Accuracy:** mengukur berapa banyak prediksi yang benar (baik positif maupun negatif) dibandingkan dengan seluruh jumlah prediksi. Semakin tinggi akurasi, semakin baik performa model dalam melakukan klasifikasi secara umum.
- **TN (True Negative):** Jumlah data negatif yang diprediksi benar oleh model.
- **FP (False Positive):** Jumlah data negatif yang salah diprediksi sebagai positif.
- **FN (False Negative):** Jumlah data positif yang salah diprediksi sebagai negatif.

3. Hasil dan Pembahasan

Pengolahan citra sangat penting untuk meningkatkan kualitas gambar yang diolah sehingga model EfficientNetB7 dapat mendeteksi bahasa isyarat hijaiyah dengan lebih optimal. Teknik pengolahan citra meliputi perubahan ukuran, konversi ke skala abu-abu, dan augmentasi data. Perubahan ukuran gambar bertujuan untuk menyamakan ukuran gambar guna mengurangi waktu komputasi. Penelitian ini menggunakan gambar dengan ukuran 200x200 piksel. Selanjutnya, gambar RGB diubah menjadi skala abu-abu. Proses ini meningkatkan kinerja model pengenalan gambar dengan mengurangi waktu eksekusi dan kompleksitas. Kita juga akan melakukan augmentasi data. Karena jumlah data yang tersedia masih sedikit dan kurang bervariasi, metode EfficientNetB7 menjadi kurang optimal dalam mengenali data, sehingga mempengaruhi tingkat akurasi. Akibatnya, untuk meningkatkan variasi data, diperlukan augmentasi data, sehingga metode EfficientNetB7 dapat mengenali data penyakit padi dengan lebih baik. Dalam proses augmentasi data, berbagai metode digunakan untuk memastikan bahwa data tambahan tidak sepenuhnya sama dengan data asli. *Rescale*, *Shear*, *Zoom*, *Rotation*, dan *Flip Horizontal*

adalah beberapa teknik augmentasi yang digunakan. Tabel 2 menunjukkan jumlah data sebelum dan sesudah augmentasi, dan Gambar 5 menunjukkan data sampel yang dihasilkan dari proses augmentasi.




Gambar 5. Gerakan tangan bahasa isyarat hijaiyah

Table 2. Data Total bahasa isyarat hijaiyah Sebelum dan Sesudah Augmentasi


No	Kelas Bahasa isyarat hijaiyah	Data Original	Data Augmentasi
1	wau	210	3360
2	qof	217	3472
3	ha	217	3472
4	dzal	227	3632
....			
29	sin	216	3456
30	lam	211	3376
31	fa	214	3424

Gambar bahasa isyarat hijaiyah yang telah melalui proses augmentasi kemudian dianalisis menggunakan metode EfficientNetB7 mampu mendeteksi huruf hijaiyah melalui gerakan tangan dengan mempelajari pola dari data latih. Semakin banyak data latih yang tersedia, semakin akurat metode EfficientNetB7 dalam mengenali pola-pola tersebut. Model EfficientNetB7 yang telah dilatih menggunakan data latih selanjutnya akan diuji dengan data uji untuk mengukur tingkat keberhasilannya dalam mendeteksi jenis penyakit tanaman padi. Penelitian ini memanfaatkan 80% data sebagai data latih (84492 data) dan 20% sebagai data uji (21123 data). Proses deteksi bahasa isyarat hijaiyah menggunakan metode EfficientNetB7 mengikuti arsitektur yang ditunjukkan pada Gambar 6.



Gambar 6. Hasil Augmentasi bahasa isyarat hijaiyah

Gambar data bahasa isyarat hijaiyah yang telah mengalami augmentasi data kemudian diidentifikasi melalui pemanfaatan pendekatan menggunakan model EfficientNetB7. Metodologi EfficientNetB7 meningkatkan efektivitas dan fungsionalitas *Convolution Neural Network* (CNN) dengan menggunakan penskalaan gabungan, yang secara bersamaan melibatkan penyesuaian kedalaman, lebar, dan resolusi jaringan secara harmonis. Melalui pemanfaatan *Neural Architecture Search* (NAS), EfficientNetB7 mengidentifikasi struktur optimal yang memungkinkan model mencapai akurasi yang lebih tinggi sekaligus memanfaatkan parameter dan sumber daya komputasi dengan lebih efisien. Oleh karena itu, ini sangat cocok untuk pembelajaran transfer dan tugas-tugas yang memerlukan model yang dapat diskalakan dan berperforma tinggi dalam pengenalan dan klasifikasi gambar. Dalam penelitian ini, distribusi 80% untuk dataset pelatihan (84492) dan 20% untuk dataset pengujian (21123) digunakan. Langkah selanjutnya melibatkan penerapan metode EfficientNetB7 untuk mengidentifikasi gerakan tangan bahasa isyarat hijaiyah berdasarkan desain arsitektur yang diilustrasikan pada Gambar 7.




Gambar 7 (a) Diagram Arsitektur model EfficientNetB7

Layer (type)	Output Shape	Param #
efficientnetb7 (Functional)	(None, 2560)	64097687
batch_normalization (Batch Normalization)	(None, 2560)	10240
dense (Dense)	(None, 128)	327808
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 31)	3999
=====		
Total params: 64439734 (245.82 MB)		
Trainable params: 336927 (1.29 MB)		
Non-trainable params: 64102807 (244.53 MB)		


Gambar 7 (b) Arsitektur Model EfficientNetB7

Gambar 7(a) menunjukkan arsitektur model jaringan saraf tiruan berbasis EfficientNetB7. Model dimulai dengan lapisan input (*efficientnetb7_input*) yang terhubung ke lapisan fungsional EfficientNetB7. Setelah itu, output dari EfficientNetB7 melewati lapisan normalisasi batch (*batch_normalization*), diikuti oleh lapisan Dense (*dense*) untuk proses klasifikasi atau regresi. Selanjutnya, terdapat lapisan dropout (*dropout*) yang digunakan untuk mengurangi overfitting dengan mengabaikan beberapa unit selama pelatihan. Akhirnya, model ini ditutup dengan lapisan Dense lainnya (*dense_1*) untuk memberikan output akhir. Gambar 7(b) menampilkan ringkasan arsitektur model jaringan saraf tiruan yang menggunakan EfficientNetB7 sebagai backbone untuk ekstraksi fitur, diikuti oleh lapisan normalisasi batch, lapisan *fully connected* dengan 128 unit, lapisan *dropout* untuk mengurangi *overfitting*, dan lapisan *fully connected* terakhir dengan 31 unit untuk keluaran akhir. Model ini memiliki total 64,439,734 parameter, dengan 336,927 parameter yang dapat dilatih dan 64,102,807 parameter yang tidak dapat dilatih, menunjukkan model klasifikasi gambar yang kompleks dan canggih. Gambar 8 dan 9 mengenai grafik akurasi dan loss metode EfficientNetB7 selama 50 *epoch*. Semakin besar jumlah *epoch* maka performa akurasi semakin meningkat. Sebaliknya, semakin besar jumlah *epoch*, semakin rendah tingkat kerugiannya. Perbedaan nilai akurasi dan *loss* masing-masing data latih dan data uji tidak terlalu jauh, hal ini menandakan tidak terjadi overfitting dan underfitting.

Dengan demikian, metode EfficientNetB7 mengklasifikasikan secara tepat sebanyak 682 data dari total 689 data sehingga akurasi yang dihasilkan sebesar 99%. Metode EfficientNetB7 memiliki akurasi yang tinggi tidak terlepas dari proses augmentasi datanya. Peneliti [9], [11], [16] menyatakan bahwa penggunaan augmentasi data dapat meningkatkan kinerja metode yang digunakan. Metode yang diusulkan lebih baik dari metode penelitian sebelumnya karena terdapat proses augmentasi data tambahan sehingga keakuratan metode EfficientNetB7 sangat tinggi seperti gambar 8.



Gambar 8 Hasil Confusion Matrix Metode EfficientNetB7 pada Deteksi Bahasa isyarat Hijaiyah



Gambar 9 Grafik Loss dan Akurasi Metode EfficientNetB7 dengan 50 Epoch

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan model EfficientNetB7 dan Teknik augmentasi data untuk deteksi bahasa isyarat hijaiyah dengan akurasi mencapai 99%. Augmentasi data terbukti efektif dalam memperluas variasi *dataset*, yang secara signifikan meningkatkan kemampuan generalisasi model. EfficientNetB7 menunjukkan kinerja unggul dalam menyeimbangkan efisiensi komputasi dan akurasi, menjadikannya cocok untuk penerapan pada perangkat berdaya terbatas. Hasil ini mengatasi keterbatasan model sebelumnya yang kurang optimal dalam menghadapi variasi gerakan dan ketersediaan data. Keberhasilan ini memberikan kontribusi penting dalam pengembangan teknologi asistif bagi komunitas tuna rungu, sekaligus membuka peluang penelitian lanjutan seperti integrasi real-time processing atau eksplorasi model yang lebih ringan tanpa mengorbankan akurasi.

Referensi

- [1] J. Jiang, "Sign Language Recognition Methods: Applications and Advances of Deep Learning Technology," in *6th International Conference on Computer Science and Intelligent Communication (CSIC 2024)*, Vancouver, 2025. <https://doi.org/10.54097/ryyycp94>.
- [2] B. A. AL ABDULLAH, G. A. AMOUDI, and H. S. ALGHAMDI, "Advancements in Sign Language Recognition: A Comprehensive Review and Future Prospects," *IEEE Access*, no. 12, p. 1, 2024, <https://doi.org/10.1109/ACCESS.2024.3457692>.
- [3] S. A. Sanjaya and H. Faustine Ilone, "BISINDO Sign Language Recognition: A Systematic Literature Review of Deep Learning Techniques for Image Processing," *Indones. J. Comput. Sci.*, vol. 12, no. 6, 2023, <https://doi.org/10.33022/ijcs.v12i6.3539>.
- [4] V. Acharya, V. Ravi, and N. Mohammad, "EfficientNet-based Convolutional Neural Networks for Malware Classification," in *12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, IEEE, 2021, <https://doi.org/10.1109/icccnt51525.2021.9579750>.
- [5] I. A. Adeyanju, O. O. Bello, and M. A. Adegboye, "Machine learning methods for sign language recognition: A critical review and analysis," 2021, <https://doi.org/10.1016/j.iswa.2021.200056>.
- [6] M. S. Nemteanu, V. Dinu, and D. C. Dabija, "Job insecurity, job instability, and job satisfaction in the context of the COVID-19 pandemic," *J. Compet.*, vol. 13, no. 2, pp. 65–82, 2021, <https://doi.org/10.7441/JOC.2021.02.04>.
- [7] Y. Brianorman and R. Munir, "Perbandingan Pre-Trained CNN: Klasifikasi Pengenalan Bahasa Isyarat Huruf Hijaiyah," *J. Sist. Info. Bisnis*, vol. 13, no. 1, 2023, <https://doi.org/10.21456/vol13iss1pp52-59>.
- [8] D. Iskandar Mulyana, M. Faizal Lazuardi, and M. Betty Yel, "Deteksi Bahasa Isyarat Dalam Pengenalan Huruf Hijaiyah Dengan Metode YOLOV5," *J. Tek. Elektro dan Komputasi*, vol. 4, 2022, <https://doi.org/10.32528/elkom.v4i2.8145>.

- [9] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, <https://doi.org/10.1186/s40537-019-0197-0>.
- [10] Q. Jiang, Y. Gu, C. Li, R. Cong, and F. Shao, "Underwater image enhancement quality evaluation: Benchmark dataset and objective metric," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 32, no. 9, pp. 5959–5974, 2022, <https://doi.org/10.1109/TCSVT.2022.3164918>.
- [11] N. Marastoni, R. Giacobazzi, and M. Dalla Preda, "Data augmentation and transfer learning to classify malware images in a deep learning context," *J. Comput. Virol. Hacking Tech.*, vol. 17, no. 4, 2021, <https://doi.org/10.1007/s11416-021-00381-3>.
- [12] M. Hossain and H. Chen, "Application of Machine Learning on Software Quality Assurance and Testing: A Chronological Survey," *Int. J. Comput. their Appl.*, vol. 29, no. 3, 2022, <https://doi.org/10.29007/5p9l>.
- [13] S. U. Rahman, F. Alam, N. Ahmad, and S. Arshad, "Image processing based system for the detection, identification and treatment of tomato leaf diseases," *Multimed. Tools Appl.*, vol. 82, no. 6, pp. 9431–9445, 2023, <https://doi.org/10.1007/s11042-022-13715-0>.
- [14] A. S. Anas and A. A. Rizal, "Deteksi Tepi dalam Pengolahan Citra Digital," *Semin. Nas. TIK dan Ilmu Sos*, vol. 2, pp. 1–6, 2017.
- [15] E. Alfariza, D. A. C. Tue, A. S. Anas, M. Tajuddin, and A. Adil, "Klasifikasi Aksara Sasak Menggunakan Convolutional Neural Networks (CNN)," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 6, no. 3, pp. 346–353, Nov. 2024, <https://doi.org/10.35746/jtim.v6i3.623>.
- [16] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Glob. Transitions Proc.*, vol. 3, no. 1, 2022, <https://doi.org/10.1016/j.gltp.2022.04.020>.