

Convolutional Neural Network (CNN) Optimization with Hyperparameter Tuning for Indonesian Language Sign System (SIBI) Recognition

Received:
21 January 2018
Accepted:
21 January 2024
Published:
1 February 2024

1^{*}Hartini Damanik, 2Suci Syahfitri, 3Fauziah Dea Irwanda
^{1,2,3}Sistem Informasi, STIKOM Tunas Bangsa Pematangsiantar
E-mail: ¹hartinidamanik12@gmail.com, ²sucisafitri012@gmail.com,
³fauziahdeairwanda06@gmail.com

*Corresponding Author

Abstract— Berkomunikasi dengan penyandang tunarungu sering kali menjadi kendala karena kurangnya pemahaman masyarakat terhadap bahasa isyarat, khususnya Sistem Isyarat Bahasa Indonesia (SIBI). Penelitian berbasis deep learning memberikan peluang baru untuk menjembatani hambatan ini melalui sistem pengenalan bahasa isyarat. Penelitian ini bertujuan untuk meningkatkan akurasi pengenalan alfabet SIBI menggunakan model Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 yang dioptimalkan melalui penyetelan hyperparameter menggunakan konsep teknik riset operasi. Dua model di uji dengan kombinasi hyperparameter yaitu untuk model awal dropout 0.4, batch size 32, jumlah epoch 20 dan augmentasi aktif, selanjutnya untuk model yang dioptimasikan dropout 0.5, batch size 16, jumlah epoch 15 tanpa augmentasi dan early stopping. Hasil menunjukkan bahwa kombinasi terbaik yaitu model dengan dropout 0.5, batch size 16, dan epoch 15 dengan kemampuan meningkatkan akurasi validasi model CNN dari 96,88% menjadi 97.44% dengan waktu 4090 detik, yang mana ini lebih efisien dari model awal yaitu 5380 detik. Penelitian ini berhasil menunjukkan efektivitas pendekatan teknik riset operasi dalam mengoptimalkan kinerja CNN untuk pengenalan alfabet SIBI. Hasil ini membuka peluang untuk pengembangan lebih lanjut dalam pengenalan bahasa isyarat berbasis deep learning. Studi lanjutan dapat difokuskan pada pengenalan kata atau kalimat SIBI secara real-time.

Keywords— Sistem Isyarat Bahasa Indonesia; Optimasi; Convolutional Neural Network; penyetelan hyperparameter; Teknik Riset Operasi; pengenalan citra; Deep Learning)

This is an open access article under the CC BY-SA License.



Corresponding Author:

Author [Sucipto],
Department [Sistem Informasi],
Institution [Universitas Nusantara PGRI Kediri],
Email [sucipto@unpkediri.ac.id]
Orchid ID: <http://orcid.org/0000-0000-0000-0000>
Handphone: 08xxx [for editor only, not published]



I. INTRODUCTION

Sistem Isyarat Bahasa Indonesia (SIBI) merupakan salah satu sarana komunikasi visual bagi penyandang disabilitas tunarungu di Indonesia[1], [2]. Sayangnya, implementasi pengenalan secara digital SIBI berbasis citra masih tergolong jarang ditemui[3], [4].

Teknologi pengenalan citra berbasis kecerdasan buatan, khususnya Deep Learning Convolutional Neural Network (CNN) khususnya pada arsitektur MobileNetV2, telah menunjukkan performa tinggi dalam klasifikasi visual, termasuk dalam pengenalan bahasa isyarat [5], [6]. Meskipun demikian, kinerja CNN sangat bergantung pada penyetelan hyperparameter seperti dropout, batch size, dan jumlah epoch [7], [8]. Penyetelan hyperparameter yang tidak tepat dapat menyebabkan model CNN kurang optimal seperti akurasi rendah, waktu pelatihan yang lama, hingga overfitting [9], [10].

Beberapa penelitian sebelumnya telah menunjukkan efektivitas penyetelan hyperparameter secara manual maupun otomatis, namun khusus untuk pengenalan alfabet SIBI masih belum banyak di eksplorasi[11]. Inilah celah penelitian yang ingin penulis jawab. Dalam penelitian ini, penulis mengusulkan pendekatan berbasis Teknik Riset Operasi dengan merumuskan fungsi objektif yang mempertimbangkan akurasi, loss dan waktu pelatihan, sebagai metode untuk mencari kombinasi hyperparameter terbaik dalam optimasi CNN untuk pengenalan alfabet SIBI.

Tujuan dari penelitian ini adalah untuk mengevaluasi dampak kombinasi hyperparameter terhadap performa CNN dalam klasifikasi isyarat sib, juga menerapkan prinsip teknik riset operasi dalam proses optimasi model CNN berbasis MobileNetV2 [12], [13], [14].

II. RESEARCH METHOD

Untuk mengembangkan model klasifikasi alfabet SIBI, penelitian ini menggunakan Convolutional Neural Network (CNN) dengan pendekatan transfer learning arsitektur MobileNetV2 yang dioptimalkan dengan penyetelan hyperparameter [15], [16], [17]. Metodologi penelitian terdiri dari lima tahap utama yaitu penentuan dataset, perancangan arsitektur CNN, formulasi masalah optimasi, implementasi teknik riset operasi (TRO), dan evaluasi performa model.



Gambar 1. Alur Metodologi Penelitian

A. Dataset

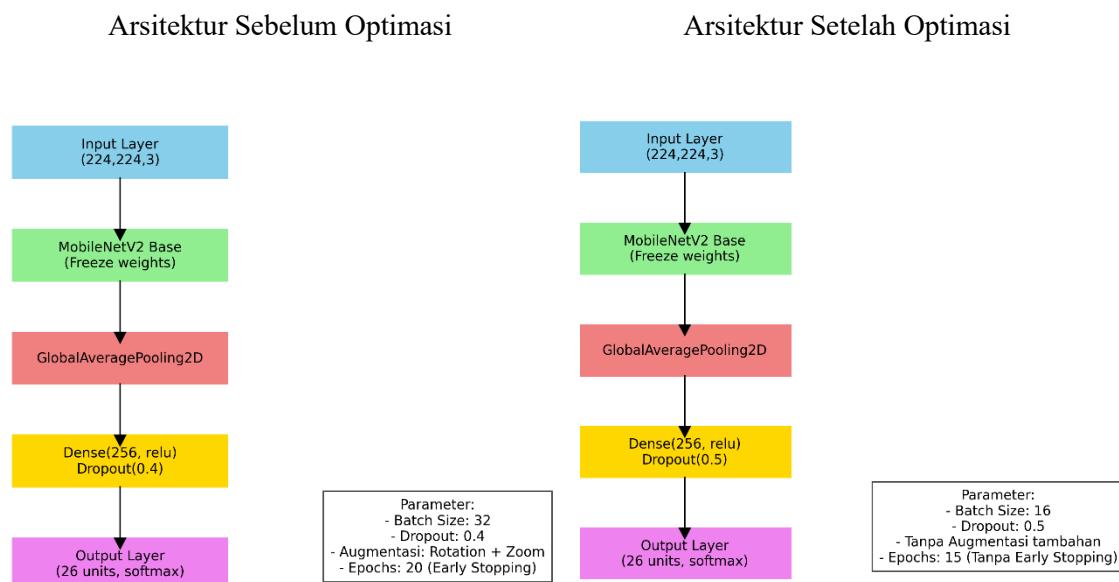
Dataset utama yang digunakan berasal dari *Combined SIBI Dataset* yang tersedia secara publik di Kaggle. Dataset ini berjumlah 2363 data terdiri dari 26 kelas huruf alfabet SIBI dalam format gambar. Untuk meningkatkan kemampuan generalisasi model, peneliti menambahkan *gambar mandiri* masing-masing 100 dari 26 kelas yang diambil oleh tiga individu berbeda. Pengambilan dilakukan dengan berbagai kondisi pencahayaan, latar belakang, tangan, dan perangkat kamera smartphone. Kemudian gambar pada setiap kelas diatur datanya agar setara, setelah itu dikonversi menjadi resolusi 224×224 piksel. Data akhir yang digunakan sebanyak 4.112 citra gambar yang mana data train sebanyak 3770 dan data test sebanyak 286.



Gambar 2. Sample Citra Huruf E

B. CNN Architecture

Model CNN dirancang dan dilatih menggunakan arsitektur MobileNetV2 (tanpa top layer) di software visual studio code dengan bahasa python[18], [19]. Arsitektur sebelum dan setelah optimasi dapat dilihat pada gambar berikut:



Gambar 3. Arsitektur CNN

C. Optimization Formulation

1. Fungsi Objektif

Fungsi objektif diformulasikan sebagai berikut:

$$\text{Maksimalkan } f(x) = \text{Accuracy}_{val}(x), \text{ Minimalkan } g(x) = \text{Loss}_{val}(x) + \alpha \cdot \text{WaktuPelatihan}(x)$$

Dimana α adalah bobot penyesuaian untuk mempertimbangkan efisiensi waktu.

2. Variabel Keputusan

- $x_1 : \text{dropout} \in \{0.4, 0.5\}$
- $x_2 : \text{batch size} \in \{32, 16\}$
- $x_3 : \text{jumlah epoch} \in \{20, 15\}$

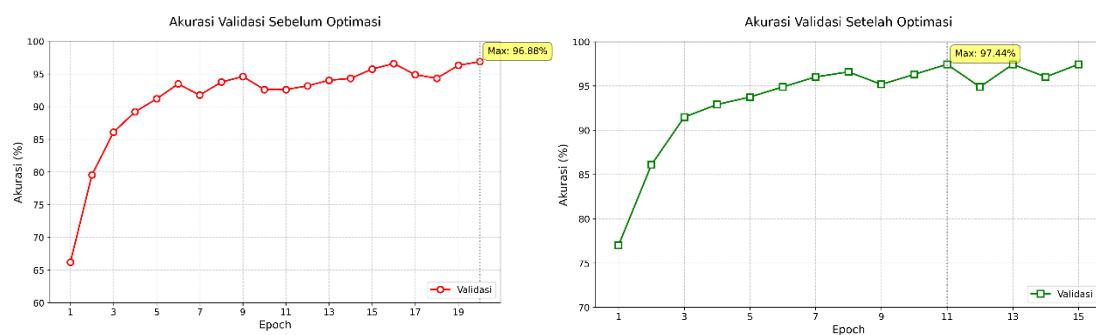
3. Batasan (*Constraint*)

- $x_3 \leq 20$
- Waktu pelatihan ≤ 6000 detik
- Overfitting $\leq 5\%$
- Akurasi minimal $\geq 95\%$

4. Evaluasi Model

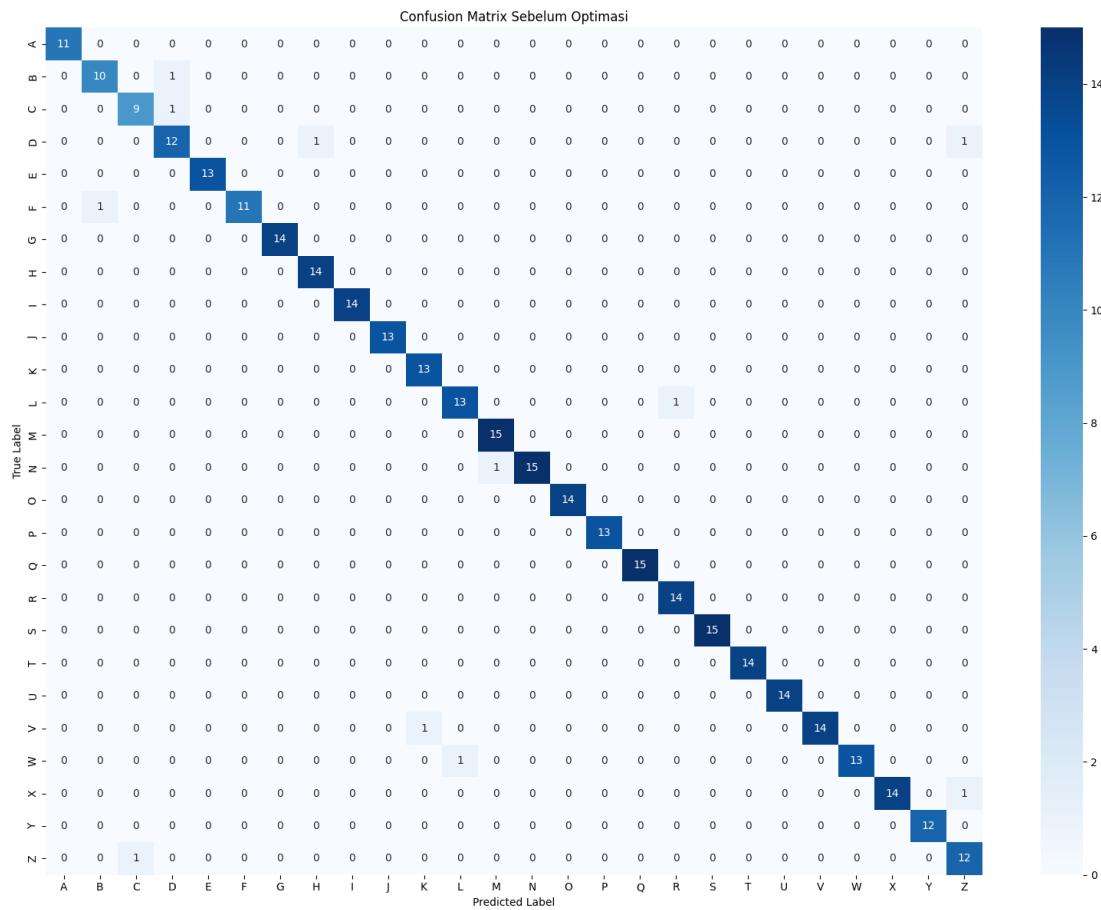
Berikut adalah visual dari penilaian terhadap dua model CNN sebagai perbandingan dalam penelitian ini:

a. Akurasi validasi

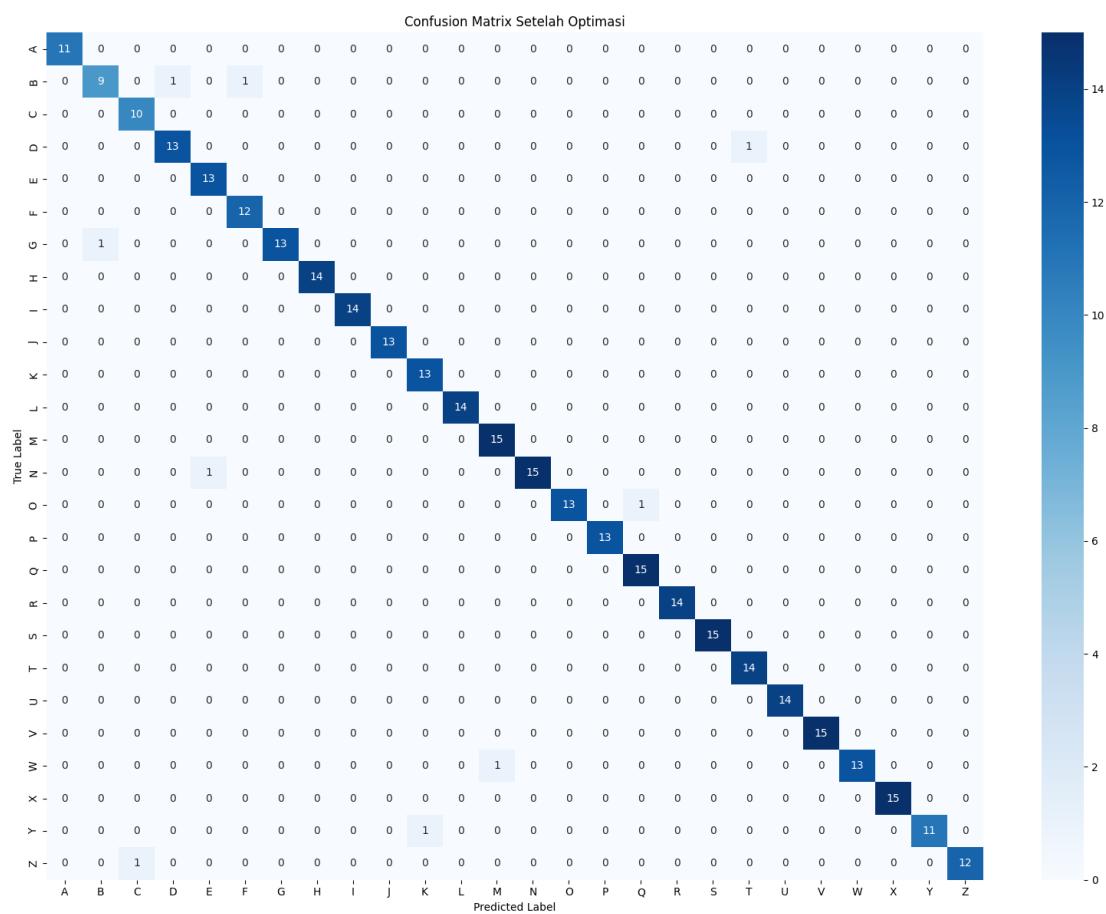


Gambar 4. Akurasi validasi

b. Confusion matrix

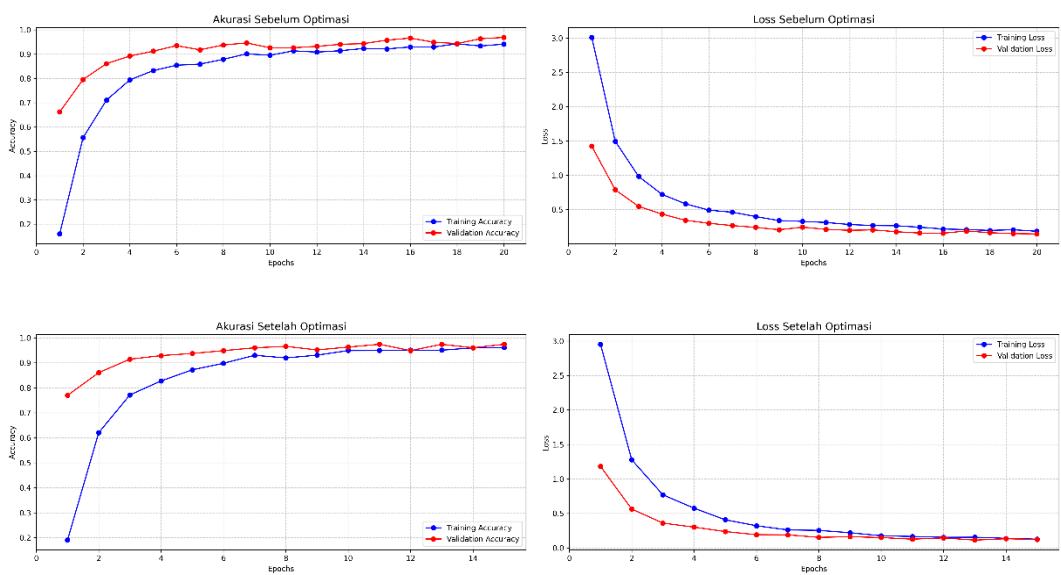


Gambar 5. Confusion Matrix Sebelum Optimasi



Gambar 6. Confusion Matrix Setelah Optimasi

c. Kurva akurasi dan loss



Gambar 7. Kurva Akurasi, Loss Sebelum dan Setelah Optimasi

III. RESULT AND DISCUSSION

A. Hasil Eksperimen

Table 1. Perbandingan Hasil Konfigurasi

Konfigurasi	Dropout	Batch Size	Epoch	Akurasi Validasi	Loss Validasi	Waktu Pelatihan
Sebelum	0.4	32	20	96.88%	0.1462	5380 detik
Setelah	0.5	16	15	97.44%	0.1217	4090 detik

Dari hasil konfigurasi kedua model dapat kita lihat jika model sebelum optimasi yaitu dengan dropout 0.4, batch size 32, dan epoch 20 dengan early stopping mendapatkan akurasi validasi yang sudah baik yaitu 96.88% serta waktu pelatihan 5380 detik. Namun, setelah di optimasi dengan penyetelan hyperparameter yaitu dropout 0.5, batch size 16 dan epoch 15 model mampu mengalami peningkatatan akurasi menjadi 97.44% dengan waktu yang lebih cepat yaitu 4090 detik. Maka optimasi yang dilakukan dapat menjadi solusi yang lebih efisien. Hal ini sesuai dengan fungsi objektif dalam teknik riset operasi yang mempertimbangkan baik efektivitas seperti akurasi tinggi maupun efisiensi seperti adanya waktu pelatihan yang lebih singkat.

B. Analisis Efisiensi Sistem

Jika ingin akurasi yang lebih tinggi maka model konfigurasi setelah dioptimasi sudah lebih unggul namun, jika waktu pelatihan juga dianggap penting maka model setelah optimasi ini menjadi solusi dua dimensi sekaligus yaitu akurasi dan waktu.

IV. CONCLUSION

Berdasarkan hasil penelitian ini, Optimasi pada model CNN arsitektur MobileNetV2 menggunakan penyetelan hyperparameter dengan penerapan pendekatan teknik riset operasi dalam mengenali bahasa isyarat SIBI berhasil dilakukan atau dalam arti, tujuan penelitian ini telah tercapai. Konfigurasi dengan penyetelan dropout 0.5, batch size 16, dan epoch 15 terbukti unggul mencapai akurasi 97.44% dari yang sebelumnya tanpa penyetelan hyperparameter yaitu dengan akurasi 96.88%. Selanjutnya efisiensi waktu pelatihan juga mengalami perubahan yaitu menjadi 4090 detik dari yang sebelumnya 5380 detik,. Penelitian ini memberi bukti bahwa pendekatan TRO dapat membantu mengurangi waktu penelitian serta menghasilkan solusi optimal untuk pengembangan model deep learning dalam klasifikasi gambar, meskipun penelitian ini masih menggunakan pendekatan teknik riset operasi yang terbilang sederhana yaitu hanya merumuskan fungsi objektif, variabel keputusan dan batasan (constraint). Untuk hasil yang lebih baik penulis

menyarankan penelitian lanjutan dengan menggunakan algoritma teknik riset operasi metaheuristik seperti Particle Swarm Optimization (PSO) dan Genetic Algorithm (GA).

Author Contributions:

Hartini Damanik was responsible for the conceptualization, code implementation, methodology, data, and served as the main contributor to the original draft, review and editing, as well as supervision of the research. **Suci Syahfitri** contributed to the methodology, investigation, data, review & co-wrote the original draft. **Fauziah dea irwanda** supported the investigation, data and participated in the review of the manuscript.

All authors have read and agreed to the published version of the manuscript.

Funding: Penelitian ini tidak menerima pendanaan dari lembaga manapun.

Acknowledgments: Terimakasih kepada penyedia dataset, dosen pengampu matakuliah Teknik Riset Operasi dan pada diri yang sudah berusaha bekerja dengan baik dalam proses pembuatan penelitian ini.

Conflicts of Interest: para penulis menyatakan memiliki konflik kepentingan yaitu pengembangan tulisan serta memenuhi tugas mata kuliah teknik riset operasi.

Data Availability: Model dan label map tersedia atas permintaan kepada penulis korespondensi.

Informed Consent: Subjek manusia yang terlibat secara langsung dalam penelitian ini yaitu para penulis yang menjadi penyalur sebagian dataset.

Animal Subjects: Subjek hewan tidak dilibatkan dalam penelitian ini.

ORCID: – this statement is mandatory

Hartini Damanik: <http://orcid.org/0000-0000-0000-0000>

Suci Syahfitri: <http://orcid.org/0000-0000-0000-0000>

Fauziah Dea Irwanda: <http://orcid.org/0000-0000-0000-0000>

REFERENCES

- [1] I. D. M. B. A. Darmawan, Linawati, G. Sukadarmika, N. M. A. E. D. Wirastuti, and R. Pulungan, “Indonesian sign language system (SIBI) dataset: Sentences enhanced by diverse facial expressions for total communication,” *Data Brief*, vol. 60, p. 111642, Jun. 2025, doi: 10.1016/J.DIB.2025.111642.
- [2] S. Syamsuddin, T. Pristiwaluyo, W. A Saleh, and Z. Zulfitrah, “Development of Indonesian Sign Language System (SIBI) Dictionary Application for Students with Special Needs,” *AL-ISHLAH: Jurnal Pendidikan*, vol. 15, no. 3, 2023, doi: 10.35445/alishlah.v15i3.2869.
- [3] B. Krismono Triwijoyo, L. Yuda Rahmani Karnaen, and A. Adil, “Deep Learning Approach For Sign Language Recognition,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, vol. 9, no. 1, 2023.
- [4] Y. Cnn ... | Brianorman and D. Utami, “Comparative Analysis of CNN Architectures for SIBI Image Classification,” 2024. [Online]. Available: <https://bit.ly/3trwIIH>
- [5] R. Gaikwad and L. Admuthe, “MULTI-USER REAL-TIME SIGN LANGUAGE RECOGNITION OF WORDS USING TRANSFER LEARNING OF DEEP LEARNING NEURAL NETWORKS,” *J Theor Appl Inf Technol*, vol. 101, no. 16, 2023.

- [6] A. Hadhiwibowo, S. R. Asri, and R. A. Dinata, "Penerapan Convolutional Neural Network dengan Arsitektur Mobilenetv2 Pada Aplikasi Penerjemah dan Pembelajaran Bahasa Isyarat," *TIN: Terapan Informatika Nusantara*, vol. 4, no. 8, pp. 518–523, Jan. 2024, doi: 10.47065/tin.v4i8.4879.
- [7] A. A. Maulani, S. Winarno, J. Zeniarja, R. T. E. Putri, and A. N. Cahyani, "Comparison of Hyperparameter Optimization Techniques in Hybrid CNN-LSTM Model for Heart Disease Classification," *Sinkron*, vol. 9, no. 1, 2024, doi: 10.33395/sinkron.v9i1.13219.
- [8] E. H. Abdulsaed, M. Alabbas, and R. S. Khudeyer, "Hyperparameter Optimization for Convolutional Neural Networks using the Salp Swarm Algorithm," *Informatica (Slovenia)*, vol. 47, no. 9, 2023, doi: 10.31449/inf.v47i9.5148.
- [9] M. A. K. Raiaan *et al.*, "A systematic review of hyperparameter optimization techniques in Convolutional Neural Networks," Jun. 01, 2024, Elsevier Inc. doi: 10.1016/j.dajour.2024.100470.
- [10] M. Adraoui *et al.*, "A novel three-phase expansion algorithm for uncovering communities in social networks using local influence and similarity in embedding space," *Decision Analytics Journal*, vol. 11, Jun. 2024, doi: 10.1016/j.dajour.2024.100472.
- [11] A. Josef and G. P. Kusuma, "Alphabet Recognition in Sign Language Using Deep Learning Algorithm with Bayesian Optimization," *Revue d'Intelligence Artificielle*, vol. 38, no. 3, pp. 929–938, Jun. 2024, doi: 10.18280/ria.380319.
- [12] I. Fawwaz, Y. Yennimar, N. P. Dharsinni, and B. A. Wijaya, "The Optimization of CNN Algorithm Using Transfer Learning for Marine Fauna Classification," *sinkron*, vol. 8, no. 4, pp. 2236–2245, Oct. 2023, doi: 10.33395/sinkron.v8i4.12893.
- [13] D. F. Kuncoro, A. Wirasto, and D. N. Triwibowo, "METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi KLASIFIKASI JENIS SAMPAH BERBASIS CONVOLUTIONAL NEURAL NETWORK DENGAN OPTIMASI HYPERPARAMETER TUNING ARSITEKTUR MOBILENET," vol. 9, no. 1, 2025, doi: 10.46880/jmika.Vol9No1.pp130-144.
- [14] V. Ya. Chornenkyi and I. Ya. Kazymyra, "ML MODELS AND OPTIMIZATION STRATEGIES FOR ENHANCING THE PERFORMANCE OF CLASSIFICATION ON MOBILE DEVICES," *Ukrainian Journal of Information Technology*, vol. 6, no. 2, pp. 74–82, 2024, doi: 10.23939/ujit2024.02.074.
- [15] K. Y. Lum, Y. H. Goh, and Y. Bin Lee, "American sign language recognition based on MobileNetV2," *Advances in Science, Technology and Engineering Systems*, vol. 5, no. 6, 2020, doi: 10.25046/aj050657.
- [16] M. Wojciuk, Z. Swiderska-Chadaj, K. Siwek, and A. Gertych, "Improving classification accuracy of fine-tuned CNN models: Impact of hyperparameter optimization," *Heliyon*, vol. 10, no. 5, 2024, doi: 10.1016/j.heliyon.2024.e26586.
- [17] A. Cornacchia, G. Sviridov, P. Giaccone, and A. Bianco, "A traffic-aware perspective on network disaggregated sketches," in *2021 19th Mediterranean Communication and Computer Networking Conference, MedComNet 2021*, 2021. doi: 10.1109/MEDCOMNET52149.2021.9501234.
- [18] W. M. Pradnya Dhuhita, M. Y. Ubaid, and A. Baita, "MobileNet V2 Implementation in Skin Cancer Detection," *ILKOM Jurnal Ilmiah*, vol. 15, no. 3, 2023, doi: 10.33096/ilkom.v15i3.1702.498-506.
- [19] D. Ajeng Kristiyanti and T. M. Adilah, "Implementation Of Transfer Learning Mobilenetv2 Architecture For Identification Of Potato Leaf Disease," *J Theor Appl Inf Technol*, vol. 31, no. 16, 2023.
- [20] D. Antonov, E. Burovski, and L. Shchur, "Mean-field interactions in evolutionary spatial games," *Phys Rev Res*, vol. 3, no. 3, 2021, doi: 10.1103/PhysRevResearch.3.L032072.
- [21] H. Yang, W. Zhang, and W. Lam, "A Two-Stage Training Framework with Feature-Label Matching Mechanism for Learning from Label Proportions," in *Proceedings of Machine Learning Research*, 2021.
- [22] Z. Fan, B. Ghaddar, X. Wang, L. Xing, Y. Zhang, and Z. Zhou, "Artificial Intelligence for Operations Research: Revolutionizing the Operations Research Process," Mar. 2024, [Online]. Available: <http://arxiv.org/abs/2401.03244>
- [23] X. Yan, J. Wang, P. Zhao, Z. Shen, X. Li, and R. Zhang, "Design and Test of Contactless Overvoltage Sensor with Spherical Six-Electrode," *IEEE Trans Instrum Meas*, vol. 70, 2021, doi: 10.1109/TIM.2021.3073444.

- [24] M. Arthur Limantara and D. Tristianto, “SIBI Alphabet Detection System Based on Convolutional Neural Network (CNN) Method as Learning Media,” *Internet of Things and Artificial Intelligence Journal*, vol. 4, no. 1, pp. 143–161, Mar. 2024, doi: 10.31763/iota.v4i1.716.
- [25] M. A. R. Mahardika, N. Yudistira, and A. Ridok, “Sistem Rekognisi Citra Digital Bahasa Isyarat Menggunakan Convolutional Neural Network dan Spatial Transformer,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 7, 2023, doi: 10.25126/jtiik.1078098.
- [26] R. Mahendra and W. Putra, “Makalah IF4073 Interpretasi dan Pengolahan Citra, Semester I Tahun,” 2023. [Online]. Available: <https://www.kaggle.com/datasets/datamunge/sign->