



KLASIFIKASI JENIS TANAMAN REMPAH RHIZOMA ZINGIBERACEAE DENGAN METODE CNN DAN VGG 19

**Haris Abdillah Firmansyah¹⁾, Muchamad Kurniawan^{2)*}, Citra Nurina Prabiantissa³⁾,
Syahri Muharom⁴⁾**

¹²³⁾Program Studi Teknik Informatika, Fakultas Teknik Elektro dan Teknologi Informasi,
Institut Teknologi Adhi Tama Surabaya, Indonesia.

⁴⁾Program Studi Teknik Elektro, Fakultas Teknik Elektro dan Teknologi Informasi,
Institut Teknologi Adhi Tama Surabaya, Indonesia.

e-mail: harisabdillahf.on1@gmail.com¹⁾, muchamad.kurniawan@itats.ac.id^{2)*},
citranurina@itats.ac.id³⁾, syahrimuharom@itats.ac.id⁴⁾

Abstract

[Classification Of Rhizoma Zingiberaceae Spice Plant Types Using CNN and VGG Methods 19] The need for identification of spice plant species is very important to achieve accuracy levels accurately and efficiently. Previous researchers have demonstrated the success of this CNN method in classifying various spice plant species. However, only three species of Zingiberaceae (also known as ginger) spice plants were studied in this research: ginger, turmeric, and galangal. There has not been much previous research on these plant species. To ensure label accuracy, this study compares the performance of two popular CNN optimizers, Adam and SGD. A dataset of spice plant images obtained from Internet websites was then diagnosed by experts. To prepare for training the CNN model with VGG19, the image data is pre-processed. The pre-trained VGG19 architecture is used as the basis for spice plant classification. The classification accuracy is used to evaluate the performance of the model. And the results of the study show that on the classification of spice plants the use of the pre-trained VGG19 architecture is used, providing research results that also show that the architectural CNN method successfully classifies Zingiberaceae spice plant species. Consistently, the use of Adam's optimizer resulted in higher accuracy than SGD. This suggests that Adam's optimizer may be more effective in optimizing VGG19 model parameters for spice plant classification.

Keywords: *Zingiberaceae; optimizer; Adam; SGD; VGG19.*

Abstrak

Kebutuhan untuk pengidentifikasian jenis tanaman rempah sangat penting untuk memperoleh tingkat akurasi secara akurat dan efisien. Peneliti sebelumnya telah menunjukkan keberhasilan metode CNN ini dalam klasifikasi berbagai spesies tanaman rempah. Namun, pada penelitian ini hanya mempelajari tiga jenis tanaman rempah *Zingiberaceae* (juga di kenal sebagai jahe-jahean): jahe, kunyit, dan lengkuas. Penelitian sebelumnya tentang jenis tanaman ini belum banyak dilakukan. Untuk memastikan akurasi label, penelitian ini membandingkan kinerja dua optimizer CNN yang populer, Adam dan SGD. Dataset gambar tanaman rempah yang diperoleh dari situs web internet kemudian di diagnosis oleh ahli. Untuk mempersiapkan pelatihan model CNN dengan VGG19, data gambar akan melalui proses *pre-processing*. *Arsitektur* VGG19 yang telah dilatih sebelumnya akan digunakan sebagai dasar untuk klasifikasi tanaman rempah. Akurasi klasifikasi digunakan untuk menilai kinerja model. Dan temuan studi menunjukkan bahwa pada klasifikasi tanaman rempah penggunaan arsitektur VGG19 yang telah terlatih sebelumnya digunakan memberikan hasil penelitian yang juga menunjukkan bahwa metode CNN arsitektural berhasil mengklasifikasi jenis tanaman rempah *Zingiberaceae*. Secara konsisten, penggunaan optimizer Adam menghasilkan akurasi yang lebih tinggi dibandingkan SGD. Ini menunjukkan bahwa *optimizer* Adam mungkin lebih efektif dalam mengoptimalkan parameter model VGG19 untuk klasifikasi tanaman rempah.

Kata Kunci: *Zingiberaceae; optimizer; Adam; SGD; VGG19.*

1. Pendahuluan

Negara Indonesia merupakan sebuah negara kepulauan yang memiliki wilayah yang sangat luas, mencapai 1,9 juta km² yang juga terdiri dari 17.000 pulau [1]. Selain memiliki wilayah yang luas, Indonesia juga memiliki letak geografis yang sangat strategis. Kepulauan Indonesia berada di antara dua benua, yaitu Benua Asia dan Benua Australia, serta dua samudra, yaitu Samudra Hindia dan Samudra Pasifik. Letak geografis inilah yang menyebabkan Indonesia memiliki iklim tropis yang unik [2]. Dengan suhu yang stabil dan curah hujan yang tinggi akan membantu proses fotosintesis dan pertumbuhan untuk tumbuhan atau tanaman tersebut. Hal itulah yang menjadi salah satu faktor keanekaragaman hayati di Indonesia [3].

Selain letak geografis yang strategis, keluasan suatu wilayah juga menjadi salah satu faktor mengapa Indonesia memiliki keanekaragaman hayati. Sebagaimana yang dijelaskan oleh Dr. Rudi Heryanto, selaku peneliti Pusat Studi Biofarmaka Tropika (TropBRC) dalam sebuah webinar yang diadakan TropBRC pada tahun 2020, “Indonesia memiliki 143 juta hektar hutan tropis yang menjadi habitat bagi 80% tanaman herba di dunia” [4].

Keanekaragaman hayati ini telah menjadi bagian integral dari budaya Indonesia, terutama dalam penggunaan rempah-rempahnya. Pada masa penjajahan, Indonesia ini terkenal kaya akan rempahnya, oleh karena itu kolonial Belanda ingin menguasai perdagangan rempah-rempah dari Indonesia ke Eropa. Rempah-rempah sendiri adalah sebuah bagian tumbuh-tumbuhan yang memiliki aroma atau rasa yang kuat. Salah satu famili dari rempah-rempah yang terkenal di Indonesia adalah *Zingiberaceae*, yang di Indonesia lebih dikenal sebagai tanaman jahe dan sejenisnya. *Zingiberaceae* telah dimanfaatkan oleh masyarakat Indonesia sebagai bumbu-bumbu dapur, obat tradisional atau jamu, bahan kosmetik, dan sebagainya.

Banyaknya jenis rempah-rempah yang ada di Indonesia membuat sebagian masyarakat susah untuk mengenali *Zingiberaceae* secara spesifik. Penelitian klasifikasi jenis-jenis *Zingiberaceae* di Indonesia menghadapi beberapa permasalahan yang cukup kompleks, salah satunya adalah keanekaragaman spesies yang tinggi. Di Indonesia kekayaan *Zingiberaceae* sangat luar biasa, dengan lebih dari 1300 spesies. Sayangnya penelitian taksonomi *Zingiberaceae* di Indonesia masih tergolong minim [5]. Hal ini menyebabkan keterbatasan data yang lengkap terkait ciri-ciri morfologi, anatomi, molekuler, serta distribusi geografis, habitat, dan ekologi masing-masing spesies *Zingiberaceae* di Indonesia, sehingga menyulitkan proses klasifikasi [6].

Dalam menanggapi tantangan klasifikasi *Zingiberaceae* di Indonesia, langkah-langkah yang solutif perlahan-lahan telah mulai diimplementasikan. Beberapa ahli botani serta peneliti telah memulai upaya untuk mengisi kesenjangan-kesenjangan tentang famili *Zingiberaceae* melalui penelitian taksonomi yang lebih mendalam. Pendekatan ini mencakup ciri-ciri morfologi, anatomi, dan molekuler dari berbagai spesies *Zingiberaceae*. Sebagai contoh penelitian yang dilakukan oleh Kessler dan Haynes (2019) dalam penelitiannya, mereka menyoroti pentingnya berkolaborasi lintas disiplin ilmu dalam menangani tantangan taksonomi dan konservasi tumbuhan [7]. Secara khusus dalam lingkup famili *Zingiberaceae* di Indonesia. Dengan kolaborasi yang akan memperluas pemahaman tentang *Zingiberaceae* diharapkan bahwa proses klasifikasi dapat ditingkatkan secara signifikan dan identifikasi spesies yang lebih akurat dan efisien.

Selain upaya-upaya yang telah disebutkan, terdapat solusi yang dapat diterapkan untuk mengatasi permasalahan yaitu dengan pengklasifikasian. Dengan mengklasifikasi kita dapat membedakan antara spesies *Zingiberaceae* yang berbeda, dan membantu kita untuk membuat informasi-informasi tersebut dengan rapi dan juga sistematis. Metode klasifikasi yang akan diimplementasikan pada penelitian ini adalah CNN (*Convolution Neural Network*), salah satu algoritma teknologi dari *Deep Learning*. CNN menunjukkan performa luar biasa dalam klasifikasi gambar. Pada penelitian yang dilakukan oleh Utami et al. (2022), peneliti menggunakan CNN dengan model arsitektur *InceptionV3* dan *optimizer* ‘adam’ untuk mengklasifikasi 20 spesies *Zingiberaceae* di Jawa Barat dengan tingkat akurasi mencapai 98,2% [8]. Penelitian lain yang dilakukan oleh Putri et al. (2023) juga menggunakan CNN dengan model arsitektur *InceptionV3* dan *optimizer* ‘adam’ untuk mengklasifikasikan 50 spesies *Zingiberaceae* di Indonesia dan memperoleh akurasi mencapai 95,7% [9]. Dan penelitian lain juga telah dilakukan oleh Wulandari et al. (2020) yang mengimplementasikan metode CNN tanpa model arsitektur dan *optimizer* ‘SGD’ untuk mengklasifikasi bumbu dapur dan rempah, peneliti mendapatkan akurasi sebesar 88,89% dalam mengklasifikasikan tiga jenis bumbu dapur dan rempah yaitu ginseng, jahe, dan lengkuas [10].

Berdasarkan dari penelitian-penelitian sebelumnya, klasifikasi untuk rempah-rempah telah banyak dilakukan. Untuk melengkapi penelitian-penelitian sebelumnya, penelitian ini akan berfokus pada perbandingan antara penggunaan *optimizer* ‘adam’ dan ‘SGD’ serta mempertimbangkan penggunaan model arsitektur yang berbeda yakni VGG19. Dengan demikian diharapkan penelitian ini akan memberikan wawasan yang lebih mendalam tentang kinerja dan kecocokan antara berbagai kombinasi model arsitektur dan *optimizer* dalam klasifikasi jenis *Zingiberaceae*.

2. Metode

Berdasarkan uraian di atas, maka penelitian ini akan mengarah pada penerapan metode *Convolutional Neural Network* (CNN) dengan model arsitektur VGG19. Penggunaan model arsitektur VGG19 diharapkan dapat menghasilkan performa yang lebih baik dalam klasifikasi rempah-rempah. Klasifikasi ini hanya akan berfokus pada tiga jenis rempah yakni jahe, kunyit, dan lengkuas. Guna memudahkan masyarakat yang masih kurang dapat membedakan rempah-rempah yang ada.

A. Pengumpulan Dataset

Dataset yang digunakan diambil dari laman *website* kaggle.com berupa gambar-gambar jahe, kunyit, dan lengkuas. Dataset ini berjumlah 300 dengan masing-masing jenis rempah adalah 100 gambar. Dialokasikan sebanyak 80 gambar untuk data *train* dan sebanyak 20 gambar untuk data tes untuk masing-masing jenis rempah.



Gambar 1. Contoh dataset rempah dari *kaggle.com*

B. Preprocessing

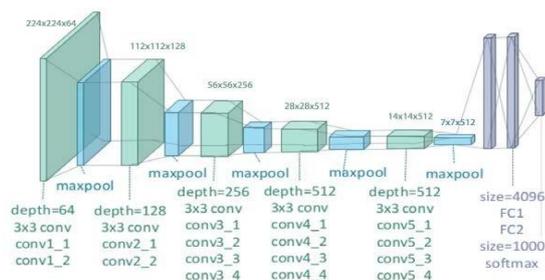
Preprocessing gambar dilakukan menggunakan library Image Data Generator yang digunakan. Ini adalah kelas keras yang digunakan untuk pipeline pada gambar untuk pembelajaran lebih lanjut. Image Data Generator juga dapat digunakan pada pra-processing data dan peningkatan data [15]. Gambar Data Generator memiliki banyak parameter, dan parameter yang digunakan dalam penelitian ini adalah "zoom_range=0,2". Setelah menerapkan parameter tersebut, penelitian akan dilakukan selanjutnya. Untuk pelatihan, parameter aliran adalah "target_size = (100,100)" dan "color_mode = "rgb".

C. Optimizer

Dalam penelitian ini penulis menggunakan dua jenis *optimizer* yang umum digunakan yaitu adam dan sgd. Karena adam salah satu *optimizer* yang paling populer dan efektif untuk melatih model CNN [11]. Sedangkan sgd dinilai dapat meningkatkan stabilitas training dan menghasilkan performa yang lebih baik pada tugas CNN[12]. Pemilihan kedua *optimizer* ini bertujuan untuk membandingkan, *optimizer* mana yang mendapatkan tingkat akurasi yang tinggi. *Optimizer* adam memiliki keunggulan keefisiensannya untuk dataset kecil sedangkan sgd lebih cocok untuk dataset yang lebih besar [13]. Dibalik itu semua baik *optimizer* adam maupun sgd, juga memiliki kelemahan, seperti pada penelitian yang dilakukan Zhang Zijun (2018), peneliti membeberkan tentang kelemahan Adam dan SGD. Salah satu kelemahan adam yaitu sensitif terhadap noise, hal ini dapat menyebabkan penurunan performa model. Sedangkan kelemahan sgd salah satunya adalah Konvergensi yang lambat [14].

D. Penggunaan Arsitektur

Penelitian ini menggunakan arsitektur VGG19. Salah satu model arsitektur dari metode CNN yang telah dibangun kemudian dilatih menggunakan data latih. Proses pelatihan dilakukan dengan meminimalkan fungsi *loss* menggunakan *optimizer* Adam dan *optimizer* SGD sebagai pembanding. VGG19 adalah salah satu model yang terkenal dan memiliki kedalaman yang cukup besar [16]. Arsitektur ini terkenal karena memiliki tingkat efisien yang cukup untuk mengekstraksi fitur dari gambar, dan pendekatan ini telah berhasil diterapkan dalam klasifikasi.

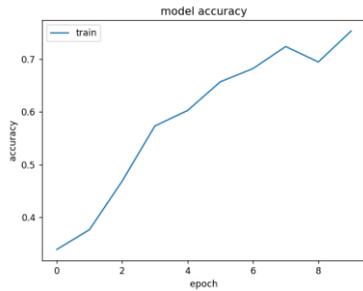


Gambar 2. Model arsitektur VGG19

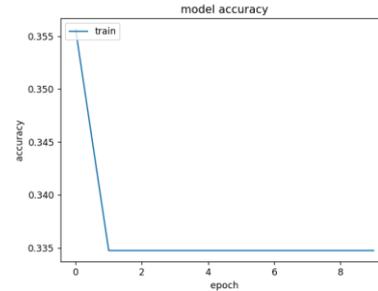
3. Hasil dan Pembahasan

Dari beberapa kali percobaan dengan penyesuaian pada optimizer, epoch, dan penggunaan model arsitektur VGG19 dapat di lihat dari grafik dan tabel hasil berikut.

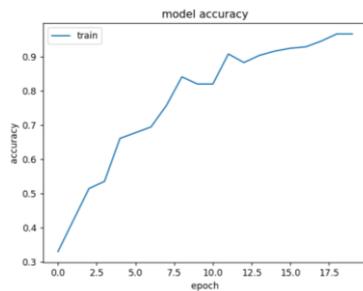
Berikut adalah grafik akurasi tanpa menggunakan model arsitektur:



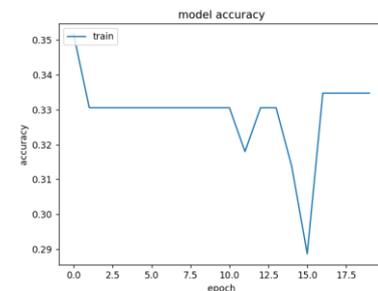
Gambar 3. Grafik akurasi - adam epoch 10



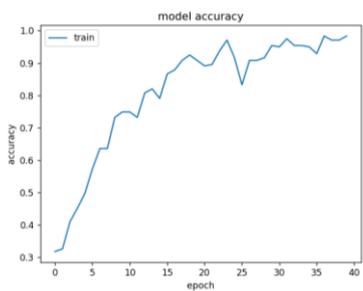
Gambar 4. Grafik akurasi - sgd epoch 10



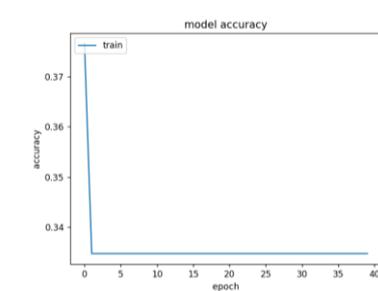
Gambar 5. Grafik akurasi - adam epoch 20



Gambar 6. Grafik akurasi - sgd epoch 20



Gambar 7. Grafik akurasi - adam epoch 40



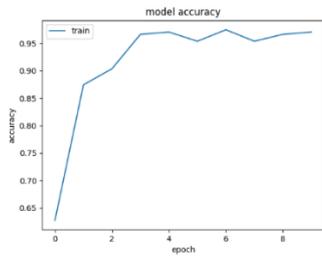
Gambar 9. Grafik akurasi - sgd epoch 40

Dari grafik-grafik percobaan diatas, tanpa menggunakan arsitektur *optimizer* adam memiliki tingkat akurasi yang lebih baik daripada sgd. Grafik pada *optimizer* adam memiliki grafik yang relatif naik sedangkan sgd memiliki grafik yang turun kebawah. Untuk selsngkapnya dapat dilihat pada tabel hasil berikut.

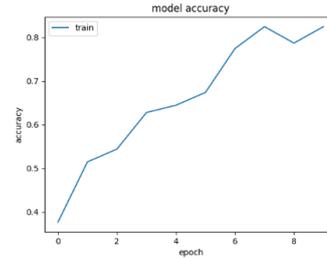
Tabel 1. Hasil percobaan tanpa menggunakan arsitektur

Optimizer	epoch	Hasil Akurasi	
		Training	Testing
adam	10	0.694	0.55
	20	0.882	0.7
	40	0.974	0.75
sgd	10	0.334	0.33
	20	0.334	0.333
	40	0.334	0.333

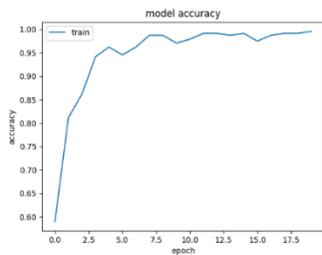
Sedangkan untuk grafik akurasi dengan menggunakan arsitektur:



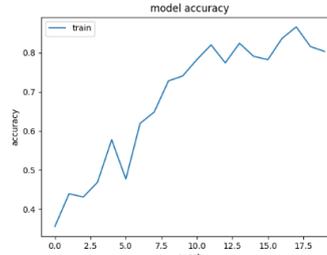
Gambar 10. Grafik akurasi - adam epoch 10



Gambar 11. Grafik akurasi - sgd epoch 10



Gambar 12. Grafik akurasi - adam epoch 20

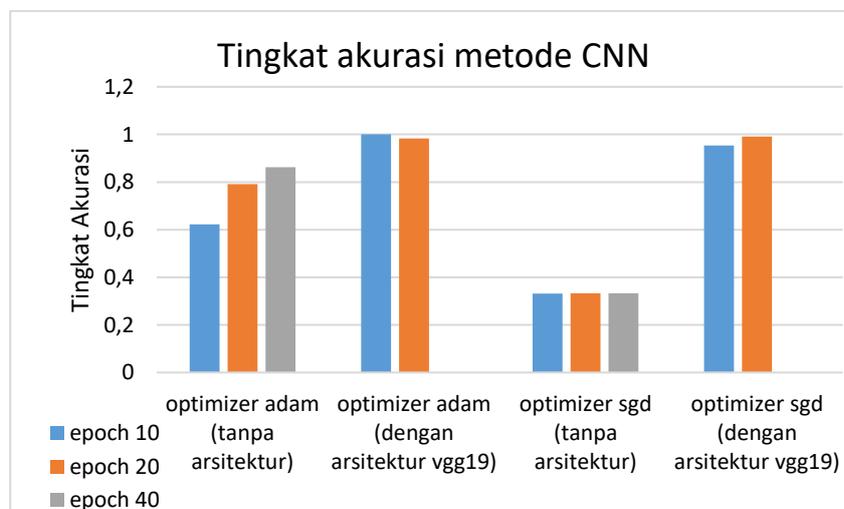


Gambar 13. Grafik akurasi - adam epoch 20

Dari grafik-grafik percobaan diatas, dengan menggunakan model arsitektur tingkat akurasi dari *optimizer* sgd sangat berbeda dengan tanpa menggunakan model. *Optimizer* adam mengalami sedikit kenaikan dan juga lebih stabil. Untuk lebih lengkapnya dapat dilihat dari tabel hasil akurasi berikut.

Tabel 2. Hasil percobaan menggunakan model arsitektur

Optimizer	epoch	Hasil Akurasi	
		Training	Testing
adam	10	1.0	1.0
	20	1.0	0.966
sgd	10	0.974	0.933
	20	1.0	0.983



Gambar 14. Tingkat Akurasi metode CNN

4. Kesimpulan

Dari hasil yang diperoleh pada penelitian ini adalah penggunaan metode CNN sangat direkomendasikan untuk klasifikasi sebuah gambar. Dan *optimizer* Adam menghasilkan tingkat akurasi yang lebih baik dibandingkan dengan *optimizer* SGD pada model tanpa arsitektur VGG19. Hal ini menunjukkan bahwa *optimizer* Adam lebih efektif dalam mengoptimalkan parameter model untuk mencapai hasil klasifikasi yang lebih akurat. Penerapan model arsitektur VGG19 secara signifikan meningkatkan performa klasifikasi, baik dengan *optimizer* Adam maupun SGD. Hal ini menunjukkan bahwa arsitektur VGG19 memiliki kemampuan yang lebih baik dalam mengekstraksi fitur dari gambar tanaman herba rimpang *Zingiberaceae* dibandingkan dengan model tanpa arsitektur. Kombinasi *optimizer* Adam dan model arsitektur VGG19 menghasilkan performa klasifikasi terbaik dengan tingkat akurasi mencapai 100% hanya dengan menggunakan *epoch* 10 dan 20. Hal ini menunjukkan bahwa kombinasi ini merupakan pilihan yang optimal untuk klasifikasi jenis tanaman herba rimpang *Zingiberaceae* menggunakan metode CNN. Dibalik tingkat akurasi yang tinggi, penggunaan model arsitektur ini juga sangat memberatkan bagi beberapa perangkat, ada beberapa perangkat yang tidak mampu untuk menjalankan program CNN dengan arsitektur ini. Ada perangkat yang prosesnya lama bahkan ada juga perangkat yang sampai berhenti ditengah jalannya proses.

Daftar Pustaka

- [1] Badan Pusat Statistik (BPS), “Statistik Indonesia-Statistical Yearbook of Indonesia 2023”.
- [2] Li J., “Geographic Distribution and Environmental Drivers of Global Amphibian Richness,” *Diversity and Distribution*, vol. 26, no. 7, hlm. 784–796, 2020.
- [3] Hariyadi H., “Biodiversity of Plants in Indonesia: Science and Conservation,” *Indonesian Journal of Conversation*, vol. 3, no. 2, hlm. 67–82, 2019.
- [4] FMIPA, “Sebanyak 80 Persen Tanaman Obat Dunia Ada di Indonesia,” *IPB University*, Bogor, 27 Juli 2020.
- [5] Syahril M., “Permasalahan klasifikasi *Zingiberaceae* di Indonesia: Sebuah tinjauan,” *Jurnal Biodiversitas*, vol. 21, no. 1, hlm. 1–10, 2020.
- [6] Ardiyanti M., Widodo E. S., dan Santosa E., “Integrating Taxonomy, Phylogeny, and Conservation of *Zingiberaceae* in Indonesia: A Case Study,” *Biodiversitas*, vol. 20, no. 6, hlm. 1688–1695, 2019.
- [7] Kessler P. W. F. B. dan Haynes E. R. S., “The Economic Botany of the *Zingiberaceae*,” *Economy Botany*, vol. 73, no. 4, hlm. 375–393, 2019.
- [8] Utami N. F., Putri D. W. A., dan Syahril M., “Classification of *Zingiberaceae* Species in West Java Using Convolutional Neural Network (CNN),” dalam *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, 2022, hlm. 012058.
- [9] Putri D. W. A., Syahril M., dan Utami N. F., “Classification of *Zingiberaceae* Species in Indonesia Using Convolutional Neural Network (CNN),” dalam *Journal of Physics*, IOP Publishing, 2023, hlm. 012053.
- [10] Wulandari C., Handayani D., dan Supriyadi S., “Klasifikasi Bumbu Dapur dan Rempah Berdasarkan Warna dan Tekstur Menggunakan Convolutional Neural Network (CNN),” *Jurnal Sains dan Teknologi Universitas Islam Indonesia*, vol. 21, no. 1, hlm. 78–85, 2020.
- [11] LeCun Y., Bengio Y., dan Hinton G., “Deep learning for computer vision: A survey,” *In arXiv preprint arXiv*, hlm. 14–15, 2015.
- [12] Lester Mackey, Volodymyr Mnih, dan Geoffrey Hinton, “On the Variance of Stochastic Gradient Descent,” *Journal of Machine Learning Research*, no. 1, hlm. 1–22, 2019.
- [13] Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun, “A Comparative Analysis of Optimization Algorithms for Deep Learning,” *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, vol. 37, no. 5, hlm. 1026–1044, 2016.

- [14] Z. Zhang, “Improved Adam Optimizer for Deep Neural Networks,” dalam *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*, IEEE, Jun 2018, hlm. 1–2. doi: 10.1109/IWQoS.2018.8624183.
- [15] F. Chollet, “Keras: The Python Deep Learning Library,” *Keras.Io*, 2015.
- [16] Verma V. K., Thakur A., dan Kumar M., “Sign Language Recognition Using Convolution Neural Networkd.,” *International Journal Computer Applications*, vol. 134, no. 14, hlm. 31–35, 2016.