

Convolutional Neural Network Untuk Perbandingan Optimizer Pada Citra Batang Pohon

Nur Zuzzaifa
Fakultas Sains dan Teknologi
Universitas Teknologi
Yogyakarta
Yogyakarta, Indonesia
nurzuzzaifa@gmail.com

Rianto Rianto
Fakultas Sains dan Teknologi
Universitas Teknologi
Yogyakarta
Yogyakarta, Indonesia
rianto@staff.uty.ac.id

Abstract—In the surrounding environment, there are various types of trees with different characteristics. One characteristic of a tree that is difficult to distinguish is its trunk. After researchers made observations, the trunks of Pine and Tabebuaya trees had the same characteristics, namely cracking. The problem of incorrectly identifying the characteristics of a tree's trunk can be overcome by classification. Deep Learning with the Convolutional Neural Network (CNN) algorithm is a method commonly used in image classification. The stages in this research include image data retrieval, data preprocessing, CNN architecture formation, model training, and model validation. Image retrieval was carried out directly by researchers, then the 1000 best images were selected. The image dataset is then divided into 75% training data and 25% validation data. Testing was carried out by comparing the Stochastic Gradient Descent (SGD) optimizer and the Adaptive Learning Rate Optimization Method (RMSprop) using epochs 10, 15, 20, 30, 50, and 80. The results showed that the SGD optimizer produced the highest accuracy compared to the RMSProp optimizer. The most optimal result when applying the SGD optimizer is 0.9360 with epochs 80, while for the RMSProp optimizer it is 0.9160 with epochs 20.

Keywords— CNN, Classification, RMSProp, SGD

I. PENDAHULUAN

Klasifikasi merupakan pengelompokan objek ke dalam kelas tertentu [1]. Ada berbagai macam jenis klasifikasi diantaranya adalah klasifikasi biner dan klasifikasi *multiclass*. Klasifikasi biner adalah proses memasukkan obyek ke dalam dua kelas yang sesuai, sementara klasifikasi *multiclass* adalah proses memasukkan obyek ke dalam banyak pilihan kelas lebih dari dua [2]. Proses klasifikasi dapat dilakukan untuk menangani data teks, numerik, ataupun citra.

Klasifikasi citra berarti, proses mengelompokkan citra kedalam beberapa kelas sehingga setiap kelas dapat menjelaskan karakter citra tersebut supaya dapat dikenali [3]. Dalam klasifikasi citra dapat memanfaatkan *machine learning* dan *deep learning*. *Machine learning* menjelaskan tentang kapasitas sistem untuk belajar dari spesifik masalah data latih untuk mengotomatisasi proses dari pembuatan model analitik dan menyelesaikan tugas terkait. *Deep learning* merupakan pengembangan konsep dari *machine learning* yang didasarkan pada *Artificial Neural Network* (ANN) [4]. Kemampuan *deep learning* visi computer sangat baik. Salah satu contoh kasusnya adalah klasifikasi objek pada citra [5].

Metode *deep learning* yang dikenal saat ini sangat dapat memberikan hasil yang paling signifikan dalam pengenalan citra adalah *Convolutional Neural Network* (CNN)[6]. Hal tersebut terjadi karena CNN terinspirasi dari jaringan syaraf manusia [7]. CNN dapat mengenali dan mendeteksi objek pada sebuah citra digital dengan baik[8]. Upaya untuk mendapatkan hasil kinerja yang lebih baik, dalam proses klasifikasi CNN dapat menggunakan metode optimizer. Metode optimizer merupakan suatu teknik pencarian yang digunakan untuk memperbaiki nilai bobot baik dengan cara mengurangi ataupun menambahkan dalam model

pengembangan ANN sehingga dapat menghasilkan bobot yang paling optimal [9]. Hal ini bertujuan untuk menurunkan nilai *loss* [10]. Beberapa optimizer yang sering digunakan contohnya *Stochastic Gradient Descent* (SGD) dan *Adaptive Learning Rate Optimization Method* (RMSprop).

Selain metode optimizer, penentuan jumlah epochs juga penting untuk mengoptimalkan hasil akurasi dari model klasifikasi. *Epochs* merupakan seluruh dataset yang telah melalui proses training model pada neural network sampai dikembalikan ke awal dalam satu putaran [11]. Tidak terdapat aturan pasti untuk menentukan jumlah *epochs* yang digunakan, untuk memudahkan pengujian dapat menggunakan kelipatan 5 atau 10.


Tahap pertama untuk melakukan klasifikasi citra tentu saja menentukan obyek. Di lingkungan sekitar, terdapat bermacam jenis pohon dengan karakteristik yang berbeda-beda. Perbedaannya dapat dilihat dari daun, buah, bunga, akar, atau batangnya. Bagian-bagian pohon tersebut dapat digunakan untuk pengklasifikasian citra menurut kemiripan karakteristiknya. Setelah melakukan pengamatan, terdapat kesamaan karakteristik batang pohon Pinus dan Tabebuaya. Keduanya memiliki batang yang pecah-pecah. *Pinus Merkusi* (pinus) termasuk dalam *famili Pinaceae* yang penyebaran alamnya sampai di selatan khatulistiwa. Bagian dari pohon pinus yang dapat dimanfaatkan adalah batang pohonnya. Batang pohonnya dapat bermanfaat untuk mebel, pulp, konstruksi ringan, korek api, dan sumpit [12]. Sedangkan Tabebuaya merupakan jenis tanaman yang termasuk suku *Bignoniaceae* berasal dari Brasil, Amerika Selatan [13]. Tabebuaya banyak ditemui di sepanjang jalan raya dan bermanfaat untuk menyerap polusi udara dari kendaraan bermotor.

Ruang lingkup dalam penelitian ini membahas terkait analisis citra dengan memanfaatkan *Convolutional Neural Network* (CNN) untuk menentukan citra batang tersebut termasuk dalam kelompok batang pohon Pinus atau Tabebuaya. Penentuan klasifikasi citra dalam penelitian ini hanya memperhatikan aspek citra batang pohon, tanpa memperhatikan bagian struktur pohon lainnya. Tujuan penelitian ini untuk mengetahui sejauh mana pengaruh kinerja optimizer SGD dan RMSProp dalam klasifikasi batang pohon Pinus dan tabebuaya dengan membandingkan akurasi dari jumlah *epochs* yang digunakan.

II. METODOLOGI DAN PENELITIAN TERKAIT

A. Metodologi

Sebelum melakukan penelitian, hal yang paling utama adalah membuat *flowchart* kegiatan agar pelaksanaan berjalan dengan efektif. Berikut merupakan beberapa tahapan yang dipakai dimulai dari pengambilan data citra, data preprocessing, pembentukan arsitektur CNN, pelatihan dan validasi model CNN, dan analisis hasil dari akurasi pelatihan dan validasi untuk mencapai tujuan penelitian.



Gambar 1. Flowchart Kerja

1. Pengambilan Data Citra

Data citra yang digunakan adalah batang pohon Tabebuya dan Pinus dengan jumlah total 1000 citra terbagi dalam 500 citra Pinus dan 500 Tabebuya. Jenis data yang digunakan pada penelitian ini adalah data primer. Data primer adalah data yang didapatkan atau diperoleh secara langsung oleh peneliti. Dalam pengambilan dataset, peneliti memotret citra batang pohon menggunakan kamera android.

2. Data Preprocessing

Setelah dataset terkumpul, langkah selanjutnya yaitu melakukan *preprocessing data* untuk mendapatkan kualitas data yang baik. Tahap *preprocessing* dalam penelitian ini sebagai berikut:

a. Pemilahan citra

Mengambil dataset secara langsung belum tentu menjadikan dataset sepenuhnya bersih, maka langkah awal dapat melakukan pemilihan data citra. Langkah ini bertujuan untuk menghapus citra yang diambil terlalu jauh dari obyek dan memiliki kualitas citra yang rendah.

b. Resize


Resize bertujuan untuk mengubah ukuran citra sesuai ratio atau piksel yang telah ditentukan. Peneliti menentukan ratio citra data menggunakan ukuran 1:1. Selanjutnya, citra yang telah diubah sesuai dengan rasio yang ditentukan akan direpresentasikan dalam bentuk matriks secara numerik[14].

c. Pembagian data


Dataset citra terbagi menjadi dua yaitu 75% data latih dan 25% data validasi.

d. Labelling


Pengubahan nama *file* citra dilakukan sesuai kelas dengan format penamaan *pinus_xx* dan *tabebuya_xx*. Dalam folder dataset citra, terdapat dua *subfolder* *pinus* dan *tabebuya* yang telah terisi citra yang sesuai.



Gambar 2. Subfolder dataset



Gambar 3. Isi subfolder pinus



Gambar 4. Isi subfolder tabebuya

3. Pembentukan Arsitektur Convolution Neural Network (CNN)

Dalam penelitian ini menggunakan bahasa pemrograman python dengan bantuan *software* Google Colab dan algoritma *Convolutional Neural Network* (CNN). Algoritma CNN termasuk dalam metode *supervised learning* atau dikenal juga pembelajaran terarah dimana dapat mengidentifikasi suatu citra dengan melatih data citra sebelumnya dan menargetkan variabel citra [10]. Dua tahapan yang ada dalam Arsitektur CNN adalah *feature learning* dan *classification* [6]. Tahapan *feature learning* terdiri dari *convolutional layer* dan *pooling layer*, sedangkan tahapan *classification* terdiri dari *flatten* dan *fully connected layer*. Pada tahap *Convolutional layer* akan dilakukan filter terhadap citra, kemudian filter itu terus bergeser ke seluruh bagian citra, dan menghasilkan *output* yang disebut *feature map* [15]. *Pooling layer* merupakan tahapan setelah *convolutional layer* [6]. *Pooling layer* adalah proses yang dilakukan untuk mengurangi ukuran matriks dari hasil proses konvolusi [11]. *Max pooling* merupakan *pooling layer* yang paling umum digunakan untuk mengurangi *feature map* sehingga dapat mempercepat komputasi [15]. *Feature map* hasil dari proses *feature extraction* menggunakan *convolutional* dan *pooling layer* masih berbentuk multidimensional array, sehingga langkah selanjutnya dilakukan *flatten* atau *reshape feature map* menjadi sebuah *vector* supaya dapat digunakan sebagai *input* dari *fully connected layer* [16].

4. Pelatihan Model CNN dan Validasi Model CNN

Dataset citra yang disiapkan dilakukan proses pengujian terhadap model CNN dengan menerapkan metode optimizer *Root-Mean-Square Propagation* (RMSProp) dan *Stochastic Gradient Descent* (SGD) serta menggunakan beberapa *epochs* sebagai parameter pembanding. *Epochs* yang digunakan dalam penelitian ini yaitu 10, 15, 20, 30, dan 50. RMSprop merupakan metode optimasi yang

menggunakan besarnya gradien terkini sehingga bermanfaat untuk menormalkan gradien, alasan fungsi ini disebut RMS karena mampu mempertahankan rata-rata bergerak di atas gradien *root mean square* [17]. Algoritma RMSProp berasal dari konsep penurunan gradien dan Resilient Back Propagation (RProp), yang berada di ranah tingkat pembelajaran adaptif dan dirancang untuk pelatihan Jaringan Syaraf Tiruan. Sedangkan, algoritma SGD adalah metode iteratif yang umum dalam *machine learning* untuk mengoptimalkan penurunan gradien. Metode ini memungkinkan pengguna dapat menginisialisasi bobot dan melakukan pembaruan vektor bobot hanya dengan satu titik data [18].

5. Akurasi Pelatihan dan Akurasi Validasi

Berdasarkan uji coba pelatihan model dan validasi model CNN, dihasilkan beberapa hasil akurasi. Hasil akurasi yang didapatkan yaitu nilai akurasi pada proses pelatihan, nilai akurasi pada proses validasi, nilai *loss* pada proses pelatihan, dan nilai *loss* pada proses validasi. Dari hasil tersebut, maka dapat disimpulkan gabungan metode dan *epochs* yang tepat untuk proses klasifikasi citra ini.

B. Penelitian Terkait

Beberapa penelitian mengenai klasifikasi bagian dari tumbuhan dan pohon telah dilakukan. Salah satunya klasifikasi citra bunga. Penelitian [19] membahas tentang klasifikasi bunga anggrek yang mengimplementasikan model Convolutional Neural Network (CNN) dan AlexNet. Performasi terbaik pada model AlexNet yaitu precision 79.76%, recall 83.33%, f score 84.10% dan akurasi sebesar 86.07%. Sedangkan untuk model CNN yaitu precision 93.75%, recall 91.66%, f score 91.74% dan akurasi sebesar 91.42%. Kelemahan dalam penelitian tersebut belum terdapat skenario pengujian menggunakan optimizer yang berbeda-beda.

Penelitian [20] mengidentifikasi parasit malaria pada citra mikroskopis hapusan darah dengan berbagai optimizer. Tujuh optimizer yang berbeda-beda yaitu Adam, AdaDelta, RMSProp, SGD, AdaMax, Nadam, dan AdaGrad digunakan untuk pengujian penelitian tersebut. Hasilnya menunjukkan bahwa algoritma RMSProp dapat menghasilkan kinerja paling baik dengan nilai presisi dan recall tertinggi sebesar 0.98, skor f1 rata-rata sebesar 0.96, dan akurasi validasi sebesar 95.83%.

Penelitian [19] menggunakan ResNet-50 dengan menggunakan metode optimizer SGD, Adam, dan RMSprop dan konfigurasi hyperparameter untuk klasifikasi citra daging sapi, babi, dan oplosan. Hasil menunjukkan SGD adalah optimizer terbaik dalam penelitian tersebut dengan tingkat nilai akurasi sebesar 97,83%, ketepatan sebesar 97%, recall sebesar 97%, dan skor f1 sebesar 97% dengan kondisi batch size 32, learning rate 0,01, dan epoch 50.

Berdasarkan beberapa penelitian yang telah dilakukan, maka peneliti menentukan penggunaan model CNN karena terbukti menghasilkan akurasi yang optimal. Selain itu, juga membandingkan optimizer SGD dan RMSProp berdasarkan penelitian [20] dan [19] untuk melihat mana yang lebih unggul jika diterapkan pada klasifikasi citra batang pohon.

III. HASIL DAN PEMBAHASAN

A. Hasil Data Preprocessing

Input citra dataset diubah menjadi 280×280 piksel. Citra akan menjadi 3 matriks sesuai *channel* yang dimiliki yaitu *Red*, *Green*, dan *Blue* (RGB). Visualisasi citra dapat diamati menggunakan library `matplotlib.pyplot` seperti Gambar 5 berikut:



Gambar 5. Data Preprocessing

B. Hasil Arsitektur CNN

Layer (type)	Output Shape	Param #
rescaling_1 (Rescaling)	(None, 280, 280, 3)	0
conv2d (Conv2D)	(None, 280, 280, 16)	448
max_pooling2d (MaxPooling2D)	(None, 140, 140, 16)	0
conv2d_1 (Conv2D)	(None, 140, 140, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 70, 70, 32)	0
conv2d_2 (Conv2D)	(None, 70, 70, 64)	18496
max_pooling2d_2 (MaxPooling2D)	(None, 35, 35, 64)	0
flatten (Flatten)	(None, 78400)	0
dense (Dense)	(None, 128)	10035328
dense_1 (Dense)	(None, 2)	258
=====		
Total params: 10,059,170		
Trainable params: 10,059,170		
Non-trainable params: 0		

Gambar 6. Model CNN

Proses pertama kali yakni input citra dengan ukuran $280 \times 280 \times 3$ sesuai dengan yang telah ditetapkan pada data *preprocessing*. *Convolution*

pertama menggunakan kernel 3×3 dengan 16 filter dan aktivasi relu sehingga hasil *convolution* pertama memiliki *output* ukuran citra sebesar $280 \times 280 \times 16$ dan parameter yang dihasilkan berjumlah $((3 \times 3 \times 16) + 1) \times 16 = 448$. Setelah itu terjadi proses *pooling* dengan menggunakan jenis *max pooling* dengan ukuran 2×2 , sehingga ukuran citra yang pada awalnya 280×280 berubah menjadi 140×140 . Parameter tidak dihitung dalam proses ini, oleh karena itu tidak terdapat jumlah parameter artinya total parameter bernilai 0. Kemudian, proses *convolution* kedua menggunakan 32 filter, *input* citra berukuran 140×140 , dan kernel 3×3 . Dari proses tersebut menghasilkan *output* parameter berjumlah $((3 \times 3 \times 16) + 1) \times 32 = 4640$. Setelah itu terjadi proses *pooling* dengan menggunakan jenis *max pooling* dengan ukuran 2×2 , sehingga ukuran citra yang pada awalnya 140×140 berubah menjadi 70×70 . Proses *convolution* ketiga dengan 64 filter, *input* citra 70×70 , dan kernel 3×3 . Dari proses tersebut menghasilkan *output* parameter berjumlah $((3 \times 3 \times 32) + 1) \times 64 = 18469$. Setelah itu terjadi proses *pooling* dengan menggunakan jenis *max pooling* dengan ukuran 2×2 , sehingga ukuran citra yang pada awalnya 70×70 berubah menjadi 35×35 .

Output tahap *flatten* yakni sebesar $35 \times 35 \times 64 = 78400$ kemudian dilanjutkan ke tahap *dense layer* dengan 128 unit sesuai besarnya unit yang sudah ditetapkan. Didapatkan hasil *output* yaitu $(78400 \times 128) + 128 = 10035328$ parameter. Selanjutnya pada *dense layer* kedua, sesuai dengan jumlah klasifikasi pada penelitian ini yaitu sebanyak 2 menghasilkan *output* sebesar $(128 \times 2) + 2 = 258$ parameter. Total keseluruhan parameter sama dengan jumlah parameter pada tahap latih yakni sebesar 10059170.

C. Hasil Pelatihan Model CNN dan Validasi Model CNN


Tabel 1. Hasil akurasi penggunaan optimizer RMSProp

	Data Latih		Data Validasi	
	Akurasi	Loss Akurasi	Akurasi	Loss Akurasi
Epochs 10	0.9103	0.2521	0.9120	0.2402
Epochs 15	0.9680	0.1107	0.8680	0.3137
Epochs 20	0.9453	0.3806	0.9160	0.2468
Epochs 30	0.9880	0.0373	0.8880	0.6047
Epochs 50	1.0000	5.5218e-07	0.8320	1.1544
Epochs 80	1.0000	6.0081e-08	0.8200	1.7096

Tabel 2. Hasil akurasi penggunaan optimizer SGD


	Data Latih		Data Validasi	
	Akurasi	Loss Akurasi	Akurasi	Loss akurasi
Epochs 10	0.6813	0.6038	0.7760	0.5396
Epochs 15	0.6276	0.6498	0.7760	0.5124
Epochs 20	0.7853	0.4928	0.8160	0.4342
Epochs 30	0.8293	0.3972	0.8960	0.3439
Epochs 50	0.9453	0.1644	0.9040	0.2398
Epochs 80	1.0000	0.0032	0.9360	0.1785

Pada tabel 1 dapat diamati bahwa semakin banyak epochs yang digunakan, akurasi data latih semakin baik. Pada epochs 50 terlihat bahwa akurasi data latih sudah mencapai 1,000. Namun, akurasi data latih tidak selalu mengakibatkan akurasi data validasi juga semakin baik. Dapat dilihat dalam tabel bahwa penggunaan optimizer RMSProp dengan *epochs* yang semakin tinggi menghasilkan akurasi data validasi yang cenderung turun. Akurasi paling optimal dapat dilihat dari tabel tersebut yaitu 0.9160. Gambar dibawah ini merupakan grafik dari performa terbaik yang dihasilkan oleh optimizer RMSProp dan *epochs* 20.



Gambar 7. Grafik akurasi RMSProp dengan epochs 20

Hasil akurasi pada data latih menggunakan optimizer SGD sama dengan RMSProp yang meningkat signifikan. Perbedaannya, penggunaan optimizer SGD dapat menghasilkan akurasi data validasi cenderung meningkat. Hasil pada penelitian ini dapat dilihat bahwa semakin banyak *epochs* yang digunakan maka akurasi data validasi menggunakan optimizer SGD semakin meningkat. Pada tabel 2 dapat dilihat akurasi paling optimal yaitu 0,9360. Gambar dibawah ini merupakan grafik dari performa terbaik yang dihasilkan optimizer SGD dan epochs 80.



Gambar 8. Grafik akurasi SGD dengan epochs 80

IV. KESIMPULAN

Dalam penelitian klasifikasi citra batang pohon Pinus dan Tabebuaya ini menggunakan model CNN yang terdiri dari tiga kali tahap *convolution*, pooling layer dengan jenis *max pooling*, *flatten*, dan *dense layer*. Hasilnya dapat terlihat bahwa SGD merupakan optimizer terbaik dengan epochs 80 menghasilkan akurasi data latih 0.9453 dan validasi 0.9160. Kemudian hasil paling optimal dari RMSProp yaitu dengan menggunakan epochs 20 yang menghasilkan akurasi data latih 1.0000 dan validasi 0.9360. Dari akurasi tersebut, sudah dapat mewakili bahwa *Convolution Neural Network* dengan bantuan optimizer SGD dan RMSProp dapat digunakan dalam klasifikasi citra.

Ada beberapa saran untuk menjadi pertimbangan dalam penelitian selanjutnya, antara lain meningkatkan kualitas pengambilan citra, mencoba variasi kombinasi lain dalam pembuatan model CNN, dan melakukan evaluasi dengan data baru.

DAFTAR PUSTAKA

- [1] H. F. Putro, R. T. Vlandari, and W. L. Y. Saptomo, "Penerapan Metode Naive Bayes Untuk Klasifikasi Pelanggan," *J. Teknol. Inf. dan Komun.*, vol. 8, no. 2, 2020, doi: 10.30646/tikomsin.v8i2.500.
- [2] R. S. Tantika, P. Statistika, F. Matematika, and P. Alam, "pada Data Pasien Penyakit Tiroid," pp. 159–166.
- [3] H. Mayatopani, R. I. Borman, W. T. Atmojo, and A. Arisantoso, "Classification of Vehicle Types Using Backpropagation Neural Networks With Metric and Eccentricity Parameters," *J. Ris. Inform.*, vol. 4, no. 1, pp. 65–70, 2021, doi: 10.34288/jri.v4i1.293.
- [4] J. Díaz-Ramírez, "Machine Learning and Deep Learning," *Ingeniare*, vol. 29, no. 2, pp. 182–183, 2021, doi: 10.4067/S0718-33052021000200180.
- [5] L. Marifatul Azizah, S. Fadillah Umayah, and F. Fajar, "Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer," *Semesta Tek.*, vol. 21, no. 2, pp. 230–236, 2018, doi: 10.18196/st.212229.
- [6] M. I. Mardiyah, "Implementasi Deep Learning untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Kebun dan Sawah," *Univ. Islam Indones.*, no. June, 2020, doi: 10.13140/RG.2.2.10880.53768.
- [7] M. Farid Naufal *et al.*, "Klasifikasi Citra Game Batu Kertas Gunting Menggunakan Convolutional Neural Network Image Classification of Rock Paper Scissor Game Using Convolutional Neural Network," *Techno.COM*, vol. 20, no. 1, pp. 166–174, 2021.
- [8] O. D. S. Sunanto and P. H. Utomo, "Implementasi Deep Learning Dengan Convolutional Neural Network Untuk Klasifikasi Gambar Sampah Organik Dan Anorganik," *Pattimura Proceeding Conf. Sci. Technol.*, vol. 1, no. 2, pp. 335–340, 2022, [Online]. Available: <https://jurnal.unej.ac.id/index.php/prosiding/article/view/33527>
- [9] K. Heryandi Suradiradja, U. Pamulang, J. Raya Puspipetek, K. Pamulang, and K. Tangerang Selatan, "Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang," *Fakt. Exacta*, vol. 14, no. 4, pp. 1979–276, 2021, doi: 10.30998/faktorexacta.v14i4.10376.
- [10] A. J. Rozaqi, A. Sunyoto, and M. rudyanto Arief, "Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural

- Network,” *Creat. Inf. Technol. J.*, vol. 8, no. 1, p. 22, 2021, doi: 10.24076/citec.2021v8i1.263.
- [11] S. Winiarti, C. Wukir, U. Ahdiani, and T. Ismail, “Klasifikasi Image Untuk Jenis Buku Bacaan Anak-Anak dengan Menggunakan Convolutional Neural Network,” *J. Media Inform. Budidarma*, vol. 6, no. 2, p. 738, 2022, doi: 10.30865/mib.v6i2.3504.
- [12] S. Suluh, “Studi Eksperimen Limbah Buah Pinus Sebagai Sumber Energi Alternatif Ditinjau Dari Variasi Butiran,” *J. Dyn. Saint*, vol. 3, no. 1, pp. 444–459, 2018, doi: 10.47178/dynamicsaint.v3i1.269.
- [13] S. Anindyanari, W. Widjanarko, and B. Widodo, “MANAJEMEN KONTEN INSTAGRAM MILIK PEMERINTAH DALAM PROMOSI POTENSI PARIWISATA DAERAH DI KABUPATEN BANYUMAS PROVINSI JAWA TENGAH: STUDI TENTANG AKUN INSTAGRAM @DINPORABUDPAR_BANYUMAS Wisnu Widjanarko Bambang Widodo,” vol. 17, no. 1, pp. 91–103, 2021, [Online]. Available: <https://banyumaskab.bps.go.id/dynamictable/2019/11/22/49/banyaknya->
- [14] I. Wulandari, H. Yasin, T. Widiharih, D. Statistika, and U. Diponegoro, “Klasifikasi citra digital bumbu dan rempah dengan algoritma convolutional neural network (cnn) 1,2,3,” vol. 9, pp. 273–282, 2020.
- [15] M. P. Véstias, “Convolutional Neural Network,” *Encycl. Inf. Sci. Technol. Fifth Ed.*, vol. 8, no. 4, pp. 12–26, 2020, doi: 10.4018/978-1-7998-3479-3.ch002.
- [16] R. Mehindra Prasmatio, B. Rahmat, and I. Yuniar, “Algoritma Convolutional Neural Network,” *J. Inform. dan Sist. Inf.*, vol. 1, no. 2, pp. 510–521, 2020.
- [17] L. G. Astuti, P. S. Informatika, and U. Udayana, “Implementasi LSTM pada Analisis Sentimen Review Film Menggunakan Adam dan RMSprop Optimizer,” vol. 10, no. 4, pp. 351–362, 2022.
- [18] B. Nugroho, E. Y. Puspaningrum, and M. S. Munir, “Kinerja Algoritma Optimasi Root-Mean-Square Propagation dan Stochastic Gradient Descent pada Klasifikasi Pneumonia Covid-19 Menggunakan CNN,” *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, p. 420, 2021, doi: 10.26418/jp.v7i3.49172.
- [19] D. Efendi, S. Sanjaya, F. Syafria, and E. Budianita, “Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet-50 untuk Klasifikasi Citra Daging Sapi dan Babi,” *J. Ris. Komput.*, vol. 9, no. 3, pp. 2407–389, 2022, doi: 10.30865/jurikom.v9i3.4176.
- [20] N. K. C. PRATIWI, N. IBRAHIM, Y. N. FU’ADAH, and S. RIZAL, “Deteksi Parasit Plasmodium pada Citra Mikroskopis Hapusan Darah dengan Metode Deep Learning,” *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 9, no. 2, p. 306, 2021, doi: 10.26760/elkomika.v9i2.306.