

Date: April 21st, 2025

LETTER OF ACCEPTANCE

Paper Number #847

Dear, Raja Pahlefi Ray

This is to inform you that the manuscript entitled: **"Analisis Pengaruh Fungsi Aktivasi CNN terhadap Performa Klasifikasi Hewan"**, which was sent on **March 19th, 2025**, is **ACCEPTED**.

We keep to ensuring a high standard of articles published in the **INCODING: Journal of Informatics and Computer Science Engineering**, and the manuscript that is being sent to you has been submitted after a first selection process based on the agreement of the **Associate Editors**. In general, the standard of manuscripts forwarded to me after the vetting is **good**.

This paper is well organized and follows the manuscript guidelines of the journal to a large extent. The introduction section is good and shows the importance of the study. The literature review is adequate. The outcomes of the study are consistent with the findings. The approach used is praiseworthy. In my opinion, it should be published without **revision again**.

Based on the review results, this manuscript is **ACCEPTED**, and **PUBLISHED** in **Mei 2025** for **Volume 3, No. 2, 2025**.

Thank you very much for your contribution. Congratulations on a wonderful job.

Warmest Regards,
Editor In Chief

INCODING
2776-432X (Online - Elektronik)

Agung Suharyanto, S.Sn, M.Si.

Editorial Office:
Mahesa Research Center

INCODING: Journal of Informatics and Computer Science Engineering

UNIVERSITAS MEDAN AREA
Perumahan Griya Nafisa 2 Blok A No 10, Jalan Benteng Hilir
Titi Sewa, RT. 06, Dusun XVI Flamboyan,
Kecamatan Percut Sei Tuan, Deli Serdang, 20371
Sumatera Utara, Indonesia
Phone: 08126493527
Email: incodingjournal@gmail.com

© Hak Cipta © Incoding Journal Online

1. Dilarang memperbanyak atau menyalin dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area



Document Accepted 27/5/25



Analisis Pengaruh Fungsi Aktivasi CNN terhadap Performa Klasifikasi Hewan

Analysis of the Effect of CNN Activation Function on Animal Classification Performance

Raja Pahlefi Ray

Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

*Corresponding Email: Rajapahlefi@gmail.com

Abstrak

Penelitian ini bertujuan untuk menganalisis pengaruh lima jenis fungsi aktivasi—ReLU, LeakyReLU, ELU, Sigmoid, dan Tanh terhadap performa model Convolutional Neural Network (CNN) dalam tugas klasifikasi citra menjadi tiga kelas: kucing, anjing, dan hewan liar. Evaluasi dilakukan menggunakan metrik akurasi validasi, grafik pertumbuhan akurasi per epoch, serta analisis confusion matrix. Hasil menunjukkan bahwa fungsi aktivasi modern seperti LeakyReLU, ELU, dan ReLU mampu memberikan akurasi tinggi dengan distribusi prediksi yang seimbang, mengindikasikan efektivitasnya dalam mengatasi permasalahan vanishing gradient dan meningkatkan kemampuan generalisasi model. Sebaliknya, fungsi klasik seperti Sigmoid dan Tanh menunjukkan performa yang sangat buruk, dengan prediksi tidak seimbang dan akurasi stagnan. Dengan demikian, pemilihan fungsi aktivasi terbukti menjadi faktor krusial dalam membangun model CNN yang optimal untuk klasifikasi citra. Penelitian ini merekomendasikan penggunaan fungsi aktivasi berbasis ReLU, khususnya LeakyReLU, sebagai pilihan utama dalam pengembangan model klasifikasi citra multi-kelas.

Kata Kunci: Klasifikasi Gambar, CNN, Fungsi Aktivasi, Evaluasi Model, Confusion Matrix

Abstract

This study aims to analyze the impact of five activation functions—ReLU, LeakyReLU, ELU, Sigmoid, and Tanh—on the performance of a Convolutional Neural Network (CNN) model for image classification into three categories: cats, dogs, and wild animals. The evaluation was conducted using validation accuracy metrics, accuracy trends across training epochs, and confusion matrix analysis. The results show that modern activation functions such as LeakyReLU, ELU, and ReLU yield high accuracy and balanced predictions, demonstrating their effectiveness in mitigating vanishing gradient issues and enhancing the model's generalization capability. In contrast, classical functions like Sigmoid and Tanh performed poorly, producing imbalanced predictions and stagnant accuracy. Therefore, the choice of activation function plays a critical role in building an optimal CNN model for image classification tasks. This study recommends ReLU-based activation functions, particularly LeakyReLU, as the primary choice for developing multi-class image classification models.

Keywords: Image Classification, CNN, Activation Function, Model Evaluation, Confusion Matrix



PENDAHULUAN

Dalam beberapa tahun terakhir, CNN telah menjadi standar dalam klasifikasi citra digital. Salah satu faktor kunci yang mempengaruhi performa model adalah pemilihan fungsi aktivasi dalam setiap lapisan konvolusi dan fully connected. Fungsi aktivasi bertanggung jawab untuk menambahkan non-linearitas ke dalam model sehingga mampu menangkap pola yang lebih kompleks dalam data (Azhar & Ismail, 2024). Penelitian ini menganalisis dampak empat fungsi aktivasi utama: ReLU, Leaky ReLU, Sigmoid, dan Tanh, dalam klasifikasi gambar hewan. CNN bekerja dengan cara mengekstraksi fitur dari gambar melalui serangkaian lapisan konvolusi, yang diikuti oleh operasi pooling untuk mereduksi dimensi fitur dan fully connected layer yang bertugas mengklasifikasikan gambar berdasarkan fitur yang telah diekstraksi (Song, 2024). Fungsi aktivasi memainkan peran penting dalam menentukan bagaimana informasi ditransformasikan dari satu lapisan ke lapisan berikutnya. Pemilihan fungsi aktivasi yang tepat dapat meningkatkan akurasi model serta mempercepat proses pembelajaran (Khadim et al., 2021). ReLU (Rectified Linear Unit) adalah fungsi aktivasi yang paling umum digunakan dalam jaringan saraf dalam karena kemampuannya mengatasi masalah vanishing gradient yang sering terjadi pada fungsi aktivasi seperti Sigmoid dan Tanh (Mesran et al., 2024). Namun, ReLU juga memiliki kelemahan, seperti Dead Neurons, di mana nilai negatif akan diubah menjadi nol sehingga menyebabkan beberapa neuron tidak aktif selama proses pelatihan (Zhang & Pang, 2023). Oleh karena itu, varian lain seperti Leaky ReLU dikembangkan untuk mengatasi masalah ini (Tomar & Patidar, 2023). Di sisi lain, fungsi aktivasi Sigmoid dan Tanh tetap banyak digunakan dalam beberapa kasus tertentu, seperti klasifikasi biner atau model yang memerlukan output terkontrol dalam rentang tertentu. Namun, kedua fungsi ini memiliki keterbatasan dalam pelatihan model yang lebih dalam, karena rentang outputnya yang terbatas menyebabkan gradient yang dihasilkan menjadi sangat kecil saat propagasi balik, sehingga menghambat pembelajaran model (Wang et al., 2020). Penelitian sebelumnya telah menunjukkan bahwa pemilihan fungsi aktivasi yang berbeda dapat menghasilkan performa yang beragam tergantung pada kompleksitas dataset dan arsitektur model yang digunakan (Joshitha et al., 2024). Oleh karena itu, dalam penelitian ini, kami mengevaluasi berbagai fungsi aktivasi dalam konteks klasifikasi hewan untuk menentukan fungsi aktivasi mana yang memberikan akurasi dan stabilitas terbaik (Goh




et al., 2024). Penelitian ini bertujuan untuk memberikan wawasan lebih lanjut mengenai dampak penggunaan fungsi aktivasi terhadap performa CNN, khususnya dalam tugas klasifikasi hewan. Dengan membandingkan empat fungsi aktivasi utama dalam jaringan CNN, diharapkan penelitian ini dapat membantu dalam pemilihan fungsi aktivasi yang paling sesuai untuk meningkatkan akurasi klasifikasi gambar dalam berbagai aplikasi kecerdasan buatan (Thomas et al., 2024).

METODE PENELITIAN

2.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah Animal faces dari kaggle.com , yang terdiri dari 4.500 gambar dari 3 spesies hewan yaitu cat, dog dan wild. Gambar-gambar dalam dataset ini memiliki variasi dalam pencahayaan, latar belakang, dan posisi objek, sehingga dapat merepresentasikan kondisi dunia nyata dalam klasifikasi hewan. Dataset ini dibagi menjadi 2 bagian yaitu training set 3000 gambar digunakan untuk melatih model dan validation set 1.500 dari total dataset, digunakan untuk tuning hyperparameter




Gambar 1 Data Jenis Hewan

2.2 Tahapan Penelitian

Metode penelitian ini menjelaskan langkah-langkah dalam eksperimen yang dilakukan untuk menganalisis Pengaruh Fungsi Aktivasi CNN terhadap Performa Klasifikasi Hewan. Penelitian ini mencakup pemilihan dataset, preprocessing data, desain arsitektur model CNN, strategi eksperimen dengan berbagai ukuran kernel, serta parameter pelatihan yang digunakan.





Gambar 2 Tahapan Penelitian

2.3 Arsitektur Model CNN.

Struktur model CNN yang digunakan dalam penelitian ini terdiri dari beberapa lapisan utama. Model ini terdiri dari tiga lapisan konvolusi dengan jumlah filter 32, 64, dan 128 serta ukuran kernel 3×3 . Setiap eksperimen menggunakan fungsi aktivasi yang berbeda, yaitu ReLU, Leaky ReLU, Sigmoid, dan Tanh, untuk mengevaluasi dampaknya terhadap akurasi dan stabilitas model. Setelah lapisan konvolusi, diterapkan lapisan max pooling 2×2 untuk mengurangi dimensi fitur. Hasil ekstraksi fitur dari lapisan konvolusi kemudian diubah ke dalam vektor satu dimensi melalui lapisan flatten sebelum diproses oleh fully connected layer. Model menggunakan dua lapisan dense dengan jumlah neuron 128 dan 64, masing-masing menggunakan fungsi aktivasi yang diuji dalam penelitian ini. Lapisan terakhir adalah output layer yang menggunakan fungsi aktivasi Softmax dengan tiga neuron output untuk mengklasifikasikan gambar ke dalam tiga kelas: cat, dog, dan wild

Tabel 1 Struktur Model

No.	Nama Layer	Jenis Layer	Parameter Utama	Output Dimensi	Fungsi Aktivasi yang Digunakan
1	Input	-	-	(3, 224, 224)	-
2	Conv2D-1	Conv2D	in=3, out=32,	(32, 224, 224)	ReLU / LeakyReLU



			kernel=3x3, padding=1		/ ELU / Sigmoid / Tanh
3	Activation-1	Dinamis	Dipilih saat training	(32, 224, 224)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
4	MaxPooling-1	MaxPooling2D	kernel_size=2x2	(32, 112, 112)	-
5	Conv2D-2	Conv2D	in=32, out=64, kernel=3x3, padding=1	(64, 112, 112)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
6	Activation-2	Dinamis	Dipilih saat training	(64, 112, 112)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
7	MaxPooling-2	MaxPooling2D	kernel_size=2x2	(64, 56, 56)	-
8	Conv2D-3	Conv2D	in=64, out=128, kernel=3x3, padding=1	(128, 56, 56)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
9	Activation-3	Dinamis	Dipilih saat training	(128, 56, 56)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
10	MaxPooling-3	MaxPooling2D	kernel_size=2x2	(128, 28, 28)	-
11	Flatten	Flatten	-	(100352,)	-
12	Fully Connected-1	Linear (FC1)	in=100352, out=256	(256,)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
13	Activation-4	Dinamis	Dipilih saat training	(256,)	ReLU / LeakyReLU / ELU / Sigmoid / Tanh
14	Dropout	Dropout	p=0.5	(256,)	-
15	Fully Connected-2	Linear (FC2 - Output)	in=256, out=3	(3,)	- (CrossEntropyLoss)

2.4 Ekperimen Ukuran Kernel.

Eksperimen ini dilakukan untuk mengevaluasi pengaruh berbagai fungsi aktivasi terhadap performa klasifikasi hewan menggunakan CNN. Empat fungsi aktivasi yang diuji dalam penelitian ini adalah ReLU, Leaky ReLU, Sigmoid, dan Tanh. Percobaan dilakukan dengan mengganti fungsi aktivasi pada lapisan konvolusi dan fully connected, sementara parameter lainnya tetap sama untuk memastikan bahwa perbedaan performa hanya disebabkan oleh pemilihan fungsi aktivasi. Model pertama menggunakan ReLU, yang dikenal dengan kecepatan konvergensi yang tinggi dan kemampuannya mengatasi masalah vanishing gradient. Model kedua menggunakan Leaky ReLU, yang merupakan varian dari ReLU dengan keunggulan dalam menangani dead neurons dengan memberikan nilai kecil untuk input negatif. Model ketiga menggunakan fungsi aktivasi Sigmoid, yang sering digunakan dalam jaringan saraf klasik tetapi memiliki kelemahan saturasi yang dapat memperlambat proses pembelajaran. Model keempat menggunakan Tanh, yang memiliki rentang output lebih luas dibandingkan Sigmoid tetapi tetap menghadapi tantangan vanishing gradient pada jaringan yang lebih dalam. Evaluasi



dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score untuk membandingkan performa masing-masing fungsi aktivasi. Selain itu, loss function selama pelatihan juga dianalisis untuk memahami bagaimana setiap fungsi aktivasi mempengaruhi proses konvergensi model. Hasil eksperimen ini akan membantu dalam menentukan fungsi aktivasi yang paling optimal untuk tugas klasifikasi hewan menggunakan CNN.

2.5 Parameter Pelatihan dan Evaluasi.

Parameter pelatihan yang digunakan dalam penelitian ini bertujuan untuk memastikan bahwa model CNN dapat berlatih secara optimal dengan berbagai fungsi aktivasi yang diuji. Model dilatih menggunakan optimizer Adam dengan learning rate sebesar 0.001, batch size 32, dan selama 50 epoch. Loss function yang digunakan adalah Categorical Cross-Entropy, yang sesuai untuk tugas klasifikasi multi-kelas. Evaluasi model dilakukan dengan menggunakan metrik berikut:

- Akurasi: Mengukur persentase prediksi yang benar dibandingkan total sampel yang diuji.
- Precision: Mengukur ketepatan model dalam mengklasifikasikan suatu kelas tertentu dengan membandingkan prediksi benar terhadap total prediksi positif.
- Recall: Mengukur kemampuan model dalam mendeteksi seluruh instance dari suatu kelas.
- F1-Score: Rata-rata harmonik dari precision dan recall yang memberikan keseimbangan antara keduanya.
- Loss Analysis: Menganalisis nilai loss selama pelatihan untuk memahami bagaimana model belajar dan mengonvergensi dengan berbagai fungsi aktivasi.
- Dengan parameter pelatihan dan evaluasi ini, penelitian ini diharapkan dapat memberikan hasil yang komprehensif dalam menentukan fungsi aktivasi terbaik untuk tugas klasifikasi hewan menggunakan CNN.

HASIL DAN PEMBAHASAN


Bagian ini membahas hasil eksperimen yang diperoleh setelah melatih model CNN dengan berbagai fungsi aktivasi. Evaluasi dilakukan berdasarkan akurasi, precision, recall, F1-score, serta analisis loss function untuk memahami dampak dari setiap fungsi aktivasi terhadap konvergensi model.



Hasil

Dalam penelitian ini, dilakukan analisis terhadap performa Convolutional Neural Network (CNN) dalam mengklasifikasikan hewan berdasarkan Fungsi Aktivasi yang digunakan pada layer konvolusi. Model CNN dievaluasi menggunakan metrik akurasi, F1-score, serta confusion matrix untuk mengukur performa klasifikasi pada dataset yang digunakan.

Akurasi Model.




Gambar 3 perbandingan akurasi

Gambar di atas menunjukkan perbandingan akurasi model CNN berdasarkan lima jenis fungsi aktivasi yang digunakan dalam proses pelatihan: ReLU, LeakyReLU, ELU, Sigmoid, dan Tanh. Dari visualisasi tersebut, terlihat bahwa ReLU, LeakyReLU, dan ELU memberikan performa yang sangat baik dengan akurasi validasi yang berada di atas 85%, menunjukkan bahwa fungsi-fungsi aktivasi tersebut mampu menangani masalah vanishing gradient secara efektif dan membantu jaringan belajar fitur secara lebih optimal. Sebaliknya, fungsi aktivasi Sigmoid dan Tanh menunjukkan performa yang jauh lebih rendah, dengan akurasi hanya sekitar 30-35%. Hal ini kemungkinan disebabkan oleh sifat non-linear dari fungsi tersebut yang rentan terhadap masalah vanishing gradient, terutama pada jaringan yang lebih dalam. Akibatnya, proses pembelajaran menjadi kurang efisien dan model sulit mengoptimalkan bobot secara efektif. Secara keseluruhan, grafik ini menegaskan bahwa pemilihan fungsi aktivasi memiliki dampak signifikan terhadap performa model CNN, dengan fungsi-fungsi aktivasi berbasis ReLU



menjadi pilihan yang lebih unggul dalam konteks klasifikasi citra pada dataset yang digunakan.


Perbandingan Akurasi dan validasi per Epoch.



Gambar 4 perbandingan Akurasi dan Validasi per epoch

Gambar di atas menyajikan grafik perbandingan akurasi validasi model CNN terhadap jumlah epoch untuk lima fungsi aktivasi yang berbeda, yaitu ReLU, LeakyReLU, ELU, Sigmoid, dan Tanh. Grafik ini memberikan wawasan yang penting mengenai performa tiap fungsi aktivasi seiring proses pelatihan berlangsung selama 10 epoch. Dari grafik tersebut, dapat diamati bahwa ReLU, LeakyReLU, dan ELU menunjukkan tren peningkatan akurasi yang stabil dan signifikan dari epoch pertama hingga akhir. Ketiga fungsi ini mencapai akurasi validasi yang tinggi, yaitu di kisaran 85–90% pada akhir pelatihan. Hal ini mengindikasikan bahwa ketiga fungsi aktivasi tersebut sangat efektif dalam membantu jaringan CNN belajar secara efisien, menjaga aliran gradien tetap stabil, dan menghindari permasalahan seperti vanishing gradient. LeakyReLU secara khusus tampak menunjukkan peningkatan yang cepat di awal epoch, mencapai performa yang hampir maksimal hanya dalam beberapa epoch pertama. ELU juga menunjukkan stabilitas yang baik, sementara ReLU tetap konsisten meskipun mengalami sedikit fluktuasi pada beberapa epoch. Sebaliknya, fungsi aktivasi Sigmoid dan Tanh menunjukkan performa yang sangat buruk dan stagnan sepanjang proses pelatihan, dengan akurasi validasi yang berada pada kisaran 30–35%. Tidak ada peningkatan signifikan yang terlihat, menunjukkan bahwa kedua fungsi ini tidak mampu memberikan kontribusi optimal terhadap proses pembelajaran dalam arsitektur CNN yang digunakan. Hal ini konsisten dengan pengetahuan bahwa Sigmoid dan Tanh sering kali mengalami vanishing gradient pada jaringan dalam, sehingga bobot tidak dapat diperbarui dengan efektif. Kesimpulannya, grafik ini menegaskan bahwa pemilihan fungsi aktivasi sangat berpengaruh terhadap efektivitas pelatihan model CNN. Fungsi aktivasi modern seperti ReLU, LeakyReLU, dan ELU memberikan hasil yang jauh lebih baik dibandingkan fungsi klasik seperti Sigmoid dan Tanh dalam konteks klasifikasi citra.

Confusion Matrix



Gambar 5 Confusion Matrix

LeakyReLU menunjukkan performa terbaik di antara kelima fungsi aktivasi. Model berhasil mengklasifikasikan 481 gambar kucing dengan benar, 460 anjing, dan 436 hewan liar. Jumlah kesalahan klasifikasi relatif kecil: misalnya hanya 12 anjing diklasifikasikan

sebagai kucing, dan 28 anjing salah sebagai hewan liar. Hal ini menunjukkan bahwa model mampu membedakan antar kelas dengan cukup akurat dan seimbang. ELU juga menunjukkan performa sangat baik, meskipun sedikit di bawah LeakyReLU. Model mengklasifikasikan 480 kucing, 456 anjing, dan 410 hewan liar dengan benar. Namun, terdapat kesalahan yang lebih besar dibanding LeakyReLU, terutama pada kelas “wild”, di mana sebanyak 49 hewan liar diklasifikasikan sebagai kucing dan 41 sebagai anjing. Ini menunjukkan bahwa model sedikit kesulitan membedakan hewan liar dari dua kelas lainnya. ReLU menunjukkan performa yang cukup baik, tetapi mulai terlihat penurunan dari dua fungsi aktivasi sebelumnya. Model mengklasifikasikan 455 kucing, 436 anjing, dan 460 hewan liar dengan benar. Kesalahan klasifikasi meningkat terutama pada anjing yang salah diklasifikasikan sebagai hewan liar sebanyak 58 kali, serta kucing yang salah menjadi hewan liar sebanyak 25 kali. Meskipun kelas “wild” cukup akurat, ReLU tampaknya kurang andal dalam membedakan kucing dan anjing. Sigmoid menunjukkan performa yang buruk dan tidak seimbang. Model mengklasifikasikan semua input (500 dari setiap kelas) sebagai hewan liar. Tidak ada satu pun instance dari kucing atau anjing yang diklasifikasikan dengan benar. Ini mengindikasikan bahwa model mengalami masalah serius, kemungkinan overfitting, underfitting, atau terjebak dalam saturasi fungsi aktivasi sigmoid. Tanh memiliki performa terburuk dari semua fungsi aktivasi yang diuji. Model mengklasifikasikan semua input sebagai kucing, sehingga menghasilkan 500 prediksi untuk kelas tersebut tanpa satu pun benar untuk anjing atau hewan liar. Seperti halnya sigmoid, ini mencerminkan masalah besar dalam pelatihan model yang menyebabkan prediksi hanya ke satu kelas saja. Dari kelima fungsi aktivasi tersebut, LeakyReLU memberikan hasil terbaik dan paling stabil dalam klasifikasi tiga kelas (cat, dog, wild). Disusul oleh ELU dan ReLU, yang juga cukup akurat namun sedikit lebih banyak melakukan kesalahan. Sebaliknya, Sigmoid dan Tanh tidak layak digunakan dalam kasus ini karena menghasilkan prediksi yang berat sebelah dan gagal membedakan antara kelas.

Pembahasan

Penelitian ini bertujuan untuk mengevaluasi pengaruh berbagai jenis fungsi aktivasi terhadap performa model Convolutional Neural Network (CNN) dalam melakukan klasifikasi citra ke dalam tiga kelas: kucing, anjing, dan hewan liar. Lima fungsi aktivasi yang diuji meliputi ReLU, LeakyReLU, ELU, Sigmoid, dan Tanh. Evaluasi dilakukan berdasarkan akurasi validasi secara keseluruhan, tren akurasi selama proses pelatihan (epoch), dan performa klasifikasi berdasarkan confusion matrix. Hasil eksperimen menunjukkan bahwa pemilihan fungsi aktivasi memberikan dampak yang signifikan terhadap kinerja akhir model. Fungsi aktivasi LeakyReLU terbukti menjadi pilihan paling unggul dengan akurasi validasi tertinggi dan tingkat kesalahan klasifikasi yang paling rendah di antara semua fungsi yang diuji. LeakyReLU mampu mengatasi permasalahan dying ReLU dengan membiarkan sejumlah kecil gradien tetap mengalir saat input bernilai negatif, sehingga memperkuat kemampuan model dalam melakukan pembaruan bobot secara konsisten. Fungsi ELU dan ReLU juga menunjukkan performa yang sangat kompetitif. ELU memberikan stabilitas yang baik selama pelatihan dan menghasilkan klasifikasi yang cukup seimbang meskipun masih terdapat kesalahan pada kelas yang lebih kompleks (hewan liar). ReLU tetap menjadi fungsi aktivasi yang efektif dan efisien, meskipun dalam eksperimen ini sedikit tertinggal dibandingkan LeakyReLU dan ELU dalam hal klasifikasi antar kelas yang mirip, seperti anjing dan kucing. Sebaliknya,



Sigmoid dan Tanh menunjukkan performa yang sangat buruk, dengan akurasi validasi yang rendah dan klasifikasi yang berat sebelah. Kedua fungsi ini rentan terhadap masalah vanishing gradient, terutama pada jaringan yang dalam seperti CNN. Akibatnya, model mengalami kesulitan dalam melakukan pembelajaran yang efektif, yang ditunjukkan oleh prediksi yang mengarah hanya pada satu kelas dan stagnasi akurasi sepanjang proses pelatihan. Temuan ini menggarisbawahi pentingnya pemilihan fungsi aktivasi yang tepat dalam membangun arsitektur CNN yang optimal. Fungsi aktivasi modern seperti LeakyReLU dan ELU mampu menjaga kestabilan aliran gradien, mempercepat konvergensi, dan meningkatkan kemampuan generalisasi model. Oleh karena itu, dalam pengembangan sistem klasifikasi citra menggunakan CNN, penggunaan fungsi aktivasi berbasis ReLU (terutama LeakyReLU) sangat direkomendasikan untuk mencapai performa terbaik.

SIMPULAN

Penelitian ini telah mengevaluasi pengaruh lima fungsi aktivasi ReLU, LeakyReLU, ELU, Sigmoid, dan Tanh terhadap performa model CNN dalam klasifikasi citra ke dalam tiga kelas: kucing, anjing, dan hewan liar. Berdasarkan hasil akurasi validasi, grafik per epoch, dan analisis confusion matrix, dapat disimpulkan bahwa pemilihan fungsi aktivasi memiliki pengaruh signifikan terhadap kinerja dan efektivitas model. Fungsi aktivasi LeakyReLU menunjukkan performa terbaik secara keseluruhan, dengan akurasi tinggi dan distribusi prediksi yang stabil dan akurat. Fungsi ELU dan ReLU juga memberikan hasil yang baik, meskipun terdapat sedikit penurunan dalam kemampuan membedakan kelas yang mirip. Di sisi lain, Sigmoid dan Tanh menunjukkan performa yang sangat buruk, dengan hasil klasifikasi yang tidak seimbang dan akurasi validasi yang stagnan. Hal ini disebabkan oleh kelemahan mendasar dari kedua fungsi tersebut, yaitu kecenderungan mengalami vanishing gradient. Dengan demikian, dapat disimpulkan bahwa fungsi aktivasi modern seperti LeakyReLU, ELU, dan ReLU lebih cocok digunakan dalam arsitektur CNN untuk tugas klasifikasi citra, terutama yang melibatkan lebih dari dua kelas dan data yang kompleks.

SARAN

Untuk pengembangan sistem klasifikasi citra menggunakan CNN, disarankan untuk menggunakan fungsi aktivasi berbasis ReLU, khususnya LeakyReLU, karena terbukti memberikan hasil terbaik dalam penelitian ini. Fungsi ini mampu mengatasi permasalahan vanishing gradient dan meningkatkan performa klasifikasi. Penelitian



selanjutnya disarankan untuk mengeksplorasi fungsi aktivasi yang lebih baru seperti Swish, Mish, atau varian adaptif lainnya yang berpotensi memberikan performa lebih baik daripada fungsi konvensional. Penggunaan arsitektur CNN yang lebih dalam, serta penerapan teknik data augmentation, dropout, atau batch normalization, dapat diteliti untuk meningkatkan akurasi dan generalisasi model lebih lanjut. Disarankan untuk melakukan pengujian fungsi aktivasi ini pada dataset citra yang lebih besar dan kompleks, untuk menguji konsistensi hasil dan kemampuan fungsi aktivasi dalam menangani berbagai kondisi nyata. Saran lainnya adalah mencoba pendekatan kombinasi beberapa fungsi aktivasi dalam berbagai layer CNN, untuk melihat apakah pendekatan tersebut dapat meningkatkan fleksibilitas dan kinerja model secara keseluruhan.

DAFTAR PUSTAKA

- Azhary, M. Z. R., & Ismail, A. R. (2024). Comparative Performance of Different Convolutional Neural Network Activation Functions on Image Classification. *International Journal on Perceptive and Cognitive Computing*.
- Song, T. (2024). Comparative Analysis of Activation Functions in Simple Convolutional Neural Networks. 2024 IEEE 6th International Conference on Civil Aviation Safety and Information Technology (ICCASIT).
- Khadim, E. U., Shah, S. A., & Wagan, R. A. (2021). Evaluation of Activation Functions in CNN Model for Detection of Malaria Parasite using Blood Smear Images. 2021 International Conference on Innovative Computing (ICIC).
- Mesran, Rachmawati, S., Nugroho, F., & Windarto, A. (2024). Investigating the Impact of ReLU and Sigmoid Activation Functions on Animal Classification Using CNN Models. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*.
- Zhang, Y., & Pang, B. (2023). Application of CNN Based on Improved Activation Function in Image Classification Processing. 2023 7th Asian Conference on Artificial Intelligence Technology (ACAIT).
- Tomar, A., & Patidar, H. (2023). Optimizing CNN Model Performance for MNIST and CIFAR Classification Using Rectified Sigmoid and ReS Activation Functions. 2023 7th International Conference On Computing, Communication, Control And Automation (ICCUBEA).
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. *Applied Sciences*.
- Joshitha, K. L., Subramanian, R. M., Kumaran, S., & Prasanth, L. (2024). Design and Comparison of Activation Functions for the Classification of Cotton Leaf Diseases. 2024 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS).



Goh, K., Surono, S., Afiatin, M. Y. F., Mahmudah, K. R., Irsalinda, N., Chaimanee, M., & Onn, C. W. (2024). Comparison of Activation Functions in Convolutional Neural Network for Poisson Noisy Image Classification. *Emerging Science Journal*.

Thomas, S., Abraham, S., Kumar, P., & Basheer, F. (2024). An Effective Implementation of Activation Functions in Nodule Classification. 2024 10th International Conference on Advanced Computing and Communication Systems (ICACCS)

