



Analisis Pengaruh Fungsi Aktivasi CNN terhadap Performa Klasifikasi Hewan

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

Raja Pahlefi Ray & Arnes Sembiring*

Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

Diterima: 21 April 2025; Direview: 22 April 2025; Disetujui: 24 April 2025

*Corresponding Email: arnessembiring@staff.uma.ac.id

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, teknologi kecerdasan buatan di bidang pengolahan citra digital berkembang pesat dengan Convolutional Neural Network (CNN) sebagai metode utama untuk klasifikasi gambar, yang mampu mengenali pola visual secara otomatis dan hierarkis tanpa intervensi manusia [1], [2]. CNN telah diterapkan luas dalam berbagai bidang, termasuk klasifikasi hewan yang menghadapi tantangan variasi pencahayaan, sudut pandang, dan latar belakang kompleks [3], [4]. Keberhasilan CNN sangat dipengaruhi oleh desain arsitektur jaringan, terutama fungsi aktivasi yang menambahkan non-linearitas pada output neuron, sehingga memengaruhi proses pembelajaran dan generalisasi model [5], [6], [7]. Fungsi aktivasi yang umum digunakan meliputi ReLU, Leaky ReLU, ELU, Sigmoid, dan Tanh, masing-masing memiliki karakteristik serta kelebihan dan kekurangan tersendiri [8], [9].

ReLU merupakan fungsi aktivasi yang paling populer dalam jaringan saraf dalam karena sederhana dan efektif mengatasi masalah vanishing gradient yang umum terjadi pada fungsi klasik seperti Sigmoid dan Tanh [10], [11]. Fungsi ini mengubah nilai input negatif menjadi nol, sehingga mempercepat konvergensi pelatihan. Namun, ReLU juga memiliki kelemahan berupa fenomena "dead neurons" di mana neuron dengan output nol selama pelatihan menjadi tidak aktif dan tidak berkontribusi pada pembelajaran [12], [13], [14]. Untuk mengatasi hal ini, dikembangkan varian seperti Leaky ReLU yang membiarkan sejumlah kecil gradien tetap mengalir pada input negatif, sehingga mengurangi risiko neuron mati dan menjaga stabilitas pembelajaran [15], [16], [17].

Selain itu, fungsi ELU merupakan alternatif yang memperbaiki kelemahan ReLU dengan memberikan nilai negatif yang kontinu untuk input negatif, sehingga meningkatkan performa dan stabilitas jaringan. Sementara itu, fungsi Sigmoid dan Tanh merupakan fungsi klasik yang memiliki rentang output terbatas dan sering digunakan dalam jaringan saraf sederhana atau kasus tertentu seperti klasifikasi biner [18], [19], [20]. Namun, keduanya rentan terhadap masalah vanishing gradient yang menghambat pembelajaran pada jaringan dalam, terutama saat backpropagation.

Pemilihan fungsi aktivasi yang tepat sangat menentukan kualitas model CNN. Fungsi yang tidak sesuai dapat menghambat proses pelatihan, memperlambat konvergensi, atau menyebabkan performa yang buruk, seperti overfitting atau underfitting. Berbagai studi sebelumnya telah menunjukkan bahwa fungsi aktivasi

modern seperti ReLU dan variannya secara signifikan lebih efektif dibandingkan fungsi klasik, namun ada variasi hasil tergantung pada dataset, kompleksitas model, dan jenis tugas klasifikasi. Oleh karena itu, penelitian yang membandingkan fungsi aktivasi secara sistematis dalam konteks klasifikasi citra, khususnya klasifikasi multi-kelas dengan data yang kompleks seperti hewan, masih sangat diperlukan untuk memberikan panduan praktis.

Penelitian ini bertujuan untuk menganalisis secara komprehensif pengaruh lima fungsi aktivasi utama ReLU, Leaky ReLU, ELU, Sigmoid, dan Tanh terhadap performa model CNN dalam tugas klasifikasi citra hewan. Fokus penelitian adalah pada tiga kelas hewan yang sering ditemui dalam dataset citra, yaitu kucing, anjing, dan hewan liar. Dengan menggunakan dataset yang memiliki variasi tinggi dalam hal pencahayaan, sudut pandang, dan latar belakang, studi ini menguji efektivitas fungsi-fungsi aktivasi tersebut dengan metrik evaluasi meliputi akurasi, precision, recall, F1-score, dan analisis confusion matrix.

Studi ini diharapkan mampu mengisi celah penelitian yang selama ini lebih banyak berfokus pada fungsi aktivasi secara teoritis atau pada dataset yang lebih sederhana. Penelitian ini juga memberikan kontribusi empiris terkait pilihan fungsi aktivasi yang optimal dalam jaringan CNN untuk klasifikasi citra kompleks dan multi-kelas. Secara teoretis, penelitian ini memperkaya literatur kecerdasan buatan dengan data komparatif yang mendalam mengenai kinerja fungsi aktivasi di lingkungan nyata. Secara praktis, hasil penelitian dapat menjadi pedoman bagi pengembang dan peneliti dalam memilih fungsi aktivasi yang paling efektif untuk aplikasi klasifikasi citra hewan maupun bidang pengolahan citra lainnya.

METODE PENELITIAN

Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berasal dari Animal Faces di kaggle.com, yang berisi 4.500 gambar dari tiga spesies hewan, yaitu kucing, anjing, dan hewan liar. Gambar-gambar tersebut memiliki variasi dalam pencahayaan, latar belakang, dan posisi objek, sehingga mencerminkan kondisi dunia nyata untuk klasifikasi hewan. Dataset ini kemudian dibagi menjadi dua bagian, yakni training set sebanyak


3.000 gambar untuk melatih model dan validation set sebanyak 1.500 gambar yang digunakan untuk penyesuaian hyperparameter.



Gambar 1 Data Jenis Hewan

Tahapan Penelitian

Metode penelitian ini menguraikan tahapan eksperimen yang dilakukan untuk mengevaluasi pengaruh variasi ukuran kernel dalam CNN terhadap klasifikasi citra hewan. Proses penelitian meliputi pemilihan dataset, tahap preprocessing data, perancangan arsitektur CNN, pelaksanaan eksperimen dengan berbagai ukuran kernel, serta penentuan parameter pelatihan yang diterapkan.



Gambar 2 Tahapan Penelitian

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, kernel=3x3, padding=1	(32, 224, 224)	ReLU / LeakyReLU / 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)

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 konvergensinya 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.

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:

- a. Akurasi: Mengukur persentase prediksi yang benar dibandingkan total sampel yang diuji.
- b. Precision: Mengukur ketepatan model dalam mengklasifikasikan suatu kelas tertentu dengan membandingkan prediksi benar terhadap total prediksi positif.
- c. Recall: Mengukur kemampuan model dalam mendeteksi seluruh instance dari suatu kelas.
- d. F1-Score: Rata-rata harmonik dari precision dan recall yang memberikan keseimbangan antara keduanya.
- e. 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.

DAFTAR PUSTAKA

- [1] Y. Xu *et al.*, "Cross-Modal Fusion Convolutional Neural Networks With Online Soft-Label Training Strategy for Mechanical Fault Diagnosis," *IEEE Trans. Ind. Informatics*, vol. 20, no. 1, pp. 73–84, 2024, doi: 10.1109/TII.2023.3256400.
- [2] A. Asrianda, H. A. K. Aidilof, and Y. Pangestu, "Machine Learning for Detection of Palm Oil Leaf Disease Visually using Convolutional Neural Network Algorithm," *J. Informatics Telecommun. Eng.*, vol. 4, no. 2, pp. 286–293, 2021, doi: 10.31289/jite.v4i2.4185.



- [3] K. Zhang, W. Zuo, Y. Chen, ... D. M.-I. transactions on, and undefined 2017, "Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising," *ieeexplore.ieee.org*, vol. 8, no. 1, Dec. 2021, Accessed: May 16, 2025. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7839189/>
- [4] S. Dewi, F. Ramadhani, and S. Djasmayena, "Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network)," *Hello World J. Ilmu Komput.*, vol. 3, no. 2, pp. 68–73, 2024, doi: 10.56211/helloworld.v3i2.518.
- [5] W. Setiawan, A. Ghofur, F. Hastarita Rachman, and R. Rulaningtyas, *Deep Convolutional Neural Network AlexNet and Squeezenet for Maize Leaf Diseases Image Classification*. KINETIK: Game Technology, Information System, Computer Network, Computing, Electronics and Control, 2021. doi: 10.22219/kinetik.v6i4.1335.
- [6] Afis Julianto, Andi Sunyoto, and Ferry Wahyu Wibowo, "Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi," *Tek. Teknol. Inf. dan Multimed.*, vol. 3, no. 2, pp. 98–105, 2022, doi: 10.46764/teknimedia.v3i2.77.
- [7] M. A. Djohar *et al.*, "Segmentasi Citra Hati Menggunakan Metode Convolutional Neural Network dengan Arsitektur U-Net," *J. Informatics Telecommun. Eng.*, vol. 6, no. 1, pp. 221–234, 2022.
- [8] N. N. PRAMONO, "SIMULASI DEEP LEARNING PADA AUTONOMOUS VEHICLE MENGGUNAKAN NVIDIA JETBOT UNTUK MENJAGA JALUR KENDARAAN PADA LINTASAN DAN BERHENTI JIKA TERDETEKSI RINTANGAN," 2020.
- [9] A. Widiyawati, "BAB 4 STRUKTUR JARINGAN SARAF TIRUAN (ARTIFICIAL NEURAL NETWORKS)," *Deep Learn.*, p. 45, 2020.
- [10] D. W. N. Muhammad, "PEMODELAN HYBRID FUNGSI TRANSFER--GRU DENGAN NEWS SENTIMENT SEBAGAI DERET INPUT UNTUK PREDIKSI HARGA SAHAM (Studi Kasus Pada Data Harga Saham IHSG Periode 2019-2021)," Universitas Brawijaya, 2021.
- [11] D. A. Navastara, S. Kom, E. C. Fatichah, S. Kom, and M. Kom, "Implementasi Model Klasifikasi Menggunakan Metode Transfer Learning untuk Pemilihan Slice Citra 3D CBCT," 2020.
- [12] D. S. Ameera, A. T. Damaliana, and M. Idhom, "PENERAPAN MODEL HIBRIDA ARIMA-LSTM PADA PREDIKSI INFLASI DI INDONESIA," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 3, pp. 3743–3749, 2025.
- [13] L. M. Jaelani, "ANALISIS KLASIFIKASI CITRA SATELIT WORLDVIEW-2 MENGGUNAKAN MODEL DEEP LEARNING," 2020.
- [14] R. E. Nugraha, "Implementasi metode vader-lstm dalam pengujian pengaruh sentimen investor terhadap prediksi harga saham," Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta, 2020.
- [15] J. Xu, Z. Li, B. Du, M. Zhang, and J. Liu, "Reluplex made more practical: Leaky ReLU," in *2020 IEEE Symposium on Computers and communications (ISCC)*, 2020, pp. 1–7.
- [16] A. Maniatopoulos and N. Mitianoudis, "Learnable leaky relu (LeLeLU): An alternative accuracy-optimized activation function," *Information*, vol. 12, no. 12, p. 513, 2021.
- [17] S. Mastromichalakis, "ALReLU: A different approach on Leaky ReLU activation function to improve Neural Networks Performance," *arXiv Prepr. arXiv2012.07564*, 2020.
- [18] S. A. Fauji, "Analisis fungsi aktivasi jaringan syaraf tiruan untuk mendeteksi karakteristik bentuk gelombang spektra babi dan sapi," Universitas Islam Negeri Maulana Malik Ibrahim, 2012.
- [19] S. Rifky *et al.*, *Artificial Intelligence: Teori dan Penerapan AI di Berbagai Bidang*. PT. Sonpedia Publishing Indonesia, 2024.
- [20] S. Rahman, M. Ramli, F. Arnia, R. Muharar, M. Zen, and M. Ikhwan, *Convolutional Neural Networks Untuk Visi Komputer Jaringan Saraf Konvolusional untuk Visi Komputer (Arsitektur Baru, Transfer Learning, Fine Tuning, dan Pruning)*. Deepublish, 2021.