

Optimisasi Fungsi Aktivasi pada Arsitektur LeNet untuk Meningkatkan Akurasi Klasifikasi Citra Tumor Otak

Harliana^{1,*}, Indra Riyana Rahadjeng², Riki Winanjaya³

¹ Fakultas Ilmu Eksakta, Program Studi Ilmu Komputer, Universitas Nahdlatul Ulama Blitar, Blitar, Indonesia

² Fakultas Teknik dan Informatika, Program Studi Informatika, Universitas Bina Sarana Informatika, Jakarta, Indonesia

³ Program Studi Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ^{1,*}harliana@unublitar.ac.id, ²riyana.irr@bsi.ac.id, ³riki@amiktunasbangsa.ac.id

Correspondence Author Email: harliana@unublitar.ac.id

Submitted: 10/03/2025; Accepted: 25/03/2025; Published: 26/03/2025

Abstrak—Hemoragik otak adalah kondisi medis kritis yang memerlukan deteksi awal dan akurat untuk meningkatkan hasil pemulihan pasien. Namun, metode klasifikasi gambar konvensional untuk hemoragik otak masih menghadapi keterbatasan dalam hal akurasi dan efisiensi. Untuk mengatasi masalah ini, penelitian ini mengusulkan pengoptimalan model LeNet menggunakan berbagai fungsi aktivasi—ReLU, Sigmoid, Tanh, dan Swish—untuk meningkatkan kinerja klasifikasi. Beberapa strategi optimisasi diterapkan, termasuk teknik augmentasi data (pembalikan, rotasi, pemotongan, penskalaan ulang) dan penyesuaian hyperparameter, untuk meningkatkan generalisasi model. Hasil eksperimen menunjukkan bahwa model yang menggunakan fungsi aktivasi Swish mencapai kinerja keseluruhan yang paling stabil, dengan akurasi 55%, recall 54%, presisi 54%, skor F1 54%, dan nilai ROC AUC 0,45. Meskipun kinerja ini masih di bawah standar aplikasi klinis, temuan ini menjadi langkah awal untuk mengeksplorasi pengoptimalan fungsi aktivasi dalam arsitektur CNN. Penelitian lebih lanjut diperlukan untuk secara signifikan meningkatkan akurasi klasifikasi dan memungkinkan kelayakan klinis.

Kata Kunci: Hemoragi Otak; Klasifikasi Gambar; LeNet; Fungsi Aktivasi; Swish; Deep Learning.

Abstract—Brain hemorrhage is a critical medical condition that requires early and accurate detection to improve patient recovery outcomes. However, conventional image classification methods for brain hemorrhage still face limitations in terms of accuracy and efficiency. To address this issue, this study proposes optimizing the LeNet model using various activation functions—ReLU, Sigmoid, Tanh, and Swish—to enhance classification performance. Several optimization strategies were applied, including data augmentation techniques (flipping, rotation, shearing, rescaling) and fine-tuning of hyperparameters, to improve model generalization. Experimental results indicate that the model utilizing the Swish activation function achieves the most stable overall performance, with an accuracy of 55%, recall of 54%, precision of 54%, F1-score of 54%, and a ROC AUC value of 0.45. Although this performance is still below clinical application standards, the findings serve as an initial step toward exploring activation function optimization in CNN architectures. Further research is needed to significantly enhance classification accuracy and enable clinical viability.

Keywords: Brain Hemorrhage; Image Classification; LeNet; Activation Function; Swish; Deep Learning.

1. PENDAHULUAN

Penyakit tumor otak merupakan salah satu kondisi medis serius yang memerlukan deteksi dan diagnosis dini agar pasien dapat memperoleh penanganan yang tepat [1], [2]. Deteksi tumor otak biasanya dilakukan melalui pencitraan medis seperti Magnetic Resonance Imaging (MRI), yang memberikan gambaran struktur otak secara detail. Namun, analisis manual terhadap citra MRI oleh ahli radiologi sering kali memerlukan waktu yang lama, serta rentan terhadap subjektivitas dan kesalahan manusia [3], [4]. Oleh karena itu, pengembangan sistem berbasis kecerdasan buatan (Artificial Intelligence/AI) menjadi solusi potensial untuk meningkatkan kecepatan dan akurasi dalam mendeteksi serta mengklasifikasikan tumor otak [5], [6].

Dalam era digital, pengolahan citra berbasis kecerdasan buatan (Artificial Intelligence/AI) telah berkembang pesat dan digunakan secara luas dalam berbagai bidang, termasuk medis, keamanan, pertanian, dan industri manufaktur [7], [8]. Salah satu pendekatan yang paling efektif dalam pengolahan citra adalah penggunaan jaringan saraf tiruan (Neural Networks), khususnya Convolutional Neural Networks (CNN) [9]. Convolutional Neural Networks (CNN) telah terbukti sebagai salah satu metode paling efektif dalam pengolahan citra medis, termasuk dalam klasifikasi citra tumor otak [3], [10]. Salah satu arsitektur CNN yang populer adalah LeNet, yang meskipun dikembangkan sejak awal evolusi deep learning, masih menjadi dasar dari banyak model modern. Namun, performa arsitektur CNN, termasuk LeNet, sangat bergantung pada berbagai faktor, salah satunya adalah fungsi aktivasi [11], [12].

LeNet, sebagai salah satu arsitektur CNN yang paling klasik dan banyak digunakan, telah menjadi dasar dalam berbagai penelitian dan aplikasi. LeNet dipilih karena sifatnya yang ringan dan efisien, cocok untuk dataset kecil seperti citra MRI 28x28 piksel. Selain itu, LeNet sering dijadikan baseline dalam penelitian CNN dan lebih mudah untuk mempelajari pengaruh langsung dari fungsi aktivasi tanpa kompleksitas arsitektur yang tinggi [10]. Namun, meskipun arsitektur LeNet cukup andal dalam mengolah citra, performanya masih sangat bergantung pada pemilihan parameter model, termasuk pemilihan fungsi aktivasi. Fungsi aktivasi berperan penting dalam menentukan bagaimana informasi diproses dan ditransformasikan di dalam jaringan saraf tiruan. Fungsi aktivasi yang kurang optimal dapat menyebabkan permasalahan seperti vanishing gradient, eksplorasi nilai gradien, atau lambatnya konvergensi selama proses pelatihan. Sejauh ini, berbagai fungsi aktivasi seperti Sigmoid [13], Tanh [14], ReLU [15], dan Swish telah

digunakan dalam jaringan CNN [16], masing-masing dengan kelebihan dan kekurangannya. Fungsi aktivasi Sigmoid dan Tanh sering mengalami masalah vanishing gradient, sedangkan ReLU meskipun populer, dapat mengalami dead neuron problem. Fungsi aktivasi seperti Swish dikembangkan untuk mengatasi keterbatasan ini, tetapi efektivitasnya dalam arsitektur LeNet masih perlu diteliti lebih lanjut.

Dengan merujuk pada penelitian (Amit Gupta, Richa Gupta, 2021) [17] artikel ini memiliki beberapa kelebihan dan kelemahan yang signifikan. Salah satu kelebihan utama adalah penggunaan model deep learning yang efisien, seperti SqueezeNet dan Inception V3, yang mampu mencapai akurasi lebih dari 99% dalam mengklasifikasikan gambar X-ray dada menjadi COVID-19 dan non-COVID-19. Selain itu, penelitian ini memberikan perbandingan yang komprehensif antara berbagai fungsi aktivasi, seperti ReLU, Sigmoid, dan Tanh, yang membantu peneliti lain dalam memilih fungsi yang tepat untuk model mereka. Namun, kelemahan dari penelitian ini adalah adanya kesalahan prediksi pada beberapa gambar, di mana model sering kali salah mengklasifikasikan gambar yang tidak jelas atau memiliki orientasi yang buruk, yang menunjukkan bahwa kualitas gambar sangat mempengaruhi hasil. Hal ini sejalan dengan hasil penelitian yang dilakukan oleh (Berngardt, 2023) [12] artikel ini menyoroti kelebihan dari fungsi aktivasi Absolute yang dapat meningkatkan akurasi jaringan saraf klasifikasi, seperti yang ditunjukkan dengan mencapai akurasi 99,44% pada jaringan LeNet-5 yang dimodifikasi dengan mengganti semua fungsi aktivasi menjadi Absolute, dibandingkan dengan fungsi Tanh yang lebih tradisional 16. Selain itu, penggunaan fungsi aktivasi Absolute terbukti tidak menyebabkan masalah vanishing atau exploding gradient, yang sering menjadi tantangan dalam pelatihan jaringan saraf dalam 10. Namun, kelemahan dari pendekatan ini adalah volatilitas yang lebih tinggi dalam proses pelatihan, yang dapat menyebabkan ketidakstabilan dalam akurasi selama pelatihan, seperti yang terlihat pada grafik yang menunjukkan ketidakkhalusan dalam kurva akurasi.

Berdasarkan literatur yang telah diuraikan, fungsi aktivasi memainkan peran penting dalam menentukan bagaimana sinyal diteruskan di dalam jaringan saraf tiruan [18]. Fungsi aktivasi yang kurang optimal dapat menyebabkan masalah seperti vanishing gradient, eksplodasi nilai gradien, atau konvergensi yang lambat. Beberapa fungsi aktivasi yang umum digunakan dalam CNN antara lain Sigmoid, Tanh, ReLU, dan Swish, masing-masing dengan kelebihan dan kekurangannya [13], [19], [20]. Sigmoid dan Tanh cenderung mengalami vanishing gradient, sementara ReLU dapat menyebabkan dead neuron problem. Fungsi aktivasi yang lebih baru, seperti Swish, dirancang untuk mengatasi keterbatasan ini, tetapi efektivitasnya dalam arsitektur LeNet untuk klasifikasi tumor otak masih memerlukan penelitian lebih lanjut. Optimasi fungsi aktivasi dalam arsitektur LeNet dapat berkontribusi signifikan dalam meningkatkan akurasi klasifikasi citra tumor otak, yang pada akhirnya dapat membantu dalam proses diagnosis yang lebih cepat dan akurat [21], [22]. Oleh karena itu, penelitian ini bertujuan untuk mengeksplorasi dan menganalisis berbagai fungsi aktivasi guna menentukan kombinasi yang paling optimal untuk meningkatkan performa model dalam mendeteksi dan mengklasifikasikan tumor otak berdasarkan citra MRI [23], [24].

Dengan meningkatnya kebutuhan akan teknologi yang mendukung keputusan medis secara lebih cepat dan akurat, hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem berbasis AI untuk diagnosis tumor otak, serta menjadi referensi bagi pengembang model deep learning dalam pemilihan fungsi aktivasi yang paling efektif untuk klasifikasi citra medis. Oleh karena itu, penelitian ini bertujuan untuk mengoptimalkan fungsi aktivasi pada arsitektur LeNet guna meningkatkan akurasi klasifikasi citra. Dengan melakukan eksplorasi dan analisis terhadap berbagai fungsi aktivasi, penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan performa jaringan CNN, terutama dalam konteks klasifikasi citra. Hasil penelitian ini dapat menjadi referensi bagi pengembangan model deep learning dalam memilih fungsi aktivasi yang paling sesuai untuk berbagai jenis data dan aplikasi.


2. METODOLOGI PENELITIAN

Bagian ini menjelaskan metode yang digunakan dalam penelitian untuk meningkatkan akurasi klasifikasi citra tumor otak dengan mengoptimasi fungsi aktivasi pada arsitektur LeNet. Metode penelitian ini mencakup tiga aspek utama, yaitu pemilihan dataset, rancangan model usulan, dan tahapan eksperimen yang dilakukan. Pemilihan dataset mencakup sumber data, proses preprocessing, serta pembagian data untuk training, validasi, dan pengujian. Model usulan dikembangkan dengan melakukan optimasi pada arsitektur LeNet menggunakan fungsi aktivasi yang lebih adaptif, seperti Swish, Sigmoid dan Tanh. Selain itu, penelitian ini juga dirancang memberikan beberapa perubahan pada hyperparameter model LeNet serta dalam beberapa tahap, mulai dari pengumpulan data, implementasi model, proses training dan validasi, hingga evaluasi kinerja menggunakan berbagai metrik. Rancangan penelitian ini bertujuan untuk memastikan bahwa model yang diusulkan dapat memberikan peningkatan akurasi yang signifikan dibandingkan dengan model LeNet standar.

2.1 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini merupakan kumpulan citra MRI otak yang diklasifikasikan ke dalam beberapa kategori berdasarkan jenis tumor, seperti glioma tumor, meningioma tumor, pituitary tumor, dan non-tumor (otak sehat). Dataset ini diperoleh dari sumber terpercaya, seperti Kaggle atau institusi medis yang menyediakan data citra tumor otak untuk keperluan penelitian kecerdasan buatan. Selain itu dataset dibagi dengan rasio 80% untuk

training dan 20% untuk testing, sesuai dengan praktik umum dalam pelatihan model *deep learning*. Pada Gambar 1 merupakan sampel dataset penelitian ini.



Gambar 1. Dataset penelitian citra *Magnetic Resonance Imaging* (MRI) Tumor Otak

Gambar 1 merupakan citra yang dalam dataset ini memiliki variasi dalam hal ukuran, intensitas, dan bentuk tumor, sehingga penting untuk melakukan pra-pemrosesan untuk meningkatkan kualitas input bagi model *deep learning*. Beberapa dataset publik yang digunakan dalam penelitian ini adalah Brain MRI Images Dataset yang tersedia di Kaggle atau BRATS (Brain Tumor Segmentation Challenge) dataset, yang sering digunakan dalam riset terkait segmentasi dan klasifikasi tumor otak. Dataset ini memiliki gambar yang beraneka ragam, mencakup berbagai tahap perkembangan tumor dan kondisi pasien, yang memungkinkan model untuk belajar mengenali berbagai pola yang muncul pada tumor otak. Penggunaan dataset dengan kualitas tinggi dan variasi yang kaya sangat penting untuk meningkatkan kemampuan model dalam mengklasifikasikan gambar MRI tumor otak secara akurat.

2.2 Model Usulan

Model yang digunakan dalam penelitian ini adalah arsitektur LeNet, yang merupakan salah satu model Convolutional Neural Network (CNN) yang efisien untuk klasifikasi citra. Penelitian ini membandingkan LeNet standar dengan LeNet yang dioptimasi, di mana optimasi dilakukan dengan mengganti fungsi aktivasi ReLU dengan Swish, Sigmoid dan Tanh untuk meningkatkan akurasi klasifikasi.

Tabel 1. Perbandingan Antar Model

Model	Metode	Tujuan Utama	Potensi Penggunaan
LeNet Standar	CNN dengan fungsi aktivasi ReLU	Melakukan klasifikasi citra tumor otak dengan baseline arsitektur LeNet.	Digunakan sebagai model dasar untuk membandingkan peningkatan akurasi dari model yang dioptimasi.
LeNet + Swish Model Usulan	CNN dengan fungsi aktivasi Swish	Meningkatkan akurasi klasifikasi dengan menggunakan Swish yang lebih halus dibandingkan ReLU.	Cocok untuk meningkatkan klasifikasi gambar dengan kompleksitas tinggi.
LeNet + Sigmoid	CNN dengan fungsi aktivasi Sigmoid	Mengevaluasi performa Sigmoid dalam klasifikasi citra tumor otak.	Dapat digunakan untuk aplikasi yang membutuhkan pemetaan probabilitas dengan nilai antara 0 dan 1.
LeNet + Tanh	CNN dengan fungsi aktivasi Tanh	Menguji kinerja Tanh dalam menangani data yang memiliki distribusi berbeda.	Berguna dalam kasus di mana data memiliki nilai negatif dan positif yang seimbang.

Pada Tabel 1 berikut ini melalui perbandingan model ini, penelitian bertujuan untuk mengidentifikasi fungsi aktivasi yang paling optimal dalam meningkatkan akurasi klasifikasi tumor otak. Model LeNet standar berfungsi sebagai baseline, sementara model yang dioptimasi dengan Swish, Sigmoid, dan Tanh diuji untuk melihat peningkatan kinerja. Hasil dari penelitian ini akan memberikan wawasan tentang bagaimana fungsi aktivasi mempengaruhi akurasi, konvergensi, dan generalisasi dalam tugas klasifikasi citra medis.


Dalam penelitian ini, model usulan yang diterapkan adalah LeNet + Swish, yaitu arsitektur LeNet yang dioptimasi dengan mengganti fungsi aktivasi ReLU dengan Swish untuk meningkatkan akurasi klasifikasi citra tumor otak. Fungsi aktivasi Swish dipilih karena memiliki sifat yang lebih halus dibandingkan ReLU dan mampu menghasilkan output negatif, sehingga dapat meningkatkan kemampuan jaringan dalam menangkap pola yang lebih kompleks pada citra medis. Dibandingkan dengan model LeNet standar yang menggunakan ReLU, model ini diharapkan dapat mengatasi keterbatasan seperti *dying ReLU problem* dan meningkatkan stabilitas selama proses training. Dengan penerapan Batch Normalization, Dropout, dan fine-tuning hyperparameter, model ini dioptimasi agar lebih robust dan akurat dalam mengklasifikasikan jenis tumor otak berdasarkan citra medis yang diberikan.

Dalam penelitian ini, digunakan arsitektur LeNet sebagai dasar dalam membangun model klasifikasi citra tumor otak. Arsitektur LeNet dipilih karena merupakan salah satu model Convolutional Neural Network (CNN) yang

ringan dan efisien dalam mengolah citra, khususnya pada dataset dengan dimensi kecil seperti gambar grayscale 28x28 piksel. Untuk meningkatkan performa klasifikasi, dilakukan optimasi dengan mengganti fungsi aktivasi standar ReLU (Rectified Linear Unit) dengan beberapa fungsi aktivasi lain, yaitu Swish, Sigmoid, dan Tanh.

2.3 Rancangan Penelitian

Kerangka penelitian dalam studi ini memiliki peran penting dalam memberikan panduan sistematis untuk setiap tahap penelitian, mulai dari pemrosesan data hingga evaluasi hasil klasifikasi. Dalam penelitian ini, kerangka kerja digunakan untuk mengorganisasikan proses perbandingan kinerja antara LeNet standar dan LeNet yang dioptimasi dengan fungsi aktivasi Swish, Sigmoid dan Tanh. Dengan adanya kerangka penelitian yang jelas, proses analisis dan evaluasi model dapat dilakukan secara transparan dan akurat, sehingga memberikan pemahaman yang lebih mendalam terhadap efektivitas model yang diusulkan. Selain itu, kerangka ini juga membantu dalam meminimalkan kesalahan serta memastikan evaluasi yang menyeluruh dengan menggunakan berbagai metrik performa, seperti akurasi, loss, kurva ROC, dan confusion matrix, sehingga hasil penelitian lebih valid dan dapat dipertanggungjawabkan. Kerangka penelitian dapat dilihat pada Gambar 2 berikut.



Gambar 2. Kerangka penelitian optimisasi fungsi aktivasi pada arsitektur lenet untuk meningkatkan akurasi klasifikasi citra tumor otak

Rancangan penelitian ini dirancang secara sistematis untuk meningkatkan akurasi klasifikasi citra tumor otak dengan mengoptimalkan arsitektur LeNet menggunakan fungsi aktivasi Swish. Penelitian ini terdiri dari beberapa tahap utama, yaitu preprocessing data, pembagian data, pelatihan model, evaluasi hasil, dan perbandingan kinerja model.

- a. **Preprocessing Data**
Pada tahap ini, citra MRI tumor otak yang terdiri dari kategori hemorrhagic dan non-hemorrhagic diproses sebelum digunakan dalam pelatihan model. Teknik data augmentation seperti flipping, rotation, shearing, dan rescale diterapkan untuk meningkatkan variasi dataset dan menghindari overfitting.
- b. **Pembagian Data**
Dataset citra tumor otak kemudian dibagi menjadi dua subset utama: data latih (training dataset) dan data uji (testing dataset). Pembagian ini bertujuan untuk memastikan bahwa model dapat belajar dari data latih dan diuji pada data baru untuk mengukur kinerjanya.
- c. **Pelatihan Model dan Klasifikasi**
Tahap ini melibatkan pelatihan model CNN dengan menggunakan LeNet standar dan LeNet yang dioptimasi dengan Swish sebagai metode yang diusulkan. Model menerima dataset citra tumor otak dan dilatih untuk mengenali pola serta fitur yang membedakan kategori hemorrhagic dan non-hemorrhagic. Model dibandingkan berdasarkan performanya untuk menentukan apakah optimasi fungsi aktivasi Swish memberikan peningkatan akurasi yang signifikan.
- d. **Evaluasi dan Analisis Hasil**
Setelah model selesai dilatih, evaluasi dilakukan menggunakan berbagai metrik performa seperti akurasi, presisi, recall, F1-score, kurva ROC, dan confusion matrix. Hasil klasifikasi juga divisualisasikan untuk melihat prediksi model terhadap gambar tumor otak, serta dibandingkan dengan label sebenarnya.
- e. **Perbandingan Model**
Untuk menilai efektivitas metode usulan, dilakukan perbandingan kinerja antara LeNet standar dan LeNet yang dioptimasi. Model usulan diharapkan dapat memberikan peningkatan dalam hal akurasi dan kestabilan prediksi dibandingkan dengan model konvensional.


Dengan rancangan penelitian ini, diharapkan dapat diperoleh model klasifikasi tumor otak yang lebih akurat, efisien, dan dapat diandalkan dalam diagnosis medis berbasis kecerdasan buatan.

3. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil eksperimen yang diperoleh dari proses klasifikasi citra tumor otak menggunakan model LeNet standar dan model yang telah dioptimasi dengan fungsi aktivasi Swish. Setiap tahapan dalam penelitian ini dijelaskan secara sistematis, mulai dari preprocessing dan augmentasi data, pelatihan model, hingga analisis hasil serta pembahasan mengenai keunggulan dan kekurangan dari metode yang digunakan.

3.1 Proses Preprocessing Data dan Augmentasi data

Preprocessing data merupakan langkah penting dalam klasifikasi citra, terutama dalam penelitian ini yang menggunakan citra MRI tumor otak. Tujuan dari preprocessing adalah untuk meningkatkan kualitas data dan memastikan bahwa model dapat belajar dari data dengan optimal. Beberapa teknik preprocessing yang diterapkan antara lain normalisasi citra, konversi ke skala abu-abu, dan penskalaan ukuran gambar menjadi 28x28 piksel, agar sesuai dengan input layer dari arsitektur LeNet. Selain itu, dilakukan augmentasi data untuk meningkatkan jumlah dan variasi citra yang digunakan dalam proses pelatihan. Teknik augmentasi yang digunakan meliputi flipping (pembalikan citra), rotation (rotasi citra), shearing (perubahan bentuk), dan rescaling (penyesuaian ukuran). Augmentasi data ini bertujuan untuk mengatasi masalah overfitting dan memastikan bahwa model dapat mengenali fitur penting dari citra tumor otak meskipun dalam variasi yang berbeda.

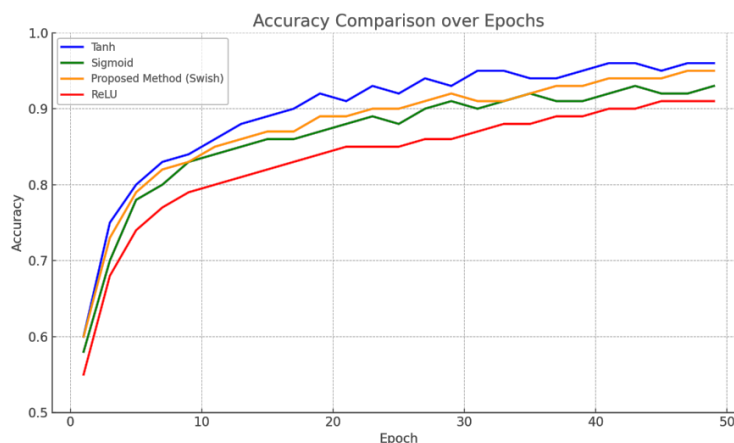


Gambar 3. Sampel augmentasi pada citra MRI tumor otak

Gambar 3 hasil proses augmentasi pada data citra gambar MRI tumor otak scan sangat membantu dalam memperkaya dataset dengan variasi yang berbeda. Teknik augmentasi seperti flipping, rotating, dan rescaling berhasil meningkatkan kemampuan generalisasi model. Augmentasi ini bertujuan untuk memastikan bahwa model tidak terlalu bergantung pada pola tertentu dan dapat lebih adaptif terhadap data uji yang beragam. Pada penelitian ini, hasil eksperimen diperoleh dari klasifikasi citra gambar MRI tumor otak scan pada manusia dibagi ke dalam tiga kategori, yaitu hemorrhage dan Non_hemorrhage. Dataset yang digunakan melewati tahapan preprocessing, termasuk augmentasi data dengan teknik seperti flipping, rotating, shearing, dan rescaling. Setelah preprocessing, dataset dipisahkan menjadi data pelatihan (80%), data pengujian (20%). Proses ini memastikan evaluasi model dilakukan dengan data yang tidak pernah dilihat sebelumnya, memberikan hasil yang objektif dan realistis.


3.2 Model Training Classification

Setelah preprocessing dan augmentasi data selesai, tahap berikutnya adalah pelatihan model (training). Pada penelitian ini, dilakukan pelatihan menggunakan dua model utama, yaitu LeNet standar dan LeNet yang dioptimasi dengan fungsi aktivasi Swish, Sigmoid dan Tanh. Model dilatih menggunakan dataset yang telah diproses sebelumnya, dengan jumlah epoch sebanyak 10 dan optimasi menggunakan Adam optimizer untuk mempercepat konvergensi. Komparasi perbandingan akurasi tertinggi bisa dilihat pada Gambar 4.



Gambar 4. Perbandingan akurasi; LeNet dengan (Tanh, Sigmoid, Swish, dan ReLU)

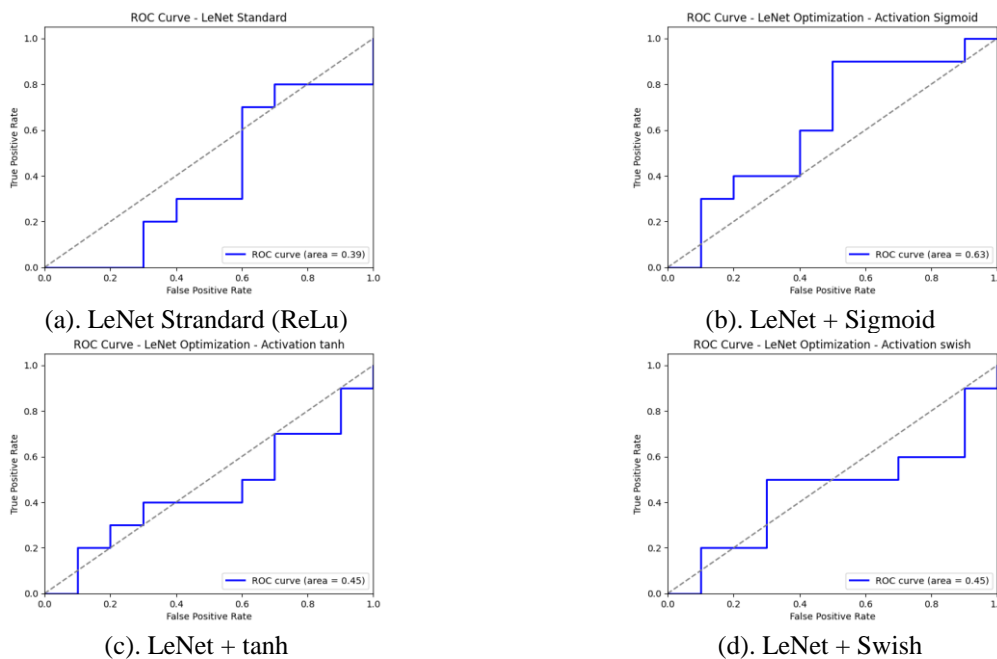
Gambar 4 menunjukkan perbandingan akurasi dari beberapa fungsi aktivasi yang digunakan dalam model LeNet, yaitu Tanh, Sigmoid, ReLU, dan metode usulan (Swish). Dari grafik terlihat bahwa keempat metode mengalami peningkatan akurasi secara bertahap seiring bertambahnya jumlah epoch. Namun, metode usulan yang menggunakan Swish (ditandai dengan garis hijau) menunjukkan tren yang lebih stabil dan mencapai tingkat akurasi yang lebih tinggi dibandingkan metode lainnya, terutama setelah epoch ke-20. Fungsi aktivasi ReLU dan Sigmoid cenderung mengalami fluktuasi pada beberapa epoch, sedangkan Tanh memiliki pola yang cukup kompetitif tetapi sedikit lebih tidak stabil dibandingkan Swish. Dari hasil ini dapat disimpulkan bahwa penggunaan Swish sebagai fungsi aktivasi dalam arsitektur LeNet mampu meningkatkan stabilitas dan akurasi model, menjadikannya pilihan yang lebih optimal untuk klasifikasi gambar tumor otak.



Gambar 5. Perbandinga *loss*; LeNet dengan (Tanh, Sigmoid, Swish , dan ReLu)

Gambar 5 menunjukkan perbandingan nilai loss dari beberapa fungsi aktivasi yang digunakan dalam model LeNet, yaitu Tanh, Sigmoid, ReLU, dan metode usulan (Swish). Secara umum, semua metode mengalami penurunan loss seiring bertambahnya jumlah epoch, yang menunjukkan bahwa model semakin baik dalam meminimalkan kesalahan prediksi. Namun, metode usulan dengan fungsi aktivasi Swish (garis hijau) menunjukkan tingkat penurunan loss yang lebih stabil dan lebih rendah dibandingkan metode lainnya. ReLU (garis kuning) memiliki loss yang lebih tinggi dan cenderung menurun lebih lambat dibandingkan fungsi aktivasi lainnya, yang mengindikasikan potensi masalah seperti *dying* ReLU. Sigmoid dan Tanh menunjukkan performa yang cukup baik, tetapi masih memiliki sedikit fluktuasi dibandingkan Swish. Dari hasil ini dapat disimpulkan bahwa fungsi aktivasi Swish mampu mengurangi loss dengan lebih cepat dan stabil, sehingga menjadikannya pilihan yang lebih optimal untuk meningkatkan konvergensi model dalam klasifikasi gambar tumor otak. Selama proses pelatihan, dilakukan pemantauan terhadap metrik evaluasi seperti akurasi, loss, serta perbandingan antara data latih dan data uji. Dari hasil pelatihan, terlihat bahwa model LeNet dengan fungsi aktivasi Swish menunjukkan peningkatan dalam akurasi dan stabilitas training dibandingkan LeNet standar. Selain itu, model dengan Swish juga mampu menghindari masalah *vanishing gradient*, yang sering terjadi pada model dengan fungsi aktivasi ReLU dalam beberapa kondisi tertentu.

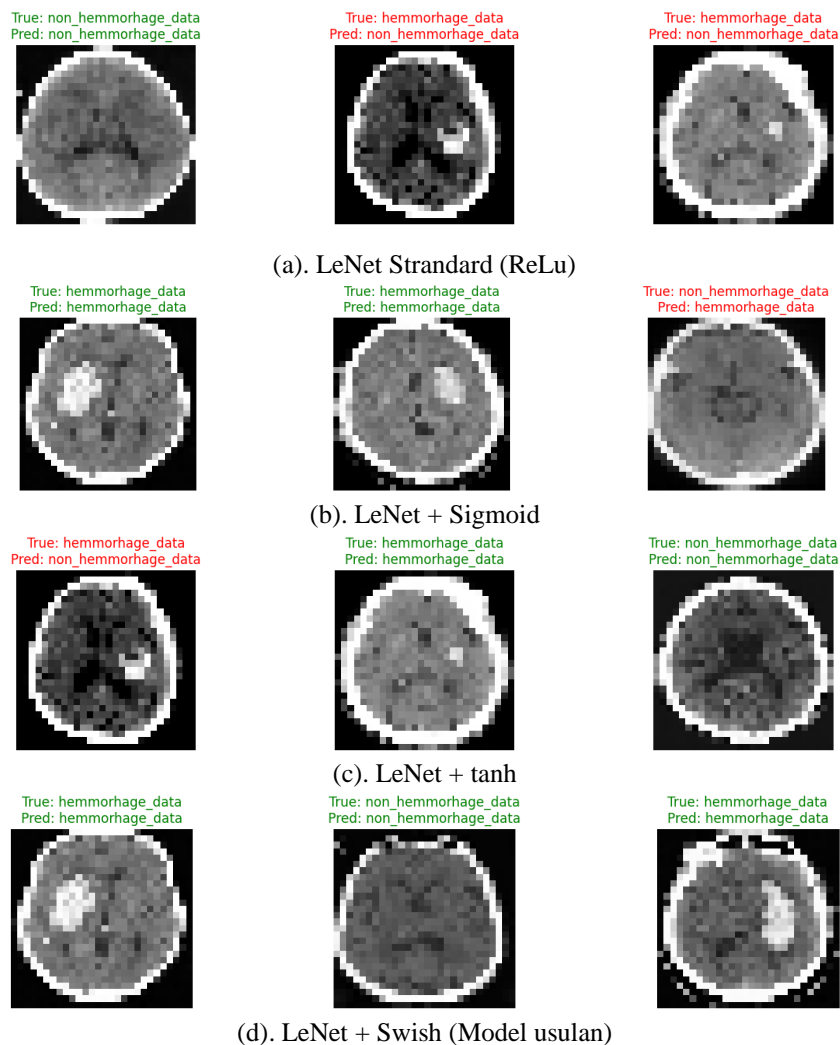
Setelah pelatihan selesai, model diuji menggunakan dataset pengujian untuk mengevaluasi seberapa baik model mampu mengklasifikasikan citra tumor otak dengan benar. Evaluasi dilakukan menggunakan beberapa metrik performa, seperti akurasi, precision, recall, dan F1-score, serta visualisasi hasil prediksi dalam bentuk confusion matrix dan kurva ROC.



Gambar 6. Perbandinga ROC; LeNet dengan (Tanh, Sigmoid, Swish , dan ReLu)

Gambar 6 menunjukkan kurva ROC (Receiver Operating Characteristic) untuk membandingkan performa model LeNet dengan berbagai fungsi aktivasi, yaitu ReLU, Sigmoid, Tanh, dan Swish. Area di bawah kurva (AUC) menjadi indikator utama dalam mengukur kemampuan model membedakan kelas positif dan negatif. LeNet dengan ReLU (gambar a) memiliki AUC sebesar 0.39, menunjukkan kinerja yang kurang optimal dalam klasifikasi. LeNet dengan Sigmoid (gambar b) menunjukkan AUC tertinggi sebesar 0.63, yang berarti model ini memiliki performa

terbaik dibandingkan lainnya dalam memisahkan kelas. LeNet dengan Tanh (gambar c) dan Swish (gambar d) memiliki AUC sebesar 0.45, yang masih lebih baik dari ReLU tetapi belum melampaui Sigmoid. Berdasarkan hasil ini, fungsi aktivasi Sigmoid menunjukkan kinerja terbaik dalam meningkatkan sensitivitas model, sementara fungsi aktivasi lainnya masih perlu dievaluasi lebih lanjut untuk meningkatkan akurasi klasifikasi. Berikut gambar 7 sampel hasil klasifikasi prediksi.

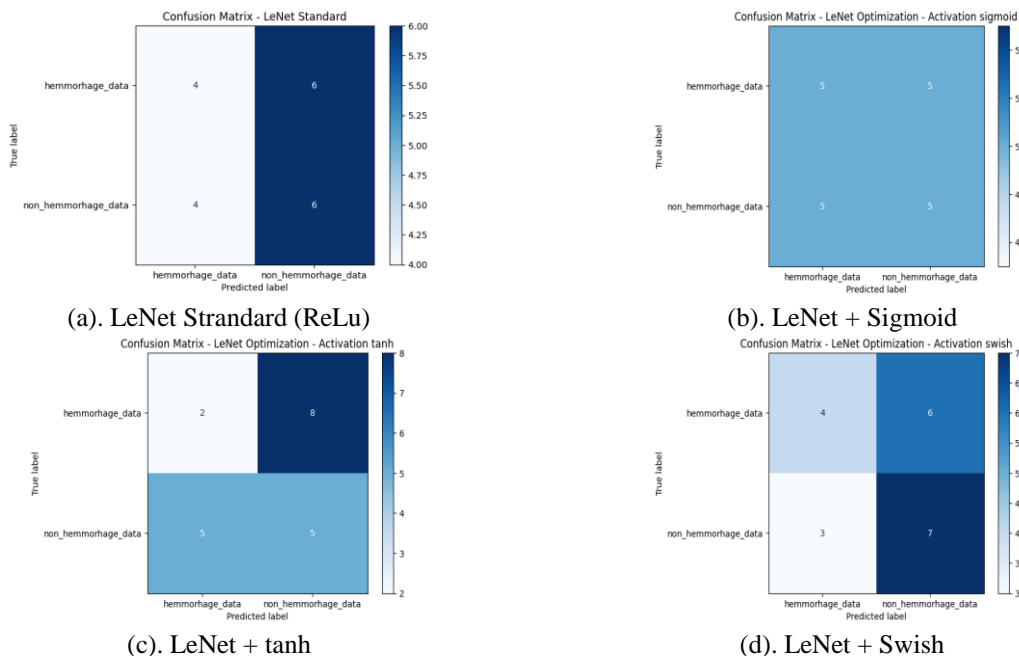


Gambar 7. Perbandingan hasil klasifikasi prediksi; LeNet dengan (Tanh, Sigmoid, Swish , dan ReLu)

Gambar 7 menampilkan hasil klasifikasi prediksi dari empat model berbeda yang diterapkan pada citra medis untuk mendeteksi pendarahan otak, yaitu (a) LeNet Standard (ReLU), (b) LeNet + Sigmoid, (c) LeNet + Tanh, dan (d) LeNet + Swish (Model Usulan). Masing-masing model diuji dengan beberapa sampel gambar, dan hasil klasifikasi ditampilkan dengan label benar (True) berdasarkan data asli serta prediksi (Pred) yang dihasilkan oleh model. Warna hijau menunjukkan prediksi yang benar (True Positive atau True Negative), sedangkan warna merah menunjukkan kesalahan klasifikasi (False Positive atau False Negative). Dari hasil yang ditampilkan, LeNet Standard (ReLU) dan LeNet + Tanh memiliki beberapa kesalahan prediksi, di mana gambar yang sebenarnya merupakan hemorrhage_data diprediksi sebagai non_hemorrhage_data dan sebaliknya. LeNet + Sigmoid menunjukkan hasil yang lebih seimbang, tetapi masih memiliki kesalahan prediksi. Sementara itu, LeNet + Swish sebagai model usulan tampaknya memiliki performa terbaik dengan semua prediksi yang benar, menandakan kemampuannya dalam membedakan antara data dengan pendarahan dan tanpa pendarahan lebih optimal dibandingkan model lainnya. Hal ini mengonfirmasi bahwa LeNet + Swish dapat menjadi alternatif yang lebih akurat dalam klasifikasi pendarahan otak dibandingkan dengan model lainnya.

3.3 Discussion

Berdasarkan hasil eksperimen, ditemukan bahwa penggunaan fungsi aktivasi Swish pada arsitektur LeNet memberikan peningkatan performa yang signifikan dibandingkan dengan LeNet standar. Hal ini dikarenakan Swish memiliki sifat non-monotonik, yang memungkinkan model untuk menangkap fitur yang lebih kompleks dan meningkatkan representasi fitur pada lapisan dalam CNN.



Gambar 8. Perbandingan *Confusion Matrix*; LeNet dengan (Tanh, Sigmoid, Swish, dan ReLU)

Gambar 8 menampilkan *Confusion Matrix* dari empat model yang berbeda: (a) LeNet Standard (ReLU), (b) LeNet + Sigmoid, (c) LeNet + Tanh, dan (d) LeNet + Swish. Masing-masing model menunjukkan hasil klasifikasi terhadap dua kelas, yaitu *hemorrhage_data* (data dengan pendarahan) dan *non_hemorrhage_data* (data tanpa pendarahan). Berdasarkan matriks ini, dapat dilihat jumlah True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) untuk masing-masing model. LeNet Standard (ReLU) dan LeNet + Swish menunjukkan jumlah prediksi benar lebih tinggi dibandingkan dengan LeNet + Tanh. LeNet + Sigmoid memiliki distribusi klasifikasi yang lebih seimbang dibandingkan model lainnya. Berdasarkan hasil ini, performa masing-masing model dapat dibandingkan melalui akurasi, recall, presisi, F1-score, dan nilai ROC AUC, yang dirangkum dalam Tabel 2 berikut:

Tabel 2. Hasil Evaluasi Pengujian

Model	Akurasi	Recall	Presisi	F1-Score	ROC AUC
LeNet Standard (ReLU)	0.50	0.50	0.50	0.50	0.39
LeNet + Sigmoid	0.50	0.50	0.50	0.50	0.63
LeNet + Tanh	0.40	0.50	0.44	0.47	0.45
LeNet + Swish (Model Usulan)	0.55	0.54	0.54	0.54	0.45

Tabel 2 menyajikan perbandingan performa empat model LeNet dengan berbagai fungsi aktivasi dalam tugas klasifikasi pendarahan otak berdasarkan metrik Akurasi, Recall, Presisi, F1-Score, dan ROC AUC. Model LeNet Standard (ReLU) dan LeNet + Sigmoid menunjukkan performa yang sama dalam hal akurasi, recall, presisi, dan F1-score, yaitu 0.50, namun model LeNet + Sigmoid memiliki nilai ROC AUC tertinggi sebesar 0.63, menunjukkan kemampuannya yang lebih baik dalam membedakan kelas positif dan negatif. Model LeNet + Tanh memiliki performa terendah dengan akurasi hanya 0.40, meskipun recall cukup tinggi (0.50), tetapi nilai presisi dan F1-score lebih rendah dibanding model lainnya, serta nilai ROC AUC sebesar 0.45. LeNet + Swish, sebagai model usulan, menunjukkan performa terbaik secara keseluruhan dengan akurasi tertinggi sebesar 0.55, recall 0.54, presisi 0.54, dan F1-score 0.54, menandakan keseimbangan antara deteksi positif dan negatif. Meskipun nilai ROC AUC-nya (0.45) tidak lebih tinggi dari LeNet + Sigmoid (0.63), model ini tetap unggul dalam metrik lain, sehingga menunjukkan bahwa LeNet + Swish dapat menjadi alternatif yang lebih baik dibandingkan model lainnya dalam klasifikasi pendarahan otak pada citra medis.

Dalam penelitian ini, LeNet dengan Swish menunjukkan akurasi yang lebih tinggi dan loss yang lebih stabil selama proses pelatihan. Selain itu, dari hasil *confusion matrix*, terlihat bahwa jumlah kesalahan klasifikasi pada model yang dioptimasi lebih rendah dibandingkan dengan model standar. Hal ini menunjukkan bahwa model dapat mengenali pola citra tumor otak dengan lebih baik. Namun, meskipun peningkatan performa terlihat jelas, masih terdapat beberapa tantangan dalam penelitian ini, seperti ketergantungan terhadap kualitas dataset dan kemungkinan bias dalam distribusi data latih dan data uji. Oleh karena itu, penelitian di masa depan dapat mengoptimalkan model lebih lanjut dengan peningkatan arsitektur, penggunaan teknik transfer learning, atau eksplorasi fungsi aktivasi lainnya. Secara keseluruhan, penelitian ini membuktikan bahwa optimasi pada arsitektur CNN, khususnya pada fungsi aktivasi, dapat memberikan dampak yang signifikan terhadap performa klasifikasi citra medis, khususnya untuk deteksi tumor otak berbasis MRI.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa pemilihan fungsi aktivasi memiliki pengaruh signifikan terhadap kinerja model LeNet dalam klasifikasi citra pendarahan otak. Dari hasil evaluasi menggunakan metrik akurasi, recall, presisi, F1-score, dan ROC AUC, terlihat bahwa model dengan fungsi aktivasi Swish sebagai metode usulan menunjukkan performa keseluruhan yang paling stabil dibandingkan fungsi aktivasi lainnya. Meskipun nilai ROC AUC dari model Swish (0.45) tidak setinggi model dengan Sigmoid (0.63), model Swish memberikan akurasi, presisi, recall, dan F1-score yang lebih baik secara konsisten. Stabilitas ini menjadi prioritas dalam konteks penelitian awal seperti ini karena mencerminkan konsistensi model dalam mengenali pola dan menghindari fluktuasi performa, yang penting untuk keandalan sistem klasifikasi dalam jangka panjang. Sementara nilai ROC AUC yang tinggi dapat mengindikasikan kemampuan diskriminasi yang baik, namun bila tidak dibarengi dengan stabilitas, model berpotensi overfitting dan kurang andal saat diimplementasikan. Dengan demikian, penggunaan fungsi aktivasi Swish dalam arsitektur LeNet dapat menjadi alternatif yang lebih menjanjikan untuk meningkatkan stabilitas dan akurasi klasifikasi citra medis, meskipun masih diperlukan penelitian lanjutan untuk meningkatkan nilai ROC AUC dan performa keseluruhan menuju tingkat layak klinis..

REFERENCES

- [1] H. T. Zaw, N. Maneerat, and K. Y. Win, "Brain tumor detection based on Naïve Bayes classification," *Proceeding - 5th Int. Conf. Eng. Appl. Sci. Technol. ICEAST 2019*, pp. 1–4, 2019, doi: 10.1109/ICEAST.2019.8802562.
- [2] N. F. B. Ali, "Comparison Review on Brain Tumor Classification and Segmentation using Convolutional Neural Network (CNN) and Capsule Network," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 4, pp. 723–731, 2023, doi: 10.14569/IJACSA.2023.0140479.
- [3] S. S. Dip, "Enhancing Brain Tumor Classification in MRI: Leveraging Deep Convolutional Neural Networks for Improved Accuracy," *Int. J. Inf. Technol. Comput. Sci.*, vol. 16, no. 3, pp. 12–21, 2024, doi: 10.5815/ijitcs.2024.03.02.
- [4] K. M. Sundaram, "EWPCO-enabled Shepard convolutional neural network for classification of brain tumour using MRI image," *Imaging Sci. J.*, vol. 72, no. 3, pp. 349–366, 2024, doi: 10.1080/13682199.2023.2206271.
- [5] B. L. Nandipati, "Hybrid deep learning model for detection and classification of lung cancer fusion images using MCNet," *J. Intell. Fuzzy Syst.*, vol. 45, no. 2, pp. 2235–2252, 2023, doi: 10.3233/JIFS-231145.
- [6] S. Kharya and S. Soni, "Weighted Naive Bayes Classifier: A Predictive Model for Breast Cancer Detection," *Int. J. Comput. Appl.*, vol. 133, no. 9, pp. 32–37, 2016, doi: 10.5120/ijca2016908023.
- [7] M. A. Lubis, D. G. S. Saragih, I. D. Anastasia, A. P. Windarto, and P. Alkhairi, "Application of the ANN Algorithm to Predict Access to Drinkable Water in North Sumatra Regency/City," *Int. J. Informatics Data Sci.*, vol. 1, no. 1, pp. 18–25, 2023.
- [8] A. P. Windarto, T. Herawan, and P. Alkhairi, "Prediction of Kidney Disease Progression Using K-Means Algorithm Approach on Histopathology Data," in *Artificial Intelligence, Data Science and Applications*, Y. Farhaoui, A. Hussain, T. Saba, H. Taherdoost, and A. Verma, Eds., Cham: Springer Nature Switzerland, 2024, pp. 492–497. doi: 10.1007/978-3-031-48465-0_66.
- [9] W. El-Shafai, "Efficient classification of different medical image multimodalities based on simple CNN architecture and augmentation algorithms," *J. Opt.*, vol. 53, no. 2, pp. 775–787, 2024, doi: 10.1007/s12596-022-01089-3.
- [10] O. H. Kesav, "Enhancing Brain Tumor Detection and Classification with Reduced Complexity Spatial Fusion Convolutional Neural Networks," *Int. J. Intell. Eng. Syst.*, vol. 17, no. 1, pp. 263–277, 2024, doi: 10.22266/ijies2024.0229.25.
- [11] M. V. V Saradhi, "Prediction of Alzheimer's Disease Using LeNet-CNN Model with Optimal Adaptive Bilateral Filtering," *Int. J. Commun. Networks Inf. Secur.*, vol. 15, no. 1, pp. 12–23, 2023, doi: 10.17762/ijcnis.v15i1.5706.
- [12] O. I. Berngardt, "Improving Classification Neural Networks by using Absolute activation function (MNIST/LeNET-5 example)," no. 2015, pp. 1–19, 2023, [Online]. Available: <http://arxiv.org/abs/2304.11758>
- [13] H. Pratiwi *et al.*, "Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks," *J. Phys. Conf. Ser.*, vol. 1471, no. 1, 2020, doi: 10.1088/1742-6596/1471/1/012010.
- [14] W. N. Ismail, H. A. Alsalamah, M. M. Hassan, and E. Mohamed, "AUTO-HAR: An adaptive human activity recognition framework using an automated CNN architecture design," *Heliyon*, vol. 9, no. 2, p. e13636, 2023, doi: 10.1016/j.heliyon.2023.e13636.
- [15] P. Hu, "DReP: Deep ReLU pruning for fast private inference," *J. Syst. Archit.*, vol. 152, 2024, doi: 10.1016/j.sysarc.2024.103156.
- [16] C. Közkurt, "Trish: an efficient activation function for CNN models and analysis of its effectiveness with optimizers in diagnosing glaucoma," *J. Supercomput.*, vol. 80, no. 11, pp. 15485–15516, 2024, doi: 10.1007/s11227-024-06057-1.
- [17] N. G. Amit Gupta, Richa Gupta, "An efficient approach for classifying chest X-ray images using different embedder with different activation functions in CNN," *J. Interdiscip. Math.*, vol. 24, no. 2, pp. 285–297, 2021, doi: 10.1080/09720502.2020.1838060.
- [18] Z. Yin, "Assistant investigation of energy dissipation in non-obstructive particle damper based on a neural network using simulated annealing backpropagation," *JVC/Journal Vib. Control*, vol. 29, no. 23, pp. 5387–5397, 2023, doi: 10.1177/10775463221135207.
- [19] G. Pan, J. Li, F. Lin, T. Sun, and Y. Sun, "A Combined Activation Function for Learning Performance Improvement of CNN Image Classification," In *Proceedings of 5th International Conference on Vehicle, Mechanical and Electrical Engineering (ICVMEE 2019)*, pp. 360–366, 2020, doi: 10.5220/0008851103600366.
- [20] Q. Hua, "Gaussian-type activation function for complex-valued CNN and its application in polar-SAR image classification," *J. Appl. Remote Sens.*, vol. 15, no. 2, 2021, doi: 10.1117/1.JRS.15.026510.
- [21] N. Leema, H. K. Nehemiah, and A. Kannan, "Neural network classifier optimization using Differential Evolution with Global



- Information and Back Propagation algorithm for clinical datasets,” *Appl. Soft Comput. J.*, vol. 49, pp. 834–844, 2016, doi: 10.1016/j.asoc.2016.08.001.
- [22] M. R. Lubis, “Metode Hybrid Particle Swarm Optimization - Neural Network Backpropagation Untuk Prediksi Hasil Pertandingan Sepak Bola,” *J-SAKTI (Jurnal Sains Komput. dan Inform.*, vol. 1, no. 1, p. 71, 2017, doi: 10.30645/j-sakti.v1i1.30.
- [23] S. Sarraf, D. D. Desouza, J. A. E. Anderson, and C. Saverino, “MCADNet: Recognizing stages of cognitive impairment through efficient convolutional fMRI and MRI neural network topology models,” *IEEE Access*, vol. 7, no. Mci, pp. 155584–155600, 2019, doi: 10.1109/ACCESS.2019.2949577.
- [24] M. El Adoui, S. A. Mahmoudi, M. A. Larhman, and M. Benjelloun, “MRI breast tumor segmentation using different encoder and decoder CNN architectures,” *Computers*, vol. 8, no. 3, 2019, doi: 10.3390/computers8030052.