

Analisis Perbandingan Fungsi Aktivasi CNN Pada Pengelompokan Jenis Beras Berdasarkan Mutu Beras

Muhammad Rais Wathani^{1,*}, Nur Hidayati²

¹Universitas Islam Kalimantan Muhammad Arsyad Al Banjari, Indonesia

²Universitas Bina Sarana Informatika, Indonesia

E-mail: ¹raiswathani@uniska-bjm.ac.id, ²nur.nrh@bsi.ac.id

Abstract

This article discusses the comparative analysis of activation functions in Convolutional Neural Network (CNN) for clustering rice types based on rice quality. Two activation functions tested are LogSoftmax and Softmax. Through data collection and CNN architecture implementation, we trained and evaluated the models using evaluation metrics such as accuracy, precision, recall, and F1 score. The results show significant differences in model performance based on the activation function used. These findings provide practical guidance for the food industry in selecting the optimal activation function for clustering rice types. The test results also indicate that the highest accuracy of 0.9787 or 97.87% was achieved with the LogSoftmax activation function architecture model, with the highest precision, recall, and F1 score. On the other hand, the Softmax activation function achieved an accuracy of 0.9286 or 92.86%.

Keywords: Convolutional Neural Network, activation function, clustering rice types, rice quality, food industry

Abstrak

Artikel ini membahas analisis perbandingan fungsi aktivasi Convolutional Neural Network (CNN) dalam pengelompokan jenis beras berdasarkan mutu beras. dua fungsi aktivasi yang diuji yaitu LogSoftmax dan Softmax. Melalui pengumpulan data dan implementasi arsitektur CNN, kami melatih dan menguji model menggunakan evaluasi metrik seperti akurasi, presisi, perolehan kembali, dan skor F1. Hasil menunjukkan perbedaan signifikan dalam kinerja model berdasarkan fungsi aktivasi yang digunakan. Temuan ini memberikan panduan praktis untuk industri pangan dalam memilih fungsi aktivasi yang optimal dalam pengelompokan jenis beras. Hasil pengujian yang didapat juga bahwa dimana diperoleh akurasi model terbesar 0,9787 atau 97,87% dengan nilai precision, recall, dan f1_score tertinggi terdapat pada kelas model arsitektur aktivasi LogSoftmax. Sedangkan pada aktivasi Softmax akurasi 0,9286 atau 92,86%.

Keywords: Convolutional Neural Network, fungsi aktivasi, pengelompokan jenis beras, mutu beras, industri pangan

1. Pendahuluan

Beras merupakan salah satu komoditas pangan yang sangat penting di berbagai negara, terutama di Asia, termasuk Indonesia. Mutu beras menjadi faktor kunci yang mempengaruhi nilai jual, kualitas gizi, dan kepuasan konsumen [1]. Dalam industri beras, pengelompokan jenis beras berdasarkan mutu beras menjadi suatu langkah penting untuk memudahkan proses distribusi dan pengolahan [2], [3].

Seiring dengan perkembangan teknologi, kecerdasan buatan telah menjadi bidang yang semakin relevan dalam meningkatkan efisiensi dan akurasi proses pengelompokan jenis beras. Salah satu teknik dalam kecerdasan buatan yang telah berhasil digunakan secara luas adalah Convolutional Neural Network (CNN) [4]. CNN telah terbukti efektif dalam mempelajari fitur-fitur berdasarkan representasi spasial dari data, dan telah sukses

diterapkan dalam berbagai bidang seperti pengenalan citra, pengenalan suara, dan pengolahan bahasa alami [5], [6].

Pengenalan dan klasifikasi beras melalui computer vision menjadi topik praktik akhir-akhir ini. Ada beberapa penelitian dan makalah akademis yang relevan dalam bidang ini dengan menggunakan metode penanganan dan ekstraksi data serta pendekatan rekognisi. Misalnya Nguyen Hong Son dan Nguyen Thai-Nghe [3] dengan judul riset Deep Learning for Rice Quality Classification yang menghasilkan Hasil percobaan untuk 2000 gambar nyata memberikan akurasi 93,85%. Hasil ini menunjukkan bahwa evaluasi dan klasifikasi kualitas beras dapat dilakukan secara otomatis dengan menggunakan pendekatan Deep Learning sangat baik [7].

Meskipun penggunaan CNN telah memberikan hasil yang menjanjikan dalam berbagai aplikasi, pemilihan fungsi aktivasi yang tepat dalam arsitektur CNN masih menjadi faktor kritis yang mempengaruhi performa model. Fungsi aktivasi berperan dalam memperkenalkan non-linearitas ke dalam model CNN, yang memungkinkan model untuk mempelajari hubungan yang kompleks antara fitur-fitur input [8].

Namun, ada berbagai fungsi aktivasi yang dapat digunakan dalam CNN, seperti ReLU (Rectified Linear Unit), Sigmoid, Tanh (Hyperbolic Tangent), Leaky ReLU. Setiap fungsi aktivasi memiliki karakteristik yang berbeda dalam mengolah informasi dan dapat memberikan pengaruh yang berbeda pada kinerja model CNN dalam pengelompokan jenis beras berdasarkan mutu beras [9], [10]. Ada pun fungsi aktivasi output untuk mengubah output mentah dari jaringan saraf menjadi vektor probabilitas, yang dipertimbangkan masalah klasifikasi multikelas dengan N kelas, berupa fungsi aktivasi *Softmax* dan *LogSoftmax* [11].

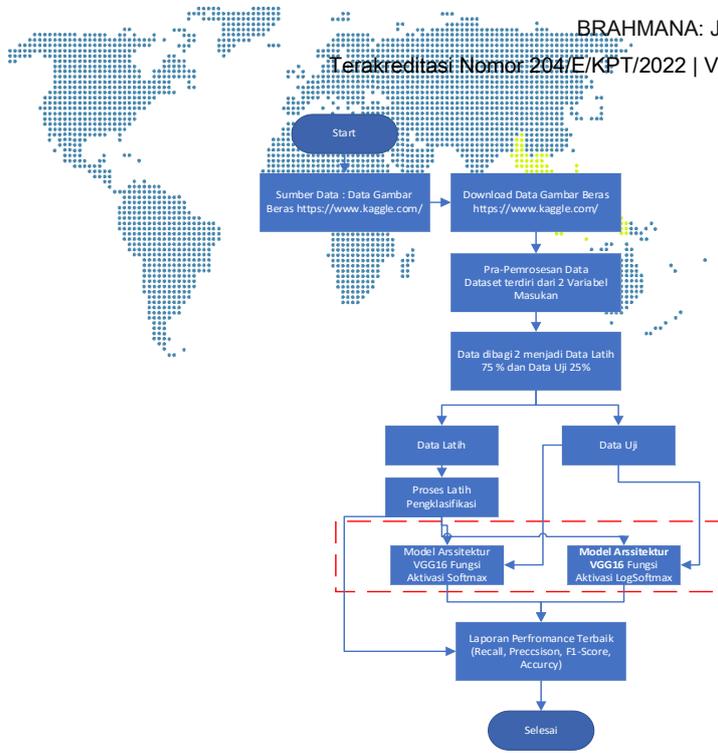
Meskipun telah ada beberapa penelitian yang menggali tentang perbandingan fungsi aktivasi dalam konteks CNN, masih diperlukan penelitian yang lebih mendalam dan spesifik untuk melihat bagaimana fungsi aktivasi tersebut berperan dalam pengelompokan jenis beras berdasarkan mutu beras. Analisis ini dapat memberikan wawasan yang berharga dalam memilih fungsi aktivasi yang paling cocok untuk tugas ini [12].

Dalam konteks tersebut, artikel ini bertujuan untuk melakukan analisis perbandingan fungsi aktivasi CNN pada pengelompokan jenis beras berdasarkan mutu beras. Penelitian ini diharapkan dapat memberikan pemahaman yang lebih baik tentang kinerja dan perbedaan masing-masing fungsi aktivasi dalam hal akurasi pengelompokan jenis beras [13], [14].

Dengan mengevaluasi dan membandingkan hasil eksperimen menggunakan beberapa fungsi aktivasi yang berbeda, diharapkan artikel ini dapat memberikan panduan praktis bagi para peneliti dan praktisi dalam memilih fungsi aktivasi yang tepat untuk pengelompokan jenis beras berdasarkan mutu beras. Yaitu fungsi aktivasi *Softmax* atau *LogSoftmax*.

2. Metodologi Penelitian

Metode penelitian ini dirancang untuk memberikan pemahaman yang komprehensif tentang perbandingan fungsi aktivasi CNN dalam pengelompokan jenis beras berdasarkan mutu beras [15], [16]. Dengan demikian, artikel ini diharapkan dapat memberikan kontribusi berharga bagi penelitian di bidang kecerdasan buatan dan aplikasinya dalam industri pangan, serta memberikan pedoman praktis untuk penggunaan fungsi aktivasi yang optimal dalam pengelompokan jenis beras. Membandingkan kinerja pengklasifikasi citra beras menggunakan arsitektur Convolutional Neural Network (CNN) [17], [18]. Desain eksperimen memungkinkan untuk menguji dan membandingkan beberapa arsitektur CNN yang umum digunakan dalam pengolahan citra. Rancangan Penelitian dapat dilihat pada gambar berikut ini:



Gambar 1. Rancangan Penelitian

Metode penelitian ini dirancang untuk memberikan pemahaman yang komprehensif tentang perbandingan fungsi aktivasi CNN dalam pengelompokan jenis beras berdasarkan mutu beras, berikut penjabarannya [19], [20] :

a. Pengumpulan Data

Untuk penelitian ini, kami mengumpulkan data jenis beras dan data mutu beras dari beberapa sumber yang terpercaya, seperti laboratorium pengujian beras dan produsen beras. Data jenis beras mencakup variasi seperti beras putih, beras merah, dan beras ketan. Sedangkan data mutu beras meliputi parameter kualitas seperti kelembaban, kandungan serat, kandungan protein, dan kandungan vitamin. Setiap jenis beras dan parameter mutu beras dikumpulkan dalam bentuk dataset yang terstruktur. Pada penelitian ini data yang digunakan adalah dataset “*Rice Images Dataset*” yang didapatkan dari situs Kaggle.com yang dibuat oleh <https://www.muratkoklu.com/datasets/>. Dataset terdiri dari 75.000 gambar beras dengan format .JPG. Pada Tabel 1 adalah kelas, gambar, jumlah dan deskripsi dari kelas biji kakao.

Tabel 1. Data Kelas, Jumlah Gambar dan Deskripsi

Kelas	Gambar	Jumlah Data	Deskripsi
Basmati		220	kelas untuk beras panjang
Ipsala		220	kelas untuk beras gemuk

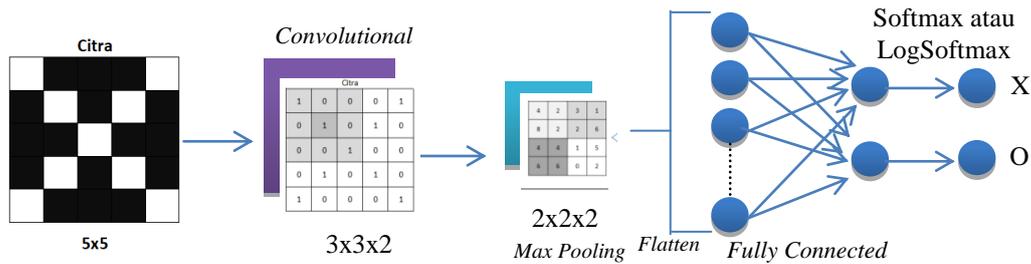
Kelas	Gambar	Jumlah Data	Deskripsi
Karacadang		220	kelas untuk beras bulat

b. Pra-pemrosesan Data

Sebelum melatih model CNN, kami melakukan pra-pemrosesan data untuk memastikan konsistensi dan kualitas dataset. Langkah-langkah pra-pemrosesan meliputi pembersihan data untuk mengatasi data yang hilang atau tidak valid, normalisasi data untuk memastikan keseragaman skala, dan pembagian dataset menjadi subset pelatihan dan subset validasi.

c. Pembangunan Arsitektur CNN

Kami mengimplementasikan arsitektur model CNN untuk pengelompokan jenis beras berdasarkan mutu beras. Arsitektur CNN yang kami gunakan terdiri dari beberapa layer konvolusi dan pooling, diikuti oleh layer fully connected. Kami menyesuaikan jumlah layer dan ukuran filter berdasarkan karakteristik data yang kami miliki. Kami menggunakan library atau framework Deep Learning seperti TensorFlow atau PyTorch untuk mengimplementasikan model CNN [21].



Gambar 2. Rancangan Penelitian

Pada Gambar 2, Rancangan penelitian contoh arsitektur yang digunakan penulis untuk menguji mutu beras dengan mengklasifikasi berdasarkan jenis beras menggunakan perbandingan fungsi aktivasi output CNN *LogSoftmax* dan *Softmax*.

d. Pemilihan Fungsi Aktivasi

Dalam penelitian ini, kami memilih empat fungsi aktivasi yang umum digunakan dalam CNN, yaitu ReLU. Dan untuk fungsi aktivasi output yang dibandingkan untuk menilai kinerja terbaik yaitu *Softmax* dan *LogSoftmax*. Kami mengaplikasikan fungsi aktivasi ini pada setiap layer yang relevan dalam arsitektur CNN kami. Dengan menggunakan berbagai fungsi aktivasi, kami dapat membandingkan dan menganalisis dampaknya terhadap kinerja pengelompokan jenis beras berdasarkan mutu beras.

e. Pelatihan Model

Kami melatih model CNN menggunakan subset pelatihan dari dataset yang telah kami siapkan. Kami menggunakan algoritma pembelajaran Adam optimizer untuk melatih model. Selama pelatihan, kami memonitor metrik evaluasi seperti akurasi dan loss untuk mengukur kinerja model. Kami mengatur hyperparameter seperti learning rate, batch size, dan jumlah epoch untuk memperoleh hasil yang optimal dan yang dibandingkan sebagai parameter tolak ukur untuk mengukur kinerja yaitu pada fungsi aktivasi output CNN.

f. Evaluasi Model

Setelah pelatihan selesai, kami menggunakan subset validasi dari dataset untuk mengevaluasi kinerja model CNN yang dilatih dengan berbagai fungsi aktivasi. Kami menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score untuk masing-masing fungsi aktivasi. Hal ini memungkinkan kita untuk membandingkan dan menganalisis perbedaan kinerja antara fungsi aktivasi yang digunakan.

g. Analisis Hasil

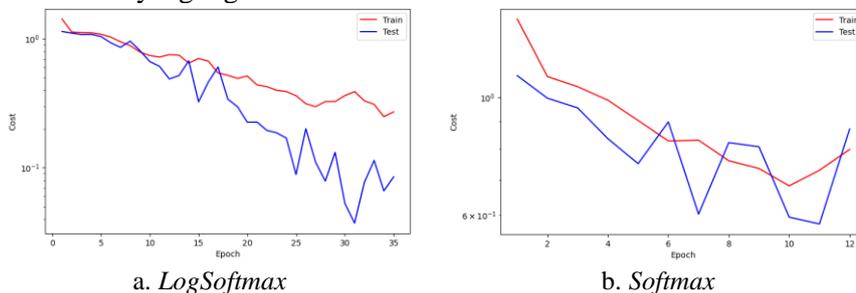
Berdasarkan hasil evaluasi, kami menganalisis perbandingan kinerja fungsi aktivasi dalam pengelompokan jenis beras berdasarkan mutu beras. Kami melihat perbedaan dalam akurasi dan metrik evaluasi lainnya untuk setiap fungsi aktivasi yang kami uji. Kami juga melakukan visualisasi hasil pengelompokan jenis beras menggunakan representasi grafis seperti confusion matrix untuk memberikan pemahaman yang lebih jelas tentang performa model.

3. Hasil dan Pembahasan

Berdasarkan hasil pelatihan dan hasil pengujian dengan menggunakan fungsi aktivasi yang berbeda untuk membandingkan hasil kinerja pengklasifikasi yang paling baik sebagai model analisis mutu beras sebagai sampel data uji.

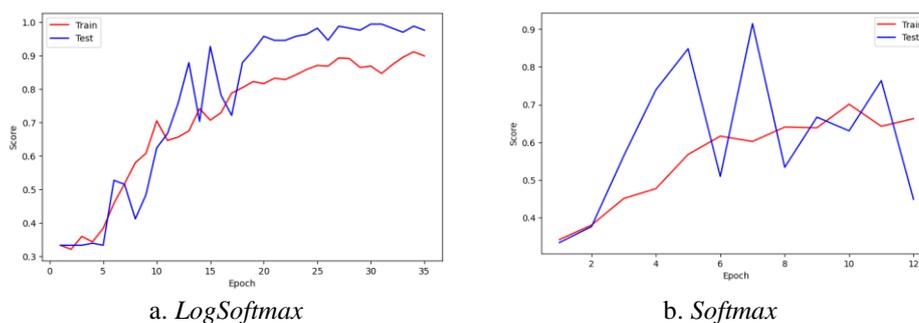
3.1. Hasil

Pada grafik Cost atau Loss dapat dilihat bahwa untuk fungsi aktivasi pada *LogSoftmax* cenderung lebih baik arah pergerakan pelatihan dan pengujiannya. Pada pengujian ini peneliti menggunakan google colab sebagai alat bantu untuk mengujinya, dan penulis juga menggunakan *early stoping* yang berguna untuk menghindari loss yang terlalu besar dalam pengujian mutu beras. Sebagai hasil akhir, bisa dilihat perbandingan dari beberapa arsitektur yang digunakan.

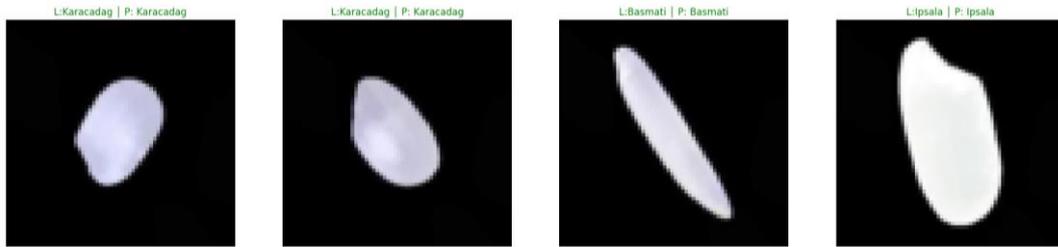


Gambar 3. Perbandingan Grafik Cost pada Pengujian menggunakan 2 aktivasi

Gambar 3, menunjukkan grafik performa hasil Cost (loss) pada grafik juga bisa dilihat bahwa line biru untuk data pengujian dan merah untuk data pelatihan. Dimana *LogSoftmax* menunjukkan bahwa hasil klasifikasi nilai Cost (loss) pada data pelatihan dan data pengujian mengalami lonjakan naik turun yang stabil. Dan grafik akurasi yang dihasilkan dari pengujian yang dilakukan peneliti dapat dilihat pada gambar berikut :



Gambar 4. Perbandingan Grafik Score atau Akurasi dari 2 Fungsi AKtivasi



Gambar 6. Visualisasi data hasil prediksi menggunakan *LogSoftmax*

Pada gambar 6 Untuk dapat melihat apa sebenarnya yang terjadi saat mesin memprediksi, peneliti coba untuk menampilkan visualisasi hasil prediksi model dengan gambar yang terdapat pada data pengujian. Dapat dilihat pada gambar 6 di atas bahwa font yang berwarna merah adalah kesalahan dalam memprediksi dan yang berwarna hijau adalah prediksi yang tepat. Hasil yang didapat ternyata pada aktivasi *LogSoftmax* sangat baik dalam mengklasifikasi data jenis beras atau dataset yang kita gunakan dan terbukti cocok diterapkan pada penelitian ini.

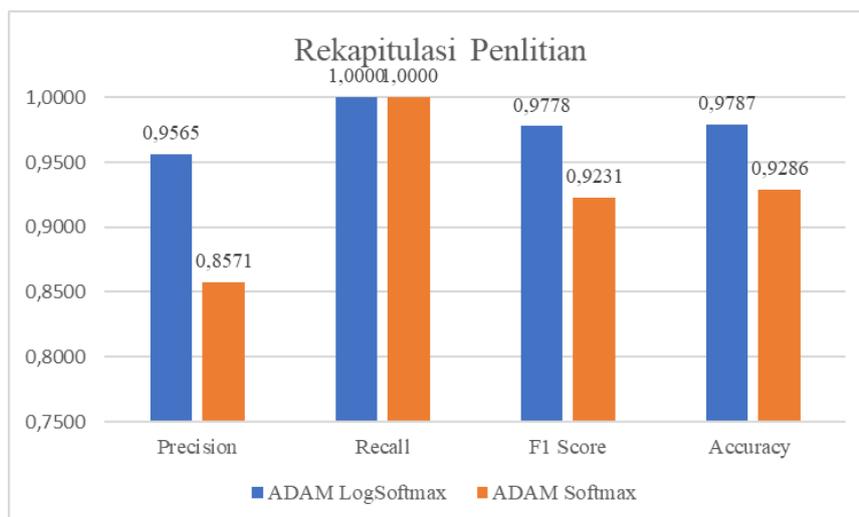
3.2. Pembahasan

Berikut hasil dari pelatihan dan pengujian yang dilakukan oleh penulis dalam menganalisis mutu beras dengan mengklasifikasi jenis beras, dengan model arsitektur dan membandingkan fungsi aktivasi output CNN mana yang paling baik kinerjanya dalam mengklasifikasi dan memprediksi mutu beras dengan menggunakan data image yang diolah dengan aplikasi google colab dengan Bahasa *pytorch*. Hasil rekapitulasi bisa kita lihat pada tabel 2 berikut ini.

Tabel 2. Rekapitulasi Hasil Pengujian

Optimize	Fungsi Aktivasi	Best Epoch	Precision	Recall	F1 Score	Accuracy
ADAM	<i>LogSoftmax</i>	35	0,9565	1,0000	0,9778	0,9787
	<i>Softmax</i>	12	0,8571	1,0000	0,9231	0,9286

Pada Tabel 2 merupakan hasil evaluasi model menggunakan `classification_report`, dimana diperoleh akurasi model terbesar 0,9787 atau 97,87% dengan nilai precision, recall, dan `f1_score` tertinggi terdapat pada kelas model arsitektur aktivasi *LogSoftmax*. Sedangkan pada aktivasi *Softmax* akurasi 0,9286 atau 92,86%.



Gambar 7. Grafik Rekapitulasi Hasil Pengujian

Pada gambar 6. merupakan hasil evaluasi model menggunakan *classification_report* yang memmunjukan *LogSoftmax* lebih unggul dibandingkan *Softmax*. Fungsi aktivasi *softmax* digunakan secara umum dalam tugas-tugas klasifikasi multikelas. Fungsi ini menghasilkan distribusi probabilitas untuk setiap kelas yang dihasilkan oleh model. Namun, dalam beberapa kasus, seperti saat menghitung fungsi loss, penggunaan log dari fungsi *softmax* (*LogSoftmax*) lebih disukai. *LogSoftmax* adalah transformasi logaritmik dari hasil *softmax*. Hal ini dilakukan untuk memperbaiki numerik dan mempermudah perhitungan fungsi loss, seperti Cross Entropy Loss. Dengan menggunakan *LogSoftmax*, probabilitas kelas yang dihasilkan oleh model diubah menjadi logaritma probabilitas tersebut.

Mengapa *LogSoftmax* lebih disukai dalam perhitungan loss function? Salah satu alasan utamanya adalah karena sifatnya yang numerik lebih stabil. Saat menggunakan *softmax*, eksponensial besar mungkin timbul dalam perhitungan, yang dapat menyebabkan ketidakstabilan numerik dan kesulitan dalam optimisasi model. Dengan menggunakan *LogSoftmax*, nilai logaritma dari probabilitas dihitung, yang dapat mengurangi kemungkinan terjadinya eksponensial besar dan menghasilkan perhitungan yang lebih stabil. Selain itu, *LogSoftmax* juga mempermudah perhitungan fungsi loss Cross Entropy. Dalam perhitungan Cross Entropy Loss, fungsi logaritma diaplikasikan pada probabilitas kelas yang diprediksi oleh model. Dengan menggunakan *LogSoftmax*, proses perhitungan loss menjadi lebih efisien dan lebih mudah diinterpretasikan.

Dalam konteks pengelompokan jenis beras berdasarkan mutu beras, penggunaan *LogSoftmax* sebagai fungsi aktivasi dan perhitungan loss function yang lebih baik dapat membantu dalam meningkatkan kestabilan numerik dan akurasi dalam proses pengelompokan tersebut. Dalam kesimpulannya, penggunaan *LogSoftmax* sebagai alternatif dari fungsi aktivasi *softmax* di dalam perhitungan loss function memberikan keuntungan numerik yang lebih stabil dan mempermudah perhitungan. Dalam tugas klasifikasi multikelas seperti pengelompokan jenis beras, penggunaan *LogSoftmax* dapat memberikan perbaikan yang signifikan dalam kinerja model dan akurasi prediksi.

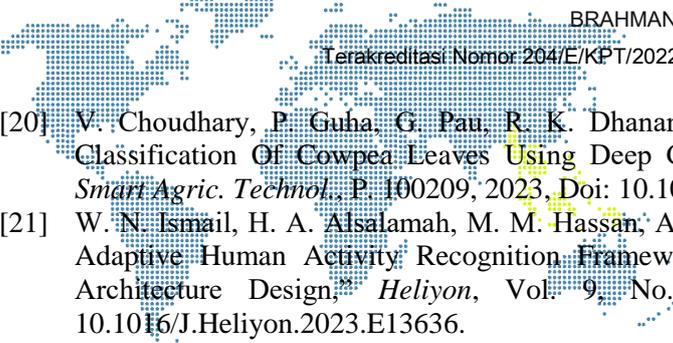
4. Kesimpulan

Penelitian ini berhasil mengimplementasikan dan membandingkan kinerja pengklasifikasi citra jenis beras dengan mengklasifikasi mutu beras menggunakan arsitektur CNN. Hasil penelitian menunjukkan bahwa pemilihan fungsi aktivasi mempengaruhi secara signifikan kinerja model dalam pengelompokan jenis beras berdasarkan mutu beras. Dalam analisis kami, kami menemukan bahwa *LogSoftmax*, yang merupakan transformasi logaritmik dari fungsi *softmax*, memberikan perhitungan loss function yang lebih baik dan numerik yang lebih stabil. Hasil pengujian yang didapat juga bahwa dimana diperoleh akurasi model terbesar 0,9787 atau 97,87% dengan nilai precision, recall, dan f1_score tertinggi terdapat pada kelas model arsitektur aktivasi *LogSoftmax*. Sedangkan pada aktivasi *Softmax* akurasi 0,9286 atau 92,86%.

Daftar Pustaka

- [1] B. Gunawan, M. E. Al-Rivan, P. S. Informatika, U. Multi, And D. Palembang, "2nd Mdp Student Conference (Msc) 2023 E-Issn: 2985-7406 Klasifikasi Jenis Beras Putih Menggunakan Cnn Residual Network Optimizer Sgd," Pp. 128–132, 2023.
- [2] S. S. A. Laros, D. B. M. Dickerscheid, S. P. Blazis, And J. A. Van Der Heide, "Machine Learning Classification Of Mediastinal Lymph Node Metastasis In Nslc: A Multicentre Study In A Western European Patient Population," *Ejnmml Phys.*, Vol. 9, No. 1, 2022, Doi: 10.1186/S40658-022-00494-8.
- [3] N. H. Son And N. Thai-Nghe, "Deep Learning For Rice Quality Classification," *2019 Int. Conf. Adv. Comput. Appl.*, Pp. 92–96, 2019, Doi: 10.1109/Acomp.2019.00021.
- [4] M. Koklu, I. Cinar, And Y. S. Taspinar, "Classification Of Rice Varieties With

- Deep Learning Methods,” *Comput. Electron. Agric.*, Vol. 187, No. June, P. 106285, 2021, Doi: 10.1016/J.Compag.2021.106285.
- [5] F. H. Hawari, F. Fadillah, M. R. Alyiandi, And T. Arifin, “Klasifikasi Penyakit Padi Menggunakan Algoritma Cnn (Convolutional Neural Network),” Vol. 4, No. 2, Pp. 184–189, 2022.
- [6] Muh Zamal Altim, Faisal, Salmiah, Kasman, Andi Yudhistira, And Rita Amalia Syamsu, “Pengklasifikasi Beras Menggunakan Metode Cnn (Convolutional Neural Network),” *J. Instek (Informatika Sains Dan Teknol.)*, Vol. 7, No. 1, Pp. 151–155, 2022, Doi: 10.24252/Instek.V7i1.28922.
- [7] H. Wang *Et Al.*, “Comparison Of Machine Learning Methods For Classifying Mediastinal Lymph Node Metastasis Of Non-Small Cell Lung Cancer From 18f-Fdg Pet/Ct Images,” *Ejnmri Res.*, Vol. 7, No. 1, 2017, Doi: 10.1186/S13550-017-0260-9.
- [8] L. Gaur, U. Bhatia, N. Z. Jhanjhi, G. Muhammad, And M. Masud, “Medical Image-Based Detection Of Covid-19 Using Deep Convolution Neural Networks,” *Multimed. Syst.*, No. 0123456789, 2021, Doi: 10.1007/S00530-021-00794-6.
- [9] L. Yu *Et Al.*, “Prediction Of Pathologic Stage In Non-Small Cell Lung Cancer Using Machine Learning Algorithm Based On Ct Image Feature Analysis,” *Bmc Cancer*, Vol. 19, No. 1, Pp. 1–12, 2019, Doi: 10.1186/S12885-019-5646-9.
- [10] N. Irtiza Trinto And M. Eunus Ali, “Detecting Multilabel Sentiment And Emotions From Bangla Youtube Comments,” *2018 Int. Conf. Bangla Speech Lang. Process. Icbslp 2018*, No. January 2019, 2018, Doi: 10.1109/Icbslp.2018.8554875.
- [11] S. Kiziloluk And E. Sert, “Covid-Ccd-Net: Covid-19 And Colon Cancer Diagnosis System With Optimized Cnn Hyperparameters Using Gradient-Based Optimizer,” *Med. Biol. Eng. Comput.*, Vol. 60, No. 6, Pp. 1595–1612, 2022, Doi: 10.1007/S11517-022-02553-9.
- [12] H. Kör, H. Erbay, And A. H. Yurttakal, “Diagnosing And Differentiating Viral Pneumonia And Covid-19 Using X-Ray Images,” *Multimed. Tools Appl.*, Vol. 81, No. 27, Pp. 39041–39057, 2022, Doi: 10.1007/S11042-022-13071-Z.
- [13] R. Kumar *Et Al.*, “Classification Of Covid-19 From Chest X-Ray Images Using Deep Features And Correlation Coefficient,” *Multimed. Tools Appl.*, Vol. 81, No. 19, Pp. 27631–27655, 2022, Doi: 10.1007/S11042-022-12500-3.
- [14] N. Hasan, Y. Bao, A. Shawon, And Y. Huang, “Densenet Convolutional Neural Networks Application For Predicting Covid-19 Using Ct Image,” *Sn Comput. Sci.*, Vol. 2, No. 5, Pp. 1–11, 2021, Doi: 10.1007/S42979-021-00782-7.
- [15] B. Xu, D. Martín, M. Khishe, And R. Boostani, “Covid-19 Diagnosis Using Chest Ct Scans And Deep Convolutional Neural Networks Evolved By Ip-Based Sine-Cosine Algorithm,” *Med. Biol. Eng. Comput.*, Vol. 60, No. 10, Pp. 2931–2949, 2022, Doi: 10.1007/S11517-022-02637-6.
- [16] A. Abbas, J. P. Vantassel, B. R. Cox, K. Kumar, And J. Crocker, “A Frequency-Velocity Cnn For Developing Near-Surface 2d Vs Images From Linear-Array, Active-Source Wavefield Measurements,” *Comput. Geotech.*, Vol. 156, No. February, P. 105305, 2023, Doi: 10.1016/J.Compgeo.2023.105305.
- [17] T. Yuan, W. Liu, J. Han, And F. Lombardi, “High Performance Cnn Accelerators Based On Hardware And Algorithm Co-Optimization,” *Ieee Trans. Circuits Syst. I Regul. Pap.*, Vol. 68, No. 1, Pp. 250–263, 2021, Doi: 10.1109/Tcsi.2020.3030663.
- [18] A. Nouriani, R. Mcgovern, And R. Rajamani, “Intelligent Systems With Applications Activity Recognition Using A Combination Of High Gain Observer And Deep Learning Computer Vision Algorithms,” *Intell. Syst. With Appl.*, Vol. 18, No. March, P. 200213, 2023, Doi: 10.1016/J.Iswa.2023.200213.
- [19] S. Sowmya And D. Jose, “Contemplate On Ecg Signals And Classification Of Arrhythmia Signals Using Cnn-Lstm Deep Learning Model,” *Meas. Sensors*, Vol. 24, No. October, P. 100558, 2022, Doi: 10.1016/J.Measen.2022.100558.

- 
- [20] V. Choudhary, P. Guha, G. Pau, R. K. Dhanaraj, And S. Mishra, “Automatic Classification Of Cowpea Leaves Using Deep Convolutional Neural Network,” *Smart Agric. Technol.*, P. 100209, 2023, Doi: 10.1016/J.Atech.2023.100209.
- [21] 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.