ISSN : 1411-1624
e-ISSN: 2621-8089

Optimasi Kontras Dan Ketajaman Citra Pada Pengenalan Makanan Indonesia Berbasis Machine Learning

Khanun Roisatul Ummah[1*], Diah Priyawati [2], Jamilatul Badriyah [3]
Universitas Muhammadiyah Surakarta [1,2], Universitas Madura [3]
Jl. A. Yani, Sukoharjo, Jawa Tengah, Indonesia[1,2],
Jl. Raya Panglegur, Pamekasan, Jawa Timur, Indonesia[3]
Sur-el : kru344@ums.ac.id[1], dp120@ums.ac.id[2], mila@unira.ac.id [3]
[*)] Corresponden Author

Received: 31 July 2025 Reviewed: 02 August 2025 Accepted: 06 August 2025

Abstract : *Indonesia has a rich culinary diversity, encompassing various types of food from different regions. In the current era of technological advancement, the application of artificial intelligence has grown significantly across multiple sectors, including in the identification of Indonesian food images. This research provides the impact of various image preprocessing techniques on the AI-based food identification system. The preprocessing methods examined include Zero Component Analysis (ZCA), Histogram Equalization (HE), Contrast Stretching, and Image Sharpening. The evaluation of these preprocessing methods was conducted to determine which technique provides the best performance in assisting the identification of Indonesian food using a Convolutional Neural Network (CNN) with a ResNet-50 transfer learning model. Performance measurement was carried out using a confusion matrix by calculating Accuracy, precision, recall, and F1-score. The results of this research show that the use of the Image Sharpening method yields higher accuracy and precision on the testing data compared to other methods, those are 0.9748 and 0.98, respectively. Next, a high level of accuracy was also demonstrated by the Contrast Stretching method, with an accuracy score of 0.9712.*

Keywords: *indonesian food identification, preprocessing, ResNet50, transfer learning.*

Abstrak : *Indonesia memiliki keragaman kuliner yang luas, mencakup berbagai jenis makanan dari berbagai daerah. Pada era perkembangan teknologi saat ini, penggunaan kecerdasan buatan dalam berbagai bidang semakin meluas, termasuk dalam proses identifikasi citra makanan Indonesia. Pada penelitian ini dilakukan sebuah percobaan mengenai efek dari berbagai macam teknik preprocessing citra terhadap performa suatu sistem identifikasi makanan berbasis kecerdasan buatan. Metode preprocessing citra yang diujikan yaitu Zero Component Analysis (ZCA), Histogram Equalization (HE), Contrast Stretching, dan Image Sharpening. Proses evaluasi berbagai metode preprocessing dilakukan dengan menilai teknik mana yang memiliki performa terbaik dalam membantu proses identifikasi makanan Indonesia menggunakan Convolutional Neural Network (CNN) dengan model transfer learning ResNet-50. Pengukuran performa ini dilakukan menggunakan confusion matrix dengan menghitung akurasi, presisi, recall, dan F1-score. Hasil dari penelitian ini dapat dilihat bahwa penggunaan metode Image Sharpening memiliki hasil akurasi dan presisi data testing yang lebih tinggi dari metode lainnya, yaitu sebesar 0,9748 dan 0,98. Selanjutnya, metode yang memiliki tingkat akurasi tinggi juga ditunjukkan oleh metode Contrast Stretching dengan nilai akurasi sebesar 0,9712.*

Kata kunci*: identifikasi makanan, preprocessing, ResNet-50, transfer learning.*

1. PENDAHULUAN

Dalam era digital dan inovasi teknologi saat ini, penggunaan kecerdasan buatan dalam berbagai bidang semakin meluas, termasuk dalam proses identifikasi citra makanan [1]. Indonesia merupakan salah satu negara yang memiliki berbagai macam jenis makanan. Setiap jenis makanan memiliki perbedaan dalam kandungan nutrisi dan energinya. Agar dapat

ISSN : 1411-1624
e-ISSN: 2621-8089

mengetahui komposisi setiap jenis makanan, penting untuk mengetahui nama makanan tersebut terlebih dahulu.

Shah dan Bhavsar [2] mengungkapkan bahwa pengenalan citra makanan merupakan topik hangat dalam *computer vision*, serta pemanfaatan *Convolutional Neural Network* (CNN) dapat meningkatkan ketepatan dalam mengidentifikasi citra makanan. Karlita [3] dalam penelitiannya menggunakan CNN untuk melakukan klasifikasi pada kue tradisional Indonesia. Dalam penelitian tersebut, citra kue digunakan secara langsung sebagai *input* ke dalam sistem klasifikasi dan menghasilkan akurasi lebih dari 90% tanpa melalui tahapan preprocessing untuk meningkatkan kualitas citra.

Mahaputri [4] memanfaatkan *Deep Convolutional Neural Network* (DCNN) untuk mengenali makanan tradisional Indonesia beserta bahan-bahannya. Sebelum citra makanan dimasukkan ke model DCNN, Mahaputri dkk melakukan *preprocessing* citra dengan proses pemotongan objek sehingga hanya fokus ke makanan saja. Penelitian tersebut menghasilkan akurasi tertinggi sebesar 64% pada citra setelah *preprocessing*.

Preprocessing data merupakan salah satu tahapan yang penting dalam pembelajaran mesin, khususnya dalam pemrosesan citra [5]. Proses *preprocessing* yang tepat dapat digunakan untuk meningkatkan akurasi dari sebuah sistem cerdas [6]. Ummah [7] dalam penelitiannya menjelaskan bahwa preprocessing yang tepat terhadap citra CT dapat meningkatkan hasil akurasi sistem cerdas. Pal [8] dalam penelitiannya menggunakan *Mean Normalization, Standardization*, dan *Zero Component Analysis* (ZCA) pada dataset CIFAR10. Setelah dimasukkan ke dalam model CNN, hasil penelitiannya menunjukkan bahwa preprocessing dapat meningkatkan hasil akurasi, terutama menggunakan metode ZCA.

Dalam penelitian Marpaung [9], sebelum proses klasifikasi menggunakan CNN, data citra dilakukan *preprocessing* dan ekstraksi fitur terlebih dahulu menggunakan HSV *color extraction, Canny shape extraction*, dan GLCM *texture extraction*. Namun, hasil penelitian tersebut menunjukkan bahwa penggunaan HSV, *Canny*, dan GLCM justru memiliki nilai akurasi yang lebih rendah dibandingkan hasil akurasi tanpa *preprocessing*.

Chaki dan Dey [10] dalam bukunya menjelaskan beberapa metode *preprocessing* dasar yang dapat digunakan pada sebuah citra. Metode tersebut diantaranya adalah *Histogram Equalization* (HE) dan *Contrast Stretching* untuk memperbaiki kontras citra. Metode lain yaitu untuk meningkatkan ketajaman citra menggunakan *Image Sharpening*.

Dari beberapa penelitian tersebut, dapat dilihat bahwa belum ada yang membahas secara mendalam mengenai penggunaan *preprocessing* yang tepat dalam meningkatkan hasil deteksi makanan Indonesia. Kita juga bisa melihat bahwa preprocessing yang tepat dapat meningkatkan akurasi model sistem cerdas. Oleh karena itu, dalam penelitian ini dilakukan penerapan serta analisis beberapa teknik *preprocessing* citra makanan Indonesia guna mengetahui metode mana yang memiliki dampak baik dalam deteksi citra makanan Indonesia.

ISSN : 1411-1624
e-ISSN: 2621-8089

Metode *preprocessing* yang digunakan yaitu ZCA, HE, *Contrast Stretching*, dan *Image Sharpening*. Pengukuran dampak metode *preprocessing* ini dilakukan dengan memasukkan citra hasil *preprocessing* kedalam model klasifikasi CNN serta *evaluation metric* berupa akurasi, presisi, *recall*, F1-*score* dari *confusion matrix*.

2. METODOLOGI PENELITIAN

Penelitian ini dilakukan untuk mengevaluasi penggunaan beberapa teknik preprocessing pada citra makanan Indonesia. Proses tersebut terdiri dari empat bagian utama yaitu *data collection*, *data preprocessing*, *classification stage*, dan *system evaluation*. Desain sistem pada Gambar 1 memperlihatkan keseluruhan proses. Tahapan secara rinci dari sistem yang dikerjakan sebagai berikut.

2.1 Data Collection

Data yang digunakan dalam penelitian ini berupa citra makanan Indonesia yang terdiri dari lima kelas. Kelas pada dataset tersebut yaitu cah kangkung, bakso, rendang, telur balado, dan tempe goreng. Gambar 2 menunjukkan contoh data dari masing-masing kelas. Dataset ini merupakan data sekunder yang didapatkan dari laman opensource universe.roboflow.com dan kaggle.com. Total dataset yang digunakan yaitu 5489 citra yang terdiri dari 985 citra cah kangkung, 1117 citra bakso, 1132 citra rendang, 1042 citra telur balado, dan 1222 citra tempe goreng. Pada proses pelatihan model, data dibagi menjadi 5220 data pelatihan dan 278 data tes.

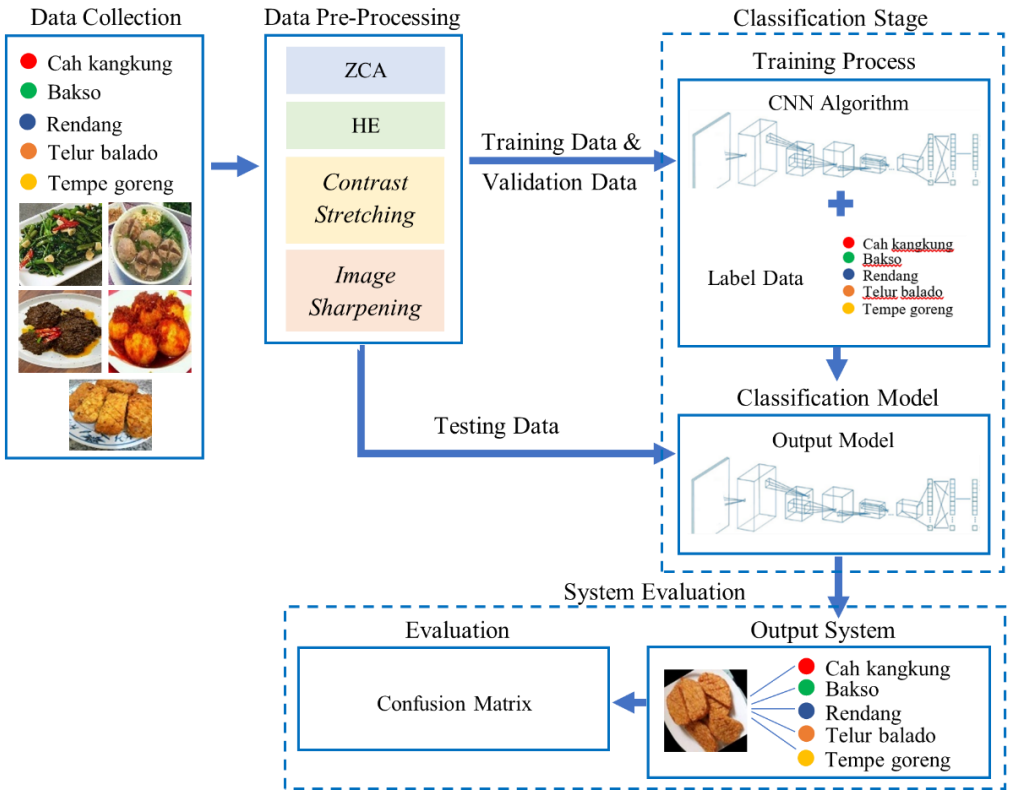

Gambar 1. Diagram sistem

ISSN : 1411-1624
e-ISSN: 2621-8089

Gambar 2. Contoh data dari masing-masing kelas, (a) cah kangkung, (b) bakso, (c) rendang, (d) telur balado, (e) tempe goreng

2.2 Data Preprocessing

Tahap selanjutnya dari penelitian ini yaitu melakukan *preprocessing* pada dataset citra makanan Indonesia yang digunakan. Terdapat empat teknik *preprocessing* yang dicoba pada tahap ini, teknik tersebut berupa penajaman detail citra yang dilakukan dengan teknik ZCA dan Image Sharpening serta memperbaiki kontras citra menggunakan teknik HE dan Contrast Stretching. Masing-masing teknik *preprocessing* diuji secara terpisah dan tidak saling berkaitan satu sama lain.

Beberapa teknik *preprocessing* yang digunakan dalam penelitian ini diantaranya yaitu ZCA dan *Image sharpening*. Dua teknik ini bertujuan untuk mempertajam detail dari citra. Transformasi ZCA dapat meningkatkan ketajaman tepi sebuah objek. Kalapos dan Toth [11] dalam penelitiannya menerapkan ZCA whitening sebagai lapisan akhir pada *encoder* dalam berbagai metode *Self-Supervised Learning* (SSL). Hasil eksperimen menunjukkan bahwa proses *whitening* ini secara konsisten meningkatkan kualitas representasi fitur, yang tercermin dari peningkatan akurasi evaluasi menggunakan *linear classifier* dan k-NN sebesar 1–5% pada beberapa benchmark dataset seperti CIFAR-10, STL-10, dan Tiny-ImageNet. Dalam proses ZCA, ukuran data (X) dinormalisasi dengan melakukan penskalaan fitur. Metode pelaksanaan ZCA dijelaskan secara rinci pada persamaan (1).

$$X' = \frac{X}{255} \quad (1)$$

Image Sharpening dapat dilakukan dengan menggunakan turunan spasial. Turunan ini diterapkan pada area datar atau area yang memiliki *gray level* yang konstan, pada tahapan atau akhir dari diskontinuitas atau *ramp discontinuities*, dan sepanjang *gray level discontinuities* atau *ramps* [10]. Diskontinuitas ini dapat berupa garis, derau titik, atau tepian. Weli dan Abdullah [12] melakukan penelitian mengenai kombinasi *image smoothing* dan *sharpening*. Penerapan *image sharpening* dalam penelitian tersebut terbukti efektif untuk meningkatkan kejernihan dan ketajaman citra, khususnya setelah proses pengurangan *noise*. Kombinasi strategi *smoothing* dan *sharpening* menghasilkan kualitas citra yang lebih optimal dibandingkan penggunaan salah satu metode secara terpisah.

Teknik *preprocessing* lainnya yang diuji yaitu HE dan *Contrast Stretching*. Dua teknik preprocessing ini digunakan untuk memperbaiki

ISSN : 1411-1624
e-ISSN: 2621-8089

kecerahan dan kontras citra. Dengan menggunakan teknik ini, tingkat kecerahan dan kontras gambar dapat diubah untuk memperkuat karakteristik yang bermanfaat dari gambar. HE merupakan teknik yang digunakan untuk meratakan distribusi histogram, sehingga tingkat keabuan dari nilai terendah (0) hingga tertinggi (255) tersebar secara merata. Panambur [13] dalam penelitiannya menggunakan *histogram equalization* secara acak sebagai teknik augmentasi data pada *patch mammogram calcification*. Penerapan probabilitas *equalizing* sebesar 0.4 pada penelitian tersebut memperbaiki akurasi rata-rata dan F1-score lebih dari 1% dibanding tanpa HE. Penerapan HE dilakukan pada citra *grayscale*, di mana prosesnya mencakup seluruh area citra secara keseluruhan (global) [14]. Fungsi matematika (2) digunakan untuk menghitung HE.

$$\boldsymbol{h(v) = round\left(\frac{cdf(v) - cdf_{min}}{(M\ x\ N) - cdf_{min}}\ x\ (L\ -\ 1)\right)} \quad (2)$$

V merupakan nilai intensitas piksel yang akan dihitung nilai transformasinya. CDF(V) merupakan nilai dari fungsi distribusi kumulatif piksel V. CDF_{min} merupakan nilai terkecil dari fungsi distribusi kumulatif pada seluruh citra. M *x* N merupakan dimensi citra, M jumlah kolom (lebar) dan N jumlah baris (tinggi). L merupakan total tingkat keabuan yang mungkin dalam citra, 8-bit (L=256).

Contrast Stretching, atau perluasan kontras, adalah sebuah teknik pengolahan gambar yang digunakan untuk meningkatkan kontras antara nilai piksel dalam rentang tertentu. Tujuan dari *Contrast Stretching* adalah memperluas jarak antara nilai piksel minimum dan maksimum dalam gambar, sehingga meningkatkan ketajaman dan kedalaman kontrasnya. Metode ini sering digunakan untuk meningkatkan visualisasi dan detail gambar yang kurang kontras. Firma dan Oktamuliani [15] dalam penelitiannya menunjukkan bahwa Kombinasi *median filter* dengan *Contrast Stretching* terbukti efektif dalam meningkatkan kualitas citra ultrasonografi abdomen, dengan nilai PSNR tinggi dan MSE rendah, serta memudahkan interpretasi oleh ahli radiologi dibandingkan kombinasi metode *filtering* dan *enhancement* lainnya. Formula *Contrast Stretching* ditunjukkan pada persamaan (3).

$$\boldsymbol{s = 255\ x\ \frac{(r - r_{min})}{r_{max} - r_{min}}} \quad (3)$$

R merupakan nilai intensitas piksel saat ini. R_{min} merupakan nilai intensitas minimal pada seluruh citra. R_{max} merupakan nilai intensitas maksimal pada seluruh citra.

2.3 Classification Stages

Tahap klasifikasi dilakukan menggunakan CNN *Transfer Learning* dengan model Resnet-50. *Transfer learning* memanfaatkan model CNN yang sebelumnya telah dilatih pada dataset besar sebagai landasan atau "*backbone*" untuk menyelesaikan tugas baru [16]. *Deep residual network* memiliki model yang hampir sama dengan model jaringan lain yang memiliki proses konvolusi, *pooling*, fungsi aktivasi, dan *fully connected layer* yang terhubung satu sama lain. Satu-satunya jaringan sederhana yang dapat membedakan jaringan residual dengan jaringan yang lainnya yaitu adanya koneksi indentitas antar lapisan [17]. Gambar 3 menunjukkan blok residual yang digunakan dalam *residual network*. Dari Gambar 3 dapat dilihat adanya koneksi

ISSN : 1411-1624
e-ISSN: 2621-8089

identitas yang digambarkan sebagai panah melengkung yang berasal dari input citra (atau dari output fitur hasil pemrosesan sebelumnya) dan mengarah ke akhir dari blok residual. Input identitas ini selanjutnya akan ditambah dengan keluaran dari blok konvolusi.

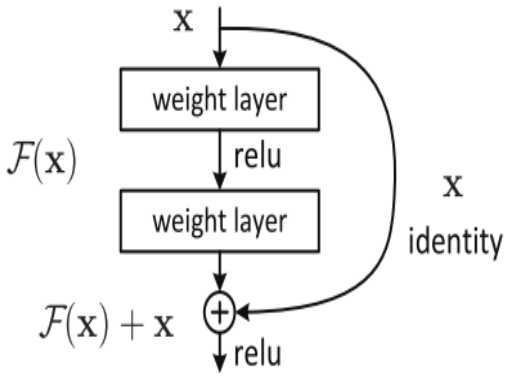

Gambar 3. Blok residual
Source: : towardsdatascience.com

Terdapat banyak variasi dari arsitektur ResNet, yaitu ResNet-18, ResNet-34, ResNet-50, dan lain-lain. Dari berbagai variasi tersebut memiliki konsep yang sama namun memiliki jumlah lapisan yang berbeda, dua digit belakang melambangkan jumlah lapisan yang digunakan.

2.4 System Evaluation

Dalam penelitian ini, *confusion matrix* digunakan dalam menguji performa sistem. *Confusion matrix* merupakan salah satu metode evaluasi sistem yang dapat digunakan dalam kasus klasifikasi [18]. Dasar dari pembacaan *confusion matrix* dapat dilihat pada Tabel 1. Untuk multiclass classification, beberapa metrik pada Tabel 1 dapat diperpanjang sesuai jumlah kelas yang digunakan. Baris pada tabel mewakili hasil prediksi kelas, sedangkan kolom pada tabel mewakili kelas yang sebenarnya.

Tabel 1. Binary class confusion matrix

		Actual	
		Positive	***Negative***
Predicted	***Positive***	*True Positive (TP)*	*False Negative (FN)*
	Negative	*False Positive (FP)*	*True Negative (TN)*

TP dan TN merepresentasikan jumlah data yang berhasil diklasifikasikan dengan benar sebagai positif dan negatif sesuai dengan ground truth. Sementara itu, FP dan FN menunjukkan jumlah kesalahan klasifikasi pada kategori positif dan negatif. Tabel *confusion matrix* ini dapat digunakan untuk menghitung Tingkat akurasi, presisi, *recall*, dan F1-*score*.

Akurasi merupakan perbandingan antara jumlah prediksi yang benar dengan total jumlah sampel yang dievaluasi, perhitungan akurasi dapat dilihat di persamaan 4. Presisi dapat digunakan untuk mengukur seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi yang dikategorikan sebagai positif, perhitungan presisi dapat dilihat di persamaan 5. *Recall* menunjukkan seberapa banyak total data positif yang berhasil dikenali secara tepat oleh sistem, perhitungan *recall* dapat dilihat di persamaan 6. F1-*score* digunakan untuk melihat keseimbangan antara presisi dan *recall*, perhitungan presisi dapat dilihat di persamaan 7.

$$\frac{tp+tn}{tp+fp+tn+fn} \quad (4)$$

$$\frac{tp}{tp+fp} \quad (5)$$

$$\frac{tp}{tp+fn} \quad (6)$$

$$\frac{2*p*r}{p+r} \quad (7)$$

ISSN : 1411-1624
e-ISSN: 2621-8089

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan dalam penelitian ini diuraikan dalam dua bagian. Bagian awal membahas mengenai hasil *preprocessing* citra makanan Indonesia, bagian ini fokus untuk menganalisis perbedaan pada citra sebelum *preprocessing* dan setelah proses *preprocessing*. Bagian yang kedua yaitu pembahasan mengenai hasil evaluasi *machine learning* menggunakan CNN terhadap proses *preprocessing* citra.

3.1 Hasil *Preprocessing*

Sebelum data dimasukkan ke dalam model *machine learning*, data citra makanan Indonesia terlebih dahulu dimasukkan ke dalam berbagai teknik *preprocessing* citra secara terpisah. Teknik *preprocessing* citra berupa ZCA, HE, *Contrast Stretching*, dan *Image Sharpening*.

Dari Gambar 4, bisa kita lihat bahwa masing-masing metode *preprocessing* menghasilkan keluaran citra yang berbeda jika dilihat secara visual. Metode ZCA pada gambar makanan Indonesia dapat meningkatkan kontras dan ketajaman citra, namun banyak merubah warna keseluruhan dari gambar. Dilain sisi, Image Sharpening secara visual memperlihatkan dengan jelas adanya peningkatan ketajaman citra makanan Indonesia tanpa banyak merubah warna dari keseluruhan gambar.

Hasil *preprocessing* menunjukkan bahwa *Histogram Equalizer* dan *Contrast Stretching* mampu memperbaiki kontras citra. Pada citra yang telah dilakukan *Histogram Equalizer* menunjukkan intensitas piksel yang sebelumnya terkonsentrasi di sebagian kecil rentang akan disebar lebih luas, sehingga detail yang sebelumnya tersembunyi menjadi lebih terlihat. Penerapan metode HE ini dapat meningkatkan detail citra, seperti tepi, tekstur, dan kontur objek menjadi lebih tajam dan terlihat jelas. Namun, pada citra dengan histogram yang sudah cukup merata, HE dapat menyebabkan efek "*over-enhancement*", membuat gambar tampak terlalu tajam, bintik-bintik noise terlihat lebih jelas, atau tampak tidak natural.

Dilain sisi, penggunaan metode *Contrast Stretching* pada citra makanan Indonesia secara visual menjadikan perbedaan terang-gelap lebih mencolok, tanpa mengubah pola distribusi intensitas secara signifikan. Metode ini dapat lebih natural dalam mempertahankan tampilan asli objek.

3.2 Hasil evaluasi pembelajaran mesin menggunakan CNN

Selain melihat dari segi visual, efek penggunaan *preprocessing* pada citra makanan Indonesia juga diuji tingkat efektivitasnya dalam kasus klasifikasi berbasis *machine learning*. Pada penelitian ini, *transfer learning* CNN ResNet50 digunakan sebagai model dasar. Pada tahap akhir, *confusion matrix* digunakan untuk menilai performa dari keseluruhan sistem.

ISSN : 1411-1624
e-ISSN: 2621-8089

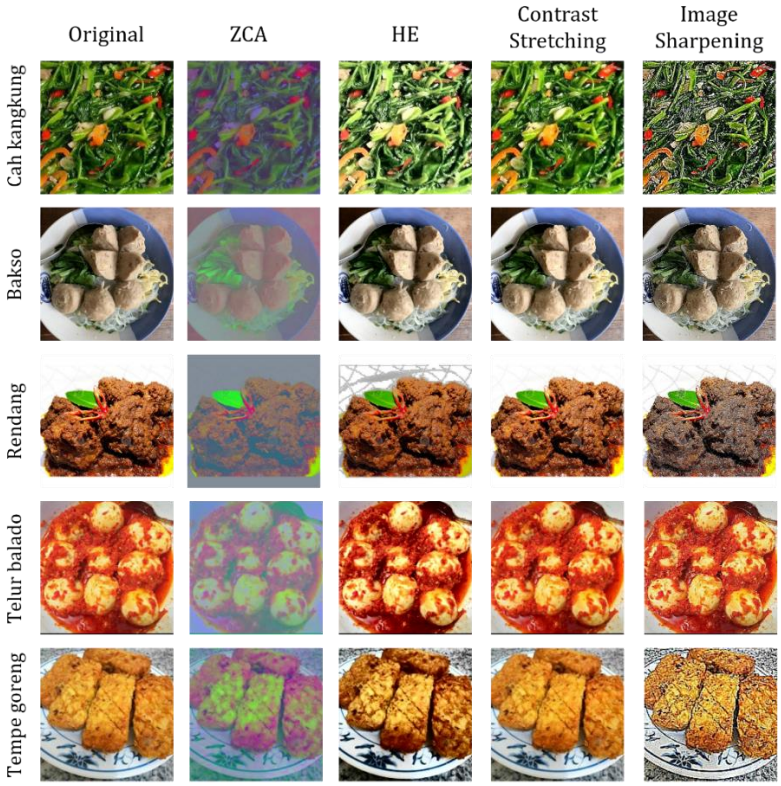

Gambar 4. Hasil preprocessing citra makanan Indonesia

Gambar 5 menunjukkan hasil *confusion matrix* pada citra data testing sebelum preprocessing dan setelah *preprocessing* pada masing-masing metode. Angka 0 menunjukkan kelas cah kangkung, 1 untuk bakso, 2 untuk rendang, 3 untuk telur balado, dan 4 untuk tempe goreng. Dari *confusion matrix* ini dapat dilihat bahwa secara garis besar sistem telah mampu melakukan proses klasifikasi citra makanan Indonesia, baik sebelum *preprocessing* maupun setelah *preprocessing*.

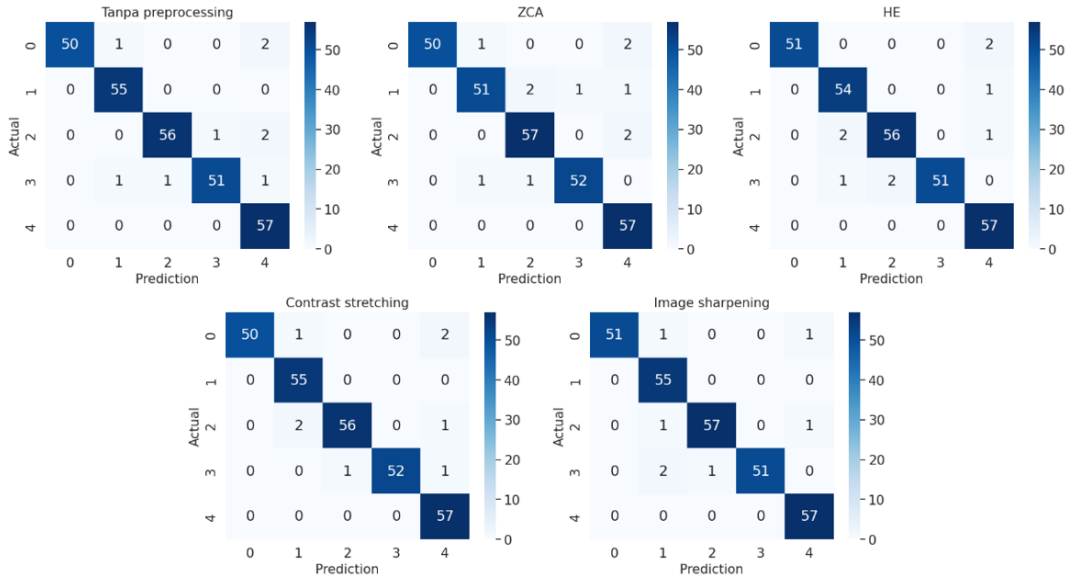

Gambar 5. Hasil confusion matrix data testing

ISSN : 1411-1624
e-ISSN: 2621-8089

Selanjutnya, untuk melihat performa sistem lebih dalam digunakan perhitungan akurasi, presisi, *recall* dan f1-*score*. Hasil perhitungan dapat dilihat pada Tabel 2. Dari hasil perhitungan ini, dapat dilihat bahwa penggunaan metode *preprocessing Image Sharpening* memiliki hasil akurasi dan presisi data *testing* yang lebih tinggi dari metode *preprocessing* lainnya, yaitu sebesar 0,9748 dan 0,98. Selain itu, penggunaan *preprocessing Image Sharpening* juga menghasilkan nilai akurasi yang lebih tinggi jika dibandingkan dengan klasifikasi tanpa *preprocessing* citra telebih dahulu

Tabel 2. Hasil perhitungan perfoma metode

Methode	*Accuracy*	*Precision*	*Recall*	*F1-score*
Tanpa preprocessing	0,9676	0,97	0,97	0,97
ZCA	0,9604	0,96	0,96	0,96
HE	0,9676	0,97	0,97	0,97
Contrast Stretching	0,9712	0,97	0,97	0,97
Image Sharpening	0,9748	0,98	0,97	0,97

4. KESIMPULAN

Penelitian ini mengkaji efektivitas empat metode *preprocessing* citra—*Zero Component Analysis* (ZCA), *Histogram Equalization* (HE), *Contrast Stretching*, dan *Image Sharpening*—dalam meningkatkan kualitas visual serta akurasi klasifikasi citra makanan Indonesia dengan model *transfer learning* ResNet50. Secara visual, masing-masing teknik menunjukkan karakteristik yang berbeda: ZCA mampu meningkatkan kontras dan ketajaman namun cenderung mengubah warna asli gambar, sedangkan *Image Sharpening* menghasilkan peningkatan ketajaman tanpa mengganggu komposisi warna secara signifikan. HE dan *Contrast Stretching* sama-sama meningkatkan kontras, namun HE berpotensi menyebabkan *over-enhancement*, sementara *Contrast Stretching* mempertahankan tampilan alami objek.

Dari hasil evaluasi kuantitatif menggunakan metrik akurasi, presisi, *recall*, dan F1-*score*, diketahui bahwa metode *Image Sharpening* memberikan performa terbaik dengan akurasi sebesar 0,9748 dan presisi sebesar 0,98 pada data uji. Selain unggul dibanding metode *preprocessing* lainnya, *Image Sharpening* juga menunjukkan peningkatan performa signifikan dibanding sistem klasifikasi tanpa *preprocessing*. Temuan ini menunjukkan bahwa pemilihan metode *preprocessing* yang tepat berkontribusi langsung terhadap peningkatan akurasi sistem klasifikasi berbasis *deep learning*, khususnya dalam domain pengenalan citra makanan. Meskipun tidak terlalu signifikan perbedaannya, namun dapat dipertingkan untuk digunakan dalam meningkatkan akurasi klasifikasi citra makanan indonesia.

DAFTAR PUSTAKA

[1] S. Upadhyay and G. Goel, “Food computing research opportunities using AI and ML,” in *Image based computing for food and health analytics: Requirements, challenges, solutions and practices: IBCFHA*, Springer, 2023, pp. 1–23.

[2] B. Shah and H. Bhavsar, “Overview of deep learning in food image classification

ISSN : 1411-1624
e-ISSN: 2621-8089

for dietary assessment system," in *Intelligent Systems, Technologies and Applications: Proceedings of Sixth ISTA 2020, India*, Springer, 2021, pp. 265–285.

[3] T. Karlita, B. P. Afif, and I. Prasetyaningrum, "Indonesian Traditional Cake Classification Using Convolutional Neural Networks," in *International Conference on Applied Science and Technology on Social Science 2021 (iCAST-SS 2021)*, Atlantis Press, 2022, pp. 924–929.

[4] C. Mahaputri, Y. Kristian, and E. Setyati, "Pengenalan Makanan Tradisional Indonesia Beserta Bahan-bahannya dengan Memanfaatkan DCNN Transfer Learning," *INSYST: Journal of Intelligent System and Computation*, vol. 4, no. 2, pp. 61–68, 2022.

[5] H. Singh, *Practical machine learning and image processing: for facial recognition, object detection, and pattern recognition using Python*. Springer, 2019.

[6] P. Misra and A. S. Yadav, "Impact of preprocessing methods on healthcare predictions," in *Proceedings of 2nd International Conference on Advanced Computing and Software Engineering (ICACSE)*, 2019.

[7] K. R. Ummah, T. Karlita, R. Sigit, E. M. Yuniarno, I. K. E. Purnama, and M. H. Purnomo, "Effect of image pre-processing method on convolutional neural network classification of COVID-19 CT scan images," *International Journal of Innovative Computing, Information and Control*, vol. 18, no. 6, pp. 1895–1912, 2022.

[8] K. K. Pal and K. S. Sudeep, "Preprocessing for image classification by convolutional neural networks," in *2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, IEEE, 2016, pp. 1778–1781.

[9] F. Marpaung, Z. A. Koemadji, M. Hidayat, A. Widianto, and F. Aulia, "Selection of Food Identification System Features Using Convolutional Neural Network (CNN) Method," *Scientific Journal of Informatics*, vol. 10, no. 2, pp. 205–2016, 2023.

[10] J. Chaki and N. Dey, *A beginner's guide to image preprocessing techniques*. CRC Press, 2018.

[11] A. Kalapos and B. Gyires-Tóth, "Whitening Consistently Improves Self-Supervised Learning," in *2024 International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2024, pp. 448–453.

[12] M. M. Weli and O. M. Abdullah, "Digital Image Noise Reduction Based on Proposed Smoothing and Sharpening Filters," *The Indonesian Journal of Computer Science*, vol. 13, no. 4, 2024.

[13] A. B. Panambur, P. Madhu, and A. Maier, "Effect of random histogram equalization on breast calcification analysis using deep learning," in *Bildverarbeitung für die Medizin 2022: Proceedings, German Workshop on Medical Image Computing, Heidelberg, June 26-28, 2022*, Springer, 2022, pp. 173–178.

[14] B. Hartono and V. Lusiana, "Analisa Teknik Adaptive Histogram Equalization dan Contrast Stretching untuk Perbaikan Kualitas Citra," *Dinamik*, vol. 19, no. 1, 2014.

[15] A. Firma and S. Oktamuliani, "Pengolahan Filtering dan Contrast Enhancement untuk Meningkatkan Kualitas Resolusi Citra Ultrasonografi Abdomen," *JOURNAL ONLINE OF PHYSICS*, vol. 8, no. 1, pp. 51–54, 2022.

[16] J. Wang and Y. Chen, *Introduction to transfer learning: algorithms and practice*. Springer Nature, 2023.

[17] D. A. Roberts, S. Yaida, and B. Hanin, *The principles of deep learning theory*, vol. 46. Cambridge University Press Cambridge, MA, USA, 2022.

[18] A. Artasanchez and P. Joshi, *Artificial Intelligence with Python*. Packt Publishing Birmingham, UK, 2020.