

KLASIFIKASI TINGKAT KEMATANGAN KUE PUKIS ORIGINAL MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* (CNN)

Gerardus Berek¹⁾, Supatman²⁾

^{1,2}Prodi Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta

Correspondence author: G Berek, garardusberek@gmail.com, Yogyakarta, Indonesia

Abstract

This study aims to classify the doneness level of original pukis cakes using a Convolutional Neural Network (CNN). The research method used is quantitative with an experimental approach. Manually determining the doneness level of pukis cakes is subjective and influenced by lighting conditions, resulting in inconsistent assessments. The dataset was obtained from images of the pukis cake baking process, which were extracted into image frames and divided into three classes: uncooked, half-cooked, and done. The preprocessing stage included image resizing to 64x64 pixels, normalization, and data augmentation. A CNN model was used to extract features and perform image classification. The results showed that the model achieved an accuracy of 97.81% on the test data. These results demonstrate that the CNN method can automatically classify the doneness level of pukis cakes with a high degree of accuracy.

Keywords : *convolutional neural network, image classification, doneness level, pukis cakes*

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan kue pukis original menggunakan metode Convolutional Neural Network (CNN). Metode penelitian yang digunakan adalah metode kuantitatif dengan pendekatan eksperimen. Penentuan tingkat kematangan kue pukis secara manual masih bersifat subjektif dan dipengaruhi oleh kondisi pencahayaan sehingga menghasilkan penilaian yang kurang konsisten. Dataset diperoleh dari citra proses pemanggangan kue pukis yang diekstrak menjadi frame citra dan dibagi ke dalam tiga kelas, yaitu belum matang, setengah matang, dan matang. Tahap praproses meliputi resize citra menjadi 64×64 piksel, normalisasi, dan augmentasi data. Model CNN digunakan untuk mengekstraksi fitur serta melakukan klasifikasi citra. Hasil penelitian menunjukkan bahwa model mampu mencapai akurasi sebesar 97,81% pada data pengujian. Hasil tersebut menunjukkan bahwa metode CNN mampu mengklasifikasikan tingkat kematangan kue pukis secara otomatis dengan tingkat akurasi yang tinggi.

Kata Kunci : convolutional neural network, klasifikasi citra, tingkat kematangan, kue pukis

A. PENDAHULUAN

Perkembangan teknologi pengolahan citra digital saat ini yang semakin pesat dan telah banyak diterapkan dalam berbagai bidang, termasuk industri makanan (Xiao et al., 2022; Zhu et al., 2021). Pengolahan citra digital memungkinkan komputer untuk mengenali objek secara otomatis berdasarkan citra sehingga dapat meningkatkan efisiensi dan akurasi dalam proses identifikasi (Chang, 2024).

Kue pukis merupakan salah satu makanan tradisional yang populer di Indonesia (Corlina, 2022). Dalam proses pembuatannya, penentuan tingkat kematangan masih dilakukan secara manual dengan mengamati warna permukaan kue. Metode ini memiliki kelemahan karena bergantung pada pengalaman individu serta kondisi pencahayaan sehingga hasil penilaian cenderung subjektif dan kurang konsisten.

Seiring dengan perkembangan teknologi, metode *deep learning* menunjukkan peningkatan signifikan dalam bidang klasifikasi citra karena mampu mempelajari pola visual secara otomatis dan efektif (Kiran et al., 2025). Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network* (CNN) yang mampu melakukan ekstraksi fitur secara otomatis dan menghasilkan performa klasifikasi yang tinggi pada berbagai kasus *computer vision* (Bataineh et al., 2023). CNN memiliki kemampuan dalam mengenali pola visual seperti warna, tekstur, dan bentuk dengan tingkat akurasi yang tinggi (Taye, 2023).

Pengolahan citra digital merupakan teknik yang digunakan untuk mengolah dan menganalisis gambar agar dapat dikenali oleh komputer. Citra digital tersusun dari kumpulan piksel yang memiliki nilai intensitas tertentu, di mana setiap piksel menyimpan informasi visual yang dapat dimanfaatkan dalam proses analisis (Archana & Jeevaraj, 2024). Dalam konteks

industri makanan, pengolahan citra banyak digunakan untuk menilai kualitas makanan secara otomatis berdasarkan karakteristik visual seperti warna, bentuk, dan tekstur sehingga dapat mengurangi subjektivitas dalam penilaian (Zhu et al., 2021).

Penelitian sebelumnya menunjukkan bahwa CNN mampu melakukan klasifikasi citra makanan dengan performa yang baik pada berbagai kondisi pencahayaan dan variasi objek (Nfor et al., 2025). CNN efektif dalam mengekstraksi fitur secara otomatis dan menghasilkan performa yang tinggi dalam berbagai tugas *computer vision* (Khanam et al., 2024). Hasil serupa juga dilaporkan oleh (Roopa et al., 2024) dan (Bataineh et al., 2023) yang menunjukkan bahwa optimasi model CNN mampu meningkatkan performa klasifikasi citra pada berbagai objek. Namun, sebagian besar penelitian masih menggunakan dataset berupa citra statis sehingga belum banyak memanfaatkan data yang diperoleh dari proses pemanggangan secara bertahap.

Meskipun demikian, penelitian mengenai klasifikasi tingkat kematangan kue pukis masih terbatas, terutama yang menggunakan dataset hasil ekstraksi *frame* dari proses pemanggangan. Padahal, penggunaan data dari proses pemanggangan memungkinkan sistem menangkap perubahan karakteristik visual secara bertahap selama proses berlangsung.

Meskipun berbagai penelitian telah menunjukkan bahwa metode *Convolutional Neural Network* (CNN) memiliki performa yang baik dalam klasifikasi citra makanan, sebagian besar penelitian masih menggunakan dataset berupa citra statis. Penelitian mengenai klasifikasi tingkat kematangan kue pukis juga masih terbatas, terutama yang memanfaatkan data hasil ekstraksi *frame* dari proses pemanggangan. Oleh karena itu, penelitian ini memanfaatkan *frame* hasil ekstraksi video proses pemanggangan sehingga perubahan karakteristik visual tingkat kematangan dapat diamati secara bertahap dan

menghasilkan sistem klasifikasi yang lebih objektif serta akurat.

Oleh karena itu, penelitian ini bertujuan untuk membangun sistem klasifikasi tingkat kematangan kue pukis secara otomatis menggunakan metode *Convolutional Neural Network* (CNN) serta memanfaatkan dataset hasil ekstraksi citra dari proses pemanggangan. Diharapkan sistem yang dihasilkan mampu memberikan hasil klasifikasi yang lebih akurat, objektif, dan konsisten.

B. METODE PENELITIAN

Alur Penelitian

Proses penelitian diawali dengan pemasakan kue pukis original. Selanjutnya dilakukan akuisisi *image* melalui pengambilan video proses pemanggangan. Video yang diperoleh kemudian diekstraksi menjadi *frame* citra dan digunakan untuk membentuk *dataset*. *Dataset* selanjutnya melalui tahap *preprocessing* yang meliputi *resize*, normalisasi, dan augmentasi data. Setelah itu dilakukan proses klasifikasi menggunakan *Convolutional Neural Network* (CNN) sehingga diperoleh hasil klasifikasi tingkat kematangan kue pukis ke dalam tiga kategori, yaitu belum matang, setengah matang, dan matang.



Gambar 1. Flowchart Penelitian

Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari citra proses pemanggangan kue pukis yang diekstrak menjadi *frame* citra dengan tiga kelas. *Dataset* ini digunakan sebagai data utama dalam proses pelatihan dan pengujian model *Convolutional Neural Network* (CNN).

Jumlah keseluruhan dataset yang digunakan sebanyak 8839 citra yang diperoleh dari hasil ekstraksi *frame* video proses pemanggangan kue pukis. *Dataset* kemudian dibagi menjadi *data training* sebanyak 6187 citra, data validasi sebanyak 1327 citra, dan *data testing* sebanyak 1325 citra. Pembagian data tersebut dilakukan untuk menghasilkan proses pelatihan dan evaluasi model yang optimal.

Dataset dibagi menjadi tiga kategori berdasarkan tingkat kematangan kue pukis, yaitu:

1. Kue pukis belum matang, ditandai dengan warna pucat atau putih.
2. Kue pukis setengah matang, ditandai dengan warna kuning kecoklatan.
3. Kue pukis matang, ditandai dengan warna coklat keemasan.

Perbedaan karakteristik visual seperti warna dan tekstur pada setiap kategori digunakan dalam proses klasifikasi tingkat kematangan kue pukis.



Gambar 2. Dataset Kue Pukis Belum Matang



Gambar 3. Dataset Kue Pukis Setengah Matang



Gambar 4. Dataset Kue Pukis Matang

Pre-processing

Tahap preprocessing dilakukan untuk menyiapkan data sebelum proses pelatihan model CNN. Tahapan ini bertujuan untuk meningkatkan kualitas data serta mempercepat proses komputasi. Proses yang dilakukan meliputi:

1. Resize citra menjadi ukuran 64×64 piksel agar seragam.
2. Normalisasi nilai piksel untuk menstabilkan proses training.
3. Augmentasi data seperti rotasi, translasi, dan flipping untuk menambah variasi data dan mengurangi overfitting.

Dengan tahap ini, model dapat belajar dari data yang lebih terstruktur sehingga meningkatkan performa klasifikasi. Teknik preprocessing dan augmentasi data digunakan untuk meningkatkan kualitas dataset dan mengurangi overfitting pada model CNN (Tribuana et al., 2024).

Model CNN

Model *Convolutional Neural Network* (CNN) digunakan untuk mengekstraksi fitur dan melakukan klasifikasi citra kue

pukis berdasarkan tingkat kematangannya. CNN mampu mengenali pola visual seperti warna dan tekstur yang menjadi pembeda utama antar kategori kematangan. Arsitektur CNN dipilih karena efektif dalam proses klasifikasi citra dan ekstraksi fitur secara otomatis (Bataineh et al., 2023).

Arsitektur CNN yang digunakan terdiri dari beberapa layer utama, yaitu:

1. *Convolution layer*, digunakan untuk mengekstraksi fitur dari citra input.
2. *Batch normalization*, digunakan untuk menstabilkan distribusi data selama proses pelatihan.
3. *ReLU (Rectified Linear Unit)*, digunakan sebagai fungsi aktivasi untuk mempercepat proses pembelajaran.
4. *Max pooling layer*, digunakan untuk mengurangi dimensi data sekaligus mempertahankan fitur penting.
5. *Fully connected layer*, digunakan untuk menghubungkan fitur yang telah diekstraksi ke tahap klasifikasi.
6. *Softmax layer*, digunakan untuk menentukan probabilitas setiap kelas output.

Arsitektur CNN yang digunakan dalam penelitian ini terdiri dari beberapa *convolution layer* yang diikuti oleh *batch normalization*, fungsi aktivasi ReLU, *max pooling layer*, *fully connected layer*, serta *softmax layer* sebagai tahap akhir klasifikasi. Kombinasi layer tersebut memungkinkan model mempelajari karakteristik warna dan tekstur pada citra kue pukis secara efektif sehingga menghasilkan performa klasifikasi yang tinggi.

Model CNN ini dirancang untuk mengenali perbedaan warna dan tekstur yang menunjukkan tingkat kematangan kue pukis, sehingga dapat menghasilkan klasifikasi yang akurat.

Parameter Training

Parameter training yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Parameter Training

Parameter	Nilai
Optimizer	Adam
Epoch	25
Batch Size	32
Learning Rate	0.001

Optimizer Adam digunakan karena mampu menyesuaikan *learning rate* secara adaptif sehingga proses pelatihan menjadi lebih stabil. Jumlah *epoch* sebanyak 25 dipilih agar model memiliki iterasi yang cukup tanpa menyebabkan *overfitting*.

Batch size sebesar 32 digunakan untuk menyeimbangkan kecepatan pelatihan dan penggunaan memori. Sementara itu, *learning rate* sebesar 0.001 digunakan untuk mengontrol proses pembelajaran agar model dapat mencapai konvergensi dengan baik.

Evaluasi

Evaluasi dilakukan untuk mengukur performa model CNN dalam mengklasifikasikan tingkat kematangan kue pukis. Metode evaluasi yang digunakan meliputi:

1. Akurasi (*accuracy*), untuk mengukur tingkat keberhasilan model secara keseluruhan.
2. *Confusion Matrix*, untuk melihat detail hasil klasifikasi pada setiap kelas.
3. *Precision*, untuk mengukur ketepatan prediksi model.
4. *Recall*, untuk mengukur kemampuan model dalam mengenali data sebenarnya.
5. *F1-Score*, untuk mengukur keseimbangan antara *precision* dan *recall*.


Dengan metrik tersebut, performa model dapat dianalisis secara menyeluruh.

C. HASIL DAN PEMBAHASAN

Hasil Ekstraksi Frame

Proses ekstraksi frame menghasilkan dataset citra dari proses pemanggangan kue pukis untuk menangkap variasi tingkat kematangan secara bertahap.

Dataset kemudian dibagi menjadi tiga kategori, yaitu belum matang, setengah matang, dan matang, berdasarkan perbedaan warna. Proses ini bertujuan menghasilkan data yang bervariasi dan representatif agar model CNN dapat mempelajari pola dengan baik dan meningkatkan akurasi klasifikasi.



Gambar 5. Hasil Ekstraksi Frame


Hasil Training

Hasil proses pelatihan model *Convolutional Neural Network* (CNN) ditunjukkan pada Gambar 6. Grafik menunjukkan bahwa akurasi *training* mengalami peningkatan yang signifikan sejak awal pelatihan, kemudian cenderung stabil pada nilai yang tinggi, yaitu berada pada kisaran 97% hingga mendekati 100%. Akurasi *validasi* juga menunjukkan nilai yang tinggi dan stabil dengan nilai akhir mencapai sekitar 96,99%.

Selain itu, nilai *loss* mengalami penurunan secara bertahap dari nilai awal yang relatif tinggi hingga mencapai nilai yang rendah dan stabil pada akhir proses pelatihan. Hal ini menunjukkan bahwa model mampu mempelajari pola data

dengan baik dan mengurangi kesalahan prediksi.

Perbedaan antara akurasi *training* dan *validasi* yang tidak terlalu signifikan menunjukkan bahwa model tidak mengalami *overfitting* yang berarti. Dengan demikian, model memiliki kemampuan generalisasi yang baik dalam mengklasifikasikan data baru.



Gambar 6. Grafik *Accuracy* dan *Loss*

Hasil Evaluasi

Hasil evaluasi model *Convolutional Neural Network (CNN)* dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 2. Hasil Akurasi

Pengujian	Jumlah Data	Akurasi
Training	6187	± 98%
Validasi	1327	96.99%
Testing	1325	97.81%

Berdasarkan hasil pengujian, model CNN yang diusulkan mampu mencapai akurasi sebesar 97,81% pada data *testing*. Nilai ini menunjukkan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan tingkat kematangan kue pukis.

Akurasi pada data *training* dan *validasi* juga menunjukkan nilai yang tinggi dengan perbedaan yang tidak signifikan. Hal ini mengindikasikan bahwa model mampu belajar dengan baik serta memiliki kemampuan generalisasi yang baik

terhadap data baru. Selain itu, pembagian data yang proporsional antara *training*, *validasi*, dan *testing* turut mendukung performa model yang optimal dan stabil.

Confusion Matrix

Confusion matrix yang dihasilkan ditunjukkan pada Gambar 7. Berdasarkan gambar tersebut, sebagian besar data berhasil diklasifikasikan dengan benar oleh model CNN.

Confusion Matrix			...	
True Class	kelas1	453		
	kelas2		444	26
	kelas3		3	399
		kelas1	kelas2	kelas3
		Predicted Class		

Gambar 7. *Confusion Matrix*

Pada kelas **belum matang**, seluruh data berhasil diklasifikasikan dengan benar sebanyak 453 data, menunjukkan performa yang sangat baik. Pada kelas **setengah matang**, sebanyak 444 data diklasifikasikan dengan benar, namun terdapat 26 data yang salah diklasifikasikan ke kelas matang, yang menunjukkan adanya kemiripan karakteristik antara kedua kelas tersebut.

Pada kelas **matang**, sebanyak 399 data berhasil diklasifikasikan dengan benar, dengan hanya 3 data yang salah diklasifikasikan ke kelas setengah matang. Secara keseluruhan, kesalahan klasifikasi relatif kecil dan sebagian besar terjadi pada kelas dengan karakteristik warna yang mirip.

Hasil Klasifikasi

Berdasarkan hasil klasifikasi, kelas Belum Matang memperoleh performa terbaik dengan nilai *precision*, *recall*, dan

F1-score sebesar 1.000. Kelas Setengah Matang memiliki nilai *recall* terendah sebesar 0.945 karena terdapat beberapa data yang salah diklasifikasikan ke kelas Matang akibat kemiripan warna. Sementara itu, kelas Matang memperoleh *recall* sebesar 0.993 yang menunjukkan bahwa sebagian besar data berhasil dikenali dengan benar.

Hasil ini menunjukkan bahwa model CNN mampu membedakan ketiga tingkat kematangan kue pukis dengan sangat baik.

Tabel 3. Hasil Klasifikasi

Kelas	Precision	Recall	F1-Score
Belum Matang	1.000	1.000	1.000
Setengah Matang	0.993	0.945	0.968
Matang	0.939	0.993	0.964
Rata-rata	0.977	0.979	0.977

Pembahasan

Berdasarkan keseluruhan hasil penelitian, model *Convolutional Neural Network* (CNN) mampu mengenali karakteristik visual pada citra kue pukis dengan sangat baik. Hal ini ditunjukkan oleh akurasi pengujian sebesar **97,81%** serta nilai *precision*, *recall*, dan *F1-score* yang tinggi pada setiap kelas.

Kesalahan klasifikasi sebagian besar terjadi pada kategori setengah matang yang disebabkan oleh kemiripan karakteristik visual dengan kategori matang. Tingkat keberhasilan model dalam mengklasifikasikan data menunjukkan bahwa fitur-fitur yang diekstraksi secara otomatis oleh CNN memberikan kontribusi yang signifikan terhadap proses identifikasi tingkat kematangan kue pukis.

CNN memiliki kemampuan untuk melakukan ekstraksi fitur secara otomatis melalui lapisan konvolusi. Model mampu mempelajari berbagai karakteristik visual seperti warna, tekstur, dan pola permukaan kue pukis yang mengalami perubahan selama proses pemanggangan. Kemampuan

tersebut memungkinkan model membedakan tingkat kematangan pada setiap kategori dengan baik.

Tingginya akurasi model juga dipengaruhi oleh tahap *preprocessing* dan augmentasi data yang diterapkan. Proses *resize* dan normalisasi membantu menyeragamkan ukuran serta nilai piksel citra, sedangkan augmentasi data meningkatkan keragaman data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik terhadap data baru.

Hasil penelitian ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa *Convolutional Neural Network* (CNN) sangat efektif digunakan dalam klasifikasi citra makanan karena mampu mengekstraksi fitur visual secara otomatis dan menghasilkan tingkat akurasi yang tinggi (Nfor et al., 2025; Sun, 2024; Xiao et al., 2022; Zhu et al., 2021).

Akurasi sebesar 97,81% yang diperoleh pada penelitian ini menunjukkan bahwa model CNN yang digunakan memiliki performa yang sangat baik dalam mengklasifikasikan tingkat kematangan kue pukis. Hasil tersebut menunjukkan bahwa pendekatan yang digunakan mampu menghasilkan tingkat akurasi yang kompetitif dibandingkan penelitian-penelitian sebelumnya pada bidang klasifikasi citra makanan menggunakan metode *Convolutional Neural Network* (CNN).

Salah satu keunggulan penelitian ini adalah penggunaan dataset yang diperoleh dari hasil ekstraksi *frame* video proses pemanggangan kue pukis. Pendekatan tersebut memungkinkan model mempelajari perubahan karakteristik visual tingkat kematangan secara bertahap sehingga mampu meningkatkan kemampuan klasifikasi secara lebih akurat dan konsisten. Selain itu, penggunaan data hasil ekstraksi *frame* memberikan variasi data yang lebih representatif terhadap kondisi

nyata selama proses pemanggangan berlangsung.

Secara keseluruhan, model yang dikembangkan memiliki performa yang sangat baik dan berpotensi untuk diterapkan sebagai sistem otomatis dalam menentukan tingkat kematangan kue pukis. Sistem ini dapat membantu mengurangi subjektivitas dalam penilaian tingkat kematangan sehingga menghasilkan proses identifikasi yang lebih objektif, konsisten, dan efisien.

Penelitian ini masih terbatas pada penggunaan *dataset* kue pukis original dengan kondisi pencahayaan yang relatif terkontrol serta jumlah data yang terbatas pada tiga kelas tingkat kematangan, yaitu belum matang, setengah matang, dan matang. Pada penelitian selanjutnya dapat digunakan *dataset* yang lebih beragam, jumlah data yang lebih banyak, serta kondisi lingkungan dan pencahayaan yang berbeda untuk menguji kemampuan generalisasi dan *robustness* model secara lebih menyeluruh.

D. PENUTUP

Berdasarkan hasil penelitian yang telah dilakukan, metode *Convolutional Neural Network* (CNN) mampu mengklasifikasikan tingkat kematangan kue pukis original dengan baik. Model yang dikembangkan menghasilkan akurasi sebesar 97,81% pada data pengujian serta didukung oleh nilai *precision*, *recall*, dan *F1-score* yang tinggi pada setiap kelas.

Model CNN mampu mempelajari karakteristik visual berupa warna dan tekstur pada citra kue pukis sehingga dapat membedakan tingkat kematangan ke dalam tiga kategori, yaitu belum matang, setengah matang, dan matang. Tahap *preprocessing* dan augmentasi data juga berkontribusi dalam meningkatkan kemampuan generalisasi model terhadap data baru.

Dengan demikian, sistem yang dikembangkan dapat digunakan sebagai solusi otomatis dalam mengidentifikasi

tingkat kematangan kue pukis secara lebih objektif, konsisten, dan efisien. Hasil penelitian ini menunjukkan bahwa metode *Convolutional Neural Network* (CNN) memiliki potensi yang baik untuk diterapkan dalam bidang pengolahan citra, khususnya pada klasifikasi tingkat kematangan produk makanan.

Penelitian selanjutnya dapat menggunakan *dataset* yang lebih banyak dan lebih beragam agar performa model serta kemampuan generalisasi sistem menjadi lebih optimal.

Penggunaan arsitektur *Convolutional Neural Network* (CNN) yang lebih kompleks atau model *deep learning* lainnya dapat dikembangkan untuk meningkatkan akurasi klasifikasi.

Sistem yang dikembangkan dapat diimplementasikan dalam bentuk aplikasi *real-time* sehingga dapat digunakan secara langsung pada proses produksi kue pukis.

Sistem dapat dikembangkan dalam bentuk aplikasi berbasis web maupun mobile agar lebih mudah digunakan dan memiliki cakupan penggunaan yang lebih luas.

E. DAFTAR PUSTAKA

- Archana, R., & Jeevaraj, P. S. E. (2024). Deep learning models for digital image processing: a review. *Artificial Intelligence Review*, 57, 11. <https://doi.org/10.1007/s10462-023-10631-z>
- Bataineh, A. Al, Kaur, D., Al-Khassawneh, M., & Al-Sharoa, E. (2023). Automated CNN Architectural Design: A Simple and Efficient Methodology for Computer Vision Tasks. *Mathematics*, 11(5), 1141. <https://doi.org/10.3390/math11051141>
- Chang, L. (2024). Application of Computer Image Processing and Recognition Technology. *Advances in Computer and Communication*, 5(2), 118–121.

- <https://doi.org/10.26855/acc.2024.04.004>
- Corlina, Y. (2022). Experiment of Processing Jackfruit Bean Flour in Making Pukis Cake. *Gastronomy: Gastronomy and Culinary Art*, 1(2), 67–77.
<https://jurnal.ampta.ac.id/index.php/Gastronomy/article/view/387>
- Khanam, R., Hussain, M., Hill, R., & Allen, P. (2024). A Comprehensive Review of Convolutional Neural Networks for Defect Detection in Industrial Applications. *IEEE Access*, 12, 94250–94295.
<https://doi.org/10.1109/ACCESS.2024.3425166>
- Kiran, K., Manne, S., Satyanarayana, B., Chandra, K. R., Sharmila, K. S., & Swathi, S. (2025). Deep Learning-Based Intelligent Image Processing for Automated Feature Extraction and Pattern Recognition. *International Conference on Information, Implementation, and Innovation in Technology (I2ITCON)*, 1–5.
<https://doi.org/10.1109/I2ITCON65200.2025.11210539>
- Nfor, K. A., Armand, T. P. T., Ismaylovna, K. P., Joo, M.-I., & Kim, H.-C. (2025). An Explainable CNN and Vision Transformer-Based Approach for Real-Time Food Recognition. *Nutrients*, 17(2), 362.
<https://doi.org/10.3390/nu17020362>
- Roopa, B. S., Prema, K. N., & Smitha, S. M. (2024). Brief Study on Convolutional Neural Networks. *International Journal For Multidisciplinary Research*, 6(5), 1–6.
<https://doi.org/10.36948/ijfmr.2024.v06i05.28671>
- Sun, Q. (2024). Food Image Classification and Food Safety Detection based on Pretrained Convolutional Neural Network. *Third International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*.
<https://doi.org/10.1109/ICDCECE60827.2024.10548096>
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3), 52.
<https://doi.org/10.3390/computation11030052>
- Tribuana, D., Hazriani, & Arda, A. L. (2024). Image Preprocessing Approaches Toward Better Learning Performance with CNN. *RESTI: Rekayasa Sistem Dan Teknologi Informasi*, 8(1), 1–9.
<https://doi.org/10.29207/resti.v8i1.5417>
- Xiao, Z., Wang, J., Han, L., Guo, S., & Cui, Q. (2022). Application of Machine Vision System in Food Detection. *Frontiers in Nutrition*, 9, 888245.
<https://doi.org/10.3389/fnut.2022.888245>
- Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, 4, 233–249.
<https://doi.org/10.1016/j.crfs.2021.03.009>