

Hybrid Convolutional Neural Network dan Learning Vector Quantization pada Klasifikasi Tempe Goreng Organik dan Non-Organik

Sri Bintang Muksin^{*1}, Supatman²,

^{1,2}Informatika/Universitas Mercu Buana Yogyakarta

e-mail: ^{*1}221110094@student.mercubuana-yogya.ac.id, ²Supatman@mercubuana-yogya.ac.id

Abstract – Tempe is a traditional Indonesian fermented soybean food widely consumed by the community. Based on the raw materials used, tempe is generally categorized into organic tempe produced from local non-GMO soybeans and non-organic tempe made from imported GMO soybeans. Both types of fried tempe, organic and non-organic, have relatively similar appearance, making manual identification difficult. This research proposes an image classification system to distinguish organic and non-organic fried tempe using a hybrid Convolutional Neural Network (CNN) and Learning Vector Quantization (LVQ) approach. CNN is employed to automatically extract image features, while LVQ is utilized for the classification process. The dataset used in this study consists of 380 fried tempe images, including 190 organic fried tempe images and 190 non-organic fried tempe images. The dataset was divided into 80% training data and 20% testing data. Experimental results show that the proposed method achieved an accuracy of 85.53%, with precision, recall, and F1-score values of 0.8575, 0.8553, and 0.8550, respectively. The results indicate that the hybrid CNN-LVQ method can be effectively implemented for fried tempe image classification. Compared to previous studies that applied CNN independently for tempe classification, the proposed hybrid CNN-LVQ method demonstrates that combining CNN as a feature extractor with LVQ as a classifier provides an effective alternative approach for organic and non-organic fried tempe image classification.

Keywords – Organic Fried Tempe, Non-Organic Fried Tempe, CNN, LVQ, Computer Vision

Abstrak – Tempe merupakan makanan fermentasi berbahan dasar kedelai yang banyak dikonsumsi masyarakat Indonesia. Berdasarkan bahan bakunya, tempe umumnya dibedakan menjadi tempe organik yang menggunakan kedelai lokal non-GMO dan tempe non-organik yang berasal dari kedelai impor GMO. Kedua jenis tempe goreng tersebut, yaitu tempe goreng organik dan non-organik, memiliki kemiripan tampilan yang relatif tinggi sehingga proses identifikasi secara manual cukup sulit dilakukan. Penelitian ini mengusulkan sistem klasifikasi citra untuk membedakan tempe goreng organik dan tempe goreng non-organik menggunakan metode hybrid Convolutional Neural Network (CNN) dan Learning Vector Quantization (LVQ). CNN digunakan untuk mengekstraksi ciri citra tempe goreng organik dan non-organik, sedangkan LVQ dimanfaatkan sebagai metode klasifikasi. Dataset penelitian terdiri dari 380 citra tempe goreng, yaitu 190 citra tempe goreng organik dan 190 citra tempe goreng non-organik. Pembagian data dilakukan dengan proporsi 80% data latih dan 20% data uji. Berdasarkan hasil pengujian, metode yang diusulkan memperoleh nilai akurasi sebesar 85,53% dengan precision, recall, dan F1-score masing-masing sebesar 0,8575, 0,8553, dan 0,8550. Hasil penelitian menunjukkan bahwa metode hybrid CNN-LVQ mampu digunakan secara efektif untuk proses klasifikasi citra tempe goreng. Dibandingkan dengan penelitian sebelumnya yang menerapkan CNN secara mandiri untuk klasifikasi tempe, penelitian ini menunjukkan bahwa kombinasi CNN sebagai ekstraktor fitur dan LVQ sebagai pengklasifikasi merupakan pendekatan alternatif yang efektif untuk klasifikasi citra tempe goreng organik dan non-organik.

Kata Kunci – Tempe Goreng Organik, Tempe Goreng Non-Organik, CNN, LVQ, Computer Vision

I. PENDAHULUAN

Tempe merupakan salah satu makanan tradisional Indonesia yang dihasilkan melalui proses fermentasi kedelai dan memiliki tingkat konsumsi yang tinggi di masyarakat. Indonesia juga dikenal sebagai salah satu negara dengan produksi dan konsumsi tempe terbesar di Asia [1]. Negara Indonesia merupakan produsen tempe terbesar di dunia, di mana sebanyak 50% kedelai Indonesia diproduksi menjadi tempe dengan konsumsi nasional rata-rata per orang per tahun diperkirakan mencapai sekitar 6,45 kg [1]. Namun demikian, konsumen sering mengalami kesulitan dalam membedakan tempe goreng organik dan non-organik karena keduanya memiliki tampilan yang sangat mirip. Berdasarkan bahan baku yang digunakan, tempe umumnya dibedakan menjadi dua jenis, yaitu tempe organik berbahan dasar kedelai lokal non-GMO dan tempe non-organik yang menggunakan kedelai impor GMO. Kedua jenis tempe goreng tersebut memiliki kemiripan tampilan yang relatif tinggi sehingga diperlukan pendekatan berbasis pengolahan citra untuk membantu proses identifikasi tempe goreng organik dan non-organik.

Perkembangan teknologi di bidang pengolahan citra dan kecerdasan buatan membuka peluang untuk melakukan identifikasi citra tempe goreng organik dan non-organik. Salah satu metode yang banyak digunakan dalam bidang klasifikasi citra adalah Convolutional Neural Network (CNN). Metode ini mampu melakukan ekstraksi fitur dari citra sehingga banyak diterapkan pada berbagai penelitian berbasis computer vision [2],[3]. CNN bekerja dengan mempelajari pola pada citra melalui beberapa lapisan konvolusi sehingga dapat mengenali karakteristik tertentu dari suatu objek [4]. Penerapan CNN pada berbagai bidang klasifikasi citra makanan juga telah menunjukkan hasil yang baik [5].

Selain CNN, metode Learning Vector Quantization (LVQ) juga sering digunakan dalam proses klasifikasi data karena memiliki kemampuan mengenali pola berdasarkan pendekatan pembelajaran berbasis prototipe. LVQ dikenal cukup efektif untuk meningkatkan performa klasifikasi pada berbagai kasus pengenalan pola dan jaringan saraf tiruan [6][7]. Metode hybrid CNN-LVQ yang memanfaatkan CNN untuk ekstraksi fitur dan LVQ untuk proses klasifikasi diharapkan mampu menghasilkan sistem klasifikasi citra tempe goreng organik dan non-organik yang lebih optimal dibandingkan penggunaan CNN atau LVQ secara mandiri.

Penelitian [1] menggunakan CNN untuk klasifikasi mutu fisik tempe menghasilkan akurasi 98,71%, namun penelitian tersebut hanya membedakan tempe kondisi baik dan membusuk, bukan membedakan jenis tempe berdasarkan bahan bakunya. Penelitian [5] menerapkan CNN pada klasifikasi citra makanan khas Pasuruan menghasilkan akurasi 100%, namun menggunakan dataset yang jauh lebih besar yaitu 1000 citra dengan objek yang memiliki perbedaan tampilan yang lebih jelas antar kelasnya. Penelitian [6],[7] menggunakan LVQ untuk klasifikasi data sinyal dan pola, menunjukkan LVQ efektif untuk pengenalan pola namun memerlukan fitur input yang sudah terstruktur dengan baik sebelum diklasifikasikan. Berdasarkan analisis tersebut, terdapat kekosongan penelitian pada klasifikasi citra tempe goreng organik dan non-organik yang memiliki kemiripan tampilan tinggi. Oleh karena itu, penelitian ini menerapkan metode hybrid CNN-LVQ yang memanfaatkan kelebihan CNN dalam mengekstraksi fitur citra tempe goreng organik dan non-organik dan kelebihan LVQ dalam mengklasifikasikan pola, sehingga diharapkan menghasilkan performa klasifikasi yang lebih baik. Berdasarkan hal tersebut, penelitian ini bertujuan untuk membangun sistem klasifikasi citra tempe goreng organik dan non-organik menggunakan metode hybrid CNN-LVQ. Sistem yang dikembangkan diharapkan dapat membantu proses identifikasi citra tempe goreng organik dan non-organik.

II. PENELITIAN YANG TERKAIT

Metode *Convolutional Neural Network* (CNN) telah banyak digunakan dalam penelitian klasifikasi citra karena memiliki kemampuan ekstraksi fitur yang baik. Penerapan CNN berkembang pada berbagai bidang, termasuk pengolahan citra makanan dan pertanian. Penelitian mengenai klasifikasi mutu fisik tempe menggunakan CNN menunjukkan bahwa metode tersebut mampu menghasilkan tingkat akurasi yang tinggi dalam membedakan kualitas tempe berdasarkan citra digital [1]. Selain itu, penerapan CNN pada klasifikasi makanan juga menunjukkan bahwa metode tersebut mampu mengenali citra makanan berdasarkan ciri yang diekstraksi [5]. Penelitian lain juga menunjukkan bahwa CNN dapat ditingkatkan performanya menggunakan model residual learning untuk klasifikasi citra makanan yang lebih detail [9]. Selain itu, CNN juga diterapkan untuk segmentasi bahan makanan tunggal berbasis citra [12].

Pada bidang pertanian, CNN dimanfaatkan untuk mendeteksi penyakit tanaman melalui citra daun. Salah satu penelitian menerapkan CNN untuk mengenali penyakit pada daun mangga dan memperoleh hasil klasifikasi yang baik [10]. Penelitian lain menggunakan pendekatan transfer learning untuk meningkatkan performa model CNN dalam proses identifikasi penyakit tanaman berbasis citra digital [8]. Penerapan CNN

juga dikembangkan pada klasifikasi citra makanan dari berbagai budaya untuk mendukung pengenalan pangan yang lebih luas [13]. Selain menggunakan CNN secara mandiri, beberapa penelitian juga menerapkan metode hybrid yang menggabungkan CNN dengan metode lain untuk meningkatkan performa klasifikasi. Salah satu pendekatan yang digunakan adalah hybrid CNN dan Long Short-Term Memory (LSTM) yang mampu memberikan hasil klasifikasi yang baik pada citra tanaman [11].

Selain CNN, metode *Learning Vector Quantization* (LVQ) juga digunakan pada berbagai penelitian klasifikasi berbasis jaringan saraf tiruan. LVQ memiliki kemampuan mengenali pola data berdasarkan pendekatan prototipe sehingga dapat diterapkan pada proses pengelompokkan dan klasifikasi data. Beberapa penelitian menunjukkan bahwa LVQ mampu memberikan hasil klasifikasi yang baik pada berbagai kasus pengenalan pola [6][7].

Berdasarkan penelitian-penelitian tersebut, dapat diidentifikasi beberapa hal penting. Penelitian [1] menggunakan CNN untuk klasifikasi mutu fisik tempe menghasilkan akurasi tinggi, namun hanya membedakan kualitas tempe kondisi baik dan membusuk, bukan berdasarkan jenis bahan bakunya. Penelitian [5],[10],[8] menunjukkan CNN efektif untuk klasifikasi citra makanan dan pertanian, namun semua penelitian tersebut menggunakan CNN secara mandiri sehingga proses klasifikasi sepenuhnya bergantung pada lapisan output CNN. Penelitian yang menggunakan LVQ secara mandiri efektif untuk pengenalan pola namun memerlukan fitur input yang sudah terstruktur dengan baik [6],[7]. Berdasarkan analisis tersebut, terdapat kekosongan penelitian pada klasifikasi citra tempe goreng organik dan non-organik yang memiliki kemiripan tampilan tinggi. Oleh karena itu, penelitian ini menerapkan metode hybrid CNN-LVQ yang memanfaatkan kelebihan CNN dalam mengekstraksi fitur citra tempe goreng organik dan non-organik dan kelebihan LVQ dalam mengklasifikasikan pola sehingga diharapkan menghasilkan performa klasifikasi yang lebih baik.

III. METODE PENELITIAN

A. Alur Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data citra, preprocessing citra, pembagian dataset, ekstraksi fitur menggunakan Convolutional Neural Network (CNN), klasifikasi menggunakan Learning Vector Quantization (LVQ), dan evaluasi performa model. Setiap tahapan dilakukan secara berurutan untuk menghasilkan model klasifikasi citra tempe goreng organik dan non-organik. Alur penelitian ditunjukkan pada Gbr. 1.




Gbr. 1 Alur Penelitian

B. Pengumpulan Data

Dataset yang digunakan berupa citra tempe goreng organik dan non-organik yang diperoleh melalui proses pengambilan citra oleh peneliti. Total dataset terdiri dari 380 citra, yang meliputi 190 citra tempe goreng organik (Non-GMO) dan 190 citra tempe goreng non-organik (GMO). Tempe organik diperoleh dari toko produk organik, sedangkan tempe non-organik diperoleh dari pasar tradisional di Yogyakarta. Setiap objek tempe goreng diambil sebanyak satu citra dengan posisi dan sudut yang bervariasi untuk mendapatkan representasi dataset yang beragam. Validasi label data dilakukan dengan memverifikasi setiap citra berdasarkan sumber pengambilan, yaitu toko produk organik untuk tempe goreng organik (Non-GMO) dan pasar tradisional untuk tempe goreng non-organik (GMO).

Proses pengambilan citra tempe goreng organik dan non-organik dilakukan menggunakan kamera smartphone pada lokasi dan kondisi pencahayaan yang relatif sama. Seluruh citra tempe goreng organik dan non-organik diambil dengan latar belakang berwarna putih serta posisi kamera tegak lurus terhadap objek pada jarak sekitar 20–30 cm. Pengaturan tersebut dilakukan untuk menjaga keseragaman citra sehingga dapat mendukung proses ekstraksi fitur dan klasifikasi. Pengambilan citra dilakukan dalam dua sesi dengan selang waktu satu minggu, yaitu sebanyak 200 citra pada sesi pertama dan 190 citra pada sesi kedua. Untuk menjaga konsistensi pencahayaan, pengambilan citra dilakukan menggunakan cahaya senter smartphone yang berbeda dari smartphone yang digunakan untuk pengambilan citra, karena penggunaan cahaya matahari menyebabkan latar belakang putih berubah menjadi kebiruan dan citra menjadi gelap. Seluruh citra diambil pada lokasi, jarak, dan sudut pengambilan yang sama untuk menjaga konsistensi dataset. Contoh dataset ditunjukkan pada Gbr. 2.



Gbr. 2. Contoh citra tempe goreng organik (a-e) dan tempe goreng non-organik (f-j)

C. Preprocessing Citra

Sebelum dilakukan proses pelatihan model, seluruh citra tempe goreng organik dan non-organik terlebih dahulu melalui tahap preprocessing. Tahap ini bertujuan untuk menyeragamkan ukuran citra tempe goreng organik dan non-organik sebelum proses ekstraksi fitur menggunakan metode CNN. Seluruh citra tempe goreng organik dan non-organik diubah menjadi ukuran 64×64 piksel sesuai dengan ukuran masukan model. Selain proses perubahan ukuran citra (*resize*), dilakukan pula normalisasi nilai piksel dengan mengubah rentang intensitas dari 0–255 menjadi 0–1. Normalisasi dilakukan dengan membagi setiap nilai piksel dengan 255. Tahap ini bertujuan untuk meningkatkan stabilitas proses pelatihan model serta membantu model mencapai konvergensi dengan lebih baik.

D. Pembagian Data

Dataset yang telah melalui tahap preprocessing kemudian dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Dari total 380 citra tempe goreng, sebanyak 304 citra digunakan sebagai data latih dan 76 citra digunakan sebagai data uji. Untuk menjaga keseimbangan jumlah data pada setiap kelas, proses pembagian data dilakukan menggunakan teknik stratifikasi sehingga proporsi citra tempe goreng organik dan non-organik tetap seimbang pada data latih maupun data uji. Distribusi dataset ditunjukkan pada Tabel I.

TABEL I
DISTRIBUSI DATASET

Kelas	Total	Data Latih (80%)	Data Uji (20%)
Tempe Goreng Organik (Non-GMO)	190	152	38
Tempe Goreng Non-Organik (GMO)	190	152	38
Total	380	304	76

E. Arsitektur CNN


Model CNN yang digunakan terdiri dari tiga lapisan konvolusi yang diikuti oleh lapisan *max pooling* dan lapisan terhubung penuh (*fully connected layer*). Lapisan konvolusi pertama menggunakan 32 filter berukuran 3×3 dengan fungsi aktivasi ReLU dan diikuti *max pooling* berukuran 2×2 . Lapisan konvolusi kedua menggunakan 64 filter, sedangkan lapisan konvolusi ketiga menggunakan 128 filter. Hasil ekstraksi fitur kemudian diubah menjadi vektor satu dimensi menggunakan lapisan *flatten* dan dilanjutkan dengan lapisan *dense* yang terdiri atas 128 neuron. Lapisan *dense* ini digunakan untuk menghasilkan representasi fitur yang lebih ringkas sebelum proses klasifikasi. Model dilatih menggunakan optimizer Adam dan fungsi kerugian (*loss function*) *categorical crossentropy* selama 30 epoch dengan ukuran *batch* 16. Detail arsitektur CNN ditunjukkan pada Tabel II.

TABEL II
ARSITEKTUR MODEL CNN

Layer	Output Shape	Parameter
Input Layer	(64, 64, 3)	0
Conv2D (32 Filter, 3x3, ReLU)	(64, 64, 32)	896
MaxPooling2D (2x2)	(32, 32, 32)	0
Conv2D (64 Filter, 3x3, ReLU)	(32, 32, 64)	18.496
MaxPooling2D (2x2)	(16, 16, 64)	0
Conv2D (128 Filter, 3x3, ReLU)	(16, 16, 128)	73.856
MaxPooling2D (2x2)	(8, 8, 128)	0
Flatten	(8192)	0
Dense - Fitur Layer (128, ReLU)	(128)	1.048.704
Dense - Output (2, Softmax)	(2)	258
Total Parameter		1.142.210

Pemilihan 3 lapisan konvolusi dengan jumlah filter yang meningkat secara bertahap (32, 64, 128) didasarkan pada pendekatan umum arsitektur CNN untuk klasifikasi citra berdimensi kecil, di mana filter pada lapisan awal bertugas menangkap fitur sederhana seperti tepi dan tekstur permukaan citra tempe goreng organik dan non-organik, sedangkan filter pada lapisan lebih dalam menangkap fitur yang lebih kompleks. Ukuran input 64×64 piksel dipilih untuk menyeimbangkan kualitas citra dan efisiensi komputasi. Batch size 16 dipilih karena dataset yang relatif kecil sehingga pembaruan bobot dilakukan lebih sering. Jumlah epoch 30 ditentukan berdasarkan pengamatan konvergensi model selama proses pelatihan.

Setelah proses pelatihan selesai, lapisan *dense* dengan 128 neuron digunakan sebagai fitur hasil ekstraksi citra tempe goreng organik dan non-organik sebelum diproses menggunakan LVQ. Grafik proses pelatihan model CNN ditunjukkan pada Gbr. 3.



Gbr. 3 Grafik pelatihan model CNN: (a) akurasi, (b) loss

F. Implementasi LVQ

Fitur hasil ekstraksi CNN selanjutnya diproses menggunakan metode Learning Vector Quantization (LVQ). Sebelum proses klasifikasi dilakukan, fitur terlebih dahulu dinormalisasi menggunakan MinMaxScaler ke rentang nilai 0–1. Model LVQ dilatih menggunakan laju pembelajaran awal sebesar 0,1 dengan penurunan nilai secara linear pada setiap iterasi pelatihan dan jumlah pelatihan sebanyak 100 iterasi. Pada penelitian ini digunakan satu vektor representasi kelas untuk setiap kelas sehingga terdapat dua vektor representasi kelas. Proses klasifikasi dilakukan dengan menghitung jarak Euclidean antara data masukan dan seluruh vektor representasi kelas. Data akan dikelompokkan ke kelas yang memiliki jarak terdekat. Apabila kelas representasi sesuai dengan kelas data latih, maka bobot representasi diperbarui mendekati data masukan. Sebaliknya, apabila kelas berbeda, maka bobot representasi diperbarui menjauhi data masukan.

G. Evaluasi Model

Evaluasi performa sistem dilakukan menggunakan data uji yang tidak digunakan pada tahap pelatihan model. Kinerja model diukur menggunakan akurasi. Selain itu, matriks konfusi (*confusion matrix*) digunakan untuk menganalisis hasil klasifikasi pada masing-masing kelas tempe goreng organik dan non-organik. Teknik validasi model dilakukan dengan membagi dataset menjadi data latih dan data uji secara tetap menggunakan metode holdout dengan proporsi 80:20, sehingga data uji tidak pernah digunakan selama proses pelatihan model. Pendekatan ini dipilih untuk memastikan evaluasi model dilakukan secara objektif terhadap data yang belum pernah dilihat oleh model sebelumnya.

IV. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan CNN

Model Convolutional Neural Network (CNN) dilatih menggunakan 304 data latih selama 30 epoch dengan proporsi data validasi sebesar 20%. Pada epoch terakhir, model memperoleh akurasi pelatihan sebesar 99,18% dan akurasi validasi sebesar 88,52%. Berdasarkan grafik pelatihan pada Gbr. 3, model menunjukkan peningkatan akurasi dan penurunan nilai loss selama proses pelatihan. Perbedaan antara akurasi training dan akurasi validasi menunjukkan bahwa model memiliki performa yang baik dalam mempelajari pola pada data latih maupun data validasi. Selisih antara akurasi pelatihan sebesar 99,18% dan akurasi validasi sebesar 88,52% mengindikasikan adanya overfitting, yaitu kondisi di mana model terlalu menyesuaikan diri terhadap data latih sehingga kemampuan generalisasinya pada data baru menjadi terbatas. Kondisi ini diduga disebabkan oleh jumlah dataset yang relatif kecil yaitu 304 citra data latih. Untuk mengurangi overfitting pada penelitian selanjutnya, dapat dipertimbangkan penggunaan teknik regularisasi seperti dropout, data augmentation untuk memperbanyak variasi data latih secara sintesis, atau penambahan jumlah dataset asli.

B. Hasil Ekstraksi Fitur CNN

Setelah proses pelatihan selesai, lapisan Dense dengan 128 neuron digunakan sebagai lapisan ekstraksi fitur. Pada tahap ini, setiap citra diubah menjadi vektor fitur berdimensi 128 yang merepresentasikan citra tempe goreng organik dan non-organik dalam bentuk numerik. Vektor fitur hasil ekstraksi kemudian disimpan dalam format Excel untuk digunakan pada tahap klasifikasi menggunakan metode Learning Vector Quantization (LVQ). File fitur_train.xlsx berisi 304 data fitur latih, sedangkan fitur_test.xlsx berisi 76 data fitur uji.


C. Hasil Klasifikasi LVQ

Model Learning Vector Quantization (LVQ) dilatih menggunakan 304 data fitur latih selama 100 iterasi pelatihan dan diuji menggunakan 76 data fitur uji yang terdiri dari 38 citra tempe non-organik dan 38 citra tempe organik. Hasil klasifikasi metode hybrid CNN-LVQ ditunjukkan pada Tabel III.

TABEL III
HASIL KLASIFIKASI METODE HYBRID CNN-LVQ

Kelas	Precision	Recall	F1-Score	Support
Tempe Goreng Non-Organik (GMO)	0,8293	0,8947	0,8608	38
Tempe Goreng Organik (Non-GMO)	0,8857	0,8158	0,8493	38

Hasil confusion matrix sistem klasifikasi ditunjukkan pada Gbr. 4.



Gbr. 4 Confusion Matrix Hybrid CNN-LVQ

Berdasarkan hasil pengujian, metode hybrid CNN-LVQ memperoleh akurasi sebesar 85,53% terhadap 76 data uji. Pada kelas tempe goreng non-organik, sebanyak 34 citra berhasil diklasifikasikan dengan benar dan 4 citra salah diklasifikasikan sebagai tempe goreng organik. Sementara itu, pada kelas tempe goreng organik terdapat 31 citra yang berhasil diklasifikasikan dengan benar dan 7 citra salah diprediksi sebagai tempe goreng non-organik. Secara keseluruhan, metode berhasil mengklasifikasikan 65 citra dengan benar dan 11 citra mengalami kesalahan klasifikasi.

Nilai recall kelas tempe goreng non-organik sebesar 0,8947 lebih tinggi dibandingkan kelas tempe goreng organik sebesar 0,8158. Hal ini menunjukkan bahwa model lebih baik dalam mengenali citra tempe goreng non-organik. Kondisi ini diduga karena tempe goreng non-organik yang berasal dari kedelai impor GMO memiliki ukuran dan bentuk butiran kedelai yang lebih homogen akibat proses produksi yang lebih standar, sehingga tekstur permukaan citra tempe goreng non-organik cenderung lebih konsisten antar sampel. Sebaliknya, tempe goreng organik yang menggunakan kedelai lokal non-GMO memiliki variasi ukuran dan bentuk kedelai yang lebih tinggi, sehingga tekstur permukaannya lebih beragam dan menyebabkan model lebih sulit mengenali pola yang konsisten.

Berdasarkan Gbr. 4, terdapat 7 kesalahan klasifikasi pada kelas tempe goreng organik yang diprediksi sebagai tempe goreng non-organik, serta 4 kesalahan pada kelas tempe goreng non-organik yang diprediksi sebagai tempe goreng organik. Meskipun model secara keseluruhan menghasilkan akurasi yang baik sebesar 85,53%, kesalahan klasifikasi pada beberapa sampel ini diduga terjadi karena adanya variasi alami pada warna dan tekstur permukaan tempe goreng yang menyebabkan kedua kelas memiliki kemiripan tampilan pada sampel tertentu, sehingga model sedikit kesulitan membedakannya. Hal ini menjadi salah satu keterbatasan model yang dapat diperbaiki pada penelitian selanjutnya.

D. Pembahasan

Hasil penelitian menunjukkan bahwa metode hybrid CNN-LVQ mampu mengklasifikasikan citra tempe goreng organik dan non-organik dengan tingkat akurasi sebesar 85,53%. Pada metode ini, CNN digunakan untuk melakukan ekstraksi fitur citra tempe goreng organik dan non-organik, sedangkan LVQ digunakan untuk melakukan klasifikasi berdasarkan fitur hasil ekstraksi ke dalam kelas tempe goreng organik dan non-organik. Penggunaan CNN sebagai ekstraktor fitur memungkinkan model mempelajari representasi citra secara hierarkis,

sedangkan LVQ sebagai pengklasifikasi memanfaatkan representasi fitur tersebut untuk membedakan kedua kelas berdasarkan kedekatan jarak terhadap vektor prototipe.

Jika dibandingkan dengan penelitian sebelumnya [1] yang menggunakan CNN untuk klasifikasi mutu fisik tempe dan memperoleh akurasi yang lebih tinggi, perbedaan hasil tersebut diduga dipengaruhi oleh perbedaan jumlah dataset yang digunakan serta tingkat kemiripan visual antar kelas yang lebih tinggi pada penelitian ini. Meskipun demikian, akurasi sebesar 85,53% menunjukkan bahwa metode hybrid CNN-LVQ yang diusulkan mampu memberikan performa klasifikasi yang baik pada dataset citra tempe goreng organik dan non-organik.

V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, diperoleh kesimpulan bahwa metode hybrid Convolutional Neural Network (CNN) dan Learning Vector Quantization (LVQ) mampu digunakan untuk mengklasifikasikan citra tempe goreng organik dan non-organik dengan akurasi sebesar 85,53%. Keterbatasan penelitian ini terletak pada jumlah dataset yang masih relatif sedikit, yaitu 380 citra tempe goreng. Oleh karena itu, penelitian selanjutnya dapat dikembangkan dengan menambah jumlah dataset citra tempe goreng organik dan non-organik, menerapkan transfer learning menggunakan arsitektur CNN yang lebih modern, serta membandingkan performa metode hybrid CNN-LVQ dengan algoritma klasifikasi lain seperti Support Vector Machine (SVM), Random Forest, atau Artificial Neural Network (ANN) untuk memperoleh gambaran performa yang lebih komprehensif.

DAFTAR PUSTAKA

- [1] I. M. K. Karo, J. A. K. Karo, Yuniarto, Hariyanto, and M. Falah, "Klasifikasi Mutu Fisik Tempe Menggunakan Metode Convolutional Neural Network (CNN)," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 8, no. 2, pp. 209–216, Dec. 2023. <https://doi.org/10.30998/string.v8i2.17596>
- [2] J. Kim, D. Lee, and S. Kwon, "Food Classification and Meal Intake Amount Estimation through Deep Learning," *Applied Sciences*, vol. 13, no. 9, p. 5742, 2023, doi: 10.3390/app13095742. <https://doi.org/10.3390/app13095742>
- [3] A. Chaitanya, J. Shetty, and P. Chiplunkar, "Food Image Classification and Data Extraction Using Convolutional Neural Network and Web Crawlers," *Procedia Computer Science*, vol. 218, pp. 143–152, 2023, doi: 10.1016/j.procs.2022.12.410. <https://doi.org/10.1016/j.procs.2022.12.410>
- [4] A. Karmakar, A. Pal, G. A. Kumar, Bhavika, V. Anand, and M. Tyagi, "Neutron-Gamma Pulse Shape Discrimination for Organic Scintillation Detector using 2D CNN based Image Classification," *arXiv preprint arXiv:2306.09356*, 2023.
- [5] E. Zidni and M. Akbar, "Klasifikasi Citra Makanan Khas Kota Pasuruan menggunakan Convolutional Neural Network," *Informatics and Artificial Intelligence Journal*, vol. 1, no. 2, 2024.
- [6] K. Ozhikenov, Z. Alimbayeva, C. Alimbayev, A. Ozhikenova, and Y. Altay, "Neural Network Algorithm Based on LVQ for Myocardial Infarction Detection and Localization Using Multi-Lead ECG Data," *Computers, Materials and Continua*, vol. 82, no. 3, pp. 5257–5284, 2025, doi: 10.32604/cmc.2025.061508. <https://doi.org/10.32604/cmc.2025.061508>
- [7] M. Nilashi *et al.*, "Electroencephalography (EEG) Eye State Classification Using Learning Vector Quantization and Bagged Trees," *Heliyon*, vol. 9, p. e15258, 2023, doi: 10.1016/j.heliyon.2023.e15258. <https://doi.org/10.1016/j.heliyon.2023.e15258>
- [8] P. Radocaj, D. Radocaj, and G. Martinovic, "Image-Based Leaf Disease Recognition Using Transfer Deep Learning with a Novel Versatile Optimization Module," *Big Data and Cognitive Computing*, vol. 8, no. 6, p. 52, 2024, doi: 10.3390/bdcc8060052. <https://doi.org/10.3390/bdcc8060052>
- [9] C. Chen *et al.*, "Improving Fine-Grained Food Classification Using Deep Residual Learning and Selective State Space Models," *PLOS One*, vol. 20, no. 5, p. e0322695, 2025, doi: 10.1371/journal.pone.0322695. <https://doi.org/10.1371/journal.pone.0322695>
- [10] P. D. Rinanda, D. N. Aini, T. A. Pertiwi, Suryani, and A. J. Prakash, "Implementation of Convolutional Neural Network (CNN) for Image Classification of Leaf Disease in Mango Plants Using Deep Learning Approach," *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 1, no. 2, pp. 55–61, Jan. 2024, doi: 10.57152/predatecs.v1i2.872. <https://doi.org/10.57152/predatecs.v1i2.872>

-
- [11] E. Kanakala and S. Ningappa, "Detection and Classification of Diseases in Multi-Crop Leaves using LSTM and CNN Models," *Journal of Innovative Image Processing*, vol. 7, no. 1, pp. 161–181, 2025, doi: 10.36548/jiip.2025.1.008. <https://doi.org/10.36548/jiip.2025.1.008>
 - [12] Z. Zhu and Y. Dai, "A New CNN-Based Single-Ingredient Classification Model and Its Application in Food Image Segmentation," *Journal of Imaging*, vol. 9, no. 10, p. 205, 2023, doi: 10.3390/jimaging9100205. <https://doi.org/10.3390/jimaging9100205>
 - [13] A. Matikas, G. Stathopoulos, and P. Papadopoulos, "MedGRFood: A New Dataset and Deep Learning Approach for Mediterranean Greek Food Recognition," *IEEE Access*, 2023, doi: 10.1109/ACCESS.2023.0429.