

Optimasi Feature Selection Dalam Sistem Pengenalan Emosi Wajah Menggunakan CNN dan GNN

¹Sahbansyah Harahap, ²Rika Rosnelly, ³Bob Subhan Riza

^{1,2,3,4} Ilmu Komputer/Fakultas Teknik dan Ilmu Komputer, Universitas Potensi Utama,
Medan, Indonesia

*Korespondensi: sahbanharahap0311@gmail.com

Submit : 29 Mei 2026 | Diterima : 22 Juni 2026 | Terbit : 08 Juli 2026

ABSTRACT

Facial Emotion Recognition (FER) is a field of computer vision that aims to identify human emotions based on facial expressions. Convolutional Neural Networks (CNNs) are widely used for automatic visual feature extraction; however, they have limitations in modeling spatial relationships among facial components. Therefore, this study implements a Graph Neural Network (GNN) based on the Graph Attention Network (GAT) architecture and applies Principal Component Analysis (PCA) as a feature selection method to improve feature representation quality and computational efficiency. The study utilizes the FER-2013 dataset, which consists of seven emotion classes: angry, disgust, fear, happy, sad, surprise, and neutral. The research stages include data preprocessing, feature extraction using MobileNetV2, dimensionality reduction using PCA, graph construction, model training, and performance evaluation using accuracy, precision, recall, and F1-score metrics. Four experimental scenarios were evaluated: CNN, CNN+PCA, GNN, and GNN+PCA. The results show that the CNN model achieved an accuracy of 62%, CNN+PCA achieved 61.95%, GNN achieved 70.71%, and GNN+PCA achieved 74.32%. Furthermore, the GNN+PCA model obtained a precision of 75.57%, recall of 74.32%, and F1-score of 74.64%, representing the best performance among all evaluated models. The findings indicate that PCA does not significantly improve CNN performance but substantially enhances GNN performance by reducing feature redundancy and optimizing graph-based feature representation. In conclusion, the combination of GNN and PCA proved to be more effective than CNN and CNN+PCA in recognizing facial emotions on the FER-2013 dataset. Therefore, this approach has strong potential as a more accurate deep learning-based facial emotion recognition system.

Keywords: CNN; Deep Learning; Facial Emotion Recognition; GNN; PCA.

ABSTRAK

Pengenalan emosi wajah (Facial Emotion Recognition/ FER) merupakan salah satu bidang computer vision yang bertujuan mengidentifikasi emosi manusia berdasarkan ekspresi wajah. Convolutional Neural Network (CNN) mampu mengekstraksi fitur visual secara otomatis, namun memiliki keterbatasan dalam memahami hubungan spasial antar bagian wajah. Oleh karena itu, penelitian ini mengimplementasikan Graph Neural Network (GNN) berbasis Graph Attention Network (GAT) serta menerapkan Principal Component Analysis (PCA) sebagai metode feature selection untuk meningkatkan kualitas representasi fitur dan efisiensi komputasi. Penelitian menggunakan dataset FER-2013 yang terdiri dari tujuh kelas emosi, yaitu angry, disgust, fear, happy, sad, surprise, dan neutral. Tahapan penelitian meliputi preprocessing data, ekstraksi fitur menggunakan MobileNetV2, reduksi dimensi menggunakan PCA, pembentukan graf, pelatihan model, dan evaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Empat skenario pengujian dilakukan, yaitu CNN, CNN+PCA, GNN, dan GNN+PCA. Hasil penelitian menunjukkan bahwa model CNN memperoleh akurasi 62%, CNN+PCA 61,95%, GNN 70,71%, dan GNN+PCA 74,32%. Selain itu, model GNN+PCA menghasilkan precision 75,57%, recall 74,32%, dan F1-score 74,64%, yang merupakan performa terbaik di antara seluruh model yang diuji. Hasil tersebut menunjukkan bahwa penerapan PCA tidak memberikan peningkatan signifikan pada CNN, namun mampu meningkatkan performa GNN melalui reduksi redundansi fitur dan optimalisasi representasi graf. Berdasarkan hasil penelitian, kombinasi GNN dan PCA terbukti lebih efektif dibandingkan CNN maupun CNN+PCA dalam mengenali emosi wajah pada

dataset FER-2013, sehingga berpotensi menjadi pendekatan yang lebih akurat untuk sistem pengenalan emosi wajah berbasis deep learning.

Kata Kunci: CNN; Deep Learning; Facial Emotion Recognition; GNN; PCA.

PENDAHULUAN

Perkembangan teknologi deep learning telah memberikan kontribusi besar dalam bidang computer vision, khususnya dalam pengenalan wajah dan ekspresi wajah secara otomatis. Deep learning merupakan cabang dari machine learning yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari representasi data secara hierarkis dan abstrak. Salah satu metode yang paling banyak digunakan dalam pengolahan citra adalah Convolutional Neural Network (CNN) yang mampu mengekstraksi fitur visual seperti tepi, tekstur, dan bentuk objek secara otomatis melalui proses konvolusi (Gura et al., 2024).

Salah satu aplikasi penting dalam computer vision adalah Facial Emotion Recognition (FER), yaitu proses identifikasi emosi manusia berdasarkan ekspresi wajah. Ekspresi wajah merupakan media utama dalam komunikasi non-verbal yang mencerminkan kondisi emosional seperti senang, sedih, marah, takut, terkejut, dan netral. Oleh karena itu, teknologi pengenalan emosi wajah memiliki peran penting dalam berbagai bidang seperti human-computer interaction, keamanan, pendidikan, hingga kesehatan mental (Shehu et al., 2025). Namun, proses pengenalan emosi wajah tidaklah mudah karena ekspresi manusia sangat bervariasi dan dipengaruhi oleh faktor budaya, kondisi psikologis, pencahayaan, serta pose wajah yang berbeda (Shinde et al., 2025).

Metode CNN telah terbukti efektif dalam mengenali pola visual lokal pada citra wajah sehingga mampu mengklasifikasikan ekspresi dengan tingkat akurasi yang cukup tinggi. CNN bekerja dengan memproses citra melalui beberapa lapisan konvolusi yang memungkinkan model memahami hubungan spasial antar piksel pada gambar wajah (Ramadevi & Das, 2024). Meskipun demikian, CNN memiliki keterbatasan dalam memahami hubungan struktural yang lebih kompleks antar bagian wajah yang terpisah, seperti hubungan antara mata, alis, dan mulut yang sering kali menentukan ekspresi emosi secara keseluruhan (I. Ali & Ghaffar, 2024).

Untuk mengatasi keterbatasan tersebut, penelitian terbaru mulai memanfaatkan Graph Neural Network (GNN) yang mampu memodelkan hubungan antar elemen data dalam bentuk graf. Dalam konteks pengenalan emosi wajah, GNN dapat merepresentasikan titik-titik landmark wajah sebagai node dan hubungan antar titik tersebut sebagai edge sehingga memungkinkan model memahami struktur wajah secara lebih holistik (Fan et al., 2025). Dengan pendekatan ini, sistem dapat menangkap hubungan spasial yang lebih kompleks antar bagian wajah dibandingkan metode berbasis piksel semata.

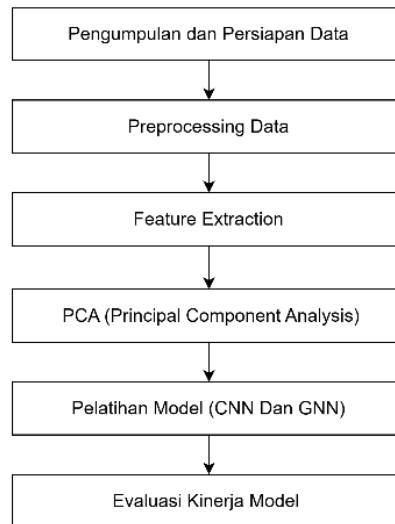
Selain metode klasifikasi, feature selection juga menjadi tahap penting dalam meningkatkan performa model pengenalan emosi wajah. Feature selection bertujuan untuk memilih fitur yang paling relevan sehingga dapat meningkatkan akurasi model sekaligus mengurangi kompleksitas komputasi. Salah satu metode reduksi dimensi yang banyak digunakan adalah Principal Component Analysis (PCA) yang bekerja dengan mentransformasikan fitur asli menjadi sejumlah komponen utama yang memiliki kontribusi terbesar terhadap variasi data (Zuo & Xia, 2025). Penggunaan PCA dapat membantu menghilangkan fitur yang redundan serta meningkatkan efisiensi proses pelatihan model (Teng, 2025).

Beberapa penelitian sebelumnya telah menunjukkan bahwa CNN mampu memberikan akurasi tinggi dalam pengenalan ekspresi wajah, sedangkan pendekatan berbasis graf seperti GNN mampu menangkap hubungan spasial antar elemen wajah secara lebih baik (Wang et al., 2025). Oleh karena itu, penelitian ini bertujuan untuk mengoptimalkan feature selection dalam sistem pengenalan emosi wajah dengan membandingkan performa CNN dan GNN serta menganalisis pengaruh penerapan PCA terhadap kedua model tersebut. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan sistem pengenalan emosi wajah yang lebih akurat dan efisien untuk berbagai aplikasi di dunia nyata.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang bertujuan untuk mengevaluasi dan membandingkan kinerja dua arsitektur deep learning yaitu Convolutional

Neural Network (CNN) dan Graph Neural Network (GNN) dalam tugas Facial Emotion Recognition (FER). Pendekatan komparatif digunakan dengan melatih dan menguji kedua model menggunakan dataset yang sama namun dengan pendekatan representasi data yang berbeda. Metode ini bertujuan untuk memperoleh gambaran objektif mengenai kelebihan dan kekurangan masing-masing model dalam mengenali ekspresi wajah manusia. CNN dianalisis berdasarkan kemampuannya mengekstraksi fitur spasial lokal dari citra wajah (I. Ali & Ghaffar, 2024), sedangkan GNN dianalisis berdasarkan kemampuannya memodelkan hubungan topologis antar bagian wajah melalui representasi graf (Fan et al., 2025).



Gambar 1. Langkah-langkah Metodologi Penelitian

Dataset yang digunakan dalam penelitian ini adalah FER-2013 yang tersedia secara publik melalui platform Kaggle dan terdiri dari 35.887 citra wajah grayscale berukuran 224 x 224 piksel. Setiap citra telah diberi label tujuh kategori emosi yaitu marah, jijik, takut, senang, sedih, terkejut, dan netral. Pada pendekatan CNN, citra wajah diproses secara langsung sebagai input model. Sementara itu pada pendekatan GNN, citra wajah terlebih dahulu dikonversi menjadi struktur graf dengan mengekstraksi 68 titik landmark wajah menggunakan pustaka seperti Dlib atau MediaPipe. Setiap titik landmark direpresentasikan sebagai node, sedangkan hubungan antar titik direpresentasikan sebagai edge sehingga membentuk struktur graf yang menggambarkan hubungan spasial antar bagian wajah.

Tahap preprocessing dilakukan untuk menyiapkan data sebelum proses pelatihan model. Pada metode CNN, preprocessing meliputi konversi citra ke format grayscale, normalisasi nilai piksel ke rentang 0 hingga 1, serta penyesuaian ukuran citra menjadi 224x224 piksel. Untuk meningkatkan variasi data dan kemampuan generalisasi model dilakukan data augmentation seperti rotasi, flipping, zooming, dan shifting. Setelah proses ini selesai, dataset dibagi menjadi training set sebesar 80%, validation set sebesar 10%, dan testing set sebesar 10% (Angel et al., 2024). Pada pendekatan GNN, preprocessing juga mencakup ekstraksi landmark wajah yang kemudian digunakan untuk membangun graf wajah yang merepresentasikan struktur geometris wajah manusia.

Tahap ekstraksi fitur dilakukan dengan pendekatan yang berbeda pada kedua model. Pada CNN, ekstraksi fitur dilakukan secara otomatis melalui lapisan konvolusi yang menghasilkan feature map yang merepresentasikan pola visual seperti tepi, tekstur, serta bentuk bagian wajah. Hasil ekstraksi kemudian diproses melalui pooling layer untuk mengurangi dimensi data sebelum diratakan menggunakan flatten layer dan diteruskan ke lapisan fully connected untuk proses klasifikasi. Pada GNN, ekstraksi fitur dilakukan melalui Graph Convolutional Layer (GCN) yang memungkinkan setiap node memperbarui representasinya berdasarkan informasi dari node tetangga melalui mekanisme message passing sehingga hubungan struktural antar bagian wajah dapat dipelajari secara lebih menyeluruh (Akram et al., 2025).

Untuk meningkatkan efisiensi model dan mengurangi fitur yang tidak relevan, penelitian ini menerapkan teknik feature selection menggunakan Principal Component Analysis (PCA). Metode PCA digunakan untuk mereduksi dimensi fitur dengan mempertahankan komponen

utama yang memiliki kontribusi terbesar terhadap variasi data. Dengan demikian, fitur yang bersifat redundan atau kurang relevan dapat dihilangkan sehingga proses pembelajaran model menjadi lebih efisien serta dapat mengurangi risiko overfitting.

Tahap pelatihan model dilakukan secara terpisah untuk CNN dan GNN menggunakan dataset yang telah melalui tahap preprocessing dan feature selection. Model CNN diimplementasikan menggunakan framework TensorFlow/Keras, sedangkan model GNN diimplementasikan menggunakan PyTorch Geometric yang mendukung pemrosesan data berbasis graf. Kedua model dilatih menggunakan optimizer Adam dengan learning rate 0,001, batch size 64, dan 100 epoch pelatihan. Fungsi kerugian yang digunakan adalah categorical cross-entropy karena penelitian ini merupakan klasifikasi multi-kelas dengan tujuh kategori emosi. Selama proses pelatihan dilakukan pemantauan terhadap nilai loss dan accuracy pada data latih dan data validasi untuk memastikan model tidak mengalami overfitting maupun underfitting.

Tahap terakhir adalah evaluasi kinerja model yang dilakukan menggunakan data uji yang tidak digunakan selama proses pelatihan. Evaluasi dilakukan menggunakan beberapa metrik yaitu accuracy, precision, recall, F1-score, dan confusion matrix untuk mengukur performa klasifikasi secara menyeluruh. Selain itu penelitian ini juga mempertimbangkan waktu inferensi untuk menilai efisiensi komputasi masing-masing model dalam menghasilkan prediksi. Hasil evaluasi dari CNN dan GNN kemudian dibandingkan untuk menentukan model yang paling efektif dalam mengenali emosi wajah. CNN diharapkan memiliki keunggulan dalam mengenali pola visual lokal seperti kontur wajah dan tekstur pada area mata atau bibir, sedangkan GNN diharapkan lebih mampu memahami hubungan spasial global antar bagian wajah melalui representasi graf.


HASIL DAN PEMBAHASAN

Penelitian ini bertujuan membandingkan performa metode Convolutional Neural Network (CNN), CNN dengan Principal Component Analysis (CNN+PCA), Graph Neural Network (GNN), dan GNN dengan Principal Component Analysis (GNN+PCA) dalam klasifikasi ekspresi wajah menggunakan dataset FER2013. Dataset yang digunakan terdiri dari lima kelas emosi yaitu angry, happy, neutral, sad, dan surprise. Sebelum proses pelatihan dilakukan, seluruh citra mengalami tahap preprocessing berupa konversi grayscale menjadi RGB, resize citra menjadi 224×224 piksel, normalisasi data, serta augmentasi citra untuk meningkatkan variasi data dan mengurangi risiko overfitting. Pada model GNN dilakukan ekstraksi landmark wajah yang kemudian direpresentasikan dalam bentuk graph menggunakan metode K-Nearest Neighbor (KNN).

Hasil pengujian model CNN berbasis MobileNetV2 menunjukkan bahwa model mampu mempelajari karakteristik ekspresi wajah dengan cukup baik. Selama proses pelatihan terjadi peningkatan nilai accuracy dan penurunan loss yang menandakan model berhasil mengenali pola-pola visual pada citra wajah. Berdasarkan hasil evaluasi, model CNN memperoleh accuracy sebesar 62% dengan weighted precision sebesar 69% dan weighted recall sebesar 62%. Hasil confusion matrix menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, terutama pada kelas happy dan surprise yang memiliki karakteristik ekspresi lebih mudah dibedakan dibandingkan kelas lainnya.

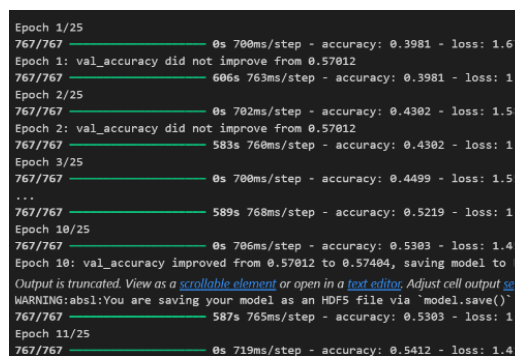


Gambar 2 Grafik Accuracy dan Loss Model CNN




Gambar 3 Confusion Matrix Model CNN

Pada skenario CNN+PCA, fitur hasil ekstraksi CNN direduksi menggunakan PCA untuk mengurangi kompleksitas data. PCA berhasil menurunkan jumlah fitur dari 1280 menjadi 128 fitur dengan mempertahankan sekitar 90% informasi penting. Meskipun proses reduksi dimensi mampu meningkatkan efisiensi komputasi, hasil evaluasi menunjukkan bahwa akurasi model hanya mencapai 61,95%. Hasil ini mengindikasikan bahwa sebagian informasi diskriminatif yang penting untuk membedakan ekspresi wajah ikut berkurang selama proses reduksi dimensi sehingga performa klasifikasi sedikit menurun dibandingkan CNN tanpa PCA.



Gambar 4 Grafik Perkembangan Akurasi dan Loss CNN + PCA



Gambar 5 Confusion Matrix Hasil Pengujian Model CNN + PCA

Pada model GNN, representasi wajah dibangun menggunakan struktur graph yang memanfaatkan hubungan antar landmark wajah. Model CNN-GAT yang digunakan mampu

mempelajari hubungan geometris antar titik wajah dengan baik. Hasil pelatihan menunjukkan nilai training accuracy mencapai 86,38% dengan loss yang terus menurun hingga akhir pelatihan. Berdasarkan hasil evaluasi, model GNN memperoleh accuracy sebesar 70,71%, precision sebesar 74,07%, recall sebesar 70,71%, dan F1-score sebesar 71,38%. Hasil ini menunjukkan bahwa pendekatan berbasis graph memiliki kemampuan yang baik dalam memahami pola geometris wajah untuk klasifikasi ekspresi.

```
Epoch 1: 100% | 1336/1336 [03:54<00:00, 5.70it/s, loss=1.54]
BEST MODEL SAVED
Epoch [1/15] | Loss : 1.7535 | Accuracy : 41.01%
BEST MODEL SAVED
Epoch 2: 100% | 1336/1336 [03:49<00:00, 5.82it/s, loss=1.68]
BEST MODEL SAVED
Epoch [2/15] | Loss : 1.4420 | Accuracy : 55.28%
BEST MODEL SAVED
Epoch 3: 100% | 1336/1336 [03:49<00:00, 5.83it/s, loss=0.803]
BEST MODEL SAVED
Epoch [3/15] | Loss : 1.2422 | Accuracy : 62.53%
BEST MODEL SAVED
Epoch 15: 100% | 1336/1336 [04:00<00:00, 5.56it/s, loss=1.91]
BEST MODEL SAVED
Epoch [15/15] | Loss : 0.4022 | Accuracy : 86.38%
BEST MODEL SAVED
```

Gambar 6 Grafik Perubahan Nilai Loss

```
100% | 166/166 [00:08<00:00, 20.47it/s]
=====
ACCURACY : 70.71%
PRECISION : 74.07%
RECALL : 70.71%
F1-SCORE : 71.38%
=====
CLASSIFICATION REPORT
precision recall f1-score support
angry 0.642857 0.590164 0.615385 61.000000
disgust 0.363636 0.444444 0.400000 72.000000
fear 0.342857 0.363636 0.352941 33.000000
happy 0.937500 0.778846 0.850840 520.000000
neutral 0.739726 0.576512 0.648000 281.000000
sad 0.576512 0.786408 0.665298 206.000000
surprise 0.599078 0.838710 0.698925 155.000000
accuracy 0.707078 0.707078 0.707078 0.707078
macro avg 0.600310 0.625532 0.604484 1328.000000
weighted avg 0.740732 0.707078 0.713776 1328.000000
```

Gambar 7 Hasil Evaluasi Model CNN-GAT

Pada model GNN+PCA dilakukan reduksi dimensi terhadap fitur node sebelum proses pembentukan graph. Berbeda dengan hasil pada CNN, penerapan PCA pada GNN justru memberikan peningkatan performa. Hasil evaluasi menunjukkan accuracy meningkat menjadi 74,32%, precision sebesar 75,57%, recall sebesar 74,32%, dan F1-score sebesar 74,64%. Peningkatan tersebut menunjukkan bahwa PCA berhasil mengurangi redundansi dan noise pada fitur node sehingga proses pembelajaran hubungan antar landmark menjadi lebih efektif. Selain itu, struktur graph tetap dipertahankan sehingga informasi geometris penting pada wajah tidak hilang selama proses reduksi dimensi.

```
Epoch [18/25] | Loss : 0.3011 | Accuracy : 87.33%
BEST MODEL SAVED
Epoch 19: 100% | 1336/1336 [04:08<00:00, 5.38it/s, loss=0.0229]
BEST MODEL SAVED
Epoch [19/25] | Loss : 0.3345 | Accuracy : 88.76%
BEST MODEL SAVED
Epoch 20: 100% | 1336/1336 [04:04<00:00, 5.46it/s, loss=2.73]
BEST MODEL SAVED
Epoch [20/25] | Loss : 0.3601 | Accuracy : 88.28%
BEST MODEL SAVED
Epoch 21: 100% | 1336/1336 [04:03<00:00, 5.49it/s, loss=0.469]
BEST MODEL SAVED
Epoch [21/25] | Loss : 0.3073 | Accuracy : 89.42%
BEST MODEL SAVED
Epoch 22: 100% | 1336/1336 [04:02<00:00, 5.50it/s, loss=0.59]
BEST MODEL SAVED
Epoch [22/25] | Loss : 0.3321 | Accuracy : 88.68%
BEST MODEL SAVED
Epoch 23: 100% | 1336/1336 [04:05<00:00, 5.44it/s, loss=0.0208]
BEST MODEL SAVED
Epoch [23/25] | Loss : 0.3160 | Accuracy : 89.58%
BEST MODEL SAVED
Epoch 24: 100% | 1336/1336 [04:07<00:00, 5.39it/s, loss=2.27]
BEST MODEL SAVED
Epoch [24/25] | Loss : 0.2013 | Accuracy : 90.47%
BEST MODEL SAVED
Epoch 25: 100% | 1336/1336 [04:03<00:00, 5.49it/s, loss=4.05]
BEST MODEL SAVED
Epoch [25/25] | Loss : 0.2000 | Accuracy : 90.81%
BEST MODEL SAVED
```

Gambar 8 Perkembangan Accuracy dan Loss GNN + PCA

```
100% | 166/166 [00:07<00:00, 22.19it/s]
=====
ACCURACY : 74.32%
PRECISION : 75.57%
RECALL : 74.32%
F1-SCORE : 74.64%
=====
CLASSIFICATION REPORT
precision recall f1-score support
angry 0.580235 0.655738 0.620155 61.000000
disgust 0.342105 0.541667 0.419355 72.000000
fear 0.481481 0.393939 0.433333 33.000000
happy 0.886940 0.875000 0.880929 520.000000
neutral 0.744681 0.622776 0.678295 281.000000
sad 0.682051 0.645631 0.663342 206.000000
surprise 0.750000 0.851613 0.797583 155.000000
accuracy 0.743223 0.743223 0.743223 0.743223
macro avg 0.639356 0.655195 0.641856 1328.000000
weighted avg 0.755737 0.743223 0.746446 1328.000000
```

Gambar 9 Hasil Evaluasi Model CNN-GAT-PCA

Berdasarkan seluruh hasil pengujian, diperoleh bahwa model CNN menghasilkan akurasi sebesar 62%, CNN+PCA sebesar 61,95%, GNN sebesar 70,71%, dan GNN+PCA sebesar 74,32%. Hasil tersebut menunjukkan bahwa PCA memberikan dampak yang berbeda pada masing-masing model. Pada CNN, reduksi dimensi menyebabkan sebagian informasi visual penting hilang sehingga performa sedikit menurun. Sebaliknya, pada GNN, PCA mampu meningkatkan kualitas representasi fitur dengan mengurangi redundansi antar fitur landmark tanpa menghilangkan hubungan geometris antar node. Dengan demikian, kombinasi GNN+PCA menjadi model terbaik dalam penelitian ini karena mampu menghasilkan performa klasifikasi tertinggi dibandingkan model lainnya.

Tabel 1 Analisis Perbandingan CNN + PCA dan GNN + PCA

Model	Accuracy
CNN	71%
CNN + PCA	61%
GNN	70,71%
GNN + PCA	74,32%

Secara keseluruhan, penelitian ini membuktikan bahwa representasi fitur memiliki pengaruh yang sangat besar terhadap performa sistem pengenalan emosi wajah. CNN lebih unggul dalam menangkap informasi visual dan tekstur citra, sedangkan GNN lebih efektif dalam memahami hubungan geometris antar landmark wajah. Hasil penelitian juga menunjukkan bahwa optimasi feature selection menggunakan PCA lebih efektif diterapkan pada GNN dibandingkan CNN. Oleh karena itu, kombinasi GNN dan PCA dapat menjadi alternatif yang menjanjikan untuk meningkatkan performa sistem klasifikasi ekspresi wajah berbasis deep learning.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan Principal Component Analysis (PCA) sebagai metode feature selection memberikan pengaruh yang berbeda terhadap model Convolutional Neural Network (CNN) dan Graph Neural Network (GNN) dalam sistem pengenalan emosi wajah menggunakan dataset FER-2013. Hasil pengujian menunjukkan bahwa model CNN memperoleh akurasi sebesar 62%, sedangkan CNN+PCA memperoleh akurasi 61,95%, yang mengindikasikan bahwa reduksi dimensi menggunakan PCA tidak memberikan peningkatan performa pada CNN karena sebagian informasi visual penting ikut berkurang selama proses seleksi fitur. Sementara itu, model GNN menghasilkan akurasi sebesar 70,71% dan meningkat menjadi 74,32% setelah penerapan PCA. Selain itu, model GNN+PCA juga memperoleh nilai precision sebesar 75,57%, recall sebesar 74,32%, dan F1-score sebesar 74,64%, yang merupakan performa terbaik dibandingkan seluruh model yang diuji. Hasil penelitian ini membuktikan bahwa representasi berbasis graf mampu menangkap hubungan geometris antar bagian wajah secara lebih efektif dibandingkan pendekatan berbasis citra piksel. PCA juga terbukti mampu mengurangi redundansi fitur dan meningkatkan kualitas representasi data pada model GNN tanpa menghilangkan informasi struktural yang penting. Dengan demikian, kombinasi GNN dan PCA merupakan pendekatan yang paling optimal dalam penelitian ini serta berpotensi digunakan untuk mengembangkan sistem pengenalan emosi wajah yang lebih akurat dan efisien pada berbagai aplikasi berbasis deep learning.

REFERENSI

- Agung, E. S., Rifai, A. P., & Wijayanto, T. (2024). Image-based facial emotion recognition using convolutional neural network on emognition dataset. *Scientific Reports*, *14*(1), 1–22. <https://doi.org/10.1038/s41598-024-65276-x>
- Akram, J., Hussain, W., Jhaveri, R. H., Rathore, R. S., & Anaissi, A. (2025). Dynamic GNN-based multimodal anomaly detection for spatial crowdsourcing drone services. *Digital Communications and Networks*. <https://doi.org/10.1016/j.dcan.2025.03.012>
- Ali, I., & Ghaffar, F. (2024). Robust CNN for facial emotion recognition and real-time GUI. *AIMS Electronics and Electrical Engineering*, *8*(2), 217–236. <https://doi.org/10.3934/electreng.2024010>
- Ali, S., Vazifedoost, M., Hajirostamloo, B., Didar, Z., & Mehdi, M. (2025). Heliyon Supercritical fluid extraction and encapsulation of Rivas (Rheum ribes) flower : Principal component analysis (PCA). *Heliyon*, *11*(2), e41746. <https://doi.org/10.1016/j.heliyon.2025.e41746>
- Angel, J. S., Andrushia, A. D., Neebha, T. M., Accouche, O., Saker, L., & Anand, N. (2024). Faster Region Convolutional Neural Network (FRCNN) Based Facial Emotion Recognition. *Computers, Materials and Continua*, *79*(2), 2427–2448. <https://doi.org/10.32604/cmc.2024.047326>
- Fan, W., Wang, C., Han, X., & Lin, C. (2025). Unmasking Social Robots' Camouflage: A GNN-

- Random Forest Framework for Enhanced Detection. *Computers, Materials and Continua*, 82(1), 467–483. <https://doi.org/10.32604/cmc.2024.056930>
- Gura, D., Dong, B., Mehlar, D., & Said, N. Al. (2024). Customized Convolutional Neural Network for Accurate Detection of Deep Fake Images in Video Collections. *Computers, Materials and Continua*, 79(2), 1995–2014. <https://doi.org/10.32604/cmc.2024.048238>
- Ma, Y., Choi, M., & Weng, Y. (2025). GNN-MAM: A graph neural network based multiple attention mechanism for regional financial risk prediction. 127(March), 1004–1014.
- Mohammad, J., & Bocklitz, T. (2025). Analytica Chimica Acta Exploring feature extraction methods for Raman spectroscopy: A comparative study. *Analytica Chimica Acta*, 1380(October), 344755. <https://doi.org/10.1016/j.aca.2025.344755>
- Osborne, A., Soladoye, A. A., Usani, K. O., Israel, A., Wada, O. Z., & Olawade, D. B. (2025). International Journal of Medical Informatics Machine learning prediction of kangaroo mother care in Sierra Leone: a comparative study of feature selection techniques and classification algorithms. *International Journal of Medical Informatics*, 206(October 2025), 106166. <https://doi.org/10.1016/j.ijmedinf.2025.106166>
- Ramadevi, P., & Das, R. (2024). Face detection based on K-medoids clustering and associated with convolutional neural networks. *Heliyon*, 10(16), e35928. <https://doi.org/10.1016/j.heliyon.2024.e35928>
- Shehu, H. A., Browne, W. N., & Eisenbarth, H. (2025). Emotion categorization from facial expressions: A review of datasets, methods, and research directions. *Neurocomputing*, 624(October 2024), 129367. <https://doi.org/10.1016/j.neucom.2025.129367>
- Shinde, S. R., Bongale, A. M., Dharrao, D., & Thepade, S. D. (2025). An enhanced light weight face liveness detection method using deep convolutional neural network. *MethodsX*, 14(December 2024), 103229. <https://doi.org/10.1016/j.mex.2025.103229>
- Teng, J. (2025). ScienceDirect Financial Data Reduction and Information Retention Strategy based on Principal Component Analysis (PCA) Algorithm. *Procedia Computer Science*, 262, 218–226. <https://doi.org/10.1016/j.procs.2025.05.047>
- Wang, R., Xin, Y., Zhang, Y., Perez-Cruz, F., & Raubal, M. (2025). Counterfactual explanations for deep learning-based traffic forecasting. *Communications in Transportation Research*, 5(October 2024), 100176. <https://doi.org/10.1016/j.commtr.2025.100176>
- Zuo, Y., & Xia, Y. (2025). A novel features selection method based on improved clustering algorithm. *Data Science and Informetrics*. <https://doi.org/10.1016/j.dsim.2025.01.011>