



Analisis Pengaruh Teknik Preprocessing terhadap Performa CNN pada Klasifikasi Citra Dataset CIFAR-10

Dannu Purwanto*¹, Alwan Fadlurohman²

universitas muhammadiyah semarang

dannupurwanto@unimus.ac.id¹, alwan@unimus.ac.id²

Informasi Artikel

Dikirim :29-03-2026

Direview :02-04-2026

Diterbitkan :30-05-2026

Kata Kunci

CNN, preprocessing, augmentasi data, normalisasi, filter median

Abstrak

Penelitian ini menganalisis pengaruh teknik preprocessing citra terhadap performa Convolutional Neural Network (CNN) pada dataset CIFAR-10. Teknik yang dievaluasi meliputi normalisasi piksel, augmentasi data, dan filter median yang disusun dalam empat kondisi eksperimen: kontrol, normalisasi, normalisasi+augmentasi, serta normalisasi+augmentasi+median. Setiap kondisi dijalankan sebanyak lima kali menggunakan seed berbeda untuk memperoleh rerata dan standar deviasi. Hasil eksperimen menunjukkan bahwa kondisi kontrol memperoleh akurasi uji tertinggi sebesar $86,42\% \pm 0,37\%$, sedangkan normalisasi menghasilkan akurasi yang hampir setara sebesar $86,36\% \pm 0,28\%$. Penambahan augmentasi menurunkan akurasi uji menjadi $79,48\% \pm 2,80\%$, dan kombinasi normalisasi, augmentasi, serta median filter menghasilkan akurasi terendah sebesar $76,20\% \pm 2,88\%$. Temuan ini menunjukkan bahwa preprocessing tambahan yang diuji belum mampu meningkatkan akurasi CNN pada konfigurasi eksperimen ini. Penurunan terutama terjadi pada kelas hewan seperti bird, cat, dog, dan deer, yang mengindikasikan bahwa augmentasi dan median filter dapat mengurangi informasi visual penting pada citra beresolusi rendah.

1. PENDAHULUAN

Klasifikasi citra merupakan salah satu tugas penting dalam bidang computer vision. Tugas ini banyak digunakan pada pengenalan objek, analisis citra medis, sistem pemantauan, dan berbagai aplikasi berbasis kecerdasan buatan. Convolutional Neural Network (CNN) menjadi salah satu pendekatan utama karena lapisan konvolusi mampu mengekstraksi pola spasial pada citra secara bertahap, mulai dari fitur sederhana hingga fitur yang lebih kompleks (Alzubaidi et al., 2021; Archana & Jeevaraj, 2024; Chen et al., 2021; Niu & Zhang, 2025; Nurtiwi et al., 2022; Taye, 2023; Zhao et al., 2024).

Walaupun CNN memiliki kemampuan ekstraksi fitur yang kuat, kinerja model tetap dipengaruhi oleh karakteristik data masukan. Perbedaan skala nilai piksel, variasi citra yang terbatas, dan keberadaan noise dapat memengaruhi proses pembelajaran. Oleh karena itu, preprocessing sering digunakan untuk menyiapkan data agar lebih konsisten sebelum proses pelatihan (Koresh, 2024; Murcia-Gómez et al., 2022; Ummah et al., 2022).

Namun, efektivitas preprocessing tidak selalu bersifat universal karena sangat bergantung pada karakteristik dataset, konfigurasi model, serta jenis transformasi yang digunakan (Alomar et al., 2023; Cubuk et al., 2020; Mumuni & Mumuni, 2022; Shorten &

Khoshgoftaar, 2019; Zeng, 2024). Pada citra beresolusi rendah seperti CIFAR-10 yang berukuran 32×32 piksel (Krizhevsky, 2009), transformasi augmentasi yang terlalu kuat atau tidak sesuai berpotensi mengubah informasi visual yang relevan terhadap label kelas (Cubuk et al., 2020; Istighosah et al., 2023; Shorten & Khoshgoftaar, 2019). Selain itu, penerapan filter spasial seperti median filter perlu dilakukan secara hati-hati karena meskipun efektif dalam mereduksi noise, filter ini juga dapat menyebabkan penghalusan berlebih atau hilangnya detail penting, terutama pada tepi dan tekstur citra (Guan et al., 2024; Ullah et al., 2025).

Dataset CIFAR-10 merupakan dataset benchmark yang terdiri dari 60.000 citra berwarna berukuran 32×32 piksel dalam 10 kelas. Dataset ini banyak digunakan untuk menguji performa model klasifikasi citra karena memiliki ukuran citra kecil, variasi objek yang tinggi, serta kemiripan visual antar beberapa kelas (Al Haris et al., 2024; Pant et al., 2023; Shen, 2024; Xia, 2024). Kondisi ini menjadikan CIFAR-10 relevan untuk menganalisis apakah preprocessing benar-benar membantu atau justru menurunkan performa model.

Penelitian ini bertujuan untuk menganalisis pengaruh normalisasi, augmentasi data, dan filter median terhadap performa CNN pada CIFAR-10. Penelitian tidak hanya melihat akurasi akhir, tetapi juga membandingkan akurasi latih, validasi, uji, learning curve, confusion matrix, classification report, dan analisis statistik tambahan. Dengan demikian, penelitian ini diharapkan memberikan gambaran yang lebih objektif mengenai dampak preprocessing pada model CNN sederhana.

2. METODOLOGI

2.1 Dataset

Dataset yang digunakan adalah CIFAR-10, terdiri dari 60.000 citra berwarna berukuran 32×32 piksel dalam 10 kelas, yaitu airplane, automobile, bird, cat, deer, dog, frog, horse, ship, dan truck (Al Haris et al., 2024; Pant et al., 2023; Shen, 2024; Xia, 2024). Data dibagi menjadi 45.000 citra untuk pelatihan, 5.000 citra untuk validasi, dan 10.000 citra untuk pengujian. Data validasi diambil dari bagian training set CIFAR-10, sedangkan pengujian menggunakan test set resmi.

2.2 Desain Eksperimen

Eksperimen dirancang dalam empat kondisi. Setiap kondisi dijalankan sebanyak lima kali menggunakan seed 42, 123, 256, 512, dan 999. Pengulangan ini dilakukan agar hasil tidak hanya bergantung pada satu inisialisasi bobot atau pembagian acak tertentu.

Tabel 1. Desain kondisi eksperimen

Kondisi	Preprocessing yang Diterapkan	Tujuan Pemanding
C0 - Kontrol	Tanpa normalisasi, augmentasi, dan median filter	Baseline performa CNN
C1 - Normalisasi	Normalisasi piksel ke rentang [0,1]	Menguji efek skala nilai piksel
C2 - Norm+Aug	Normalisasi + augmentasi data	Menguji efek variasi data pelatihan
C3 - Norm+Aug+Median	Normalisasi + augmentasi + filter median 3×3	Menguji efek kombinasi preprocessing lengkap

2.3 Teknik *Preprocessing*

Normalisasi dilakukan dengan membagi nilai piksel dengan 255. Augmentasi data dilakukan secara *on-the-fly* selama pelatihan dengan transformasi rotasi acak hingga 20 derajat, *flipping* horizontal, pergeseran lebar dan tinggi 10%, serta *zoom* 10%. Filter median menggunakan kernel 3x3 dan diterapkan per-*channel* pada citra RGB.

2.4 Arsitektur CNN

Model CNN terdiri dari tiga blok konvolusi. Setiap blok menggunakan dua lapisan Conv2D, *Batch Normalization*, aktivasi ReLU, *MaxPooling 2x2*, dan *Dropout*. Jumlah filter pada tiga blok berturut-turut adalah 32, 64, dan 128. Bagian classifier terdiri dari lapisan Dense 256 dan 128 neuron dengan Dropout, kemudian lapisan output softmax untuk 10 kelas. Komponen seperti *convolution layer*, *pooling*, *Batch Normalization*, *Dropout*, *fully connected layer*, dan *output layer* merupakan bagian yang umum dibahas pada arsitektur CNN modern (Alzubaidi et al., 2021; Norhikmah et al., 2022; Purwono et al., 2022; Sarvamangala & Kulkarni, 2022; Taye, 2023; Zhao et al., 2024). Jumlah parameter tidak dijadikan variabel pembanding karena arsitektur yang sama digunakan pada seluruh kondisi.

Tabel 2. Ringkasan arsitektur CNN

Bagian	Komponen	Keterangan
Input	Citra RGB 32x32x3	Format masukan CIFAR-10
Blok 1	Conv2D 32 filter, BN, ReLU, MaxPooling, Dropout	Ekstraksi fitur awal
Blok 2	Conv2D 64 filter, BN, ReLU, MaxPooling, Dropout	Ekstraksi fitur menengah
Blok 3	Conv2D 128 filter, BN, ReLU, MaxPooling, Dropout	Ekstraksi fitur tingkat tinggi
Classifier	Dense 256, Dense 128, Dropout	Klasifikasi fitur
Output	Dense 10, Softmax	Prediksi 10 kelas CIFAR-10

2.5 Hyperparameter Pelatihan

Tabel 3. Hyperparameter pelatihan

Parameter	Nilai
Optimizer	Adam
Learning rate	0,001
Batch size	64
Maksimum epoch	60
Early Stopping	patience=10, monitor=val_accuracy
ReduceLRonPlateau	factor=0,5; patience=5; min_lr=1e-6
Fungsi loss	Sparse Categorical Crossentropy
Inisialisasi bobot	He normal
Jumlah run per kondisi	5 run
Seed	42, 123, 256, 512, 999

2.6 Evaluasi dan Uji Statistik

Evaluasi dilakukan menggunakan akurasi latih, akurasi validasi, akurasi uji, learning curve validasi, *confusion matrix*, *precision*, *recall*, dan *f1-score*. Nilai akurasi dilaporkan dalam bentuk mean \pm standar deviasi dari lima *run*. Sebagai analisis statistik tambahan

setelah seluruh training selesai, perbedaan akurasi uji antar kondisi dianalisis menggunakan *One-Way* ANOVA dengan taraf signifikansi 5%. ANOVA digunakan untuk mengetahui apakah terdapat perbedaan rerata antar kondisi, sedangkan arah perbedaan ditentukan dengan membaca nilai rerata akurasi pada setiap kondisi.

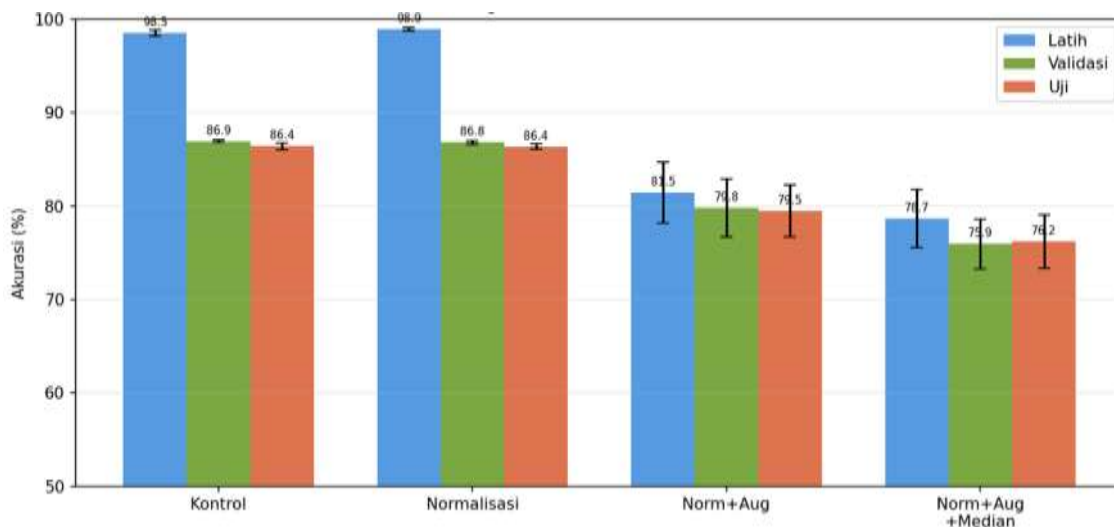
3. HASIL DAN PEMBAHASAN

3.1 Perbandingan Akurasi Antar Kondisi

Tabel 4 menyajikan hasil akurasi latih, validasi, dan uji dalam bentuk mean \pm standar deviasi. Hasil menunjukkan bahwa kondisi kontrol menghasilkan akurasi uji tertinggi, sedangkan kombinasi normalisasi, augmentasi, dan median filter menghasilkan akurasi uji terendah.

Tabel 4. Hasil akurasi mean \pm std (n=5 run) per kondisi eksperimen

Kondisi	Akurasi Latih	Akurasi Validasi	Akurasi Uji	Gap Latih-Uji
C0 - Kontrol	98.52% \pm 0.31%	86.94% \pm 0.13%	86.42% \pm 0.37%	12.10%
C1 - Normalisasi	98.92% \pm 0.17%	86.81% \pm 0.21%	86.36% \pm 0.28%	12.56%
C2 - Norm+Aug	81.46% \pm 3.25%	79.81% \pm 3.09%	79.48% \pm 2.80%	1.98%
C3 - Norm+Aug+Median	78.67% \pm 3.14%	75.94% \pm 2.67%	76.20% \pm 2.88%	2.47%



Gambar 1. Perbandingan Akurasi Antar Kondisi (Mean \pm Std, n=5)

Berdasarkan Gambar 1 dan Tabel 4, akurasi uji pada kondisi kontrol adalah 86,42% \pm 0,37%. Kondisi normalisasi menghasilkan akurasi uji 86,36% \pm 0,28%, atau hampir sama dengan kontrol. Perbedaan ini sangat kecil, yaitu -0,06 poin persentase. Dengan demikian, normalisasi dalam konfigurasi ini tidak memberikan peningkatan akurasi yang bermakna secara praktis.

Penurunan mulai terlihat setelah augmentasi data ditambahkan. Kondisi C2 memperoleh akurasi uji 79,48% \pm 2,80%, turun 6,89 poin persentase dibanding normalisasi. Penambahan median filter pada C3 kembali menurunkan akurasi uji menjadi

76,20% \pm 2,88%. Dibanding kontrol, C3 mengalami penurunan sebesar 10,22 poin persentase. Hasil ini menunjukkan bahwa *preprocessing* tambahan yang diuji tidak meningkatkan akurasi CNN, melainkan menurunkan performa pada dataset CIFAR-10.

3.2 Perubahan Inkremental Akurasi Uji

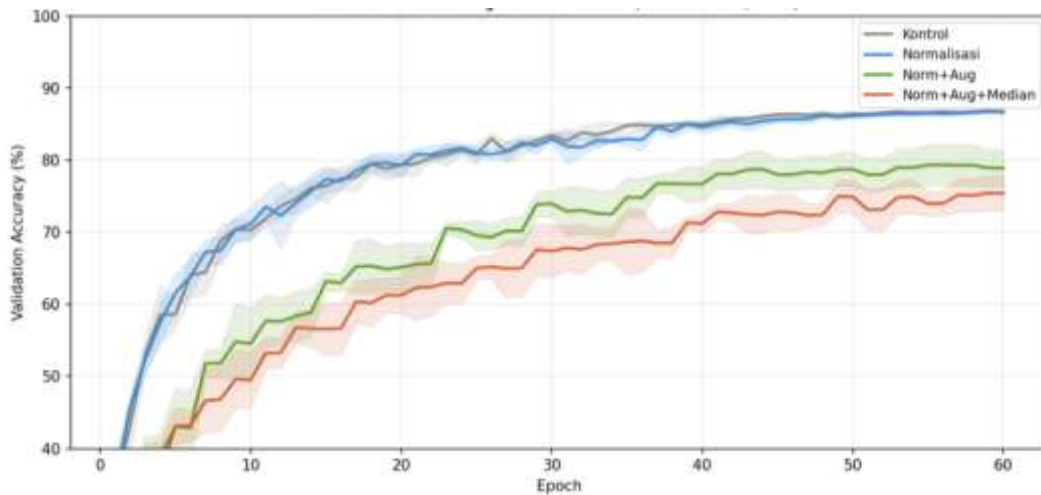
Tabel 5 menampilkan perubahan akurasi uji antar kondisi secara bertahap. Tanda negatif menunjukkan penurunan performa dibanding kondisi sebelumnya.

Tabel 5. Perubahan inkremental akurasi uji antar kondisi

Perbandingan Kondisi	Δ Akurasi Uji	Perubahan Relatif
C0 - Kontrol \rightarrow C1 - Normalisasi	-0.06 poin %	-0.07%
C1 - Normalisasi \rightarrow C2 - Norm+Aug	-6.89 poin %	-7.97%
C2 - Norm+Aug \rightarrow C3 - Norm+Aug+Median	-3.27 poin %	-4.12%
C0 - Kontrol \rightarrow C3 - Norm+Aug+Median	-10.22 poin %	-11.83%

Perubahan C0 ke C1 hanya sebesar -0,06 poin persentase, sehingga normalisasi dapat dikatakan relatif netral terhadap akurasi. Namun, perubahan C1 ke C2 sebesar -6,89 poin persentase menunjukkan bahwa konfigurasi augmentasi yang digunakan belum sesuai untuk meningkatkan generalisasi model. Perubahan C2 ke C3 sebesar -3,27 poin persentase menunjukkan bahwa median filter semakin menurunkan performa. Secara total, C0 ke C3 mengalami penurunan -10,22 poin persentase.

3.3 Analisis Learning Curve Validasi



Gambar 2. Learning Curve Validasi (Mean \pm Std, n=5)


Gambar 2 memperlihatkan bahwa kondisi kontrol dan normalisasi mengalami kenaikan akurasi validasi yang cepat dan kemudian stabil pada kisaran 86%. Kedua kurva tersebut berada pada posisi tertinggi sepanjang proses pelatihan. Hal ini menunjukkan bahwa CNN dapat mempelajari pola citra CIFAR-10 dengan baik tanpa *preprocessing* tambahan selain normalisasi.

Sebaliknya, kurva Norm+Aug dan Norm+Aug+Median berada jauh di bawah kontrol dan normalisasi. Norm+Aug cenderung stabil pada kisaran 79%, sedangkan Norm+Aug+Median berada pada kisaran 75-76%. Dengan demikian, penurunan performa tidak hanya terjadi pada hasil akhir, tetapi juga sudah terlihat selama proses pelatihan. Kondisi ini mengindikasikan bahwa augmentasi dan median filter membuat proses belajar menjadi lebih sulit atau mengurangi informasi visual yang relevan.

Gap antara akurasi latih dan akurasi uji pada kontrol dan normalisasi cukup besar, masing-masing sekitar 12,10% dan 12,56%. Ini menunjukkan adanya kecenderungan *overfitting*. Namun, pada Norm+Aug dan Norm+Aug+Median, gap menjadi lebih kecil karena akurasi latih juga turun. Gap yang kecil pada kondisi ini tidak dapat langsung ditafsirkan sebagai perbaikan generalisasi, karena performa latih, validasi, dan uji sama-sama menurun. Kondisi tersebut lebih tepat dibaca sebagai indikasi *underfitting* atau hilangnya informasi penting akibat *preprocessing*.

3.4 Analisis Confusion Matrix per Kelas

Confusion matrix pada Gambar 3 menunjukkan pola kesalahan klasifikasi pada run terbaik setiap kondisi. Secara umum, kelas kendaraan seperti *automobile*, *ship*, dan *truck* tetap memiliki nilai *recall* relatif tinggi. Penurunan paling jelas terjadi pada kelas hewan, terutama *bird*, *cat*, *dog*, dan *deer*.



Gambar 3. Confusion Matrix per Kondisi

Pada kelas *bird*, *recall* turun dari 0,77 pada kontrol menjadi 0,56 pada Norm+Aug+Median. Kelas *cat* turun dari 0,74 menjadi 0,52, *dog* turun dari 0,76 menjadi 0,60, dan *deer* turun dari 0,90 menjadi 0,76. Penurunan ini menunjukkan bahwa *preprocessing* tambahan terutama berdampak pada kelas yang membutuhkan detail bentuk dan tekstur. Median filter berpotensi menghaluskan tepi dan tekstur halus, sedangkan augmentasi dapat menghasilkan variasi citra yang terlalu jauh dari distribusi asli.

Sebaliknya, beberapa kelas dengan bentuk visual lebih tegas seperti automobile, ship, dan truck relatif tetap tinggi meskipun mengalami sedikit penurunan. Hal ini menjelaskan mengapa penurunan akurasi keseluruhan tidak hanya berasal dari satu kelas, tetapi paling dominan pada kelas hewan yang secara visual lebih mirip satu sama lain.

3.5 Hasil Uji Statistik

Sebagai analisis statistik tambahan, uji *One-Way* ANOVA dilakukan pada akurasi uji dari lima run setiap kondisi. Hasil uji disajikan pada Tabel 7.

Tabel 6. Hasil uji *One-Way* ANOVA pada akurasi uji

Parameter	Nilai
F-statistik	32.08
p-value	5.32e-07
Taraf signifikansi (α)	0,05
Effect size (η^2)	0.857
Kesimpulan	H0 ditolak - terdapat perbedaan signifikan antar kondisi

Nilai p sebesar $5,32 \times 10^{-7}$ lebih kecil dari 0,05, sehingga hipotesis nol yang menyatakan tidak ada perbedaan akurasi antar kondisi ditolak. Artinya, terdapat perbedaan performa yang signifikan antar kondisi eksperimen. Namun, hasil ANOVA tidak menyatakan bahwa *preprocessing* meningkatkan akurasi. Arah perbedaan harus dilihat dari nilai rerata. Berdasarkan rerata akurasi, kondisi kontrol dan normalisasi merupakan kondisi terbaik, sedangkan Norm+Aug+Median merupakan kondisi terendah. Karena jumlah run per kondisi relatif kecil ($n=5$), hasil ANOVA dalam penelitian ini diposisikan sebagai analisis tambahan untuk mendukung pembacaan rerata, bukan sebagai satu-satunya dasar kesimpulan.

4. KESIMPULAN

Penelitian ini menganalisis pengaruh normalisasi, augmentasi data, dan median filter terhadap performa CNN pada dataset CIFAR-10. Berdasarkan lima run eksperimen, kondisi kontrol memperoleh akurasi uji tertinggi sebesar $86,42\% \pm 0,37\%$, sedangkan normalisasi menghasilkan akurasi yang hampir setara sebesar $86,36\% \pm 0,28\%$. Penambahan augmentasi data menurunkan akurasi uji menjadi $79,48\% \pm 2,80\%$, dan kombinasi normalisasi, augmentasi, serta median filter menghasilkan akurasi uji terendah sebesar $76,20\% \pm 2,88\%$. Dengan demikian, teknik Norm+Aug+Median tidak meningkatkan akurasi CNN pada konfigurasi eksperimen ini, melainkan menurunkan akurasi sebesar 10,22 poin persentase dibanding kontrol. Uji *One-Way* ANOVA sebagai analisis tambahan menunjukkan adanya perbedaan signifikan antar kondisi eksperimen. Namun, arah perbedaan menunjukkan bahwa kondisi dengan *preprocessing* tambahan bukan kondisi terbaik. Confusion matrix memperlihatkan bahwa penurunan paling besar terjadi pada kelas hewan seperti bird, cat, dog, dan deer. Hal ini mengindikasikan bahwa augmentasi dan median filter dapat mengurangi informasi visual penting pada citra beresolusi rendah.

Kesimpulan utama penelitian ini adalah bahwa *preprocessing* harus dievaluasi secara empiris dan tidak dapat diasumsikan selalu meningkatkan performa. Untuk penelitian selanjutnya, disarankan menguji parameter augmentasi yang lebih ringan, menambahkan kondisi Normalisasi+Median tanpa augmentasi, membandingkan beberapa ukuran kernel median, serta menguji arsitektur CNN yang lebih dalam atau arsitektur modern lainnya.

DAFTAR PUSTAKA

- Al Haris, M., Dzeaulfath, M., & Wasono, R. (2024). Principal component analysis on convolutional neural network using transfer learning method for image classification of CIFAR-10 dataset. *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, 10(2), 141–150. <https://doi.org/10.26594/register.v10i2.3517>
- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), Article 46. <https://doi.org/10.3390/jimaging9020046>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, Article 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep learning models for digital image processing: A review. *Artificial Intelligence Review*, 57(1), Article 11. <https://doi.org/10.1007/s10462-023-10631-z>
- Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., & Miao, Y. (2021). Review of image classification algorithms based on convolutional neural networks. *Remote Sensing*, 13(22), Article 4712. <https://doi.org/10.3390/rs13224712>
- Cubuk, E. D., Zoph, B., Shlens, J., & Le, Q. V. (2020). RandAugment: Practical automated data augmentation with a reduced search space. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (pp. 702–703). <https://doi.org/10.1109/CVPRW50498.2020.00359>
- Guan, S., Liu, B., Chen, S., Wu, Y., Wang, F., Liu, X., & Wei, R. (2024). Adaptive median filter salt and pepper noise suppression approach for common path coherent dispersion spectrometer. *Scientific Reports*, 14, Article 17445. <https://doi.org/10.1038/s41598-024-66649-y>
- Istighosah, M., Sunyoto, A., & Hidayat, T. (2023). Image augmentation for BreKHis medical data using convolutional neural networks. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 8(4), 2381–2392. <https://doi.org/10.33395/sinkron.v8i4.12878>
- Koresh, H. J. D. (2024). Impact of the preprocessing steps in deep learning-based image classifications. *National Academy Science Letters*, 47, 645–647. <https://doi.org/10.1007/s40009-023-01372-2>
- Krizhevsky, A. (2009). *Learning multiple layers of features from tiny images* (Technical report). University of Toronto. <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>
- Mumuni, A., & Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, Article 100258. <https://doi.org/10.1016/j.array.2022.100258>
- Murcia-Gómez, D., Rojas-Valenzuela, I., & Valenzuela, O. (2022). Impact of image preprocessing methods and deep learning models for classifying histopathological breast cancer images. *Applied Sciences*, 12(22), Article 11375. <https://doi.org/10.3390/app122211375>
- Niu, S., & Zhang, J. (2025). Image processing based on convolution neural network. *Electronics*, 14(23), Article 4649. <https://doi.org/10.3390/electronics14234649>
- Norhikmah, Lutfhi, A., & Rumini. (2022). The effect of layer batch normalization and dropout of CNN model performance on facial expression classification. *JOIV: International Journal on Informatics Visualization*, 6(2-2), 481–488. <https://doi.org/10.30630/joiv.6.2-2.921>
- Nurtiwi, Ruliana, & Rais, Z. (2022). Convolutional neural network (CNN) method for classification of images by age. *JINAV: Journal of Information and Visualization*, 3(2), 126–130. <https://doi.org/10.35877/454RI.jinav1481>

- Pant, Y., Shah, G., Ojha, R., Thapa, R., & Bhatta, B. (2023). Comparison of CNN architecture of image classification using CIFAR10 datasets. *International Journal on Engineering Technology*, 1(1), 37–52. <https://doi.org/10.3126/injet.v1i1.60898>
- Purwono, Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of convolutional neural network (CNN): A review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: A survey. *Evolutionary Intelligence*, 15(1), 1–22. <https://doi.org/10.1007/s12065-020-00540-3>
- Shen, X. (2024). A study of the images classification on the CIFAR10 dataset based on CNNs. In *Proceedings of the 1st International Conference on Data Analysis and Machine Learning (DAML 2023)* (pp. 114–118). SCITEPRESS. <https://doi.org/10.5220/0012798800003885>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, Article 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Taye, M. M. (2023). Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions. *Computation*, 11(3), Article 52. <https://doi.org/10.3390/computation11030052>
- Ullah, F., Kumar, K., Rahim, T., Khan, J., & Jung, Y. (2025). A new hybrid image denoising algorithm using adaptive and modified decision-based filters for enhanced image quality. *Scientific Reports*, 15, Article 8971. <https://doi.org/10.1038/s41598-025-92283-3>
- Ummah, K. R., Karlita, T., Sigit, R., Yuniarno, E. M., Purnama, I. K. E., & Purnomo, M. H. (2022). 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*, 18(6), 1895–1912. <https://doi.org/10.24507/ijicic.18.06.1895>
- Xia, Z. (2024). Overfitting of CNN model in CIFAR-10: Problem and solutions. *Applied and Computational Engineering*, 37(1), 212–221. <https://doi.org/10.54254/2755-2721/37/20230511>
- Zeng, W. (2024). Image data augmentation techniques based on deep learning: A survey. *Mathematical Biosciences and Engineering*, 21(6), 6190–6224. <https://doi.org/10.3934/mbe.2024272>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), Article 99. <https://doi.org/10.1007/s10462-024-10721-6>