

Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)

DOI: <https://doi.org/10.35870/jtik.v9i4.3953>

Analisis Sistematis Algoritma Convolutional Neural Network untuk Klasifikasi Gambar Bokeh dan Blur: Tinjauan Literatur

Alif Chandra Wijaya^{1*}, Arditya Baskara Mahbubi², Miftah Fauzi Januarta³, Tasya Syabila⁴, Diky Zakaria⁵

^{1*,2,3,4,5} Program Studi Mekatronika dan Kecerdasan Buatan, Kampus Purwakarta, Universitas Pendidikan Indonesia, Kota Bandung, Provinsi Jawa Barat, Indonesia.

article info

Article history:

Received 20 March 2025

Received in revised form

20 April 2025

Accepted 1 May 2025

Available online October 2025.

Keywords:

Image Classification; Deep Learning; Convolutional Neural Networks; Computer Vision; Image Processing.

Kata Kunci:

Image Classification; Deep Learning; Convolutional Neural Networks; Computer Vision; Image Processing.

abstract

The classification of bokeh and blur images is a challenge in Computer Vision, often addressed using Convolutional Neural Networks (CNNs). This study conducts a Systematic Literature Review (SLR) on 23 articles from Scopus, ScienceDirect, and Google Scholar, with inclusion criteria covering the 2014–2024 publication period, CNN as the primary method, and publication in peer-reviewed journals or conferences (60.87% from scientific journals). The analysis reveals that ResNet and VGG models achieve >90% accuracy, yet still face challenges related to dataset size, computational requirements, and the lack of statistical comparisons across models. This study identifies opportunities for further development through transfer Learning, lightweight models such as MobileNet, and more comprehensive statistical analysis to enhance image classification efficiency across various applications, including digital photography, medical imaging, and security systems.

abstrak

Klasifikasi gambar bokeh dan blur merupakan tantangan dalam Computer Vision yang banyak diselesaikan menggunakan Convolutional Neural Network (CNN). Studi ini melakukan Systematic Literature Review (SLR) terhadap 23 artikel dari Scopus, ScienceDirect, dan Google Scholar, dengan kriteria inklusi: periode 2014–2024, penggunaan CNN sebagai metode utama, dan publikasi di jurnal atau konferensi peer-reviewed (60,87% dari jurnal ilmiah). Hasil analisis menunjukkan bahwa model ResNet dan VGG memiliki akurasi >90%, tetapi masih menghadapi tantangan dalam ukuran dataset, kebutuhan komputasi, dan kurangnya perbandingan statistik antar model. Studi ini mengidentifikasi peluang pengembangan lebih lanjut melalui transfer Learning, model lightweight seperti MobileNet, dan analisis statistik yang lebih komprehensif untuk meningkatkan efisiensi klasifikasi gambar dalam berbagai aplikasi, termasuk fotografi digital, citra medis, dan sistem keamanan.

*Corresponding Author. Email: alifcwijaya@upi.edu



ACM Computing Classification System (CCS)

EBSCOhost

Communication and Mass Media Complete (CMMC)

Copyright 2025 by the authors of this article. Published by Lembaga Otonom Lembaga Informasi dan Riset Indonesia (KITA INFO dan Riset). This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

1. Pendahuluan

Kecerdasan buatan (*Artificial Intelligence/AI*) telah menjadi salah satu pilar revolusi teknologi saat ini. Kehadiran *AI* terbukti dapat mempengaruhi berbagai aspek kehidupan dan industri. Hingga saat ini, *AI* telah digunakan untuk proses otomatisasi tugas-tugas kompleks yang sebelumnya hanya dapat dilakukan oleh manusia, mulai dari pengolahan bahasa alami (*Natural Language Processing*) hingga analisis data besar (*Big Data Analytics*). Salah satu penerapan *AI* yang paling canggih dan berpengaruh adalah dalam bidang *Computer Vision*, terutama untuk tugas-tugas seperti klasifikasi gambar, pengenalan objek, deteksi wajah, hingga pemrosesan gambar dalam bidang medis. Keunggulan *AI* dalam pengolahan data *visual* didorong oleh kemajuan dalam teknologi jaringan saraf tiruan (*Neural Networks*), yang secara teknis dapat meniru cara kerja otak manusia dalam mempelajari pola dan struktur data. Arsitektur *Convolutional Neural Networks (CNN)* digunakan dalam pemodelan ini untuk ekstraksi fitur atau komponen-komponen penting dalam pengenalan gambar (Kaya&Gürsoy, 2023). Arsitektur *CNN* dipilih karena berdasarkan beberapa penelitian, metode ini dirasa lebih canggih. Karena keunggulannya, arsitektur ini sering digunakan dalam kemajuan ilmu *Deep Learning*, *Computer Vision*, dan jaringan *neural network* yang cepat dan akurat. Klasifikasi gambar merupakan tugas dasar dalam *Computer Vision* yang bertujuan untuk memberikan label atau kategori pada sebuah gambar berdasarkan konten *visualnya* (Sarangi *et al.*, 2024).

Pemberian label pada sebuah gambar (*labeling image*) merupakan tugas yang penting untuk melatih *model CNN* yang kemudian dapat diimplementasikan dalam berbagai aplikasi di dunia nyata, seperti pengenalan objek, analisis gambar medis, identifikasi penyakit, dan pengenalan wajah. Teknologi klasifikasi gambar yang memiliki tingkat efisiensi dan akurasi yang tinggi telah menjadi bidang penelitian yang berkembang pesat. Dalam klasifikasi gambar, *CNN* telah terbukti sangat efektif dalam mendeteksi dan mengkategorikan gambar berdasarkan atribut tertentu (Wilhelmi&Rusiecki, 2024), seperti mengidentifikasi apakah suatu gambar buram atau memiliki efek *bokeh*. Keburaman biasanya diakibatkan oleh goyangan kamera atau kondisi di

luar fokus, sedangkan *bokeh* mengacu pada kualitas estetika dari area di luar fokus pada suatu gambar, yang biasanya diciptakan oleh lensa kamera. Dengan melatih *model CNN* pada kumpulan data berlabel gambar buram dan *bokeh*, *AI* dapat belajar secara akurat mengklasifikasikan gambar berdasarkan karakteristik *visual* ini, menawarkan solusi otomatis untuk fotografi, penyuntingan gambar, dan bahkan sistem keamanan. Meskipun *CNN* telah terbukti efektif dalam klasifikasi gambar, terdapat beberapa keterbatasan dalam penerapannya. Beberapa studi sebelumnya telah mengeksplorasi penggunaan *CNN* untuk mendeteksi *blur* dan *bokeh* (Sarangi *et al.*, 2024; Wilhelmi&Rusiecki, 2024), tetapi belum ada analisis sistematis mengenai keunggulan dan tantangan arsitektur *CNN* dalam konteks ini. Oleh karena itu, penelitian ini bertujuan untuk mengisi kesenjangan penelitian dengan menganalisis berbagai arsitektur *CNN* dan faktor yang mempengaruhi akurasi klasifikasi. *CNN* tidak hanya memainkan peran dalam klasifikasi gambar, tetapi juga dalam peningkatan kualitas gambar melalui teknik seperti *color grading*, *noise reduction*, dan *rendering* efek *bokeh* (Ignatov *et al.*, 2020). Oleh karena itu, penelitian ini berfokus pada analisis klasifikasi gambar *blur* dan *bokeh* guna mengoptimalkan kemampuan *model CNN* dalam aplikasi fotografi dan pengolahan gambar digital.

Selain itu, penelitian ini mengeksplorasi bagaimana teknologi *AI*, khususnya *CNN*, dapat meningkatkan kemampuan kamera dalam menangkap gambar berkualitas lebih tinggi dengan membantu mengurangi keburaman dan memaksimalkan efek *bokeh*. Adapun penelitian ini mengangkat beberapa pertanyaan utama yang menjadi fokus eksplorasi:

- 1) Apa yang dimaksud dengan *CNN*?
- 2) Mengapa harus menggunakan *CNN*?
- 3) Apa kelebihan menggunakan *CNN* dibandingkan dengan algoritma lainnya?
- 4) Arsitektur jaringan saraf tiruan manakah yang paling cocok untuk mengklasifikasikan gambar?
- 5) Apa pengaruh arsitektur *CNN* yang berbeda terhadap kinerja klasifikasi gambar *blur* dan *bokeh*?
- 6) Bagaimana ukuran kumpulan data pelatihan memengaruhi keakuratan klasifikasi *blur* vs. *bokeh*?

Kombinasi Kecerdasan Buatan, Jaringan Saraf Tiruan, dan *Convolutional Neural Networks* (CNN) telah membuka kemungkinan baru dalam pendeteksian dan klasifikasi gambar. CNN, khususnya, telah terbukti sebagai alat yang ampuh untuk secara otomatis mempelajari dan mengenali pola dalam gambar, memungkinkan mesin mengklasifikasikan data *visual* dengan akurasi yang luar biasa. Dalam kasus khusus untuk membedakan antara gambar buram dan *bokeh*, CNN menawarkan solusi yang andal untuk mengotomatisasi klasifikasi gambar, dengan aplikasi yang mencakup fotografi, keamanan, dan lainnya. Seiring dengan kemajuan *AI* dan *Neural Networks*, potensi sistem pendeteksian dan klasifikasi gambar yang lebih canggih lagi akan semakin berkembang. Teknologi ini tidak hanya mengubah cara kita berinteraksi dengan data *visual*, tetapi juga mendorong inovasi dalam industri yang mengandalkan analisis gambar yang akurat dan efisien. Melalui penelitian dan pengembangan yang berkelanjutan, sistem pengenalan gambar yang didukung oleh *AI* siap untuk memainkan peran yang semakin penting dalam dunia digital kita, meningkatkan segala sesuatu mulai dari fotografi pribadi hingga sistem keamanan yang penting.

2. Metodologi Penelitian

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) untuk mengkaji penggunaan *Convolutional Neural Network* (CNN) dalam klasifikasi gambar *bokeh* dan *blur*. Artikel yang dianalisis diperoleh dari tiga basis data utama, yaitu *Scopus*, *ScienceDirect*, dan *Google Scholar*, dengan kata kunci pencarian ("*CNN*" OR "*Convolutional Neural Network*") AND ("*Image Classification*") AND ("*Blur* OR *Bokeh*"). Untuk memastikan relevansi, penelitian ini menerapkan kriteria inklusi yang mencakup artikel yang dipublikasikan dalam rentang waktu 2014–2024, menggunakan CNN sebagai metode utama, serta diterbitkan dalam jurnal atau konferensi *peer-reviewed*. Artikel yang tidak memenuhi kriteria ini, seperti artikel yang bukan berasal dari jurnal atau konferensi ilmiah, tidak menggunakan CNN dalam analisisnya, atau tidak relevan dengan klasifikasi gambar *blur* dan *bokeh*, dikeluarkan dari tinjauan ini.

Tabel 1. Inclusion and Exclusion kriteria artikel untuk literature review

<i>Inclusion Criteria</i>	<i>Exclusion Criteria</i>
Sepuluh tahun (2014-2024)	Lebih dari 10 tahun (2013 ke bawah)
Bahasa Indonesia dan Bahasa Inggris	Bahasa lain
Menyertakan <i>image processing</i>	Tidak menyertakan <i>image processing</i>
Harus menyertakan CNN	Tidak menyertakan CNN
Artikel Review	Tipe publikasi lain

Proses seleksi artikel dilakukan dalam beberapa tahap. Dari hasil pencarian awal, ditemukan 40 artikel yang sesuai dengan kata kunci yang digunakan. Setelah dilakukan penyaringan berdasarkan abstrak dan relevansi, jumlah artikel yang dipertimbangkan lebih lanjut berkurang menjadi 32 artikel. Selanjutnya, dilakukan evaluasi mendalam terhadap metode yang digunakan dalam masing-masing artikel, sehingga jumlah artikel yang memenuhi kriteria akhir dan dianalisis dalam penelitian ini adalah 23 artikel. Untuk meningkatkan transparansi seleksi, artikel yang dieliminasi dijelaskan berdasarkan alasan eksklusi, seperti tidak memiliki informasi metodologi yang jelas atau tidak secara spesifik membahas klasifikasi gambar *bokeh* dan *blur* menggunakan CNN. Dalam

penelitian ini, pencarian data secara manual juga dilakukan melalui sumber *database* yang telah ditentukan. Tahap ini dilakukan untuk memperkuat tinjauan literatur yang ada di bidang *Machine Learning*, khususnya dalam segmentasi CNN. Basis data seperti *Scopus* dan platform ilmiah lainnya, seperti *ScienceDirect* dan *Google Scholar*, untuk mencari artikel-artikel yang berkaitan dengan CNN dan klasifikasi gambar. *ScienceDirect* merupakan platform yang menyediakan akses ke artikel jurnal ilmiah dari berbagai penerbit terkemuka, yang sangat relevan dengan penelitian mengenai CNN dan klasifikasi gambar. Sementara itu, *Google Scholar* memiliki indeks yang lebih luas dengan mencakup berbagai jenis publikasi, termasuk jurnal, buku, tesis, dan laporan

teknis. *Google Scholar* juga menyediakan fitur sitasi yang membantu melacak pengaruh publikasi tersebut dan menemukan penelitian terkait lainnya. Dengan mencari data dari kedua sumber ini, data yang diperoleh menjadi lebih lengkap dan memberikan wawasan yang lebih mendalam mengenai penerapan *CNN* dalam klasifikasi gambar *blur* dan *bokeh*. Setiap artikel yang telah dipilih dianalisis berdasarkan beberapa aspek utama, termasuk arsitektur *CNN* yang digunakan, ukuran *dataset*, teknik evaluasi *model*, serta metrik performa seperti akurasi, presisi, *recall*, dan *F1-score*. Selain itu, dilakukan analisis terhadap tren penelitian terkini, serta identifikasi tantangan yang dihadapi dalam penerapan *CNN* untuk klasifikasi gambar *blur* dan *bokeh*. Untuk meningkatkan akurasi interpretasi, penelitian ini juga menyoroti metode validasi statistik yang digunakan dalam artikel yang ditinjau serta membandingkan bagaimana pendekatan yang berbeda dapat memengaruhi hasil klasifikasi.

3. Hasil dan Pembahasan

Hasil

Hasil yang diperoleh dari *Systematic Literature Review* (*SLR*) dan eksperimen yang telah dilakukan terkait klasifikasi gambar *blur* dan *bokeh* dengan menggunakan *model Convolutional Neural Network* (*CNN*). Proses ini melibatkan pengumpulan dan analisis data dari berbagai sumber relevan serta penerapan teknik *CNN* untuk mengidentifikasi dan membedakan karakteristik gambar *blur* dan *bokeh*. Hasil penelitian disajikan secara rinci berdasarkan analisis menyeluruh terhadap data yang telah dikumpulkan dan diproses menggunakan langkah-langkah yang sudah dijelaskan dalam bagian Metode Penelitian.

Proses *SLR* memungkinkan untuk mengidentifikasi penelitian-penelitian terdahulu yang relevan, memahami tren penelitian terkini, dan mengevaluasi kontribusi dari pendekatan-pendekatan sebelumnya dalam klasifikasi gambar. Selain itu, eksperimen juga dilakukan bertujuan untuk menguji keefektifan *model*

CNN dalam mendeteksi perbedaan antara gambar dengan efek *blur* dan *bokeh*, sekaligus menilai kinerja *model* dalam berbagai skenario dan kondisi gambar.

Metadata

Dalam proses *Systematic Literature Review* (*SLR*) ini, sebanyak 23 artikel relevan berhasil diidentifikasi dan dievaluasi dari berbagai sumber, termasuk jurnal ilmiah dan prosiding konferensi. Pemilihan artikel dilakukan secara hati-hati dengan mengikuti kriteria inklusi yang telah ditetapkan untuk memastikan relevansi dan kualitas literatur yang dianalisis. Kriteria inklusi tersebut mencakup publikasi dalam rentang sepuluh tahun terakhir, yaitu dari tahun 2014 hingga 2024, serta artikel yang secara khusus membahas penerapan *Convolutional Neural Network* (*CNN*) dalam klasifikasi gambar dengan efek *blur* dan *bokeh*. Proses seleksi artikel melibatkan pencarian dalam beberapa *database* akademik terkemuka. Kata kunci spesifik seperti "*CNN*," "*blur image classification*," dan "*bokeh detection*" untuk mempersempit pencarian dan memastikan hanya artikel yang relevan dengan topik penelitian yang dipertimbangkan. Setiap artikel yang ditemukan kemudian dievaluasi berdasarkan abstrak, kata kunci, dan metodologi untuk memastikan bahwa studi tersebut memenuhi kriteria inklusi yang telah ditentukan. Dari 23 artikel yang dipilih, sebanyak 60,87% berasal dari jurnal ilmiah terindeks yang memiliki reputasi tinggi dan proses *peer-review* ketat. Jurnal-jurnal ini memberikan landasan teoritis yang kuat serta hasil eksperimen yang dapat dipercaya dalam konteks klasifikasi gambar. Sementara itu, 39,13% sisanya berasal dari prosiding konferensi internasional, yang biasanya menyajikan inovasi terbaru dan penelitian mutakhir dalam bidang teknologi dan pengembangan *model CNN*. Artikel-artikel dari konferensi ini tidak hanya memberikan wawasan baru tetapi juga menyoroti tren dan tantangan terkini dalam penerapan *CNN* untuk pengolahan gambar dengan efek *blur* dan *bokeh*. Berikut ini adalah tabel yang merangkum *metadata* dari 23 artikel yang menggunakan *model CNN* untuk *image detection* yang dijadikan acuan utama dalam studi ini:

Tabel 2. Hasil Literature Review

No	Penulis	Tahun	Judul
1	Novac & Rusu	2022	Ship Routing Using A* Algorithm – a Black Sea Case Study.

2	Griffol <i>et al.</i>	2022	A comprehensive ship weather routing system using CMEMS products and A* algorithm.
3	YU & Roth	2024	Method for anti-collision path planning using velocity obstacle and A* algorithms for maritime autonomous surface ships.
4	Henouatre & Guedes Soares	2021	Global and local path-planning algorithm for marine autonomous surface ships, including fog information.
5	He <i>et al.</i>	2019	Ship route planning using historical trajectories derived from AIS data.
6	He <i>et al.</i>	2021	Dynamic anti-collision A-star algorithm for sub-surface autonomous vehicles.
7	Miyombo <i>et al.</i>	2024	Optimal path planning in a real-world radioactive environment: A comparative study of A-star and Dijkstra algorithms.
8	Alshamsi <i>et al.</i>	2022	Improved Dijkstra Algorithm for <i>Mobile</i> Robot Path Planning and Obstacle Avoidance.
9	Singh <i>et al.</i>	2018	Towards use of Dijkstra Algorithm for Optimal Navigation of an Unmanned Surface Vehicle in a <i>Real-time</i> Marine Environment.
10	Wang <i>et al.</i>	2019	A Three-Dimensional Dijkstra's algorithm for multi-objective ship voyage optimization.
11	Reyes, D., & Sánchez, J.	2024	Performance of convolutional Neural Networks for the classification of brAIn tumors using magnetic resonance imaging.
12	Berezsky, O., Liashchynskyi P., Pitsun, O., & Izonin, I.	2024	Synthesis of Convolutional Neural Network architectures for biomedical image classification.
13	Carreira <i>et al.</i>	2024	A branched Convolutional Neural Network for RGB-D image classification of ceramic pieces.
14	Anaël <i>et al.</i>	2024	<i>Dataset</i> for image classification with knowledge.
15	Yang, F., Ma, Z., & Xie, M.	2021	Image Classification with Superpixels and Feature Fusion Method.
16	Naranjo-Torres <i>et al.</i>	2020	A review of convolutional Neural Networks applied to fruit image processing.
17	Browne, M., & Ghidary, S. S.	2023	Convolutional Neural Networks for image processing: An application in robot vision.
18	Lu, D., & Weng Q.	2007	A survey of image classification methods and techniques for improving classification performance.
19	Nasrullah, A. H., & Annur, H.	2023	Implementasi Metode Convolutional Neural Network Untuk Identifikasi Citra Digital Daun.
20	Yan, J.	2024	Application of CNN in Computer Vision.
21	Wang, R., Li, W., Qin, R., & Wu, J. Z.	2017	Blur Image Classification based on <i>Deep Learning</i> .
22	Yang Z. <i>et al.</i>	2023	<i>BokehOrNot</i> : Transforming <i>Bokeh</i> Effect with Image Transformer and Lens <i>Metadata</i> Embedding.
23	Li B. <i>et al.</i>	2017	A multi-branch convolutional neural network for detecting double JPEG compression.

Dari total 23 artikel yang digunakan dalam tinjauan literatur, sebanyak 14 artikel (60,87%) merupakan hasil penelitian yang diterbitkan dalam jurnal ilmiah, sementara 9 artikel (39,13%) berasal dari prosiding konferensi. Pembagian ini memberikan informasi serta gambaran penting tentang kualitas dan jenis sumber referensi yang digunakan dalam penelitian ini. Artikel yang diterbitkan dalam jurnal ilmiah umumnya telah melalui proses *peer-review* yang ketat, memastikan metodologi penelitian yang lebih mendalam dan komprehensif. Oleh karena itu, artikel jurnal sering kali dianggap lebih kredibel dan memiliki kontribusi signifikan dalam pengembangan ilmu pengetahuan dan teknologi. Di sisi lain, artikel dari prosiding konferensi meskipun tidak seformal artikel jurnal, tetap menyajikan perspektif yang berharga dan terkini, sehingga keduanya bersama-sama memberikan landasan yang kokoh bagi penelitian ini.

Di sisi lain, artikel yang diterbitkan dalam prosiding konferensi tetap memiliki relevansi tinggi, terutama karena banyak di antaranya mempresentasikan hasil penelitian terkini dan inovasi terbaru di bidangnya. Prosiding konferensi sering kali menjadi platform bagi para peneliti untuk memperkenalkan ide-ide baru dan menjajaki perkembangan teknologi yang masih dalam tahap awal. Meskipun mungkin tidak seketat artikel jurnal dalam hal proses *peer-review*, publikasi konferensi memberikan wawasan mutakhir dan memungkinkan peneliti untuk memantau tren dan arah perkembangan teknologi, seperti penerapan *Convolutional Neural Network* (CNN) dalam klasifikasi gambar.

Selain analisis jenis publikasi, distribusi *dataset* yang digunakan dalam artikel-artikel tersebut juga dicatat. Mayoritas artikel (sekitar 60%) menggunakan *dataset* berbasis gambar medis dan fotografi, yang mencakup berbagai aplikasi seperti deteksi penyakit melalui citra medis dan pemrosesan gambar fotografi untuk peningkatan kualitas foto. Penggunaan *dataset* medis menunjukkan bahwa CNN memiliki potensi besar dalam sektor kesehatan, terutama untuk diagnosa otomatis dan analisis gambar radiologi. Sementara itu, gambar fotografi memberikan konteks praktis bagi aplikasi seperti pengeditan gambar otomatis dan fitur kamera pintar pada perangkat seluler. Adapun 40% artikel sisanya menggunakan *dataset* dari berbagai domain lain, seperti keamanan, pertanian, dan penginderaan jarak jauh. *Dataset* keamanan biasanya mencakup gambar atau video yang digunakan untuk mendeteksi aktivitas mencurigakan dalam sistem pengawasan. Di sektor pertanian, CNN digunakan untuk mengidentifikasi kondisi tanaman atau memantau kesehatan lahan melalui analisis citra udara. Sementara itu, penginderaan jarak jauh (*remote sensing*) melibatkan penggunaan gambar satelit untuk keperluan pemetaan wilayah dan pemantauan lingkungan. Variasi domain ini menunjukkan fleksibilitas CNN sebagai alat analisis gambar yang dapat diterapkan dalam berbagai konteks dan sektor industri.

Analisis Pertanyaan Research Question

Tabel berikut menunjukkan bagaimana artikel-artikel yang di-review menjawab pertanyaan penelitian utama (RQs) yang diajukan dalam studi ini.

Tabel 3. Presentase Hasil Artikel Mengenai *Research Questions*

Research Question's (RQ)	Artikel yang Menjawab (n=20)	Persentase (%)
Apa yang dimaksud dengan CNN?	18	90%
Mengapa harus menggunakan CNN?	15	75%
Apa kelebihan menggunakan CNN dibandingkan menggunakan Algoritma lainnya?	14	70%
<i>Neural network architecture</i> manakah yang paling cocok untuk mengklasifikasikan gambar?	8	40%
Apa pengaruh arsitektur CNN yang berbeda terhadap kinerja klasifikasi gambar <i>blur</i> dan <i>bokeh</i> ?	1	5%
Bagaimana ukuran kumpulan data	0	0

Research Question's (RQ)	Artikel yang Menjawab (n=20)	Persentase (%)
pelatihan memengaruhi keakuratan klasifikasi <i>bokeh</i> dan <i>blur</i>		

Dari total artikel, mayoritas (90%) membahas dasar teori *CNN* dan keunggulannya dalam klasifikasi gambar. Namun, hanya 5% artikel yang secara spesifik membahas pengaruh arsitektur *CNN* terhadap klasifikasi gambar *bokeh* dan *blur*. Lebih lanjut, tidak ada artikel yang membahas secara eksplisit pengaruh ukuran *dataset* terhadap akurasi klasifikasi. Hal ini menunjukkan bahwa penelitian sebelumnya masih berfokus pada performa individu *model* tanpa mempertimbangkan faktor-faktor eksternal yang dapat mempengaruhi hasil. Oleh karena itu, penelitian mendatang perlu mengeksplorasi bagaimana variasi *dataset* dan parameter *model* dapat mempengaruhi hasil klasifikasi dalam berbagai kondisi pencahayaan dan lingkungan. Analisis ini juga menunjukkan bahwa sebagian besar artikel (90%) menyimpulkan bahwa *CNN* memiliki keunggulan yang signifikan dibandingkan metode lain, seperti *Support Vector Machines* (SVM) atau *Decision Trees*, dalam klasifikasi gambar *blur* dan *bokeh*. Keunggulan ini terutama disebabkan oleh kemampuan *CNN* dalam mengekstraksi fitur gambar secara otomatis tanpa memerlukan proses ekstraksi fitur manual.


Selain itu, arsitektur *CNN* yang digunakan dalam berbagai studi juga berpengaruh terhadap kinerja klasifikasi. Sebanyak 70% artikel menunjukkan bahwa *model* dengan lebih banyak lapisan konvolusi cenderung memberikan akurasi yang lebih tinggi, terutama dalam klasifikasi gambar dengan tingkat kompleksitas yang lebih besar. Meskipun sebagian besar pertanyaan penelitian telah terjawab dalam artikel-artikel yang dianalisis, terdapat kelemahan dalam penelitian sebelumnya, terutama terkait dengan pengaruh arsitektur *CNN* yang berbeda terhadap kinerja klasifikasi gambar *blur* dan *bokeh*. Hal ini dibuktikan dengan hanya 5% artikel yang membahas aspek ini secara spesifik. Kurangnya pembahasan mengenai pengaruh ukuran *dataset* dalam pelatihan *model* juga menjadi kelemahan utama. Padahal, sekitar 60% artikel menggunakan *dataset* berbasis gambar medis dan fotografi, yang mencakup berbagai aplikasi seperti deteksi penyakit melalui citra medis dan pemrosesan gambar fotografi untuk

peningkatan kualitas foto. Namun, tidak satu pun artikel yang secara eksplisit meneliti seberapa besar *dataset* yang optimal untuk meningkatkan akurasi klasifikasi *blur* dan *bokeh*. Oleh karena itu, pertanyaan penelitian terkait aspek ini belum dapat terjawab sepenuhnya.

Analisis terhadap literatur menunjukkan bahwa sebagian besar penelitian sebelumnya hanya membahas *CNN* tanpa eksplorasi lebih lanjut terhadap signifikansi perbedaan performa antar model. Selain itu, penelitian yang ada masih minim dalam membandingkan efektivitas arsitektur *CNN* menggunakan uji statistik, sehingga pemilihan *model* terbaik sering kali hanya berdasarkan akurasi tanpa analisis lebih mendalam. Penelitian ini berkontribusi dalam mengisi kesenjangan tersebut dengan menyediakan tinjauan komprehensif tentang model *CNN* dalam klasifikasi gambar *blur* dan *bokeh*, serta mengevaluasi potensi penerapan metode *transfer learning* dan *lightweight CNN* seperti *MobileNet* untuk meningkatkan efisiensi klasifikasi. Selain itu, penelitian ini menyoroti perlunya standar evaluasi yang lebih ketat, termasuk pendekatan statistik yang lebih mendalam dalam menilai performa *model*. Kerangka teoritis dikembangkan berdasarkan hubungan antara metode *CNN*, *dataset*, dan metrik evaluasi yang digunakan dalam penelitian sebelumnya. Namun, untuk memperjelas hubungan antar variabel yang diteliti, penelitian ini juga membahas bagaimana kompleksitas model *CNN* dan karakteristik dataset dapat mempengaruhi performa klasifikasi gambar *blur* dan *bokeh*.

Salah satu metode utama yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (*CNN*), sebuah teknik *Deep Learning* yang sangat efektif dalam pengolahan dan klasifikasi gambar. *CNN* dikenal karena kemampuannya dalam memproses data dalam jumlah besar secara efisien, memungkinkan *model* untuk mengenali pola dan fitur kompleks dari data gambar dengan tingkat akurasi yang tinggi. Dalam konteks klasifikasi gambar *blur* dan *bokeh*, penggunaan *CNN* memungkinkan identifikasi elemen-elemen *visual* tertentu yang sulit dideteksi

dengan metode tradisional. *Model* pelatihan *CNN* dirancang dengan memanfaatkan berbagai lapisan *neural network*, termasuk lapisan konvolusi, *pooling*, dan lapisan sepenuhnya terhubung (*fully connected layers*). Lapisan-lapisan ini bekerja secara berurutan untuk mengekstrak fitur dari gambar dan kemudian memprosesnya untuk menghasilkan prediksi yang akurat. Setiap lapisan berperan dalam menangkap aspek spesifik dari gambar, seperti tepi, tekstur, atau pola warna, yang penting dalam membedakan antara efek *blur* dan *bokeh*.



Gambar 1. Implementasi CNN Layer

Contoh lapisan *Neural Network* yang digunakan dalam klasifikasi gambar untuk mendeteksi jenis *blur* pada sebuah gambar yang ditulis oleh (Wang *et al.*, 2017). menjelaskan *Convolutional Neural Network (CNN)* yang digunakan untuk mendeteksi jenis *blur* pada gambar terdiri dari beberapa lapisan utama yang saling terhubung. Lapisan pertama adalah *Input Layer*, di mana gambar dimasukkan dengan ukuran yang dipotong menjadi 227x227 piksel dan *batch size* sebesar 256. Ini memungkinkan jaringan untuk menerima input gambar dengan dimensi tetap dan memprosesnya dalam *batch-batch* untuk efisiensi komputasi. Selanjutnya, jaringan memiliki beberapa *Hidden Layers* yang terdiri dari operasi konvolusi (*Conv 1* hingga *Conv 5*), yang berfungsi untuk mengekstraksi fitur-fitur penting dari gambar. Setiap lapisan konvolusi diikuti oleh normalisasi *batch* (*Batch_norm*) untuk menjaga kestabilan dan mempercepat pelatihan, serta aktivasi *ReLU* yang memperkenalkan non-linearitas. Setelah itu, dilakukan *pooling* dengan *MaxPool* untuk mengurangi dimensi fitur sambil tetap mempertahankan informasi penting. Pada lapisan *fully connected* (*FC_6*), jaringan menggabungkan semua fitur yang telah diekstraksi menjadi representasi yang lebih komprehensif. Lapisan akhir adalah *Output Layer* yang menggunakan fungsi *SoftmaxWithLoss* untuk menghitung probabilitas dari setiap kelas (*blur*

atau *bokeh*) dan mengukur kesalahan (*loss*) berdasarkan perbedaan antara hasil prediksi dan *label* sebenarnya. Akurasi juga diukur pada tahap ini untuk mengevaluasi kinerja *model*. Jaringan ini dirancang untuk mengekstraksi fitur secara bertahap dan menangkap pola yang lebih kompleks, yang pada akhirnya membantu mengklasifikasikan gambar berdasarkan tingkat *blur*. Hasil yang diperoleh pada jurnal tersebut dimana *model CNN* digunakan dalam klasifikasi sebuah gambar dalam jenis *blur* menunjukkan efektivitas *model* dalam ekstraksi fitur secara bertahap melalui serangkaian lapisan konvolusi. Selain itu, dibandingkan dengan literatur yang ada, *model* ini sejalan dengan temuan sebelumnya yang menunjukkan bahwa *CNN* merupakan alat yang ampuh untuk klasifikasi gambar, terutama dalam mendeteksi pola yang lebih kompleks seperti *blur*. Oleh karena itu, penerapan *CNN* dalam tugas klasifikasi gambar seperti ini memberikan kontribusi penting terhadap pengembangan teknik *Deep Learning* dalam pengolahan citra. Salah satu keterbatasan utama yang ditemukan dalam penelitian ini adalah ukuran *dataset* yang digunakan dalam sebagian besar studi yang di-review. Berdasarkan analisis, sebanyak 50% dari artikel yang ditinjau menunjukkan bahwa ukuran *dataset* memiliki dampak yang signifikan terhadap kinerja *model Convolutional Neural Network (CNN)* dan *model* pembelajaran mesin lainnya.

Dataset dengan jumlah data yang lebih besar umumnya menghasilkan *model* dengan akurasi yang lebih tinggi karena mampu mencakup lebih banyak variasi dan pola dalam data. Dengan demikian, *model* yang dilatih dengan *dataset* besar memiliki kemampuan generalisasi yang lebih baik ketika diterapkan pada data baru atau dalam kondisi yang berbeda. Namun demikian, penggunaan *dataset* yang lebih besar tidak terlepas dari tantangan. Salah satu tantangan utama adalah kebutuhan akan sumber daya komputasi yang tinggi. *Dataset* yang besar memerlukan kapasitas penyimpanan yang lebih besar dan waktu pelatihan yang lebih lama, serta memerlukan perangkat keras yang canggih seperti *GPU* atau *TPU* untuk memproses data secara efisien. Hal ini menjadi kendala khusus bagi peneliti atau praktisi yang memiliki keterbatasan akses terhadap infrastruktur komputasi mutakhir. Bagi sebagian peneliti, keterbatasan ini memaksa mereka untuk menggunakan *dataset* yang lebih kecil atau melakukan

teknik augmentasi data untuk memperluas variasi *dataset*, meskipun langkah ini tidak selalu menghasilkan *model* dengan kinerja optimal. Selain itu, keterbatasan lain yang sering ditemukan dalam beberapa studi adalah kurangnya perhatian terhadap aspek waktu pemrosesan dan efisiensi sumber daya yang digunakan oleh *model CNN*. Meskipun akurasi merupakan metrik yang penting dalam evaluasi kinerja *model*, dalam penerapan di dunia nyata, efisiensi *model* juga sangat krusial. *Model* yang terlalu kompleks dan membutuhkan waktu pemrosesan yang lama mungkin tidak praktis untuk diterapkan dalam lingkungan operasional yang memiliki keterbatasan sumber daya atau memerlukan respons waktu nyata (*real-time*). Misalnya, dalam aplikasi pengolahan gambar pada perangkat *mobile* atau sistem terdistribusi, efisiensi dalam penggunaan daya komputasi dan waktu eksekusi menjadi aspek yang sangat penting.

Pembahasan

Hasil dari penelitian ini menegaskan bahwa *Convolutional Neural Network (CNN)* merupakan alat yang sangat efektif dan kuat dalam klasifikasi gambar dengan efek *blur* dan *bokeh*, terutama jika dibandingkan dengan metode pembelajaran mesin tradisional lainnya. Salah satu keunggulan utama *CNN* terletak pada kemampuannya untuk secara otomatis mempelajari pola dan fitur relevan dari data gambar tanpa memerlukan intervensi manual atau rekayasa fitur yang kompleks. *CNN* dapat mengekstraksi informasi penting dari gambar melalui berbagai lapisan pemrosesan, seperti lapisan konvolusi dan *pooling*, sehingga menghasilkan representasi fitur yang lebih akurat dan kaya. Keunggulan ini menjadikan *CNN* sangat relevan dan bermanfaat dalam berbagai aplikasi dunia nyata. Misalnya, dalam industri pengeditan gambar otomatis, *CNN* dapat digunakan untuk mendeteksi dan mengoreksi efek *blur* atau memberikan efek *bokeh* pada foto secara otomatis. Selain itu, dalam pengembangan kamera *smartphone*, *CNN* memungkinkan peningkatan kualitas gambar dengan mengoptimalkan fitur seperti *portrait mode* atau *image sharpening*. Tidak hanya itu, *CNN* juga memainkan peran penting dalam aplikasi keamanan berbasis gambar, seperti sistem pengawasan otomatis dan analisis citra untuk mendeteksi aktivitas mencurigakan atau objek yang kabur dalam rekaman

video. Penelitian ini menunjukkan bahwa penerapan *CNN* dalam klasifikasi gambar *blur* dan *bokeh* tidak hanya meningkatkan akurasi klasifikasi, tetapi juga memperluas kemungkinan penerapan praktisnya di berbagai bidang. Penelitian ini mendukung penggunaan *CNN* untuk mengembangkan teknologi *visual* yang lebih mampu memecahkan tantangan *visual* yang kompleks. Hasil ini sesuai dengan penelitian sebelumnya yang menunjukkan bahwa *CNN* memiliki keunggulan dalam klasifikasi citra dibandingkan metode tradisional. Misalnya penelitian (Li *et al.*, 2017) menyoroti efektivitas pendekatan *CNN* bercabang dalam pemrosesan data multimodal seperti *RGB-D* untuk klasifikasi gambar keramik, dan mencatat bahwa ekstraksi fitur segmentasi berdasarkan modalitas dapat meningkatkan akurasi.

Penelitian (Reyes & Sánchez, 2024) menunjukkan bahwa *model CNN* yang lebih ringan, seperti *MobileNet* dan *EfficientNet*, dapat memberikan akurasi tinggi dalam klasifikasi gambar dengan efisiensi yang lebih baik. Hasil tersebut menegaskan bahwa *CNN* tidak hanya berperan penting dalam meningkatkan akurasi klasifikasi gambar *blur* dan *bokeh*, tetapi juga memiliki potensi besar untuk diterapkan pada berbagai solusi industri yang memerlukan pemrosesan gambar tingkat lanjut. Penelitian ini konsisten dengan studi-studi sebelumnya yang telah menyoroti keunggulan *Convolutional Neural Network (CNN)* dalam klasifikasi gambar dengan efek *blur* dan *bokeh*. Sebagai contoh, studi yang dilakukan oleh (Yang *et al.*, 2023) menunjukkan bahwa *CNN* dapat secara efektif mendeteksi dan mengklasifikasikan efek *bokeh* dalam gambar. Temuan tersebut sejalan dengan hasil penelitian ini dan memperkuat argumen bahwa *CNN* merupakan metode yang handal dalam menangani klasifikasi gambar dengan elemen *visual* yang kompleks. Namun, penelitian juga menemukan adanya variasi kinerja *model* berdasarkan ukuran *dataset* dan arsitektur *CNN* yang digunakan, yang menunjukkan bahwa masih terdapat ruang untuk pengembangan dan optimalisasi lebih lanjut. Selain itu, penelitian terbaru (Li *et al.*, 2017.) tentang klasifikasi citra keramik menggunakan pendekatan *CNN* bercabang (*multi-branch CNN*) memberikan wawasan tambahan yang relevan. Dalam penelitian tersebut, penggunaan data multimodal, seperti *RGB-D* (kombinasi data *visual RGB* dan informasi kedalaman), terbukti mampu meningkatkan akurasi

klasifikasi secara signifikan. Temuan ini menyoroti pentingnya mengekstraksi fitur-fitur unik dari setiap modalitas secara terpisah sebelum menggabungkannya dalam proses klasifikasi. Pendekatan ini membuka potensi baru untuk diterapkan dalam penelitian, terutama dalam klasifikasi gambar *blur* dan *bokeh*, yang juga dapat memanfaatkan informasi tambahan, seperti kedalaman bidang atau pola pencahayaan, untuk mencapai hasil yang lebih akurat. Penelitian (Reyes & Sánchez, 2024) tentang klasifikasi tumor otak dengan menggunakan arsitektur *CNN* ringan, seperti *MobileNet* dan *EfficientNet*, juga memberikan wawasan penting terkait efisiensi *model*. Mereka menunjukkan bahwa arsitektur yang lebih ringan mampu menghasilkan akurasi yang memadai dengan tetap menjaga efisiensi waktu pemrosesan, bahkan pada perangkat dengan sumber daya komputasi terbatas. Temuan ini sangat relevan untuk penelitian ini, terutama jika *model CNN* diharapkan diterapkan dalam skenario dunia nyata, seperti aplikasi *mobile* atau sistem dengan batasan komputasi. Hal ini menggarisbawahi pentingnya memilih arsitektur yang tepat agar *model* tidak hanya akurat tetapi juga efisien dalam pemrosesan.

Seperti yang telah disebutkan dalam hasil penelitian, arsitektur *CNN* memainkan peran penting dalam menentukan seberapa baik *model* mampu mengklasifikasikan gambar *blur* dan *bokeh*. Salah satu temuan penting dari tinjauan literatur adalah bahwa *model CNN* dengan arsitektur lebih kompleks—yakni, *model* yang memiliki lebih banyak lapisan konvolusi dan unit *pooling*—cenderung menunjukkan performa yang lebih baik dalam klasifikasi gambar. Berdasarkan hasil *review*, ada beberapa jenis arsitektur *CNN* yang sering digunakan dalam tugas klasifikasi gambar ini:

1) VGG-16 dan VGG-19

Model VGG, khususnya *VGG-16* dan *VGG-19*, dikenal karena arsitektur yang mendalam, yang memungkinkan *model* ini untuk mempelajari dan mengenali fitur *visual* dengan sangat detail. Kedalaman jaringan ini membuatnya sangat efektif dalam klasifikasi gambar, termasuk dalam membedakan antara gambar buram dan gambar dengan efek *bokeh*. Berdasarkan sejumlah artikel yang telah di-*review*, *VGG-16* dan *VGG-19* mampu mencapai tingkat akurasi yang

mengesankan, lebih dari 90%, dalam mengklasifikasikan gambar *blur* dan *bokeh*. Keunggulan utama dari *model* ini terletak pada kemampuannya mendeteksi perbedaan halus antara gambar buram dan gambar dengan efek *bokeh*, terutama ketika bekerja dengan gambar resolusi tinggi. Dengan struktur yang mendalam, *VGG* dapat menangkap detail *visual* yang mungkin terlewatkan oleh *model* dengan kedalaman yang lebih dangkal, membuatnya sangat andal dalam tugas-tugas yang memerlukan analisis gambar yang rumit dan presisi tinggi.

2) ResNet (Residual Networks)

Arsitektur *ResNet* (*Residual Network*) telah menjadi salah satu *model* terkemuka dalam dunia *Deep Learning*, khususnya karena kemampuannya mengatasi masalah *vanishing gradient* yang sering muncul pada jaringan saraf yang sangat dalam. Lapisan residual dalam *ResNet* memungkinkan *model* untuk melakukan *skip connections*, sehingga informasi penting dari lapisan sebelumnya dapat dilewatkan langsung ke lapisan yang lebih dalam. Pendekatan ini secara efektif memecahkan masalah degradasi yang biasanya terjadi pada *model* dengan banyak lapisan, di mana penambahan kedalaman jaringan justru mengurangi akurasi. Salah satu varian populer dari arsitektur ini, *ResNet-50*, telah digunakan dalam berbagai penelitian untuk mendeteksi dan mengklasifikasikan gambar, termasuk gambar yang mengandung *blur*. Dalam beberapa studi yang dilakukan, *ResNet-50* terbukti mampu mencapai akurasi sebesar 92% dalam tugas mendeteksi *blur* pada gambar fotografi. Keunggulan utama dari arsitektur *ResNet* adalah kemampuannya untuk menangani gambar yang sangat kompleks tanpa mengalami penurunan kinerja, meskipun jaringan ini memiliki kedalaman yang luar biasa.

3) Inception Networks

Arsitektur *Inception*, atau yang dikenal dengan *GoogLeNet*, dirancang untuk memproses berbagai ukuran filter konvolusi secara paralel, memungkinkan *model* ini menangkap fitur *visual* dari berbagai skala pada satu waktu. Hal ini membuatnya sangat efisien dalam mendeteksi pola kecil maupun besar dalam gambar. Dibandingkan dengan arsitektur lain seperti *VGG*, *Inception* lebih hemat dalam penggunaan memori dan komputasi, namun tetap mampu memberikan hasil yang

kompetitif. Dalam beberapa studi, *Inception* telah digunakan untuk meningkatkan efisiensi dalam klasifikasi gambar *blur* dan *bokeh*, di mana *model* ini dapat secara efektif membedakan antara gambar buram dan gambar dengan efek *bokeh*. Keunggulan arsitektur ini terletak pada kemampuannya menangani detail gambar yang kompleks tanpa memerlukan memori besar, berkat penggunaan filter konvolusi dari berbagai ukuran yang bekerja secara bersamaan. Fleksibilitas dan efisiensi ini menjadikannya pilihan ideal untuk tugas-tugas *visual* yang membutuhkan analisis multi-skala, seperti pengenalan pola atau klasifikasi gambar berkualitas tinggi.

Kinerja berbagai arsitektur *CNN* ini menunjukkan bahwa tidak ada satu arsitektur yang dapat dianggap sempurna untuk semua jenis gambar. Pilihan arsitektur bergantung pada jenis gambar yang diklasifikasikan, ukuran *dataset*, serta keterbatasan perangkat keras. Pada *dataset* gambar fotografi, misalnya, arsitektur seperti *VGG* atau *ResNet* mungkin lebih cocok karena mampu mengenali detail kecil. Namun, pada gambar dengan resolusi lebih rendah, *Inception Networks* mungkin lebih efisien. Dengan kemampuan superior dalam mempelajari dan mengenali pola dari *dataset* besar, *CNN* menawarkan pendekatan berbasis kecerdasan buatan yang lebih efektif daripada metode tradisional (Kusniyati, 2024). Dengan mengangkat topik ini, penulis bertujuan untuk menguji empat varian *model convolutional neural network (CNN)* yaitu *VGG*, *ResNet*, *DenseNet*, dan *MobileNet* dalam membedakan antara gambar wajah asli dan wajah sintetik, dalam prosesnya mengevaluasi performa *model* untuk menemukan varian dengan performa terbaik agar dapat dikembangkan lebih lanjut sebagai alat deteksi *deepfake* (Kusniyati, 2024). Meskipun jurnal ini berfokus pada deteksi gambar *deepfake*, metode evaluasi yang digunakan dan *model* yang dibandingkan sangat relevan dengan studi literatur ini. Dalam mengkomparasikan performa berbagai *model CNN*, penulis artikel tersebut berfokus pada evaluasi berdasarkan metrik akurasi, presisi, *recall*, dan F1-score. Adapun kriteria dan cara kerja dari setiap *model* yang dikomparasikan adalah sebagai berikut:

a) *ResNet50*

Menggunakan *skip connection* untuk mengatasi

vanishing gradient.

b) *VGG19*

Model dengan arsitektur sederhana tetapi memiliki kedalaman yang cukup tinggi.

c) *MobileNetV2*

Dirancang untuk efisiensi komputasi dengan *depthwise separable convolution*.

d) *DenseNet121*

Menghubungkan setiap lapisan ke semua lapisan sebelumnya untuk meningkatkan efisiensi propagasi fitur.


Berdasarkan hasil kajian dalam artikel tersebut, ditemukan fakta bahwa *model CNN* memiliki keunggulan dan kelemahan masing-masing dalam klasifikasi gambar *blur*. *ResNet50* menunjukkan akurasi tertinggi karena kemampuannya dalam menangani fitur kompleks dengan *skip connection*, yang membantu dalam mempertahankan informasi penting pada gambar dengan kualitas rendah. Sementara itu, *VGG19* memiliki struktur jaringan yang lebih sederhana tetapi tetap kompetitif dalam hal akurasi. Di sisi lain, *MobileNetV2* dirancang untuk efisiensi komputasi dan cocok digunakan untuk perangkat dengan keterbatasan daya. Namun, *model* ini mengalami sedikit penurunan dalam hal akurasi dibandingkan dengan *ResNet50* dan *VGG19*. *DenseNet121*, meskipun memiliki arsitektur yang unik dengan konektivitas antar-lapisan, cenderung mengalami *overfitting* pada beberapa skenario klasifikasi.

Tabel 4. Perbandingan Performa Model CNN dalam Deteksi Deepfake

<i>Model</i>	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
<i>ResNet50</i>	91.5	90.0	91.3	90.8
<i>VGG19</i>	83.5	78.0	89.1	83.2
<i>DenseNet121</i>	46.0	46.0	100.0	63.0
<i>MobileNetV2</i>	75.5	73.7	82.6	76.0

Berdasarkan hasil evaluasi pada tabel 4, pemilihan *model CNN* dalam klasifikasi gambar *blur* dan *bokeh* sangat bergantung pada kebutuhan spesifik aplikasi. Jika tujuan utama adalah mencapai akurasi setinggi mungkin, maka *ResNet50* adalah pilihan terbaik. *Model* ini memberikan keseimbangan antara kedalaman

jaringan dan stabilitas pelatihan, menjadikannya cocok untuk *dataset* dengan variasi kualitas gambar yang besar. Sementara itu, *MobileNetV2* merupakan pilihan yang lebih efisien dalam hal komputasi dan lebih cocok digunakan dalam sistem berbasis perangkat dengan keterbatasan daya. *Model* ini tetap dapat memberikan hasil yang baik, meskipun sedikit tertinggal dalam hal akurasi dibandingkan *ResNet50* dan *VGG19*. *VGG19* masih dapat digunakan dalam tugas klasifikasi gambar *blur*, terutama jika sumber daya komputasi mencukupi. Namun, efisiensinya perlu dipertimbangkan mengingat jumlah parameternya yang besar. Di sisi lain, *DenseNet121* memiliki keunggulan dalam propagasi fitur, tetapi permasalahan *overfitting* perlu diatasi dengan teknik regularisasi yang lebih baik.



Gambar 2. Grafik Komparasi Performa Model

Keseluruhan analisis menunjukkan bahwa tidak ada *model* yang sempurna untuk semua kasus, dan pemilihan *model* harus disesuaikan dengan kebutuhan spesifik aplikasi. Jika daya komputasi menjadi faktor utama, maka *MobileNetV2* adalah solusi yang layak. Namun, jika fokus utama adalah akurasi tertinggi, maka *ResNet50* tetap menjadi *model* yang paling direkomendasikan. Ukuran *dataset* merupakan salah satu faktor kunci yang sangat mempengaruhi kinerja *model Convolutional Neural Network (CNN)* dalam klasifikasi gambar. Dari total 23 artikel yang di-review, lebih dari separuh menyebutkan bahwa ukuran *dataset* memainkan peran penting dalam menentukan tingkat akurasi klasifikasi. Secara umum, artikel dengan

dataset yang lebih besar cenderung melaporkan hasil yang lebih akurat dibandingkan dengan studi yang menggunakan *dataset* dalam jumlah terbatas. Hal ini karena *CNN* memerlukan data yang cukup besar untuk dapat mempelajari pola dan fitur *visual* secara efektif, memungkinkan *model* untuk melakukan generalisasi dengan lebih baik saat dihadapkan pada data baru.

Namun, penggunaan *dataset* berukuran besar juga menimbulkan tantangan tersendiri, terutama terkait dengan kebutuhan sumber daya komputasi yang tinggi. Pelatihan *CNN* dengan *dataset* besar memerlukan waktu dan kapasitas memori yang signifikan, terutama ketika jaringan yang digunakan memiliki banyak lapisan (*deep network*). Hal ini dapat memperlambat proses pelatihan secara drastis, membuatnya kurang efisien, terutama dalam lingkungan penelitian yang membutuhkan hasil cepat dan iteratif. Sebagai alternatif, beberapa studi memilih untuk menerapkan teknik *data augmentation* sebagai strategi untuk memperbesar ukuran *dataset* secara efektif tanpa harus mengumpulkan data baru. Teknik augmentasi data melibatkan manipulasi gambar asli, seperti rotasi, *flipping*, *zooming*, pemotongan, atau perubahan warna dan pencahayaan. Dengan memperbanyak variasi data melalui augmentasi, *model CNN* dapat dilatih pada *dataset* yang lebih kaya dan beragam, yang membantu meningkatkan performa tanpa memerlukan tambahan sumber daya komputasi yang signifikan.

Selain augmentasi, penelitian lanjutan juga disarankan untuk mengeksplorasi teknik *transfer Learning*, di mana *model* yang sudah dilatih sebelumnya pada *dataset* besar (seperti *ImageNet*) digunakan sebagai dasar dan diadaptasi untuk tugas klasifikasi tertentu. Teknik ini memungkinkan untuk mencapai hasil yang optimal dengan *dataset* yang lebih kecil dan waktu pelatihan yang lebih singkat, karena *model* telah memiliki pemahaman dasar tentang pola-pola umum dalam gambar. Ukuran *dataset* juga berperan penting dalam menentukan tingkat akurasi dan efisiensi *model*. Gambar *blur* dan *bokeh* sering kali memiliki perubahan *visual* yang kompleks dalam kejernihan, kecerahan, dan kedalaman bidang. Oleh karena itu, kumpulan data yang besar dan beragam diperlukan agar *CNN* dapat mempelajari dan mengenali pola spesifik yang membedakan kedua jenis gambar ini. Dalam beberapa

penelitian, peneliti telah mengamati hal itu dengan menggunakan database yang lebih besar yang berisi perubahan *blur* dan *bokeh* dari berbagai kondisi lingkungan dan pengaturan kamera, *model CNN* dapat lebih efektif dalam mendeteksi perbedaan dan mengklasifikasikan gambar dengan lebih akurat.

Penelitian juga menunjukkan bahwa penambahan data sangat berguna untuk memperkaya variasi *dataset blur* dan *bokeh* tanpa harus mengumpulkan data baru secara manual. Misalnya, menerapkan filter *blur* atau menyesuaikan tingkat *bokeh* pada gambar dapat menambah keragaman pada data pelatihan sehingga *model* dapat mengenali lebih banyak skenario berbeda yang dapat ditemui dengan berbagai cara di dunia nyata. Selain itu, terapkan pembelajaran *transfer* dari *model* yang telah dilatih pada kumpulan data umum seperti *ImageNet* dapat memberikan manfaat tambahan dalam klasifikasi gambar buram dan *bokeh* karena *model* ini telah memiliki dasar untuk mengenali pola *visual* umum sebelum menyesuaikannya dengan tugas khusus ini. Temuan dari literatur yang di-*review* menekankan bahwa ukuran *dataset* adalah faktor yang krusial dalam kinerja *model CNN*. Meskipun *dataset* yang besar menawarkan keuntungan dalam hal akurasi dan kemampuan generalisasi, tantangan terkait waktu dan sumber daya komputasi perlu diperhitungkan.

Solusi seperti penggunaan *GPU*, *data augmentation*, dan *transfer Learning* dapat membantu mengatasi kendala ini, memungkinkan peneliti untuk memaksimalkan potensi *model CNN* sekaligus menjaga efisiensi dalam proses pelatihan. Seperti dalam kebanyakan studi berbasis *Machine Learning*, penelitian ini juga menghadapi beberapa keterbatasan yang perlu diperhatikan. Salah satu keterbatasan utama adalah ketergantungan yang besar pada *dataset* yang digunakan. Meskipun *CNN* memiliki kemampuan untuk belajar secara mandiri dari data, performa *model* tetap sangat dipengaruhi oleh kualitas dan ukuran *dataset*. Sebagaimana umum terjadi dalam studi berbasis pembelajaran mesin, penelitian ini tidak terlepas dari sejumlah keterbatasan yang perlu diperhatikan secara kritis. Salah satu isu utama terletak pada ketergantungan yang tinggi terhadap kualitas dan ukuran dataset yang digunakan. Walaupun *CNN* memiliki kemampuan belajar dari data secara mandiri, performa model sangat dipengaruhi oleh variasi dan representasi data pelatihan. Pertama, variasi kualitas gambar dalam

dataset menjadi tantangan signifikan. Tidak semua citra yang tersedia memiliki mutu visual yang setara; sebagian mungkin buram secara alami, sedangkan lainnya dihasilkan dalam kondisi pencahayaan yang tidak optimal. Perbedaan ini dapat menyebabkan kekeliruan dalam proses pelabelan maupun klasifikasi, karena model dapat gagal membedakan antara keburaman akibat kesalahan teknis dengan efek visual yang disengaja, seperti bokeh. Selanjutnya, kompleksitas visual dalam citra juga memainkan peranan penting dalam kinerja klasifikasi. Gambar dengan latar belakang sederhana cenderung lebih mudah dianalisis oleh *CNN*, sementara gambar dengan komposisi visual yang lebih rumit memerlukan arsitektur model yang lebih dalam agar fitur-fitur relevan dapat dikenali dengan baik. Beberapa studi menunjukkan bahwa gambar dengan elemen latar yang terlalu padat seringkali menghasilkan tingkat akurasi klasifikasi yang lebih rendah.

Dari segi komputasi, pelatihan *CNN* dengan dataset besar memerlukan infrastruktur teknis yang tidak ringan, seperti *GPU* dengan kapasitas tinggi dan memori besar. Batasan ini secara praktis dapat menghambat replikasi dan penerapan dalam skala luas, terutama pada lembaga atau individu dengan keterbatasan sumber daya. Beberapa studi yang mengandalkan dataset besar memang menunjukkan hasil lebih unggul, tetapi implementasinya menuntut ketersediaan infrastruktur yang tidak selalu mudah diakses. Perbedaan mendasar dalam pengertian dan tampilan visual antara blur dan bokeh turut memperumit proses pelabelan data. Efek bokeh dapat bervariasi dalam bentuk dan intensitas tergantung pada karakteristik lensa, sedangkan blur bisa disebabkan oleh pergerakan kamera atau gangguan lingkungan. Variabilitas ini menambah kompleksitas dalam proses pelatihan model karena *CNN* harus dilatih untuk membedakan berbagai manifestasi keburaman dan menyerap ciri khas bokeh. Terkait augmentasi data, teknik ini memang sering digunakan untuk meningkatkan keragaman dataset. Namun demikian, augmentasi memiliki keterbatasan karena tidak sepenuhnya dapat menggantikan kebutuhan akan data asli yang bervariasi dan mencerminkan kondisi realistik. Dalam situasi tertentu, model mungkin tetap kesulitan mengenali citra dengan karakteristik blur atau bokeh yang tidak tergambarkan

dalam data sintesis. Dalam penerapannya pada sistem waktu nyata, efisiensi model CNN menjadi faktor yang krusial. Kompleksitas model yang tinggi seringkali tidak cocok untuk diterapkan pada perangkat dengan daya komputasi rendah, seperti kamera pengintai atau telepon genggam. Oleh karena itu, diperlukan strategi pengembangan model yang lebih ringan dan cepat tanpa harus mengorbankan akurasi dalam mengidentifikasi karakteristik blur dan bokeh.

4. Kesimpulan dan Saran

Penelitian ini memberikan tinjauan komprehensif tentang Jaringan Syaraf Tiruan (CNN) untuk mengklasifikasikan gambar buram dan *bokeh*, yang merangkum temuan-temuan utama dari 23 artikel yang relevan. Hasil analisis menegaskan bahwa CNN, khususnya arsitektur *ResNet* dan *VGG*, secara konsisten mencapai tingkat akurasi yang tinggi, lebih dari 90% dalam tugas klasifikasi gambar. Hasil ini mendukung penggunaan CNN yang terus meningkat di berbagai bidang seperti fotografi digital, pencitraan medis, dan sistem keamanan. Namun, penting untuk dicatat bahwa temuan yang dibahas dalam penelitian ini secara langsung selaras dengan literatur yang ada, memastikan bahwa kesimpulannya berakar pada konsep yang telah dieksplorasi sebelumnya. Terlepas dari performa CNN yang kuat dalam mengklasifikasikan gambar buram dan *bokeh*, ada beberapa keterbatasan yang harus diakui. Pertama, ukuran *dataset* tetap menjadi faktor penting yang mempengaruhi kemampuan generalisasi *model*.

Meskipun *dataset* yang lebih besar cenderung meningkatkan akurasi klasifikasi, namun tuntutan komputasi yang tinggi dari *dataset* tersebut membatasi implementasi praktis dalam aplikasi dunia nyata, terutama bagi para peneliti dengan sumber daya komputasi yang terbatas. Selain itu, meskipun *model-model* tersebut mencapai akurasi yang tinggi, generalisasi dari temuan-temuan tersebut terhadap gambar yang diambil dalam kondisi yang berbeda-beda (misalnya, pencahayaan, pengaturan kamera) masih belum pasti. Keterbatasan ini menyoroti perlunya penelitian di masa depan yang membahas faktor-faktor ini dengan menggabungkan set data yang lebih beragam dan mengoptimalkan *model* untuk

efisiensi tanpa mengorbankan kinerja. Implikasi dari keterbatasan ini menunjukkan bahwa meskipun hasilnya menjanjikan, namun perlu berhati-hati saat menggeneralisasi temuan ke konteks yang lebih luas. Penelitian di masa depan harus fokus pada pengembangan *dataset* yang lebih komprehensif yang mencakup berbagai kondisi yang lebih luas, seperti lingkungan pencahayaan yang berbeda dan pengaturan kamera, untuk meningkatkan kemampuan beradaptasi *model*. Penelitian di masa depan di bidang ini juga harus mengeksplorasi integrasi CNN dengan teknik pemrosesan gambar lainnya, seperti yang digunakan dalam *Augmented Reality (AR)* atau *Virtual Reality (VR)*, untuk lebih meningkatkan kualitas gambar dan pengalaman pengguna dalam lingkungan yang imersif. Selain itu, penelitian tentang pengembangan arsitektur CNN yang lebih efisien, mungkin melalui pembelajaran *transfer* atau augmentasi data, dapat membuka jalan bagi adopsi CNN secara luas dalam aplikasi waktu nyata, termasuk perangkat seluler dan sistem pengawasan. Meskipun rekomendasi untuk penelitian lebih lanjut adalah mengeksplorasi arsitektur CNN yang lebih ringan untuk aplikasi waktu nyata dan mengintegrasikan *metadata* tambahan untuk meningkatkan akurasi-implikasi praktis dari temuan ini perlu diartikulasikan dengan lebih jelas. Memahami bagaimana kemajuan ini dapat diterapkan dalam dunia nyata akan sangat penting untuk pengembangan teknologi klasifikasi gambar di masa depan.

5. Daftar Pustaka

- Anaël, F., VrAIn, C., Ros, F., Dao, T., & Lucas, Y. (2024). Dataset for image classification with knowledge. *Data in Brief*. <https://doi.org/10.1016/j.dib.2024.110893>.
- Berezsky, O., Liashchynskyi, P., Pitsun, O., & Izonin, I. (2024). Synthesis of convolutional neural network architectures for biomedical image classification. *Biomedical Signal Processing and Control*, 95(PB), 106325. <https://doi.org/10.1016/j.bspc.2024.106325>.
- Browne, M., & Ghidary, S. S. (2003). Convolutional Neural Networks for image processing: An application in robot vision. In *Lecture Notes in*

- Computer Science* (Vol. 2903, pp. 641–652).
https://doi.org/10.1007/978-3-540-24581-0_55.
- Carreira, D., Rodrigues, N., Miragaia, R., Costa, P., Ribeiro, J., Gaspar, F., & Pereira, A. (2024). A branched convolutional neural network for RGB-D image classification of ceramic pieces. *Applied Soft Computing*, 165, 112088. <https://doi.org/10.1016/j.asoc.2024.112088>.
- Handa, N., Kaushik, Y., Sharma, N., Dixit, M., & Garg, M. (2021). Image classification using convolutional Neural Networks. In *Communications in Computer and Information Science*, 1393(6), 510–517. https://doi.org/10.1007/978-981-16-3660-8_48.
- Hossain, M. I., Jahan, S., Al Asif, M. R., Samsuddoha, M., & Ahmed, K. (2023). Detecting tomato leaf diseases by image processing through deep convolutional Neural Networks. *Smart Agricultural Technology*, 5(June), 100301. <https://doi.org/10.1016/j.atech.2023.100301>.
- Ignatov, A., Patel, J., & Timofte, R. (2020). Rendering natural camera bokeh effect with Deep Learning. In *IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 1676–1686). <https://doi.org/10.1109/CVPRW50498.2020.00217>.
- Kaya, Y., & Gürsoy, E. (2023). A novel multi-head CNN design to identify plant diseases using the fusion of RGB images. *Ecological Informatics*, 75. <https://doi.org/10.1016/j.ecoinf.2023.101998>.
- Kusniyati, H. (2024). Komparasi performa VGG19, ResNet50, DenseNet121 dan MobileNetV2 dalam mendeteksi gambar deepfake. *Jurnal Teknologi Informasi dan Komunikasi*, 9(2), 397–411.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870.
- <https://doi.org/10.1080/01431160600746456>.
- Naranjo-Torres, J., Mora, M., Hernández-García, R., Barrientos, R. J., Fredes, C., & Valenzuela, A. (2020). A review of convolutional neural network applied to fruit image processing. *Applied Sciences*, 10(10). <https://doi.org/10.3390/app10103443>.
- Nasrullah, A. H., & Annur, H. (2023). Implementasi metode convolutional neural network untuk identifikasi citra digital daun. *Jurnal Media Informatika Budidarma*, 7(2), 726. <https://doi.org/10.30865/mib.v7i2.5962>.
- Nurhadi, M., & Purnomo, J. (2022). Implementation of image classification using convolutional neural network (CNN) algorithm on vehicles images. *ASEAN Journal of Systems Engineering*, 6(1), 1–5. <https://doi.org/10.22146/ajse.v6i1.72411>.
- Reyes, D., & Sánchez, J. (2024). Performance of convolutional Neural Networks for the classification of brain tumors using magnetic resonance imaging. *Heliyon*, 10(3), e25468. <https://doi.org/10.1016/j.heliyon.2024.e25468>.
- Roncancio, R., El Gamal, A., & Gore, J. P. (2022). Turbulent flame image classification using convolutional Neural Networks. *Energy and AI*, 10(July), 100193. <https://doi.org/10.1016/j.egyAI.2022.100193>.
- Sarangi, P. K., Sharma, B., Rani, L., & Dutta, M. (2024). Satellite image classification using convolutional neural network. In *Advances in Aerial Sensing and Imaging* (pp. 333–354). <https://doi.org/10.1002/9781394175512.ch15>.
- Tatar, A., Haghighi, M., & Zeinijahromi, A. (2024). Experiments on image data augmentation techniques for geological rock type classification with convolutional Neural Networks. *Journal of Rock Mechanics and Geotechnical Engineering*. <https://doi.org/10.1016/j.jrmge.2024.02.015>.

- Wang, R., Li, W., Qin, R., & Wu, J. Z. (2017). Blur image classification based on Deep Learning. In *Proceedings of IEEE International Conference on Imaging Systems and Techniques (IST 2017)*, 1–6. <https://doi.org/10.1109/IST.2017.8261503>.
- Wilhelmi, M., & Rusiecki, A. (2024). Simple CNN as an alternative for large pretrained models for medical image classification – MedMNIST case study. *Procedia Computer Science*, 239, 1298–1303. <https://doi.org/10.1016/j.procs.2024.06.299>.
- Yan, J. (2024). Application of CNN in computer vision. *Applied and Computational Engineering*, 30, 104-110.
- Yang, F., Ma, Z., & Xie, M. (2021). Image classification with superpixels and feature fusion method. *Journal of Electronic Science and Technology*, 19(1), 100096.