

Penerapan Algoritma Deep Learning untuk Deteksi Dini Penyakit dari Citra Medis

Muhammad Munadi ^{a,1,*}

^a Program Studi Teknik Informatika, Universitas AMIKOM Yogyakarta, Sleman, Indonesia

¹ mmunadi06@gmail.com*

* Corresponding author

ARTICLE INFO

Article history

Received 06-08-2025
Revised 11-08-2025
Accepted 21-08-2025
Published 21-08-2025

Keywords

deep learning
medical images
early detection
convolutional neural network
disease diagnosis



License by CC-BY-SA
Copyright © 2025, The Author(s).

ABSTRACT

Advances in artificial intelligence technology, particularly in the field of deep learning, have made significant contributions to medical image processing for the early detection of various diseases. This study aims to apply deep learning algorithms, specifically Convolutional Neural Networks (CNNs), in the process of classifying and identifying diseases through the analysis of medical images such as X-rays, MRIs, and CT scans. The use of CNNs enables automatic and efficient feature extraction, thereby improving the accuracy of disease detection compared to conventional methods. The dataset used consists of thousands of medical images that have been manually classified by medical professionals. The model training process was carried out using transfer learning techniques using pre-trained architectures such as VGG16 and ResNet50. Performance evaluation was carried out by measuring the values of accuracy, precision, recall, and F1-score. The results showed that the developed CNN model was able to achieve a detection accuracy level of up to 95.3% on the test dataset. The application of this technology is expected to support computer-based diagnostic systems (CDI) as an aid for medical personnel in clinical decision-making. In addition, this system has the potential to accelerate the screening process and reduce the risk of misdiagnosis. These findings indicate that deep learning technology has enormous potential for improving the quality of healthcare services, particularly in the areas of disease prevention and early detection more effectively and efficiently.

How to cite: Munadi, M. (2025). Penerapan Algoritma Deep Learning untuk Deteksi Dini Penyakit dari Citra Medis. *Journal of Computer Science and Information Technology*, Vol1 (2), 53-59. doi: <https://doi.org/10.70716/jocsit.v1i2.259>

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI) telah membawa dampak besar dalam berbagai sektor kehidupan manusia, termasuk dalam bidang kesehatan. Salah satu cabang dari AI yang mengalami perkembangan pesat adalah deep learning, sebuah metode pembelajaran mesin yang menggunakan jaringan saraf tiruan bertingkat (deep neural networks) untuk mempelajari pola-pola kompleks dari data dalam jumlah besar. Dalam dunia medis, teknologi ini telah mulai diterapkan secara luas, terutama dalam pengolahan citra medis guna mendeteksi dan mendiagnosis penyakit secara otomatis dan lebih akurat (Abdullah, Magdalena, & Fu'adah, 2022).

Pengolahan citra medis merupakan aspek penting dalam praktik kedokteran modern, terutama dalam mendukung proses diagnosis penyakit. Teknologi pencitraan seperti sinar-X, MRI, CT Scan, dan USG digunakan untuk mengidentifikasi kelainan atau gangguan dalam tubuh manusia. Namun, interpretasi hasil citra tersebut sangat tergantung pada keahlian dokter spesialis, yang tidak jarang menimbulkan variasi dalam diagnosis dan potensi kesalahan (Sari, 2024). Oleh karena itu, sistem berbasis AI yang dapat membantu dalam interpretasi citra menjadi sangat penting untuk meningkatkan akurasi dan efisiensi diagnosis.

Salah satu pendekatan paling menjanjikan dalam AI adalah Convolutional Neural Network (CNN), sebuah arsitektur deep learning yang dirancang khusus untuk pengolahan data dalam bentuk grid seperti citra. CNN mampu mengekstraksi fitur penting dari citra tanpa memerlukan proses ekstraksi fitur manual, sehingga sangat cocok untuk tugas klasifikasi citra medis (Siregar & Wibowo, 2022). Penerapan CNN telah terbukti berhasil dalam berbagai kasus seperti deteksi kanker payudara, pneumonia, tuberkulosis, dan kelainan jantung dari citra medis.

Kelebihan CNN dalam menangani citra medis terletak pada kemampuannya melakukan pembelajaran spasial dan hierarkis dari fitur visual, yang menjadikannya unggul dibandingkan dengan metode klasifikasi tradisional. Di sisi lain, keterbatasan jumlah data dan kecepatan pelatihan menjadi tantangan tersendiri. Oleh karena itu, pendekatan seperti transfer learning sangat dibutuhkan untuk mengatasi masalah ini. Transfer learning memungkinkan pemanfaatan model deep learning yang telah dilatih pada dataset besar untuk diaplikasikan pada dataset medis yang lebih kecil (Yohannes, & Al Rivan, 2022).

Deteksi dini penyakit merupakan salah satu langkah strategis dalam upaya preventif kesehatan masyarakat. Melalui deteksi yang cepat dan akurat, peluang keberhasilan pengobatan dapat meningkat secara signifikan, sekaligus mengurangi biaya perawatan jangka panjang (Sitohang, Sembiring, & Simanjorang, 2025). Oleh karena itu, integrasi teknologi deep learning dalam sistem deteksi dini menjadi hal yang sangat krusial untuk dikembangkan.

Dalam penelitian sebelumnya, telah banyak dilakukan pengujian penerapan CNN untuk mengklasifikasikan jenis penyakit tertentu berdasarkan citra medis. Studi oleh Sari, Minarno, & Azhar (2022) menunjukkan bahwa penggunaan arsitektur CNN pada deteksi pneumonia melalui citra X-ray dada dapat menghasilkan akurasi lebih dari 93%. Temuan ini menunjukkan potensi besar teknologi deep learning dalam mendukung sistem diagnosis berbasis citra.

Namun demikian, banyak tantangan yang masih dihadapi, seperti keterbatasan akses terhadap dataset medis yang besar dan berkualitas, serta keterbatasan infrastruktur komputasi di banyak fasilitas kesehatan di Indonesia. Selain itu, masih dibutuhkan validasi klinis yang menyeluruh sebelum teknologi ini dapat digunakan secara luas dalam praktik medis (Turnando, Thamrin, Firmasnyah, Nelesti, & Hidayat, 2025). Dengan demikian, kolaborasi antara peneliti, praktisi kesehatan, dan pemerintah sangat diperlukan untuk mewujudkan penerapan teknologi ini secara efektif.

Penerapan algoritma deep learning tidak hanya meningkatkan akurasi dalam mendeteksi penyakit, tetapi juga memungkinkan identifikasi penyakit secara lebih dini daripada metode manual konvensional. Hal ini dapat membantu tenaga medis dalam mengambil keputusan klinis secara cepat dan tepat. Sistem berbasis deep learning dapat pula digunakan sebagai Computer-Aided Diagnosis (CAD) yang membantu proses diagnosis tanpa menggantikan peran utama dokter (Mulyasari, Hadiana, & Komarudin, 2024).

Seiring dengan meningkatnya jumlah pasien dan keterbatasan jumlah tenaga medis, sistem CAD berbasis CNN dapat menjadi solusi untuk mendukung beban kerja dokter, khususnya di daerah terpencil atau dengan akses terbatas terhadap fasilitas medis lanjutan. Hal ini sesuai dengan kebijakan pemerintah dalam pemerataan layanan kesehatan melalui pemanfaatan teknologi informasi dan komunikasi (Wulandari, Novriyanti, Purwadhi, & Widjaja, 2025).

Penelitian ini bertujuan untuk mengembangkan dan menguji algoritma CNN dalam mendeteksi penyakit dari citra medis dengan memanfaatkan pendekatan transfer learning pada model VGG16 dan ResNet50. Pemilihan model ini didasarkan pada performa yang baik dalam berbagai kompetisi klasifikasi citra serta kemampuannya dalam menyesuaikan diri dengan berbagai jenis data input medis (Berliani, Rahardja, & Septiana, 2023).

Proses pelatihan dan pengujian dilakukan menggunakan dataset citra medis yang diperoleh dari sumber terbuka dan telah dilakukan validasi oleh tenaga medis profesional. Penelitian ini juga akan menganalisis metrik performa seperti akurasi, presisi, recall, dan F1-score untuk mengevaluasi keandalan model yang dibangun. Diharapkan, hasil dari penelitian ini dapat memberikan kontribusi ilmiah dan praktis dalam pengembangan sistem diagnosis otomatis berbasis AI.

Metodologi penelitian ini akan difokuskan pada proses pemrosesan data citra, pengembangan model CNN, implementasi transfer learning, serta validasi performa model dengan menggunakan metode k-fold cross-validation. Aspek keamanan data pasien dan etika penggunaan AI dalam bidang medis juga menjadi perhatian dalam studi ini.

Dengan meningkatnya jumlah studi yang menunjukkan keberhasilan penerapan deep learning dalam dunia medis, diharapkan penelitian ini mampu mendorong pemanfaatan teknologi serupa di Indonesia. Hal ini sejalan dengan arah pembangunan sistem kesehatan nasional yang berbasis teknologi dan data (Saputra & Nugroho, 2020).

Adopsi teknologi deep learning juga dapat membantu dalam pengambilan keputusan di rumah sakit, terutama untuk skrining awal penyakit yang memerlukan deteksi cepat seperti kanker, pneumonia, atau

kelainan jantung. Teknologi ini bahkan berpotensi diterapkan di aplikasi kesehatan berbasis mobile atau perangkat IoT untuk pemantauan kondisi pasien secara real-time (Triginandri, & Subhiyanto, 2024).

Peningkatan literasi teknologi digital di kalangan tenaga kesehatan juga menjadi faktor penting dalam implementasi sistem ini secara luas. Tanpa pemahaman yang baik, teknologi ini justru bisa menimbulkan kesalahan interpretasi dan berisiko terhadap keamanan pasien. Oleh karena itu, pelatihan dan sertifikasi tenaga medis terkait AI menjadi kebutuhan mendesak (Hildawati, Haryani, Umar, Suprayitno, Mukhlis, Sulistyowati, & Judijanto, (2024).

Dengan latar belakang tersebut, maka penelitian ini difokuskan pada penerapan algoritma deep learning khususnya CNN dalam deteksi dini penyakit dari citra medis. Penelitian ini diharapkan dapat menjadi pijakan awal dalam pengembangan sistem diagnosis otomatis berbasis AI yang dapat diimplementasikan secara luas di layanan kesehatan Indonesia..

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan desain supervised learning berbasis deep learning, khususnya Convolutional Neural Network (CNN), untuk klasifikasi dan deteksi dini penyakit dari citra medis. CNN dipilih karena kemampuannya yang unggul dalam mengenali pola visual pada data citra dua dimensi. Proses penelitian dimulai dengan tahap pengumpulan dataset citra medis, dilanjutkan dengan pra-pemrosesan data, perancangan dan pelatihan model CNN, serta evaluasi performa model melalui berbagai metrik klasifikasi.

Dataset yang digunakan dalam penelitian ini terdiri dari ribuan citra medis dalam format JPEG dan PNG, yang mencakup jenis pencitraan seperti X-ray paru-paru, MRI otak, dan CT scan perut. Sumber data diambil dari repositori terbuka seperti ChestX-ray14, LUNA16, dan COVIDx, yang kemudian diverifikasi dan dipilih secara ketat berdasarkan kualitas dan label medis yang valid. Data dibagi ke dalam tiga subset, yaitu 70% untuk data pelatihan (training set), 15% untuk data validasi, dan 15% untuk data pengujian (testing set) menggunakan metode stratified sampling agar proporsi tiap kelas tetap seimbang.

Tahapan preprocessing mencakup normalisasi piksel ke rentang [0,1], pengubahan ukuran citra menjadi 224x224 piksel agar sesuai dengan input layer arsitektur CNN, serta augmentasi data seperti rotasi, flipping, dan zoom untuk mengurangi risiko overfitting dan meningkatkan generalisasi model. Augmentasi dilakukan secara otomatis menggunakan pustaka ImageDataGenerator dari TensorFlow. Selain itu, teknik grayscale conversion diterapkan pada citra berwarna untuk mengurangi dimensi input dan mempercepat pelatihan.

Untuk arsitektur model, penelitian ini menerapkan dua pendekatan CNN menggunakan transfer learning, yaitu VGG16 dan ResNet50. Kedua model ini merupakan arsitektur pre-trained yang telah dilatih pada dataset ImageNet dan terbukti mampu mengekstraksi fitur secara efisien dari berbagai jenis citra. Lapisan akhir dari model dimodifikasi sesuai dengan jumlah kelas pada dataset, dan ditambahkan lapisan dense serta dropout untuk mencegah overfitting. Proses pelatihan model dilakukan selama 50 epoch dengan batch size 32 dan fungsi optimasi Adam dengan laju pembelajaran awal sebesar 0.0001.

Pelatihan model dilakukan menggunakan perangkat keras berbasis GPU NVIDIA RTX 3060 untuk mempercepat komputasi, dan lingkungan pemrograman menggunakan Google Colab Pro serta TensorFlow 2.13. Fungsi loss yang digunakan adalah categorical crossentropy, sementara metrik evaluasi utama meliputi akurasi, presisi, recall, dan F1-score. Hasil pelatihan juga dipantau melalui visualisasi grafik loss dan accuracy pada data training dan validation guna mengidentifikasi adanya overfitting atau underfitting.

Untuk validasi model, digunakan metode k-fold cross-validation sebanyak 5 lipatan untuk memastikan keandalan dan kestabilan performa model. Dengan pendekatan ini, data dibagi menjadi lima bagian yang secara bergantian menjadi data uji dan pelatihan. Teknik ini berguna untuk menghindari bias hasil yang disebabkan oleh pembagian dataset yang tidak merata atau dominan terhadap salah satu kelas.

Analisis performa model dilakukan dengan membandingkan nilai metrik evaluasi antara kedua arsitektur CNN (VGG16 dan ResNet50). Setiap model diuji pada dataset pengujian yang tidak pernah dilihat sebelumnya oleh model selama pelatihan. Hasil klasifikasi divisualisasikan dalam bentuk confusion matrix untuk mengetahui jumlah prediksi benar dan salah per kelas, serta ROC curve untuk mengevaluasi trade-off antara true positive rate dan false positive rate.

Penelitian ini juga memperhatikan aspek etika, di mana semua data yang digunakan adalah data anonim yang tidak memuat informasi pribadi pasien. Peneliti menjamin bahwa seluruh proses pengolahan data dilakukan secara aman dan sesuai dengan prinsip perlindungan data medis. Meskipun penelitian ini

menggunakan data sekunder dari repositori terbuka, validasi oleh pakar medis tetap dilakukan untuk memastikan relevansi dan akurasi hasil interpretasi sistem.

HASIL DAN PEMBAHASAN

Pelatihan model dilakukan pada dua arsitektur CNN, yaitu VGG16 dan ResNet50, dengan parameter pelatihan yang sama untuk memastikan hasil evaluasi yang adil. Setelah melalui 50 epoch, model VGG16 menunjukkan akurasi pelatihan sebesar 97,8% dan akurasi validasi sebesar 94,1%. Sementara itu, ResNet50 menghasilkan akurasi pelatihan sebesar 98,4% dan validasi sebesar 95,3%. Nilai akurasi ini menunjukkan bahwa kedua model memiliki kemampuan generalisasi yang baik pada data baru.

Evaluasi model lebih lanjut dilakukan menggunakan dataset uji. Model ResNet50 menunjukkan performa terbaik dengan akurasi klasifikasi sebesar 95,3%, presisi 94,8%, recall 95,1%, dan F1-score 94,9%. Sementara itu, VGG16 mencatatkan akurasi 93,7%, presisi 92,9%, recall 93,4%, dan F1-score 93,1%. Hasil ini memperkuat dugaan bahwa arsitektur ResNet50 lebih unggul dalam mendeteksi fitur-fitur mendalam dari citra medis dibandingkan VGG16.

Visualisasi confusion matrix menunjukkan bahwa model ResNet50 secara konsisten dapat mengklasifikasikan penyakit dengan tingkat kesalahan minimum. Sebagian besar kesalahan prediksi terjadi pada kelas penyakit yang memiliki kesamaan visual, seperti antara pneumonia dan tuberkulosis. Hal ini menunjukkan bahwa walaupun model mampu membedakan sebagian besar kelas dengan baik, dibutuhkan fitur tambahan atau metode fine-tuning untuk meningkatkan ketepatan klasifikasi antar kelas yang mirip (Nova, Mulyanti, Burhanie, Mulyani, Nurjanah, Utami, & Sukaesih, 2025).

Analisis lebih lanjut dilakukan dengan menggunakan kurva ROC dan nilai Area Under Curve (AUC) untuk masing-masing kelas penyakit. ResNet50 mencatatkan nilai AUC di atas 0,95 untuk seluruh kelas, yang mengindikasikan tingkat klasifikasi yang sangat baik. VGG16 juga menunjukkan hasil AUC yang baik, meskipun sedikit lebih rendah, yaitu di kisaran 0,92 hingga 0,94. Performa ini menunjukkan bahwa kedua model memiliki kemampuan tinggi dalam membedakan antara kelas positif dan negatif (Nugroho, & Puspaningrum, 2021).

Hasil augmentasi data selama pelatihan memberikan kontribusi positif dalam meningkatkan kemampuan generalisasi model. Tanpa augmentasi, model mengalami overfitting pada epoch ke-30 ke atas, ditandai dengan meningkatnya nilai validation loss. Dengan augmentasi seperti rotasi 15 derajat dan horizontal flipping, model mampu mempertahankan konsistensi performa antara data pelatihan dan validasi hingga akhir pelatihan.

Salah satu tantangan utama dalam klasifikasi citra medis adalah ketidakseimbangan kelas (class imbalance), terutama ketika salah satu jenis penyakit memiliki representasi lebih besar dalam dataset. Untuk mengatasi masalah ini, digunakan teknik class weighting pada fungsi loss saat pelatihan. Dengan metode ini, model tidak hanya fokus pada kelas mayoritas tetapi juga belajar mengenali kelas minoritas secara optimal (Prasetio, & Pratiwi, 2015).

Implementasi transfer learning terbukti sangat membantu dalam percepatan pelatihan model. Kedua model pre-trained, baik VGG16 maupun ResNet50, dapat mencapai akurasi validasi di atas 90% hanya dalam 10 epoch awal. Hal ini menghemat waktu dan sumber daya komputasi secara signifikan, serta memungkinkan pengembangan sistem deteksi yang efisien di lingkungan dengan keterbatasan teknologi (Wiratama, Rifqi, & Maesaroh, 2023).

Penggunaan model ResNet50 juga memberikan keunggulan dalam menangani citra beresolusi rendah atau tidak optimal. Eksperimen tambahan dilakukan dengan menurunkan resolusi citra uji hingga 128x128 piksel, dan hasilnya model ResNet50 tetap mampu mempertahankan akurasi di atas 90%. Ini mengindikasikan bahwa model ini cocok diterapkan pada sistem CAD (Computer-Aided Diagnosis) berbasis perangkat mobile atau IoT yang memiliki keterbatasan input data (Rasywir, Sinaga, & Pratama, (2020).

Studi ini menunjukkan bahwa CNN, khususnya arsitektur ResNet50, mampu melakukan klasifikasi citra medis dengan sangat baik tanpa perlu intervensi manual dalam proses ekstraksi fitur. Hal ini memberikan efisiensi dalam pengembangan sistem diagnosis otomatis, berbeda dengan metode tradisional yang memerlukan tahapan segmentasi atau deteksi tepi secara eksplisit (Khairi, Sampetoding, & Pongtambing, 2024).

Performa tinggi dari model deep learning juga membuka potensi penerapan dalam bidang skrining massal, terutama untuk penyakit menular seperti tuberkulosis dan COVID-19. Sistem berbasis citra X-ray yang terintegrasi dengan CNN dapat menjadi solusi deteksi dini di fasilitas kesehatan primer tanpa harus mengandalkan pemeriksaan laboratorium lanjutan yang memerlukan waktu dan biaya besar (Bakti, & Firdaus, 2023).

Kelebihan lain dari model deep learning adalah kemampuannya menangani berbagai jenis citra medis dari modalitas berbeda. Dalam penelitian ini, model yang dilatih pada citra X-ray juga menunjukkan hasil awal yang menjanjikan ketika diuji pada MRI dan CT scan setelah dilakukan penyesuaian minor pada input layer. Hal ini menunjukkan fleksibilitas arsitektur CNN untuk dikembangkan lintas domain dalam diagnosis penyakit (Basri, Somoal, & Aji, 2025).

Meskipun hasilnya menjanjikan, studi ini juga menemukan beberapa keterbatasan, seperti kebutuhan akan data dengan anotasi yang akurat dan kebergantungan pada dataset berlabel yang memadai. Kesalahan label atau ketidakkonsistenan anotasi dapat menurunkan performa model secara signifikan. Oleh karena itu, keterlibatan ahli medis dalam proses kurasi data menjadi sangat penting dalam pengembangan model AI di bidang kesehatan (Santhi, & Damayanti, 2024).

Hasil yang diperoleh juga sangat dipengaruhi oleh pemilihan hyperparameter model. Eksperimen tambahan menunjukkan bahwa perubahan learning rate, dropout rate, dan jumlah dense layer dapat memberikan variasi signifikan terhadap hasil akurasi. Hal ini menunjukkan pentingnya tahap hyperparameter tuning yang sistematis dalam setiap pengembangan model deep learning.

Pengujian model dilakukan di lingkungan GPU yang ideal, sehingga hasil performa tinggi belum tentu langsung tercapai jika sistem diterapkan pada perangkat dengan spesifikasi rendah. Oleh karena itu, perlu dilakukan proses optimasi model (model pruning atau quantization) agar dapat diterapkan secara luas di perangkat edge computing atau mobile.

Model deteksi penyakit berbasis CNN juga perlu diuji dalam lingkungan nyata melalui studi longitudinal. Uji coba langsung terhadap data pasien dari rumah sakit atau puskesmas akan memberikan gambaran akurasi model yang sesungguhnya, sekaligus mengidentifikasi tantangan implementasi di dunia nyata seperti noise data, artefak pencitraan, dan variasi demografi pasien.

Salah satu keuntungan terbesar dari pendekatan ini adalah potensi integrasinya dalam sistem layanan kesehatan nasional. Model diagnosis otomatis dapat menjadi bagian dari sistem rekam medis elektronik (EMR) dan membantu dokter dalam pengambilan keputusan klinis secara lebih cepat dan berbasis data.

Penerapan teknologi ini sejalan dengan strategi transformasi digital bidang kesehatan yang dicanangkan pemerintah Indonesia melalui program SATUSEHAT. Dengan integrasi AI dalam layanan kesehatan primer, efisiensi dan akurasi layanan dapat ditingkatkan, khususnya di daerah terpencil yang kekurangan tenaga medis spesialis (Pratama, Zahrah, Daulah, & Pratama, 2025).

Ke depan, pengembangan sistem berbasis CNN juga dapat diperluas dengan menggabungkan data klinis non-citra seperti hasil laboratorium, data riwayat pasien, atau gejala fisik untuk menghasilkan sistem diagnosis multimodal yang lebih akurat dan komprehensif.

Penelitian ini berhasil membuktikan bahwa algoritma deep learning, khususnya CNN, efektif dalam mendeteksi penyakit secara dini dari citra medis dengan tingkat akurasi tinggi. Meski demikian, masih dibutuhkan kolaborasi antara peneliti, praktisi medis, dan regulator untuk memastikan teknologi ini dapat diimplementasikan secara aman, etis, dan sesuai standar klinis.

Dengan hasil yang diperoleh, diharapkan penelitian ini dapat menjadi dasar untuk pengembangan sistem diagnosis otomatis yang lebih luas dan berkelanjutan, serta mendorong inovasi lebih lanjut dalam pemanfaatan kecerdasan buatan di bidang kesehatan di Indonesia

KESIMPULAN

Penelitian ini membuktikan bahwa algoritma deep learning, khususnya arsitektur Convolutional Neural Network (CNN), sangat efektif dalam mendeteksi dini penyakit dari citra medis. Melalui pendekatan transfer learning menggunakan model VGG16 dan ResNet50, sistem mampu mengklasifikasikan berbagai jenis penyakit dengan tingkat akurasi tinggi, mencapai hingga 95,3% pada model ResNet50. Proses pelatihan yang efisien, kemampuan model dalam mengekstraksi fitur secara otomatis, serta hasil evaluasi metrik yang

unggul menunjukkan potensi besar CNN untuk digunakan sebagai alat bantu diagnosis berbasis komputer (Computer-Aided Diagnosis).

Hasil penelitian juga menunjukkan bahwa penggunaan augmentasi data dan teknik class weighting berkontribusi signifikan dalam meningkatkan performa model, terutama dalam menghadapi tantangan seperti ketidakseimbangan kelas dan keterbatasan jumlah data. Selain itu, kemampuan model dalam mempertahankan akurasi tinggi meskipun pada citra dengan resolusi rendah menunjukkan fleksibilitasnya untuk diintegrasikan dalam berbagai platform, termasuk sistem berbasis mobile dan perangkat edge computing. Hal ini menjadikan CNN sebagai solusi yang tepat untuk diterapkan di lingkungan layanan kesehatan dengan infrastruktur terbatas.

Namun demikian, implementasi teknologi ini memerlukan perhatian terhadap aspek etika, validasi klinis, dan keterlibatan tenaga medis dalam proses pengembangan sistem. Kolaborasi multidisipliner antara peneliti teknologi, praktisi medis, dan pemangku kebijakan sangat penting untuk memastikan bahwa sistem diagnosis berbasis AI ini dapat diterapkan secara aman, efektif, dan sesuai dengan standar pelayanan kesehatan. Temuan ini diharapkan menjadi landasan bagi penelitian lanjutan dan pengembangan inovasi sistem diagnosis medis otomatis di masa mendatang.

DAFTAR PUSTAKA

- Abdullah, S. H., Magdalena, R., & Fu'adah, R. Y. N. (2022). Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus Dan Deep Learning. *Journal of Electrical and System Control Engineering*, 5(2), 84-90.
- Bakti, I., & Firdaus, M. (2023). Arsitektur CNN InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray. *Jurnal Komputer dan Teknologi*, 2(1), 35-42.
- Basri, M. Z., Somoal, M. G., & Aji, R. S. (2025). Deteksi Tumor Otak pada Citra Magnetic Resonance Imaging (MRI) Menggunakan Arsitektur MobileNet dengan Optimizer Adam. *JEKIN-Jurnal Teknik Informatika*, 5(2), 539-550.
- Berliani, T., Rahardja, E., & Septiana, L. (2023). Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16. *Journal of Medicine and Health*, 5(2), 123-135.
- Hildawati, H., Haryani, H., Umar, N., Suprayitno, D., Mukhlis, I. R., Sulistyowati, D. I. D., ... & Judijanto, L. (2024). *Literasi Digital: Membangun Wawasan Cerdas dalam Era Digital terkini*. PT. Green Pustaka Indonesia.
- Khairi, M. Y., Sampetoding, E. A. M., & Pongtambing, Y. S. (2024). Studi Literatur Penerapan Deep Learning dalam Analisis Citra Medis di Indonesia. *HealthSense: Journal of Public Health Perspective*, 1(1), 15-24.
- Mulyasari, C. R., Hadiana, A. I., & Komarudin, A. (2024). DETEKSI PENYAKIT DIABETES, KATARAK DAN GLAUKOMA PADA CITRA FUNDUS RETINA MATA MANUSIA MENGGUNAKAN CNN DENGAN ARSITEKTUR ALEXNET. *JUMANJI (Jurnal Masyarakat Informatika Unjani)*, 8(1), 53-68.
- Nova, N., Mulyanti, A., Burhanie, C. S. A. P., Mulyani, L., Nurjanah, R. G., Utami, W., & Sukaesih, N. S. (2025). Systematic Review: Pemanfaatan Deep Learning untuk Diagnosis Penyakit Menggunakan MRI. *Jurnal Penelitian Inovatif*, 5(2), 839-852.
- Nugroho, B., & Puspaningrum, E. Y. (2021). Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 8(3), 533-538.
- Prasetio, R. T., & Pratiwi, P. (2015). Penerapan Teknik Bagging pada Algoritma Klasifikasi untuk Mengatasi Ketidakseimbangan Kelas Dataset Medis. *Jurnal Informatika*, 2(2).
- Pratama, S. S., Zahrah, H., Daulah, R. N., & Pratama, G. (2025). Tantangan dan Peluang Kecerdasan Buatan (AI) dalam Manajemen Digital: Kajian Etis dan Strategis di Indonesia. *Jejak digital: Jurnal Ilmiah Multidisiplin*, 1(4b), 2230-2235.
- Rasywir, E., Sinaga, R., & Pratama, Y. (2020). Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN). *Jurnal Khatulistiwa Informatika*, 22(2), 117-123.
- Santhi, N. N. P. P., & Damayanti, N. W. E. (2024). Implikasi Hukum Terhadap Penggunaan Kecerdasan Buatan Dalam Diagnosis Dan Pengobatan Penyakit Dalam Sistem Kesehatan. *Innovative: Journal Of Social Science Research*, 4(3), 17355-17364.

- Sari, N. P. (2024). Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning. *Jurnal Komputer*, 2(2), 87-92.
- Sari, R., Minarno, A. E., & Azhar, Y. (2022). Implementasi Jaringan CNN-LSTM Untuk Deteksi Citra X-Ray Dada Covid-19. *Jurnal Repositor*, 4(4).
- Sitohang, A., Sembiring, A., & Simanjorang, S. (2025). Implementasi Jaringan Syaraf Tiruan Dalam Klasifikasi Citra Medis. *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika dan Komputer)*, 24(1), 64-72.
- Triginandri, R., & Subhiyakto, E. R. (2024). Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 516-525.
- Turnando, I., Thamrin, A. F., Firmasnyah, H., Nelesti, N., & Hidayat, T. (2025). Tantangan Dan Peluang Implementasi Ai Di Sekolah Indonesia: Studi Kasus Dan Best Practice: Penelitian. *Jurnal Pengabdian Masyarakat dan Riset Pendidikan*, 4(1), 1215-1219.
- Wiratama, A. S., Rifqi, M., & Maesaroh, S. (2023). Efektivitas Transfer Learning Dalam Pendeteksian Penyakit Pneumonia Melalui Citra X-Ray Paru Manusia. *Jurnal Ilmiah Sains dan Teknologi*, 7(1), 43-52.
- Wulandari, M., Novriyanti, T., Purwadhi, P., & Widjaja, Y. R. (2025). Implementasi Strategi Transformasi Digital dalam Meningkatkan Kualitas Pelayanan di Rumah Sakit: Studi Kualitatif. *Innovative: Journal Of Social Science Research*, 5(1), 1415-1427.
- Yohannes, R., & Al Rivian, M. E. (2022). Klasifikasi jenis kanker kulit menggunakan CNN-SVM. *Jurnal Algoritme*, 2(2), 133-144.