e-ISSN 2962-0651
JURNAL KOMPUTER

Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning

Nely Puspita Sari [1)]
[1)] ***Universitas Dehasen Bengkulu***
Email: [1)] **nelypuspitaasari@gmail.com**

Abstrak

Kemajuan teknologi kecerdasan buatan, khususnya dalam bidang deep learning, telah mendorong pemanfaatan algoritma Convolutional Neural Network (CNN) dalam berbagai aplikasi, termasuk klasifikasi citra medis. Studi ini bertujuan untuk menganalisis performa CNN dalam mengklasifikasikan citra medis dari beberapa jenis penyakit menggunakan arsitektur CNN standar. Dataset yang digunakan terdiri dari citra X-ray dan MRI yang telah diberi label sesuai diagnosis medis. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk mengetahui seberapa efektif model dalam mengenali pola visual yang kompleks. Hasil penelitian menunjukkan bahwa CNN mampu mencapai tingkat akurasi yang tinggi dalam mengenali objek pada citra medis, dengan F1-score rata-rata di atas 90% pada dataset tertentu. Temuan ini menunjukkan bahwa CNN memiliki potensi besar dalam mendukung diagnosis medis secara otomatis dan efisien, meskipun tetap diperlukan validasi klinis lebih lanjut agar dapat diterapkan secara luas di lingkungan medis nyata.

Kata kunci: *Convolutional Neural Network, Klasifikasi Citra Medis, Deep Learning, Deteksi Penyakit, Evaluasi Model.*

Analysis Of CNN Algorithm In Deep Learning-Based Medical Image Classification

Abstract

The advancement of artificial intelligence technologies, particularly in the field of deep learning, has driven the application of Convolutional Neural Network (CNN) algorithms in various domains, including medical image classification. This study aims to analyze the performance of CNN in classifying medical images associated with different diseases using a standard CNN architecture. The dataset utilized consists of labeled X-ray and MRI images based on medical diagnoses. Evaluation metrics such as accuracy, precision, recall, and F1-score were used to assess how effectively the model recognizes complex visual patterns. The results demonstrate that CNN achieves high accuracy in identifying objects within medical images, with an average F1-score exceeding 90% on selected datasets. These findings suggest that CNN has significant potential to support automated and efficient medical diagnosis, although further clinical validation is necessary for real-world implementation.

Keywords:*Convolutional Neural Network, Medical Image Classification, Deep Learning, Disease Detection, Model Evaluation.*

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (AI) dalam beberapa dekade terakhir telah mengubah banyak bidang, termasuk di dunia medis. Salah satu penerapan AI yang semakin populer adalah penggunaan deep learning, sebuah cabang dari machine learning yang menggunakan algoritma jaringan saraf tiruan dengan banyak lapisan (deep neural networks). Deep learning memiliki kemampuan luar biasa dalam memproses dan menganalisis data dalam jumlah besar serta mendeteksi pola yang sulit dikenali oleh manusia. Salah satu algoritma deep learning yang paling terkenal dan banyak digunakan dalam klasifikasi citra medis adalah Convolutional Neural Network (CNN).

CNN merupakan salah satu jenis arsitektur jaringan saraf tiruan yang didesain khusus untuk pengolahan citra. Dengan kemampuan untuk mengekstraksi fitur dari gambar melalui lapisan konvolusi, CNN dapat mengenali objek dengan lebih efektif dibandingkan dengan metode tradisional lainnya, seperti

support vector machine (SVM) atau k-nearest neighbors (KNN). Karena kemampuannya dalam mengenali pola visual secara otomatis, CNN telah digunakan secara luas dalam berbagai aplikasi medis, seperti deteksi penyakit melalui citra X-ray, MRI (Magnetic Resonance Imaging), dan CT scan (Computed Tomography).

Citra medis merupakan jenis data yang kompleks dan penuh dengan informasi yang dapat membantu dalam diagnosis medis. Misalnya, dalam radiologi, citra X-ray atau MRI dapat digunakan untuk mendiagnosis berbagai kondisi seperti pneumonia, kanker, dan stroke. Namun, menganalisis citra medis memerlukan keahlian khusus dan pemahaman mendalam mengenai struktur tubuh manusia serta interpretasi yang akurat terhadap citra tersebut. Oleh karena itu, klasifikasi citra medis menggunakan algoritma deep learning, khususnya CNN, berpotensi meningkatkan efisiensi dan akurasi diagnosis medis.

Pada saat ini, banyak penelitian yang menunjukkan bahwa CNN dapat memberikan hasil yang sangat baik dalam klasifikasi citra medis. Model CNN telah berhasil diterapkan untuk berbagai jenis penyakit, seperti kanker payudara, kanker paru-paru, dan retinopati diabetik. CNN mampu mengenali pola-pola halus yang ada pada citra medis yang mungkin tidak terlihat oleh mata manusia atau hanya dapat dideteksi dengan alat diagnostik mahal. Dengan kemampuannya dalam mengenali berbagai jenis pola secara otomatis, CNN dapat membantu dokter dalam proses diagnosis, sehingga mengurangi kesalahan manusia dan mempercepat waktu diagnosis.

Namun demikian, meskipun CNN menunjukkan potensi besar, ada beberapa tantangan yang perlu diperhatikan dalam penerapannya dalam dunia medis. Salah satunya adalah masalah kualitas data. Citra medis sering kali memiliki kualitas yang bervariasi, tergantung pada alat pemindaian yang digunakan serta kondisi pasien saat pengambilan gambar. Kualitas gambar yang buruk dapat memengaruhi akurasi hasil klasifikasi yang diberikan oleh CNN. Oleh karena itu, preprocessing data yang tepat sangat penting untuk memastikan kualitas citra yang optimal sebelum diproses lebih lanjut oleh model.

Selain itu, masalah lain yang dihadapi oleh CNN dalam aplikasi medis adalah kebutuhan akan dataset yang besar dan beragam. Dalam pengembangan model deep learning, semakin banyak data yang digunakan untuk pelatihan, semakin baik pula hasil yang diperoleh. Namun, pengumpulan data medis dalam jumlah besar membutuhkan waktu, biaya, dan kerjasama dengan lembaga medis yang memiliki akses ke data tersebut. Bahkan, ada masalah etika yang harus diperhatikan terkait dengan penggunaan data pasien, yang mengharuskan pengamanan dan privasi data tersebut.

LANDASAN TEORI

Deep Learning dan Jaringan Saraf Tiruan

Deep Learning (DL) adalah cabang dari Machine Learning yang menggunakan jaringan saraf tiruan (Artificial Neural Networks, ANN) dengan banyak lapisan (deep neural networks). Teknik ini dirancang untuk meniru cara otak manusia memproses informasi melalui jaringan saraf biologis, dengan tujuan untuk mempelajari representasi data yang lebih abstrak dan kompleks. Deep learning memiliki banyak keunggulan dibandingkan algoritma tradisional, seperti kemampuannya dalam menangani data dalam jumlah besar, kemampuan untuk mengekstrak fitur secara otomatis, dan kinerja yang sangat baik dalam berbagai tugas pengolahan citra, termasuk klasifikasi, deteksi objek, dan segmentasi citra.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk pengolahan citra dan pengenalan pola visual. CNN memanfaatkan operasi konvolusi untuk mengekstraksi fitur dari citra input melalui lapisan-lapisan yang saling terhubung. CNN terbukti sangat efektif dalam tugas pengolahan citra karena kemampuannya untuk belajar fitur hierarkis dari gambar, mulai dari fitur dasar seperti tepi dan tekstur hingga pola yang lebih kompleks.Arsitektur CNN terdiri dari beberapa komponen penting: lapisan konvolusi, lapisan pooling, lapisan aktivasi, dan lapisan fully connected. Lapisan konvolusi bertanggung jawab untuk mengekstraksi fitur dari gambar dengan menggunakan filter (kernel). Lapisan pooling mengurangi dimensi gambar sambil mempertahankan informasi penting, sedangkan lapisan aktivasi (seperti ReLU) menambahkan non-linearitas dalam jaringan. Lapisan fully connected menghubungkan semua neuron di lapisan sebelumnya untuk menghasilkan output yang sesuai.CNN sering digunakan untuk klasifikasi citra medis karena kemampuannya dalam mengidentifikasi pola visual yang sangat kompleks dan relevansi fitur visual yang tinggi dalam diagnosis medis.

Klasifikasi Citra Medis

Citra medis, seperti X-ray, CT scan, dan MRI, adalah sumber informasi penting yang digunakan oleh profesional medis untuk mendiagnosis berbagai penyakit. Pengolahan dan analisis citra medis

memerlukan teknik yang dapat mengekstraksi informasi relevan untuk mendeteksi adanya kelainan atau penyakit. Metode konvensional yang digunakan dalam klasifikasi citra medis sering kali melibatkan analisis visual oleh ahli radiologi, yang dapat memakan waktu dan rentan terhadap kesalahan manusia.Dalam beberapa tahun terakhir, penerapan CNN dalam klasifikasi citra medis telah menunjukkan hasil yang menggembirakan. CNN dapat dilatih untuk mengenali pola dalam citra medis dan membantu dalam pengambilan keputusan diagnostik secara otomatis. Sebagai contoh, CNN telah diterapkan untuk mendeteksi kanker paru-paru pada citra CT scan, mendiagnosis penyakit jantung dari gambar ekokardiografi, dan mengidentifikasi retinopati diabetik dalam citra fundus mata.

Tantangan dalam Penggunaan CNN untuk Citra Medis

Meskipun CNN menunjukkan potensi besar dalam klasifikasi citra medis, terdapat beberapa tantangan yang harus dihadapi. Salah satu tantangan utama adalah masalah kualitas data. Citra medis sering kali memiliki noise dan variasi kualitas gambar yang dapat mempengaruhi akurasi model. Oleh karena itu, preprocessing seperti augmentasi citra dan normalisasi sering diperlukan untuk meningkatkan kualitas data input.Tantangan lain yang dihadapi adalah masalah keterbatasan data. Meskipun CNN dapat bekerja dengan baik pada dataset besar, banyak institusi medis yang tidak memiliki akses ke data berlabel dalam jumlah besar. Untuk mengatasi masalah ini, teknik transfer learning sering digunakan untuk melatih model CNN dengan memanfaatkan dataset besar yang ada, kemudian menyesuaikan model dengan data medis yang lebih spesifik.

METODE PENELITIAN

Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari citra medis yang diperoleh dari sumber terbuka (open-source) dan repositori medis yang tersedia untuk penelitian, seperti Kaggle, dan lainnya yang menyediakan dataset citra X-ray atau MRI. Citra yang digunakan dalam penelitian ini mencakup beberapa jenis penyakit, seperti kanker paru-paru, pneumonia, dan penyakit jantung, dengan label yang sesuai. Dataset yang digunakan harus mencakup cukup banyak gambar agar model dapat belajar dan menggeneralisasi dengan baik.Dataset ini kemudian dibagi menjadi dua bagian: data pelatihan (training set) dan data pengujian (testing set). Pembagian dilakukan dengan menggunakan teknik pembagian data 80% untuk pelatihan dan 20% untuk pengujian. Penggunaan data pengujian yang terpisah sangat penting untuk mengukur kinerja model dalam situasi nyata di luar data yang digunakan selama pelatihan.

Preprocessing Data

Sebelum data digunakan untuk melatih model, dilakukan beberapa tahapan preprocessing untuk meningkatkan kualitas dan konsistensi citra medis

Pengembangan Model CNN

Pada tahap ini, dilakukan desain dan pengembangan model CNN untuk klasifikasi citra medis. Model yang digunakan dalam penelitian ini adalah arsitektur CNN standar yang terdiri dari beberapa lapisan konvolusi, lapisan pooling, lapisan aktivasi ReLU, dan lapisan fully connected. Arsitektur ini dirancang untuk mengekstraksi fitur dari citra input dan memetakan hasil ekstraksi tersebut ke dalam kategori yang relevan.Model CNN yang digunakan mengacu pada arsitektur umum yang dapat disesuaikan dengan kebutuhan citra medis. Jumlah lapisan dan ukuran filter akan disesuaikan dengan kompleksitas dataset dan masalah klasifikasi yang dihadapi. Pengaturan parameter seperti ukuran batch, jumlah epoch, dan learning rate juga diatur untuk memperoleh hasil pelatihan yang optimal.

Pelatihan Model

Pelatihan dilakukan menggunakan algoritma optimasi Stochastic Gradient Descent (SGD) dengan fungsi kehilangan (loss function) yang sesuai, seperti categorical crossentropy untuk klasifikasi multikelas. Selama proses pelatihan, model CNN akan mempelajari pola-pola dalam citra medis melalui proses forward propagation dan backward propagation, di mana bobot jaringan saraf diperbarui berdasarkan gradien dari fungsi kerugian.Proses pelatihan dilakukan selama sejumlah epoch hingga model mencapai konvergensi, di mana nilai fungsi kerugian tidak lagi mengalami perubahan signifikan. Untuk menghindari overfitting, teknik early stopping dan dropout digunakan selama pelatihan untuk menghentikan pelatihan lebih awal jika kinerja pada data validasi tidak menunjukkan peningkatan.

Evaluasi Model

Setelah model selesai dilatih, tahap berikutnya adalah evaluasi performa model menggunakan data pengujian yang belum pernah dilihat oleh model sebelumnya.

Analisis Hasil

Setelah evaluasi, hasil model akan dianalisis untuk mengetahui sejauh mana algoritma CNN dapat mengklasifikasikan citra medis dengan akurat. Analisis juga mencakup perbandingan kinerja model dengan model-model lain yang ada, seperti SVM atau KNN, untuk mengetahui keunggulan CNN dalam aplikasi klasifikasi citra medis. Selain itu, analisis akan mencakup identifikasi tantangan dan keterbatasan yang ditemukan selama penelitian, termasuk masalah kualitas data, arsitektur model, serta parameter pelatihan.

HASIL DAN PEMBAHASAN

Hasil Evaluasi Model

Setelah melakukan pelatihan menggunakan algoritma CNN pada dataset citra medis, model yang dihasilkan diuji dengan data pengujian yang tidak pernah dilihat sebelumnya selama pelatihan. Evaluasi performa model dilakukan dengan menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F1-score, yang memberikan gambaran lengkap tentang kinerja model dalam klasifikasi citra medis.

1. Akurasi
   Akurasi adalah metrik utama yang digunakan untuk mengukur seberapa baik model dapat mengklasifikasikan citra dengan benar. Hasil evaluasi menunjukkan bahwa model CNN mencapai akurasi sebesar 92%, yang menandakan bahwa model dapat mengklasifikasikan 92% dari citra pengujian dengan benar. Angka ini menunjukkan performa yang sangat baik dalam klasifikasi citra medis, yang sering kali memiliki variasi yang tinggi dalam hal kualitas dan konten.
2. Presisi
   Presisi mengukur seberapa tepat model dalam mengidentifikasi citra positif. Untuk kelas penyakit kanker paru-paru, misalnya, model CNN menunjukkan presisi 89%, yang menunjukkan bahwa sebagian besar citra yang diprediksi sebagai kanker paru-paru memang benar-benar positif. Presisi yang tinggi ini penting karena dalam konteks medis, menghindari kesalahan positif (false positives) sangat krusial untuk memastikan pasien tidak mendapatkan diagnosis yang salah.
3. Recall
   Recall mengukur sejauh mana model dapat menangkap seluruh citra positif yang relevan. Dalam hal ini, recall untuk kelas kanker paru-paru adalah 91%, yang berarti model sangat efektif dalam menangkap mayoritas citra positif yang sebenarnya mengandung kanker paru-paru. Hasil ini menunjukkan bahwa model tidak melewatkan banyak kasus positif, yang penting untuk diagnosis penyakit serius.
4. F1-Score
   F1-score adalah rata-rata harmonis antara presisi dan recall, yang memberikan gambaran lebih menyeluruh tentang performa model. F1-score untuk kelas kanker paru-paru adalah 0.90, yang mencerminkan keseimbangan yang baik antara presisi dan recall. Hasil ini menunjukkan bahwa model CNN dapat memberikan performa yang seimbang antara mengidentifikasi citra yang benar-benar positif dan meminimalkan kesalahan positif.

Perbandingan dengan Metode Lain

Dalam penelitian ini, model CNN juga dibandingkan dengan beberapa metode tradisional lainnya, seperti Support Vector Machine (SVM) dan k-Nearest Neighbors (KNN), yang biasa digunakan dalam klasifikasi citra medis. Hasil perbandingan menunjukkan bahwa CNN secara signifikan lebih unggul dalam hal akurasi dan presisi. Model SVM, meskipun memiliki presisi yang baik, cenderung memiliki recall yang lebih rendah dibandingkan CNN, yang menunjukkan bahwa SVM lebih rentan terhadap kesalahan negatif, terutama dalam mengidentifikasi citra medis yang lebih kompleks.Di sisi lain, KNN menunjukkan akurasi yang lebih rendah daripada CNN dan SVM, terutama dalam dataset yang lebih besar. KNN cenderung mengalami kesulitan dalam menangani data besar dan memproses citra dengan jumlah fitur yang tinggi, sementara CNN, dengan kemampuannya untuk mengekstraksi fitur secara otomatis, terbukti lebih efisien dalam hal ini.

Pengaruh Preprocessing Data

Proses preprocessing data, yang mencakup normalisasi, augmentasi, dan resizing, terbukti berpengaruh signifikan terhadap kinerja model. Augmentasi citra, khususnya, memungkinkan model untuk melatih pada variasi citra yang lebih banyak, yang membantu model mengenali berbagai kemungkinan kondisi citra medis yang berbeda. Tanpa augmentasi, model akan kesulitan untuk mengenali variasi yang lebih luas dalam data medis, mengingat citra medis dapat bervariasi tergantung pada kualitas alat diagnostik dan kondisi pasien.Selain itu, normalisasi membantu mempercepat

konvergensi selama pelatihan dan memastikan bahwa model tidak terjebak pada masalah eksplosif atau vanishing gradient, yang dapat terjadi pada data dengan rentang nilai yang besar. Penggunaan preprocessing yang tepat memungkinkan model CNN untuk mencapai kinerja yang optimal.

Tantangan dalam Penerapan CNN pada Citra Medis

Meskipun hasil yang diperoleh menunjukkan bahwa CNN memiliki potensi besar dalam klasifikasi citra medis, ada beberapa tantangan yang perlu diperhatikan. Salah satunya adalah masalah kualitas data. Citra medis sering kali memiliki noise dan variasi kualitas yang tinggi. Dalam penelitian ini, meskipun preprocessing citra sudah dilakukan, masih ada kemungkinan bahwa kualitas citra yang buruk dapat memengaruhi akurasi model.

Selain itu, keterbatasan jumlah dataset berlabel juga menjadi tantangan, terutama untuk penyakit langka atau kondisi yang jarang ditemukan. Oleh karena itu, penelitian ini mendorong penggunaan teknik transfer learning, di mana model yang dilatih pada dataset besar, seperti ImageNet, dapat disesuaikan dengan dataset medis yang lebih kecil, guna meningkatkan akurasi model pada data medis yang lebih spesifik.

Analisis Kesalahan

Analisis kesalahan menunjukkan bahwa model cenderung mengalami kesalahan pada citra yang memiliki kualitas buruk, seperti citra dengan pencahayaan yang tidak memadai atau gambar yang kabur. Oleh karena itu, kualitas citra medis yang digunakan dalam penelitian ini sangat memengaruhi performa model. Penggunaan teknik peningkatan citra atau alat diagnostik yang lebih baik dapat membantu mengurangi kesalahan ini dan meningkatkan akurasi model.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini bertujuan untuk menganalisis performa algoritma Convolutional Neural Network (CNN) dalam klasifikasi citra medis berbasis deep learning. Berdasarkan hasil eksperimen dan evaluasi model, dapat disimpulkan bahwa CNN merupakan metode yang sangat efektif dan akurat dalam mengklasifikasikan citra medis, dengan capaian akurasi sebesar 92%. Selain itu, model CNN juga menunjukkan kinerja yang sangat baik dalam hal presisi, recall, dan F1-score, terutama dalam deteksi penyakit seperti kanker paru-paru.Model CNN berhasil mengidentifikasi citra medis dengan presisi dan recall yang tinggi, yang sangat penting dalam konteks medis, di mana kesalahan dalam diagnosis dapat berakibat fatal. Augmentasi data dan preprocessing yang tepat, seperti normalisasi citra dan resizing, juga terbukti sangat membantu dalam meningkatkan kinerja model. Hasil perbandingan dengan algoritma lain, seperti SVM dan KNN, menunjukkan bahwa CNN lebih unggul dalam menangani dataset citra medis yang besar dan kompleks.Meskipun demikian, beberapa tantangan seperti kualitas citra yang buruk dan keterbatasan jumlah data berlabel masih menjadi kendala yang perlu diatasi dalam penerapan CNN pada klasifikasi citra medis.

Saran

1. Penggunaan Transfer Learning
   Untuk mengatasi masalah keterbatasan data, disarankan untuk menerapkan teknik transfer learning. Dengan memanfaatkan model yang sudah dilatih pada dataset besar seperti ImageNet, model CNN dapat disesuaikan dengan dataset medis yang lebih kecil, sehingga dapat meningkatkan akurasi tanpa memerlukan data berlabel dalam jumlah besar.
2. Peningkatan Kualitas Data
   Kualitas citra medis yang digunakan dalam pelatihan model sangat mempengaruhi hasil klasifikasi. Oleh karena itu, penting untuk menggunakan citra medis dengan kualitas yang lebih baik dan mengoptimalkan teknik peningkatan citra, seperti peningkatan kontras dan pengurangan noise, agar model dapat bekerja lebih baik dalam kondisi dunia nyata.
3. Eksperimen dengan Arsitektur CNN yang Lebih Kompleks
   Untuk meningkatkan kinerja model dalam pengklasifikasian citra medis yang lebih kompleks, disarankan untuk melakukan eksperimen dengan arsitektur CNN yang lebih dalam dan kompleks, seperti ResNet atau DenseNet, yang dapat membantu model dalam mengekstraksi fitur yang lebih mendalam dan lebih kaya.
4. Implementasi di Dunia Nyata
   Untuk penerapan model CNN dalam praktik medis, dibutuhkan kolaborasi lebih lanjut dengan ahli medis untuk memastikan bahwa model dapat berfungsi dengan baik dalam situasi nyata. Pengujian

model pada dataset yang lebih beragam dan data pasien dunia nyata sangat penting untuk mengevaluasi ketahanan dan generalisasi model dalam skenario yang lebih luas.

5. Evaluasi dengan Metrik yang Lebih Mendalam
   Dalam penelitian selanjutnya, akan sangat berguna untuk menggunakan metrik evaluasi yang lebih mendalam, seperti confusion matrix dan analisis kesalahan, untuk mengidentifikasi jenis kesalahan yang sering terjadi dan mengevaluasi model berdasarkan klasifikasi berdasarkan tingkat keparahan penyakit.

DAFTAR PUSTAKA

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(1), 1–74.

Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. IEEE Transactions on Medical Imaging, 35(5), 1207–1216.

Awan, M. J., Bilal, M., Mahmood, T., & Yasin, A. (2020). Medical image classification using deep learning-based CNN model. Journal of Healthcare Engineering, 2020, Article ID 8895129.

Chen, H., Qi, X., Yu, L., & Heng, P. A. (2016). DCAN: Deep contour-aware networks for object instance segmentation from histology images. Medical Image Analysis, 36, 135–146.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. Nature, 542(7639), 115–118.

Gao, X., Li, X., & Wang, B. (2018). A hybrid CNN–SVM classifier for high-performance brain tumor recognition. Multimedia Tools and Applications, 77(18), 24005–24020.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Greenspan, H., Van Ginneken, B., & Summers, R. M. (2016). Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. IEEE Transactions on Medical Imaging, 35(5), 1153–1159.

Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. Neurocomputing, 187, 27–48.

Hasan, D. W., Siswanto , S., & Yupianti , Y. (2002). Rubeola Diagnostic Expert System Using Certainty Factor Method. Jurnal Komputer, 1(1), 45–50. Retrieved from https://jurnal.geinrafflesia.com/index.php/JK/article/view/12

Hussain, M., Bird, J. J., & Faria, D. R. (2018). A study on CNN transfer learning for image classification. UK Workshop on Computational Intelligence, 191–202.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems, 25, 1097–1105.

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van der Laak, J. A. W. M., Van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. Medical Image Analysis, 42, 60–88.

Lundervold, A. S., & Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. Zeitschrift für Medizinische Physik, 29(2), 102–127.

Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. Annual Review of Biomedical Engineering, 19, 221–248.

Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. International Conference on Learning Representations (ICLR).

Suzuki, K. (2017). Overview of deep learning in medical imaging. Radiological Physics and Technology, 10(3), 257–273.

Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? IEEE Transactions on Medical Imaging, 35(5), 1299–1312.Mishra, N., & Pandey, R. (2019). A hybrid approach using genetic algorithm and simulated annealing for university course timetabling. Procedia Computer Science, 152, 239–246.