

Implementasi Arsitektur *Visual Geometry Group 16* (VGG16) untuk Deteksi *Cardiomegaly* pada *Chest X-Ray*

Rahma Nur Azizah¹, Muhamat Maariful Huda¹, Vion Age Tricahyo¹, Amalia Agung Septarina²

¹Universitas Nahdlatul Ulama Blitar

²Universitas Islam Raden Rahmat Malang

E-mail: rahmaazizah26102001@gmail.com, hudha.maariful@gmail.com, vionage@gmail.com.

Abstract— Penelitian ini ditujukan untuk pengembangan metode deteksi *cardiomegaly* menggunakan foto toraks yang menghasilkan dua klasifikasi yakni kelas *cardiomegaly* dan *non cardiomegaly*. *Cardiomegaly* adalah pembengkakan jantung dengan kondisi jantung memiliki berat yang tidak normal daripada jantung pada umumnya. Deteksi dini *cardiomegaly* perlu dilakukan, karena hal ini merupakan faktor penting dalam penyakit jantung yang parah. Selain itu, pentingnya deteksi dini juga dapat mengurangi risiko komplikasi akibat *cardiomegaly*. Pemanfaatan teknologi kecerdasan buatan dalam sistem pendukung pakar medis dengan data medis memberikan kontribusi dalam bidang kedokteran. Oleh karena itu, teknik hasil analisis dari sistem medis menjadi faktor penting dalam pengembangan dan implementasi yang efektif. Analisa yang digunakan dalam penelitian ini melibatkan model *Convolutional Neural Network* arsitektur *Visual Geometry Group* (VGG16) dengan tahap preprocessing dan penggunaan layer augmentasi dalam menganalisis citra. Melalui implementasi VGG16, hasil penelitian ini mencapai tingkat akurasi 78% dan ROC AUC terdefinisi sebagai *good classification* dengan nilai sebesar 0,83. (*Abstract*)

Kata Kunci—jantung, *cardiomegaly*, *cnn*, *vgg16*, *chest x-ray* (*key words*)

I. PENDAHULUAN

Cardiomegaly merupakan kondisi medis yang mempengaruhi sistem kardiovaskular, khususnya yang terkait dengan pembesaran jantung. Kondisi abnormal jantung dengan kondisi jantung mengalami pertumbuhan tidak proporsional sebagai respons terhadap berbagai faktor patologis. Ketidakseimbangan struktural dan fungsional jantung berakibat pada peran utama jantung yaitu menurunnya kemampuan pendistribusian aliran darah secara efisien [1]. *Cardiomegaly* dapat mengakibatkan komplikasi serius serta beberapa risiko kesehatan seperti aritmia, gagal jantung, hipertensi sampai kematian pada penderita [2]. Pada tahun 2018, Riset Kesehatan Dasar mencatat 2 juta jiwa di Indonesia menderita penyakit jantung, angka ini bahkan terus meningkat setiap tahunnya [3]. Minimnya oksigen dalam aliran darah sebagai akibat dari penumpukan karbon monoksida juga menjadi salah satu faktor penyebab penyakit pada jantung [4]. Diagnosis *cardiomegaly* dapat dilakukan melalui berbagai teknik pencitraan seperti pencitraan resonansi magnetik, *echocardiography*, *chest x-ray* atau rontgen dada, *electrocardiography* dan lain-lain. Jika suatu citra terindikasi adanya peningkatan ketebalan dinding

ventrikel, maka hal ini dapat ditentukan sebagai kasus kelainan jantung [5].

Otomatisasi proses deteksi menggunakan model *Visual Geometry Group* (VGG16) ditujukan untuk mempercepat evaluasi citra yang memungkinkan petugas medis dalam memeriksa ratusan atau ribuan citra jantung secara efisien. Karena diagnosa *cardiomegaly* ini hanya memerlukan citra *x-ray*, biaya medis yang diperlukan menjadi sangat berkurang. Selain itu, sistem deteksi dengan implementasi VGG16 ini dapat berkontribusi pada interpretasi internal dan mempermudah penyampaian informasi jaringan syaraf tiruan kepada orang awam yang tidak memiliki keahlian dalam jaringan syaraf tiruan seperti ahli medis.

II. BAHAN DAN METODE

A. Penelitian terdahulu

Penelitian untuk mendeteksi *cardiomegaly* ini merujuk pada penelitian terdahulu dalam bidang kardiologi dan pemrosesan citra medis. Penelitian tersebut menggunakan metode yang berbeda-beda dalam mendeteksi *cardiomegaly*, beberapa metode seperti *ResNet*, *Hybrid Classic Quantum*, prevalensi risiko tinggi, dan lain-lain. Penelitian Yoo et al. [6] mendiagnosa *cardiomegaly* menggunakan CNN dengan arsitektur *ResNet* serta visual peta fitur yang dapat dijelaskan. Metode analisis tersebut memperoleh akurasi hampir sebesar 80% dengan 60–80 *epoch*.

Pada penelitian lain yang diteliti oleh Decoodt et al. [7] memperoleh nilai akurasi 87% serta ROC-AUC 0,93 dicapai untuk beberapa model *Classical-Quantum*. Metode bawaan yang digunakan *Classical-Quantum* ialah *Qiskit* dan *PennyLane* yang memungkinkan penggunaan sirkuit parameter kuantum dalam kerangka *Pytorch*. Selain itu, penelitian mengenai prevalensi *cardiomegaly* yang dilakukan oleh Damayanti [1] mendiagnosa 54% *chest x-ray* calon jemaah haji memiliki *cardiomegaly*. Penelitian terdahulu menunjukkan deteksi *cardiomegaly* dengan beberapa metode memiliki hasil yang baik, maka dari itu penelitian ini mencoba mengaplikasikan CNN arsitektur VGG16 dalam deteksi *cardiomegaly*.

B. *Cardiomegaly*

Cardiomegaly atau pembengkakan jantung merupakan sebuah gejala yang disebabkan oleh hipertrofi dan dilatasi otot jantung. Pembesaran dapat terjadi karena faktor fisiologi umur, pertumbuhan badan, jenis kelamin, tinggi dan berat badan. *Cardiomegaly* pada jantung mengacu ketika kondisi

diameter melintang gambaran jantung sama besar atau lebih besar dari 50% diameter transversal dada, atau disebut juga sebagai peningkatan *Cardiothoracic Ratio* (CTR) [1]. Pada beberapa penderita *cardiomegaly* tidak serta merta menimbulkan gejala yang jelas, kondisi ini dimulai dengan gejala ringan yang terjadi dalam jangka waktu bertahun-tahun. Biasanya, *cardiomegaly* baru menunjukkan gejala nyata ketika kemampuan jantung untuk memompa darah menurun secara signifikan. Beberapa gejala yang muncul pada penderita *cardiomegaly* adalah sesak napas, terutama saat melakukan aktivitas fisik yang berat, sensasi pusing, peningkatan berat badan, gangguan irama jantung (aritmia), pembengkakan pada tungkai (edema), dan mudah lelah [8].


C. X-Ray

Pemanfaatan *x-ray* mampu memeriksa fisik manusia tanpa melalui operasi bedah yang *invasive*. Hal ini menjadikan *x-ray* sebagai salah satu pengecekan citra medis yang umum dan ekonomis. *X-ray* memungkinkan diagnosis penyakit, kondisi, atau cedera dalam tubuh yang membantu petugas medis dalam merencanakan perawatan yang tepat dan menghemat biaya pasien [9]. Mesin *x-ray* atau radiologi konvensional bekerja dengan mengarahkan sumber cahaya gelombang elektromagnetik melalui fisik manusia dan selanjutnya mencapai pelat film yang berfungsi untuk menghasilkan gambaran tubuh manusia dalam bentuk foto rontgen. *X-ray* maupun sinar *rontgen* berbentuk radiasi elektromagnetik berupa panjang gelombang kisaran 10 *nanometer* hingga 100 *pikometer*, setara frekuensi 30 *petahertz* sampai 30 *exahertz* serta mempunyai energi kisaran 100 eV hingga 100 KeV. Meskipun *x-ray* biasa dipergunakan dalam dunia kesehatan untuk tujuan diagnosa citra medis dan kristalografi *x-ray*, rontgen ini termasuk ke dalam jenis radiasi ion yang berarti memiliki potensi merusak sel-sel jaringan biologis. Oleh karena itu *x-ray* harus dilakukan dengan hati-hati dan hanya digunakan ketika diperlukan, ini dilakukan untuk meminimalisir risiko potensial terhadap pasien dan tenaga kerja medis [10]. *Rontgen toraks* dapat menunjukkan tanda hipertensi vena atau edema pada paru-paru serta mampu mengindikasikan *cardiomegaly* yang memiliki ciri peningkatan diameter transversal dengan ukuran jantung melebihi 15,5 cm untuk laki-laki serta 14,5 cm pada wanita [8].

D. Convolutional Neural Network

Nama CNN/*Convolutional Neural Network* berasal dari operasi matematika yang diaplikasikan dalam algoritma ini, yakni konvolusi [11]. CNN merujuk pada *Multilayer Perception* (MLP) yang dikembangkan sebagai pengolah data dua dimensi yang banyak diaplikasikan pada data citra [12]. CNN adalah bagian bidang *deep learning* yang digunakan untuk mengklasifikasi sebuah objek dan mendeteksi gambar [13]. Arsitektur ini digunakan secara luas dalam menganalisis citra karena kemampuannya dalam mengidentifikasi pola dan karakteristik dalam data citra. Jenis jaringan syaraf tiruan CNN dirancang untuk memproses data dalam bentuk matriks. Struktur CNN dinilai cukup sederhana karena struktur ini mencakup lapisan *input*, beberapa lapisan *hidden* dan lapisan *output* [14]. Proses CNN dimulai dari input awal yang melibatkan berbagai tahapan untuk mengidentifikasi pola dan fitur dalam gambar. Tahapan CNN mencakup beberapa layer, layer

utama yakni *convolutional layer* atau lapisan konvolusi, *pooling layer*, serta *fully connected layer* [15]. CNN merepresentasikan 3D (tiga dimensi) yang meliputi lebar, tinggi, maupun kedalaman dari gambar yang diproses [14]. Beberapa model CNN yang telah dikembangkan untuk mengolah data citra yaitu ResNet (*Residual Network*), VGGNet (VGG16, VGG19), LeNet, ZfNet, AlexNet, serta GoogLeNet. Setiap model CNN memiliki keunggulan dan dapat disesuaikan dengan tugas spesifik atau kebutuhan komputasi yang berbeda [16]. Ilustrasi metode CNN tertera pada gambar 1.




Gambar 1. Metode CNN

Sumber: [researchgate.net/https://www.researchgate.net/publication/346444515_Face_Reconignition_using_Cascade_Classifier_haar_selection_OpenCv](https://www.researchgate.net/publication/346444515_Face_Reconignition_using_Cascade_Classifier_haar_selection_OpenCv)

E. Visual Geometry Group

Visual Geometry Group 16 atau VGGNet adalah struktur jaringan CNN yang dikembangkan di Universitas Oxford melalui makalah "*Very Deep Convolutional Networks for Large-scale Image recognition*". Pada saat itu VGGNet meraih posisi 1st runner-up dalam kontes ILSVRC untuk *Image Classification* serta meraih gelar pemenang dalam kategori *Image Localization*. Model ini mencapai tingkat akurasi sebesar 92,7% dan berada di peringkat 5 besar dalam pengujian akurasi dataset *imageNet*, yang menyertakan belasan juta gambar dengan sepuluh ribu kelas yang tidak sama [11]. VGGNet mempunyai jaringan parameter yang besar yakni 138 juta parameter [17]. Ilustrasi VGG16 tertera pada gambar 2.



Gambar2. Arsitektur VGG16


Sumber: [researchgate.net/publication/355049790_Detection_and_analysis_of_COVID_19_in_medical_images_using_deep_learning_techniques](https://www.researchgate.net/publication/355049790_Detection_and_analysis_of_COVID_19_in_medical_images_using_deep_learning_techniques)

Pada dasarnya, arsitektur ini terdiri dari 16 lapisan dengan 13 *convolutional layer* dan memiliki dua lapisan *fully connected* beserta *layer softmax* sebagai output [17]. VGGNet dibuat dengan menggantikan kernel berukuran besar pada model AlexNet, yaitu kernel 1x1, 5x5 serta sejumlah kernel 3x3 yang bergerak menggunakan 1 *stride*. Kernel tersebut berfungsi sebagai pengekstrak fitur-fitur yang lebih kompleks. Selanjutnya model ini mengaplikasikan *max pooling* 3x3 beserta 2 *stride*. Penggunaan filter 3x3 pada *layer convolution* dan *layer*

maxpooling dengan filter 2x2 diterapkan secara konsisten di seluruh struktur [18].

F. Metode Penelitian

Beberapa tahapan dilakukan secara seksama guna memastikan kelancaran penelitian yang dilakukan. Tahapan tersebut mencakup pengumpulan data citra, *preprocessing*, implementasi VGG16, pelatihan model, serta evaluasi model. Metode penelitian ini terangkum pada gambar 3.



Gambar 3. Metodologi riset

G. Pengumpulan data

Dataset penelitian ini didapat dan dikumpulkan melewati situs *open source kaggle repository*. Gambar 4 merupakan contoh dataset *chest x-ray* yang digunakan dalam penelitian.



Gambar 4. Chest x-ray cardiomegaly

Data *chest x-ray* tersebut merupakan dataset citra tahun 2017 dan memiliki keseluruhan data sebanyak 112.120 serta 2776 data citra merupakan pasien dengan *cardiomegaly*. Oleh karena itu, 13880 citra digunakan untuk pelatihan dan sisa data lainnya digunakan untuk proses pengujian. Penelitian ini menggunakan perbandingan sebesar 90:10 pada data *training testing* dengan jumlah masing-masing 9716 data *training*, 1666 data *testing* yang termasuk dalam kategori *cardiomegaly* dan *non-cardiomegaly*. Keseluruhan dataset tersebut terangkum pada tabel I.


TABEL I. DATASET CITRA

Dataset	Non cardiomegaly	Cardiomegaly	Jumlah data
Data training	7773	1943	9716
Data testing	1333	333	1666
Data validasi	1998	500	2498
Jumlah data	11104	2776	13880

H. Preprocessing


Preprocessing data bertujuan untuk meningkatkan kualitas citra dan menghasilkan *output* yang optimal. *Preprocessing* merupakan proses analisis data dalam

mengorganisir dan mempersiapkan dataset sebelum data dapat diaplikasikan pada tahap klasifikasi [15]. Selanjutnya data latih akan diaugmentasi melalui *ImageDataGenerator* dan menetapkan ukuran citra dengan *IMG_SIZE* menjadi (512,512). Kontrol augmentasi pada data dengan *ImageDataGenerator* menggunakan opsi yang berupa *flipping horizontal*, *flipping vertical*, rotasi, perubahan *brightness*, *shear*, dan *zoom*. Gambar 5 memvisualisasikan beberapa citra yang digunakan dalam pelatihan dan telah melalui augmentasi.



Gambar 5. Dataset citra

I. Implementasi VGG16

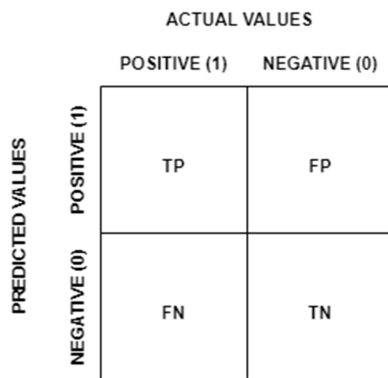


Gambar 6. Arsitektur VGG16

Sistem menggunakan model CNN dengan arsitektur VGG16, tahap ini dilakukan pada data train dengan dikompilasi menggunakan optimizer Adam, *loss function*, dan *metric accuracy*. Pada proses ini fungsi *fit generator* pada model menggunakan *train_gen* sebagai *data train* dan *valid_gen* sebagai data validasi. Beberapa poin yang dilakukan selama pelatihan yaitu mengganti ukuran pada batch menjadi 24 dengan menetapkan *train_gen.batch_size = 24* dan proses berlangsung selama 30 *epoch*. Pada setiap *epoch*, model mengalami proses pelatihan secara iteratif dengan mengoptimalkan perbaruan nilai parameter internal yang melibatkan keseluruhan *dataset*. Proses ini secara bertahap meningkatkan akurasi prediksi berdasarkan pola dan fitur penting dari data citra. Setelah tahap pelatihan, model menyimpan hasil pelatihan untuk digunakan pada proses pengujian.

J. Evaluasi Model

Evaluasi model dilakukan untuk menemukan kombinasi model yang optimal, faktor-faktor yang dipertimbangkan dalam proses evaluasi adalah akurasi, *confusion matrix* serta ROC AUC. *Confusion matrix* merupakan alat visual *machine learning* yang mana kolom dalam *confusion matrix* merepresentasikan hasil prediksi kelas, sementara baris merupakan representasi dari kelas sebenarnya [19].



Gambar 7. Skema Confusion Matriks

Confusion matrix menunjukkan perhitungan berbagai kemungkinan dalam masalah klasifikasi. Pada persamaan (1) akurasi mengukur rasio prediksi kebenaran seluruh data. Persamaan (2) mengenai presisi merupakan perbandingan *true positive* dan total prediksi positif. Persamaan (3) menunjukkan *recall* yang membandingkan prediksi positif yang benar dengan total kasus positif yang sebenarnya [19]. Sedangkan rumus (4) menyatakan *f1score* adalah perbandingan mean antara presisi serta *recall*[20].

$$accuracy = \frac{TP+TN}{TP+FN+TN+FP} \quad (1)$$

$$precision = \frac{TP}{TP+FP} \quad (2)$$

$$recall = \frac{TP}{TP+FN} \quad (3)$$

$$f1score = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (4)$$

Keterangan:

- TP : True Positive
- TN : True Negative
- FP : False Positive
- FN : False Negative

ROC-AUC (*Receiver Operating Characteristic-Area Under Curve*) merupakan representasi grafis dari kinerja sistem pengklasifikasian biner pada ambang batas diskriminasi yang berubah-ubah. Kurva ROC-AUC menunjukkan *tradeoff* antara *False Positive Rate* (FPR) berupa garis horizontal sedangkan *True Positive Rate* (TPR) berupa garis vertikal [21]. Nilai ROC-AUC terbatas antara 0 – 1, yang mana nilai 1 didefinisikan sebagai klasifikasi sempurna dan 0.5 terdefinisi sebagai klasifikasi yang setara dengan acak. Dapat disimpulkan bahwa hasil uji yang makin mendekati 1, maka kemampuan model memiliki kinerja baik pula dalam mengidentifikasi perbedaan antara kelas negatif atau positif. ROC-AUC memiliki 5 tingkatan yakni [22]:

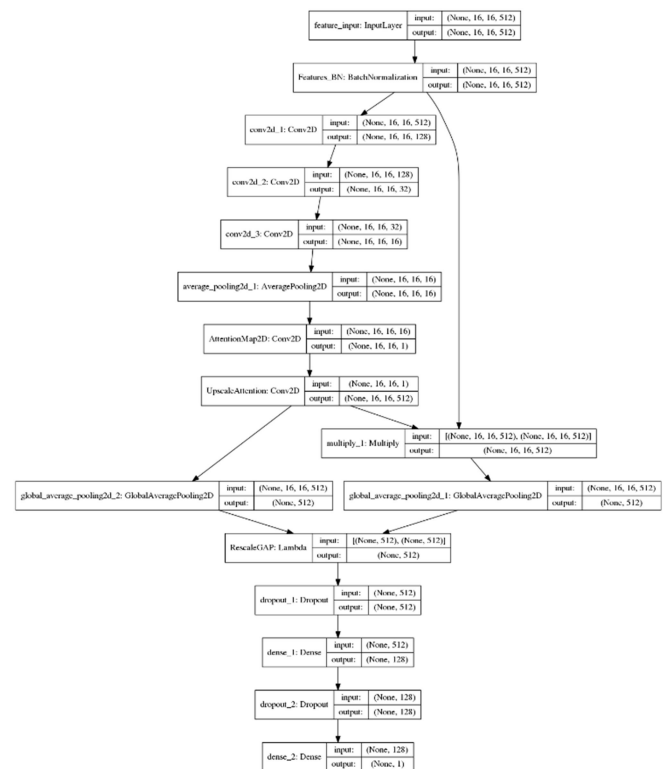
- i. 0.90 – 1.00 didefinisikan sebagai *excellent classification*
- ii. 0.80 – 0.90 didefinisikan sebagai *good classification*
- iii. 0.70 – 0.80 didefinisikan sebagai *fair classification*
- iv. 0.60 – 0.70 didefinisikan sebagai *poor classification*

v. 0.50 – 0.60 didefinisikan sebagai *failure*

III. HASIL DAN PEMBAHASAN


A. Pelatihan model

Arsitektur deteksi *cardiomegaly* dengan model VGG16 menerima input berupa citra pada layer *feature_input* dengan ukuran dimensi 16x16 dan memiliki 512 features (16,16,512). Beberapa layer konvolusi (*conv2d*) dengan jumlah filter yang berbeda digunakan untuk mengekstraksi fitur dari input, diikuti oleh normalisasi batch (*BatchNormalization*) untuk mempercepat konvergensi dan mengurangi *overfitting*. Pada *Layer Average Pooling* dilakukan operasi *average pooling* pada hasil konvolusi dan mereduksi dimensi spasial. Model ini juga memanfaatkan sebuah *Attention Mechanism* yang diimplementasikan melalui *AttentionMap2D* dan *UpscaleAttention*. Lapisan Arsitektur tertera pada gambar 7.



Gambar 8. Layer arsitektur

Layer AttentionMap sendiri digunakan untuk menghasilkan attention map dari fitur yang diekstraksi, kemudian UpscaleAttention digunakan untuk mengubah ukuran attention map tersebut sebelum diolah kembali dengan fitur input menggunakan *multiply*. Selanjutnya model melakukan operasi *Global Average Pooling* untuk menghitung rata-rata nilai fitur di seluruh spatial dimensi. RescaleGAP digunakan untuk menyesuaikan *Global Average Pooling* dari dua jalur berbeda dan *dropout* digunakan untuk mencegah *overfitting* selama pelatihan. Lapisan *dense (fully connected)* ditujukan untuk klasifikasi dan model menghasilkan *output* dengan satu neuron sebagai hasil klasifikasi biner. Parameter dan ukuran output tertera pada bagian *output shape* di setiap lapisan. Model dengan *Attention Mechanism* ini digunakan untuk menekankan pada area yang lebih relevan dalam citra. Hasil *Attention Map* tertera pada gambar 8.



Gambar 9. Attention Map

B. Hasil Evaluasi

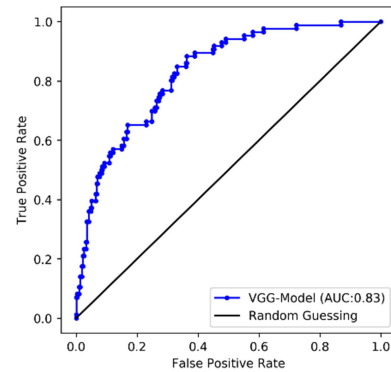
Pada tahap evaluasi diperoleh presisi sebagai hasil dari perbandingan keseluruhan data positif *non-cardiomegaly* dari keseluruhan data prediksi *non-cardiomegaly* sebesar 89%, recall sebagai perbandingan prediksi *non-cardiomegaly* dengan seluruh kasus positif *non-cardiomegaly* sebesar 84%, serta perbandingan rata-rata *recall* dan presisi sebesar 86% untuk hasil F1 score *non-cardiomegaly*. Sedangkan pada citra *cardiomegaly* didapatkan presisi, recall, serta F1 score masing-masing sebesar 50%, 60%, 54%. Nilai yang diperoleh dalam proses evaluasi tertera pada tabel II.

TABEL II. HASIL EVALUASI

Evaluasi model	Presisi (%)	Recall (%)	F1 Score (%)
Non cardiomegaly	89	84	86
Cardiomegaly	50	60	54

Hasil kurva ROC-AUC dalam penggunaan metode VGG16 sebagai deteksi *cardiomegaly* diwakili oleh kurva

sebaran berwarna biru dengan model acak yang divisualisasikan dengan garis diagonal. Kedua kurva tidak tumpang tindih dan memiliki ukuran keterpisahan ideal serta menunjukkan kurva ROC-AUC lebih dekat ke sudut kiri yang berarti model mampu membedakan kelas positif dan kelas negatif dengan baik. Penelitian ini memperoleh hasil ROC-AUC yang tertera pada gambar 10 dengan nilai mendekati 1 yakni sebesar 0.83 dan termasuk pada kategori *good classification*. Hasil tersebut divisualisasikan pada gambar 10.



Gambar 10. Hasil ROC AUC VGG16

IV. KESIMPULAN

Hasil uji penelitian menunjukkan model CNN arsitektur VGG16 mampu mendeteksi *cardiomegaly* pada chest x-ray nilai akurasi yang diperoleh sebesar 78,75%, serta presisi, *recall*, f1 score pada deteksi *cardiomegaly* masing-masing sebesar 50%, 60%, dan 54%. Sementara nilai ROC AUC mencapai 0,83 yang termasuk dalam kategori *good classification*. Metode VGG16 deteksi *cardiomegaly* yang disertai output *Attention map* dengan *Attention Mechanism* yang lebih menekankan pada area relevan ini mempermudah penyampaian informasi jaringan syaraf tiruan kepada orang awam. Sistem ini memiliki kinerja baik dan mampu digunakan dalam mempercepat diagnosis *cardiomegaly* sebagai deteksi dini serta mengurangi komplikasi yang terjadi akibat kondisi *cardiomegaly*. Pengembangan penelitian ini dapat dimaksimalkan dengan menggunakan akuisisi citra yang lebih detail terkait *cardiomegaly* dan memiliki kualitas yang terjamin kelayakannya untuk meningkatkan efisiensi dalam proses pengolahan data.

DAFTAR PUSTAKA

- [1] M. A. Damayanti, "Prevalensi Gambaran Kardiomegali Pada Foto Toraks Pasien Calon Jemaah Haji Dengan Risiko Tinggi Di Rumah Sakit Haji Jakarta Tahun 2013-2019," pp. 1-60, 2020.
- [2] S. Efendi, N. Sriyana, Nirawati, and Djuenaedi, "Hubungan Hipertensi dengan Pembesaran Jantung pada Pasien di Ruang Perawatan Relationship of Hypertension with Enlargement of the Heart in Patients in the Treatment Room," *An Idea Heal. J.*, vol. 2, no. 02, pp. 97-101, 2022.
- [3] H. MARDERINA, "Asuhan Keperawatan Congestive Heart Failure (CHF) Dengan Ketidakefektifan Pola Nafas di Ruang Melati 3 Rumah Sakit Umum Daerah Dokter Soekardjo Tasikmalaya," *Univ. Bhakti Kencana*, p. 7, 2020.
- [4] A. B. Laksono and A. Bachri, "Detektor Otomatis Gas Karbon Monoksida dan Gas Benzene pada Ruangan

- Tertutup Berbasis AT Mega 328,” *J. Tek. Elektro dan Komput. TRIAC*, vol. 10, no. 2, pp. 65–68, 2023, doi: 10.21107/triac.v10i2.20987.
- [5] A. R. PRATAMA, “Diagnosis and Management of Thalamic Cardiomyopathy,” *J. Kedokt. Syiah Kuala*, vol. 21, no. 3, pp. 335–339, 2021, doi: 10.24815/jks.v21i3.21063.
- [6] H. Yoo, S. Han, and K. Chung, “Diagnosis Support Model of Cardiomegaly Based on CNN Using ResNet and Explainable Feature Map,” *IEEE Access*, vol. 9, pp. 55802–55813, 2021, doi: 10.1109/ACCESS.2021.3068597.
- [7] P. Decoodt *et al.*, “Hybrid Classical–Quantum Transfer Learning for Cardiomegaly Detection in Chest X-rays,” *J. Imaging*, vol. 9, no. 7, 2023, doi: 10.3390/jimaging9070128.
- [8] A. Rasyid, S. Syahrul, and T. Tahir, “Faktor Yang Mempengaruhi Kejadian Readmisi 30 Hari Terhadap Pasien Congestive Heart Failure (Chf),” *J. Telenursing*, vol. 3, no. 1, pp. 238–251, 2021.
- [9] B. M. Sapata and D. Juniati, “Klasifikasi Penyakit Paru Berdasarkan Citra X-Ray Thorax Menggunakan Metode Fraktal Box Counting,” *MATHunesa*, vol. 7, no. 3, pp. 228–235, 2019.
- [10] Z. A. Matondang, “Penerapan Metode Contrast Limited Adaptive Histogram Equalization (Clahe) Pada Citra Digital Untuk Memperbaiki Gambar X-ray,” *Publ. Ilm. Teknol. Inf. Neumann*, vol. 3, no. 2, pp. 24–29, 2018.
- [11] A. M. Rizki and N. Marina, “Klasifikasi Kerusakan Bangunan Sekolah Menggunakan Metode Convolutional Neural Network Dengan Pre-Trained Model Vgg-16,” *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 197–206, 2019, doi: 10.35760/tr.2019.v24i3.2396.
- [12] R. Yohannes and M. E. Al Rivan, “Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM,” *J. Algoritma*, vol. 2, no. 2, pp. 133–144, 2022, doi: 10.35957/algoritma.v2i2.2363.
- [13] R. Ardiawan, T. Rakasiwi, G. R. Maulana, and N. Yudistira, “Aplikasi Deteksi Covid-19 dan Pneumonia melalui Citra X-ray Dadam menggunakan Residual Convolutional Neural Network,” *RINARxiv*, 2021.
- [14] S. A. Erni Albakia and R. A. Saputra, “Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16,” *J. Inform. Polinema*, vol. 9, no. 4, pp. 451–460, 2023, doi: 10.33795/jip.v9i4.1420.
- [15] F. N. Cahya, N. Hardi, D. Riana, and S. Hadiyanti, “Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN),” *Sistemasi*, vol. 10, no. 3, p. 618, 2021, doi: 10.32520/stmsi.v10i3.1248.
- [16] T. Berliani, E. Rahardja, and L. Septiana, “Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16,” *J. Med. Heal.*, vol. 5, no. 2, p. 123, 2023, [Online].
- [17] D. M. Wonohadidjojo, “Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasi Sel Darah Putih,” *Ultim. J. Tek. Inform.*, vol. 13, no. 1, pp. 51–57, 2021, doi: 10.31937/ti.v13i1.2040.
- [18] J. Pardede and H. Hardiansyah, “Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG16,” *MINDJ*, vol. 7, no. 1, pp. 21–36, 2022, doi: 10.26760/mindjournal.v7i1.21-36.
- [19] A. Ridhovan and A. Suharso, “Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jupi.v7i1.2410.
- [20] M. Harahap, Emmanuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, “Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 70–77, 2022, doi: 10.29207/resti.v6i1.3373.
- [21] M. R. Andryan, M. Fajri, and N. Sulistyowati, “Komparasi Kinerja Algoritma Xgboost dan Algoritma Support Vector Machine (Svm) Untuk Diagnosis Penyakit Kanker Payudara,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 1, p. 1, 2022, doi: 10.26798/jiko.v6i1.500.
- [22] A. Purwanto and H. W. Nugroho, “Analisa Perbandingan Kinerja Algoritma C4.5 dan Algoritma K-Nearest Neighbors Untuk Klasifikasi Penerima Beasiswa,” *J. Teknoinfo*, vol. 17, no. 1, p. 236, 2023, doi: 10.33365/jti.v17i1.2370.