

BINARY CLASSIFICATION COVID-19 MENGGUNAKAN MODEL CONVOLUTIONAL NEURAL NETWORK VGG16 PADA CITRA RADIOGRAFI THORAKS

Fifin Dewi Ratnasari^{*}, Nida Rihadatul Aisy Nahdah

Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang

**Corresponding author: fifin_fisika@mail.unnes.ac.id*

ABSTRAK

Infeksi Corona Virus Disease 2019 (COVID-19) adalah penyakit menular yang menjadi masalah kesehatan masyarakat secara global. Diagnosis melalui citra radiografi dapat mengidentifikasi kasus COVID-19 untuk memerangi virus tersebut. Tidak seperti jumlah kasus COVID-19 yang semakin meningkat, waktu peninjauan kasus sangatlah terbatas. Selain itu, beban kerja dan stress berlebihan pada tenaga medis khususnya radiologist dapat menyebabkan kesalahan analisis citra (missed findings). Oleh karena itu, auto-deteksi infeksi COVID-19 berbasis deep learning sangatlah diperlukan untuk menganalisis citra X-ray secara cepat dan efisien. Penelitian ini bertujuan untuk menganalisis kinerja model CNN dalam binary classification pada citra radiografi. Untuk menemukan model yang paling cocok untuk tugas klasifikasi, model CNN VGG16 pra-latih diuji coba dengan dua pendekatan: tanpa dan dengan transfer learning. Sejumlah 800 citra telah digunakan dan dibagi menjadi 3 bagian, 80% citra untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Berdasarkan hasil penelitian, model VGG16 dengan transfer learning memperoleh nilai akurasi tertinggi sebesar 93,7% untuk klasifikasi kasus COVID-19 dan normal. Informasi tersebut menunjukkan bahwa model yang diusulkan pada penelitian ini yaitu model transfer learning VGG16 sangat efektif dalam mengenali kasus kelas biner menggunakan citra X-ray thoraks. Dengan demikian, penerapan model tersebut dapat memberikan manfaat serta kontribusi dalam diagnosis secara cepat dan akurat, membantu mengurangi beban kerja radiologis, dan meningkatkan efisiensi penanganan pasien.

Kata kunci: COVID-19, citra X-ray, VGG16, transfer learning.

PENDAHULUAN

*Severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) atau Corona Virus Disease 2019 (COVID-19) merupakan infeksi saluran pernapasan akut yang ditularkan melalui droplet atau sekresi pernapasan seperti batuk dan bersin. Penderita yang terinfeksi COVID-19 memiliki kemiripan gejala dengan sakit flu seperti demam tinggi, nyeri dada, pusing kepala, batuk kering, sakit tenggorokan dan beberapa gejala penyakit pernapasan lainnya (Huang *et al.*, 2020). Awal penyebaran virus tersebut dimulai dari laporan beberapa rumah sakit di wilayah Huanan pada 31 Desember 2019. Beberapa pasien dilaporkan memiliki infeksi serta gejala yang sama kemudian didiagnosis tertular virus varian baru yaitu COVID-19. Tingginya aktivitas migrasi internasional menjadi penyebab meluasnya penularan ke seluruh dunia. World Health Organization (WHO) mengumumkan penyakit COVID-19 sebagai pandemi global pada 11 Maret 2020*

(Ahmad, 2020). Terhitung sejak 31 Desember 2019 hingga 3 Oktober 2022 terdapat 615.310.890 total kasus terkonfirmasi COVID-19 dengan 6.524.568 total angka kematian (WHO, 2022).

Pemerintah Indonesia mengumumkan kasus COVID-19 pertama pada 6 Maret 2020, dimana seorang wanita terdeteksi positif COVID-19 yang penularannya berasal dari warga negara Jepang (Tosepu *et al.*, 2020). Indonesia setidaknya telah melalui dua kali gelombang pandemi dimulai dari bulan Desember 2020 kemudian memasuki puncak gelombang pertama di tanggal 25 Januari 2021 dengan jumlah kasus per minggu mencapai 98.902 kasus. Pada puncak gelombang kedua di tanggal 21 Juni 2021, angka kasus mingguan meningkat hampir 5 kali lipat lebih tinggi dibandingkan puncak pertama dengan jumlah kasusnya mencapai 125.396 kasus (Haryono *et al.*, 2022).

Akibat tingginya penularan infeksi penyakit, diagnostik secara cepat serta akurat sangat diperlukan untuk pengidentifikasian dan penanganan pasien COVID-19 sesegera mungkin. Saat ini, terdapat berbagai macam tes pendeteksi diagnostik COVID-19 yang digunakan oleh khalayak umum, salah satunya adalah swab nasofaring dengan *real time-reverse transcriptase polymerase chain reaction* (rRT-PCR). Pemeriksaan rRT-PCR dianggap sebagai standar primer yang direkomendasikan dalam diagnostik COVID-19 (Aditia, 2021). Namun, rRT-PCR dinilai kurang efisien dikarenakan memerlukan waktu yang lama untuk mendapatkan hasil diagnosa penyakit sehingga kemungkinan dapat memperparah infeksi yang berkelanjutan (Stogiannos *et al.*, 2020). Sebuah studi oleh Gu *et al.* (2021) mengungkapkan bahwa waktu deteksi dari CT-Scan sekitar 2 hari lebih cepat daripada RT-PCR untuk memperoleh diagnosis COVID-19 pneumonia.

Citra medis sangat umum digunakan untuk memproyeksikan gambar anatomi serta fisiologis tubuh manusia sehingga dapat mejadi informasi klinis yang berguna (Rundo *et al.*, 2019). Belakangan ini, modalitas pencitraan thoraks seperti radiografi thoraks memerankan peran penting dalam pemeriksaan dini kasus dugaan COVID-19 (Aljondi *et al.*, 2020). Namun, *American College Radiology* (ACR) tidak merekomendasikan citra radiografi sebagai lini pertama dalam pemeriksaan diagnostik COVID-19 meskipun tingkat sensitivitasnya cukup tinggi. Hal tersebut disebabkan kurangnya akurasi dalam mendeteksi

COVID-19 dengan gambaran klinis yang lebih kompleks dan detail (Varadarajan *et al.*, 2021). Selain itu, pekerja medis khususnya ahli radiologi yang memiliki beban kerja berlebih sering kali mengalami kelelahan fisik dan mental (Cao *et al.*, 2022). Sebuah penelitian menyebutkan bahwa pekerja medis sebanyak 52 orang mengalami beban kerja berat, tingkat kelelahan yang tinggi serta stres kerja dengan tingkat presentase sebesar 78,8%, 67,3%, serta 82,7% (Tonapa *et al.*, 2022). Tidak seperti jumlah kasus COVID-19 yang semakin meningkat, waktu peninjauan kasus oleh ahli radiologi sangatlah terbatas. Oleh karena itu, proses tersebut memerlukan waktu yang lama serta dapat memicu kesalahan fatal yaitu *missed findings* (Zhou *et al.*, 2020).

Deep learning (DL) beroperasi dengan menganalisis sejumlah data atau citra berskala besar. Algoritma DL populer digunakan sebagai metode pilihan dalam analisis citra radiologi (Tang, 2020). Model DL yang lazim digunakan adalah *Convolutional Neural Network* (CNN) karena mencapai kesuksesan yang luar biasa dalam analisis citra medis hingga saat ini. Fungsi prediksi serta fitur identifikasi otomatis juga menjadikannya populer dalam diagnosis penyakit. Penerapan DL khususnya CNN baik dalam frekuensi penggunaan maupun inovasi pada *medical imaging* terus mengalami peningkatan (Dong *et al.*, 2021; Suganyadevi *et al.*, 2022). Arsitektur CNN fundamental seperti AlexNet, VGGNet, ResNet, GoogleNet bertujuan untuk klasifikasi citra.

VGG16, salah satu keluarga VGGNet, sangat luas digunakan dalam deteksi COVID-19 menggunakan citra radiografi. Penelitian (Rahaman *et al.*, 2020) oleh mengusulkan model *transfer learning* VGG16 dalam klasifikasi biner antara COVID-19 dan normal. Berdasarkan penelitian tersebut diperoleh hasil akurasi sebesar 88%. Studi oleh (Mohammadi *et al.*, 2020) menggunakan *pre-trained* model VGG16 yang dikombinasikan dengan *transfer learning* memperoleh hasil rata-rata akurasi sebesar 93,6%. (Ramadhan *et al.*, 2022) memodifikasi model VGG16 dengan mereduksi 138 juta parameter menjadi 40 juta parameter. Dari penelitian tersebut, didapatkan hasil berupa tingkat akurasi 99,7%.

Berlandaskan dari penelitian yang telah dikemukakan, model VGG16 terbukti memiliki kemampuan yang baik dalam klasifikasi citra berbagai penyakit

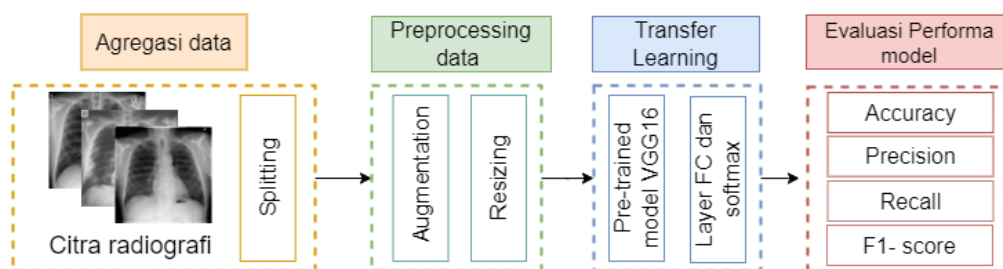
khususnya COVID-19. Oleh karena itu, penelitian ini menggunakan model arsitektur CNN VGG16 dalam *binary classification* COVID-19 dan normal pada citra radiografi. Tujuan penelitian ini adalah menganalisis hasil performa dari model arsitektur VGG16 dalam *binary classification* (COVID-19 dan normal) menggunakan citra radiografi.

METODE

A. Lingkungan Pengembang Model

Lingkungan pengembang model CNN dalam penelitian ini menggunakan platform *cloud computing* Google Colaboratory (Colab) yang berbasis pada *Jupyter Notebook* untuk proses pelatihan dan pengujian. *Jupyter Notebook* mengkonfigurasi python 2 dan 3 serta beberapa *library* yang diperlukan untuk visualisasi ML seperti TensorFlow, Keras, Matplotlib, NumPy dan scikit-learn sehingga tidak memerlukan instalasi secara manual untuk memulai program (Carneiro *et al.*, 2018). Colab, dengan dukungan dari GPU, dapat mempercepat proses *runtime* sehingga menunjang pembelajaran DL khususnya CNN (Praveen Gujjar *et al.*, 2021). Selain itu, seluruh dataset dan kode pemrograman tersimpan dalam *google drive* yang terintegrasi dengan Colab. Seluruh eksperimen pada penelitian ini dilakukan menggunakan perangkat keras laptop dengan spesifikasi *hardware* intel Celeron dengan RAM 4 GB.

B. Alur Penelitian




Gambar 1. Diagram alir alur penelitian.

Penelitian ini menelaah tentang klasifikasi biner antara citra medis paru-paru terinfeksi COVID-19 dan normal menggunakan model arsitektur CNN VGG16. Evaluasi performansi model arsitektur CNN didasarkan pada perhitungan akurasi,

precision, *recall*, dan *F1-score*. Alur penelitian yang telah tersusun disajikan dalam *flowchart* untuk memperjelas langkah kerja suatu proses penelitian sehingga mudah dipahami. Gambar 1. menunjukkan alur kerja dari awal hingga akhir terhadap model CNN yang diajukan. Berikut ini akan dijelaskan secara detail untuk setiap langkah yang tertera pada alur penelitian.

C. Agregasi Data

Penulis mengagregasikan dataset citra radiografi untuk klasifikasi biner atau 2-*class* (COVID-19 dan Normal). Adapun dataset COVID-19 yang disiapkan, bersumber dari *open source* repositori data. COVID-19 *Radiography Database* (Rahman *et al*, 2021) untuk dataset citra radiografi baik normal maupun COVID-19. Terdapat dua sampel citra radiografi dari dataset tersebut ditampilkan pada Gambar 2. untuk masing-masing kelas. Semua citra tersebut berformat *.png



Gambar 2. Sampel citra radiografi thoraks, COVID-19 (kiri), Normal (kanan).

yang selanjutnya akan melalui tahap pra-proses.

Sebanyak 800 citra radiografi dan 1200 citra CT-scan digunakan untuk proses *training*, *validation* dan *testing* yang terbagi menjadi kelas biner yaitu COVID-19 dan normal. Untuk mengkonstruksikan dataset yang seimbang, citra dipilah secara random menjadi tiga bagian, 80% citra untuk tahap *training*, 10% citra untuk *validation* dan 10% untuk *testing*. Distribusi dataset tersebut ditunjukkan pada Tabel 1.

Tabel 1. Distribusi dataset citra.

No	Modalitas	Kelas	<i>Training</i>	<i>Validation</i>	<i>Testing</i>	Jumlah citra
1	Radiografi	COVID-19	320	40	40	400
		Normal	320	40	40	400
Jumlah total citra						800

D. Pemrosesan Data

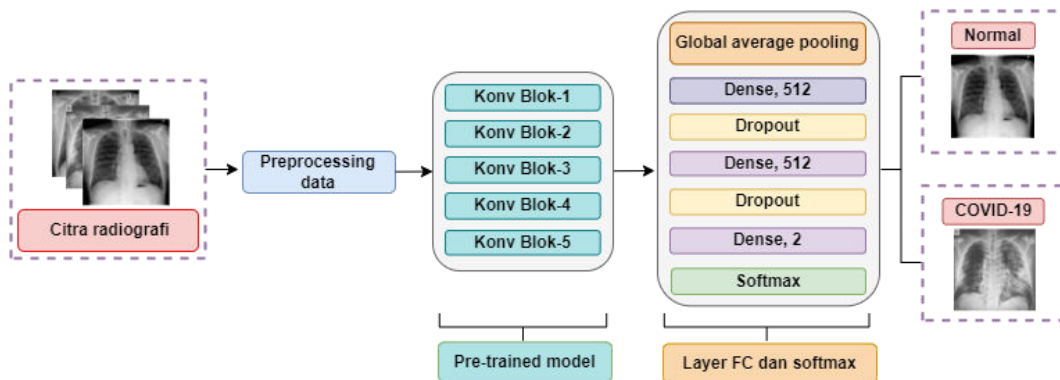
Citra yang dikumpulkan harus melalui tahap *resizing* karena berasal dari dataset dengan dimensi yang masih bervariasi. *Resizing* berfungsi untuk mereduksi atau menghilangkan efek gangguan serta menyeragamkan resolusi citra menjadi 224x224 pixels. Selain itu, teknik *data augmentation* juga diterapkan untuk meningkatkan performa pembelajaran dari model dengan membuat beragam variasi citra sampel data *training* (Shorten *et al.*, 2019). Berbagai teknik augmentasi telah diaplikasikan pada dataset *training* seperti ditunjukkan pada Tabel 2.

Tabel 2. Detail dari data augmentation yang diaplikasikan pada sample citra.

Teknik	Detail value	
<i>Re-scaling</i>	1/255	1/255
<i>Width shift range</i>	0,2	0,2
<i>Height shift range</i>	0,2	0,2
<i>Shear range</i>	0,2	0,2
<i>Zoom range</i>	0,2	0,2
<i>Horizontal flip</i>	<i>True</i>	<i>True</i>
<i>Vertical clip</i>	<i>True</i>	<i>True</i>

E. Transfer Learning

Salah satu masalah yang sering ditemui dalam DL adalah skala data *training* yang kurang mencukupi sehingga mempengaruhi performansi model CNN. *Transfer learning* (TL) menjadi solusi dari permasalahan keterbatasan dataset yang dimiliki dengan *running time* yang lebih efisien (Zhao, 2017). Pada penelitian ini, proses TL diterapkan pada arsitektur model VGG16, dimana model tersebut telah dilatih sebelumnya menggunakan dataset ImageNet. Terdapat dua tahapan TL, langkah pertama adalah mengimpor *pre-trained* model CNN yaitu VGG-16 melalui *library* Keras. Teknik *feature extraction* diaplikasikan pada model dengan cara membekukan basis konvolusi (layer ekstraksi fitur) dan memodifikasi layer klasifikasi. Dalam hal ini, lapisan tersebut akan digantikan dengan lapisan pengklasifikasi baru.



Gambar 3. Arsitektur model VGG16 *transfer learning* pada citra radiografi dan CT-Scan.

Gambar 3 menunjukkan arsitektur model VGG-16 dengan TL pada citra radiografi. Setelah layer ekstraksi fitur gambar, terdapat layer klasifikasi yang terdiri dari *global average pooling* (GAP) layer, yang mengambil nilai rata rata dari setiap vektor fitur. GAP membantu dalam mengurangi overfitting dan mengurangi jumlah parameter yang dapat dipelajari model serta memiliki beban komputasi yang rendah (Hsiao *et al.*, 2019; Lin *et al.*, 2013). Setelah proses GAP, dua layer *dense* dengan 512 neuron serta fungsi aktivasi ReLu. Pada setiap layer dense, terdapat layer *dropout* yang berfungsi untuk menghindari overfitting dengan tingkat dropout sebesar 0,5. Terakhir, ditambahkan fungsi aktivasi softmax sebagai pengklasifikasi. Selain itu, beberapa parameter juga diterapkan pada metode ini dengan rincian yang ditabulasikan pada Tabel 3.

Tabel 3. Detail parameter yang diterapkan pada model.

Parameter eksperimental	Citra radiografi
<i>Batch size</i>	32
<i>Epoch</i>	50
<i>Optimizer</i>	Adam
<i>Learning rate</i>	0,001
<i>Dropout</i>	0,5
<i>ReduceOnPlateu</i>	<i>Factor</i> = 0,3 <i>Patience</i> = 5

F. Evaluasi Performa

Evaluasi performa model CNN didasarkan pada *confusion matrix binary classification* dengan empat variabelnya yaitu TP, TN, FP, dan FN. Selanjutnya, dari parameter-parameter tersebut digunakan untuk mengevaluasi performa model dalam analisis medik dengan menghitung nilai *accuracy*, *precision*, dan *recall*, dan *F1-score*. Rumus – rumus berikut ini digunakan untuk menilai kinerja dari model CNN.

$$Accuracy : \frac{(TP+TN)}{(TP+FP+TN+FN)}$$

$$Precision : \frac{(TP)}{(TP+FN)}$$

$$Recall : \frac{(TN)}{(TN+FP)}$$

HASIL DAN PEMBAHASAN

A. Hasil Analisis

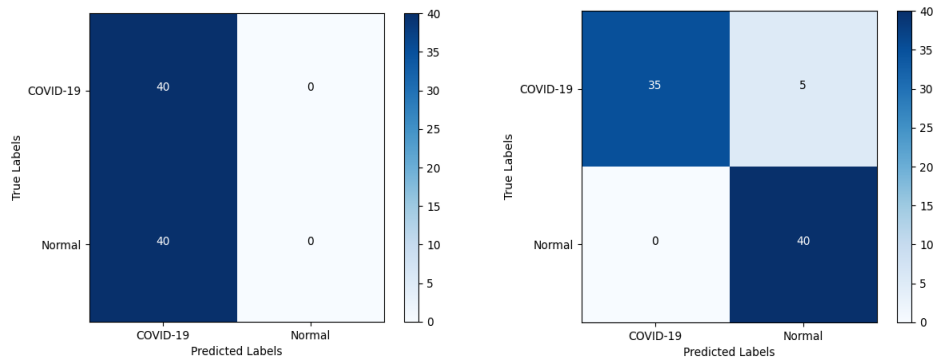
Sejumlah parameter seperti *epoch* 50, *batch size* 32, *learning rate* 0,001 serta *adam optimizer* diterapkan pada model VGG16 untuk menilai kinerja model pada citra radiografi dan CT-Scan. Terdapat dua perlakuan yang diterapkan pada model VGG16, model tanpa *transfer learning* (TL) serta model dengan TL. Dataset citra telah dibagi menjadi tiga bagian, 80% untuk pelatihan, 10% untuk validasi dan 10% untuk pengujian. Berdasarkan evaluasi performansi model yang telah diuji, dihasilkan beberapa metrik yaitu *precision*, *recall*, *F1-score*, dan *accuracy* dari masing masing modalitas citra.

Tabel 4. Metriks perfomansi model VGG16 menggunakan citra radiografi

Model CNN	Kelas	Precision	Recall	Accuracy (%)
VGG16 tanpa TL	COVID-19	0,50	1,00	50,00%
	Normal	1,00	0,00	
VGG16 dengan TL	COVID-19	1,00	0,88	93,75%
	Normal	0,89	1,00	


Tabel 4 menampilkan metrik kinerja dari model VGG16 pada citra radiografi untuk mengidentifikasi paru paru terindikasi COVID-19 dan normal pada dataset pengujian. Berdasarkan hasil pengujian, model VGG16 tanpa TL

hanya dapat mencapai rata-rata akurasi 50%. Namun, dengan TL, model mengalami peningkatan rata-rata akurasi yang signifikan hingga mencapai 93,75%. Dalam tabel tersebut nilai *precision* serta *recall* tertinggi didapat oleh model VGG16 dengan TL sebesar 1,00 dan 0,89 untuk kasus COVID-19 sementara 0,88 dan 1,00 untuk kasus normal.



Gambar 4. *Confusion matrix* model VGG16: (a) tanpa TL (b) dengan TL.

Gambar 4 menampilkan *confusion matrix* yang didapatkan dari dataset pengujian untuk menunjukkan performa model VGG16 tanpa TL dalam mengklasifikasi citra kelas biner COVID-19 dan normal. Baik pada Gambar 4 (a) maupun Gambar 4 (b), model tersebut tidak dapat mengidentifikasi dengan benar untuk kelas normal, sehingga semua sampel normal diprediksi sebagai kelas COVID-19. Hal ini menunjukkan bahwa model VGG16 tanpa TL tidak dapat membedakan antara kelas COVID-19 dan normal.



Gambar 5. Visualisasi kinerja model VGG16 dengan TL antara training terhadap validation dataset pada citra radiografi (a) accuracy (b) loss.

Gambar 5 (a) dan (b) merupakan visualisasi data dari tahap pelatihan dan validasi untuk memberikan gambaran sekilas mengenai kinerja model VGG16

dengan TL terhadap *epoch*. Berdasarkan kedua gambar tersebut, dapat dilihat bahwa kurva model pada citra radiografi mengalami peningkatan akurasi yang paling stabil sehingga memberikan nilai akurasi lebih dari 90%. Pada grafik akurasi data *training* dari *epoch* 0 hingga 8, meningkat dengan cepat hingga 88% kemudian dengan perlahan-lahan mencapai 93,75% setelah *epoch* 50. Demikian pula, akurasi validasi data memperoleh nilai sekitar 85% pada akhir *epoch*, sedangkan pada grafik *loss* dari data *training* dan *validation*, nilai *loss* menurun drastis hingga 0,3 pada *epoch* 8 kemudian mencapai kestabilan hingga *epoch* 50. Begitu juga dengan *loss* data validasi yang menurun tajam pada lima *epoch* pertama.

B. Pembahasan

Model VGG16 yang diusulkan pada penelitian ini, dilatih dan diuji menggunakan citra radiografi dengan sejumlah dataset yang terbatas. Oleh karena itu, teknik augmentasi diaplikasikan pada data citra untuk menambah variasi data sehingga dapat membantu model dalam mengenali pola atau fitur citra dengan lebih baik. Selain itu, proses klasifikasi citra paru paru COVID-19 dan normal ini ditinjau dengan dua pendekatan. Pada pendekatan pertama, sejumlah dataset melalui proses *training* dan *testing* menggunakan model basis konvolusi VGG-16 tanpa adanya modifikasi layer.

Tabel 5. Referensi artikel pembandingan terhadap model yang diusulkan pada penelitian ini.

Ref.	Model	Total dataset	Nilai akurasi
Rahaman <i>et al.</i> (2020)	VGG16	560 (COVID-19 260; Normal 300)	88,57%
Mohamadi <i>et al.</i> (2020)	VGG16	545(COVID-19 181; Normal 364)	93,6%
Ramadhan <i>et al.</i> (2022)	VGG16	2159 (COVID-19 576; Normal 1583)	99,76%
Model yang diusulkan	VGG16	800 (COVID-19 400; Normal 400)	93,70%

Pada pendekatan kedua, diterapkan teknik TL dengan menggunakan *pre-trained* model VGG16 serta layer FC yang dimodifikasi. Pada layer FC, layer *global average pooling* (GAP) ditambahkan untuk mengganti layer *flatten*. Berdasarkan Tabel 5, terbukti bahwa metode TL secara efektif dapat mengatasi masalah keterbatasan dataset agar menghasilkan nilai akurasi tinggi serta grafik yang stabil. Hal tersebut didukung oleh (Rahaman *et al.*, 2020), dimana teknik TL yang menggunakan *pre-trained* model VGG16 serta modifikasi layer FC berupa penambahan layer *flatten*, mampu mencapai nilai akurasi melebihi 50% dan mendekati 90%.

Tabel 5 menunjukkan perbandingan antara model yang diusulkan dalam penelitian ini dengan beberapa referensi studi lainnya. Model CNN yang diusulkan oleh (Rahaman *et al.*, 2020) menggunakan layer *flatten* pada layer FC. Jika dibandingkan dengan model tersebut, model VGG-16 dengan modifikasi berupa penambahan layer GAP memperoleh nilai akurasi sekitar 50% lebih tinggi. Model VGG16 yang diusulkan oleh studi yang dilakukan ((Mohammadi *et al.*, 2020)) memperoleh nilai akurasi yang mendekati hasil akurasi pada model penelitian dengan selisih sebesar 10%. Berbeda dengan total citra yang digunakan di penelitian ini, (Ramadhan *et al.*, 2022) mengumpulkan 2159 citra radiografi untuk dilatih dan diuji. Selain itu, studi tersebut juga mereduksi jumlah parameter VGG16 menjadi 40 million dengan hanya mengaplikasikan empat blok saja sehingga akurasinya mencapai 99,76%. Namun, klasifikasi yang menggunakan banyaknya sampel citra akan meningkatkan beban komputasi sehingga dapat memperlambat kinerja dari perangkat keras yang digunakan.

SIMPULAN

Arsitektur VGG16 *pre-trained* model *convolutional neural network* (CNN) telah diterapkan pada klasifikasi biner (COVID-19 dan normal) menggunakan citra radiografi. Dua pendekatan digunakan untuk mengevaluasi kinerja model CNN: dengan atau tanpa *transfer learning*. Berdasarkan temuan penelitian, dapat ditarik kesimpulan bahwa model dengan *transfer learning* dapat secara efektif menyelesaikan masalah keterbatasan dataset dalam penelitian ini. Model tersebut

mencapai kinerja klasifikasi yang tinggi untuk identifikasi COVID-19 dengan akurasi sebesar 93,70%. Model mampu menjadi diagnosis klinis yang dapat membantu tenaga medis di departemen radiologi. Keterbatasan penelitian kami adalah kemampuan perangkat keras yang kurang memadai untuk menjalankan program dengan jumlah dataset yang besar. Di masa mendatang, pembaruan komponen *hardware* dapat meningkatkan performa saat mengolah dataset serta parameter yang lebih besar.

DAFTAR PUSTAKA

- Aditia, A. (2021). COVID-19, Epidemiologi, Virologi, Penularan, Gejala Klinis, Diagnosa, Tatalaksana, Faktor Risiko dan Pencegahan. *Jurnal Penelitian Perawat Profesional*, 3(4), 653–660.
- Ahmad, S. (2020). A Review of COVID-19 (Coronavirus Disease-2019) Diagnosis, Treatments and Prevention. *Eurasian Journal of Medicine and Oncology*. <https://doi.org/10.14744/ejmo.2020.90853>.
- Aljondi, R., & Alghamdi, S. (2020). Diagnostic Value of Imaging Modalities for COVID-19: Scoping review. *Journal of Medical Internet Research*, 22(8). <https://doi.org/10.2196/19673>.
- Cao, D. J., Hurrell, C., & Patlas, M. N. (2022). Current Status of Burnout in Canadian Radiology. In *Canadian Association of Radiologists Journal*. SAGE Publications Inc. <https://doi.org/10.1177/08465371221117282>.
- Carneiro, T., Da Nobrega, R. V. M., Nepomuceno, T., Bian, G. Bin, De Albuquerque, V. H. C., & Filho, P. P. R. (2018). Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications. *IEEE Access*, 6, 61677–61685. <https://doi.org/10.1109/ACCESS.2018.2874767>.
- Dong, S., Wang, P., & Abbas, K. (2021). A Survey on Deep Learning and Its Applications. In *Computer Science Review* (Vol. 40). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.cosrev.2021.100379>.
- Gu, J., Yang, L., Li, T., Liu, Y., Zhang, J., Ning, K., & Su, D. (n.d.). *Temporal Relationship Between Serial RT-PCR Results and Serial Chest CT Imaging, and Serial CT Changes in Coronavirus 2019 (COVID-19) Pneumonia: A Descriptive Study Of 155 Cases in China Hospital Information System NHCPRC National Health Commission Of The People's Republic Of China*. <https://doi.org/10.1007/s00330-020-07268-9/Published>.
- Haryono, E., & Yunia Harsari, A. (2022). Taming Two Waves of the Covid-19 Pandemic: The Case of Indonesia. *KnE Social Sciences*. <https://doi.org/10.18502/kss.v7i4.10514>.

- Hsiao, T. Y., Chang, Y. C., Chou, H. H., & Chiu, C. Te. (2019). Filter-Based Deep-Compression with Global Average Pooling for Convolutional Networks. *Journal of Systems Architecture*, 95, 9–18. <https://doi.org/10.1016/j.sysarc.2019.02.008>.
- Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., Zhang, L., Fan, G., Xu, J., Gu, X., Cheng, Z., Yu, T., Xia, J., Wei, Y., Wu, W., Xie, X., Yin, W., Li, H., Liu, M., ... Cao, B. (2020). Clinical Features of Patients Infected with 2019 Novel Coronavirus in Wuhan, China. *The Lancet*, 395(10223), 497–506. [https://doi.org/10.1016/S0140-6736\(20\)30183-5](https://doi.org/10.1016/S0140-6736(20)30183-5).
- Lin, M., Chen, Q., & Yan, S. (2013). *Network In Network*. <http://arxiv.org/abs/1312.4400>.
- Mohammadi, R., Salehi, M., Ghaffari, H., Rohani, A. A., & Reiazi, R. (2020). Transfer Learning-Based Automatic Detection of Coronavirus Disease 2019 (COVID-19) from Chest X-ray Images. *Journal of Biomedical Physics and Engineering*, 10(5), 559–568. <https://doi.org/10.31661/jbpe.v0i0.2008-1153>.
- Praveen Gujjar, J., Prasanna Kumar, H. R., & Chiplunkar, N. N. (2021). Image Classification and Prediction Using Transfer Learning in Colab Notebook. *Global Transitions Proceedings*, 2(2), 382–385. <https://doi.org/10.1016/j.gltip.2021.08.068>.
- Rahaman, M. M., Li, C., Yao, Y., Kulwa, F., Rahman, M. A., Wang, Q., Qi, S., Kong, F., Zhu, X., & Zhao, X. (2020). Identification of COVID-19 Samples from Chest X-Ray Images Using Deep Learning: A Comparison of Transfer Learning Approaches. *Journal of X-Ray Science and Technology*, 28(5), 821–839. <https://doi.org/10.3233/XST-200715>.
- Rahman, T., Chowdhury, M.E.H., Khandakar, A. (2021). COVID-19 Radiography Database. <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>.
- Ramadhan, A. A., & Baykara, M. (2022). A Novel Approach to Detect COVID-19: Enhanced Deep Learning Models with Convolutional Neural Networks. *Applied Sciences (Switzerland)*, 12(18). <https://doi.org/10.3390/app12189325>.
- Rundo, L., Tangherloni, A., Nobile, M. S., Militello, C., Besozzi, D., Mauri, G., & Cazzaniga, P. (2019). MedGA: A Novel Evolutionary Method for Image Enhancement in Medical Imaging Systems. *Expert Systems with Applications*, 119, 387–399. <https://doi.org/10.1016/j.eswa.2018.11.013>.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>.
- Stogiannos, N., Fotopoulos, D., Woznitza, N., & Malamateniou, C. (2020). COVID-19 in the Radiology Department: What Radiographers Need to

- Know. In *Radiography* (Vol. 26, Issue 3, pp. 254–263). W.B. Saunders Ltd. <https://doi.org/10.1016/j.radi.2020.05.012>.
- Suganyadevi, S., Seethalakshmi, V., & Balasamy, K. (2022). A Review on Deep Learning in Medical Image Analysis. *International Journal of Multimedia Information Retrieval*, 11(1), 19–38. <https://doi.org/10.1007/s13735-021-00218-1>.
- Tang, X. (2020). *the role of artificial intelligence in medical imaging research*. <https://doi.org/https://doi.org/10.1259/bjro.20190031>.
- Tonapa, E. P., Kawatu, P. A. T., & Kapantow, N. H. (2022). Hubungan Antara Beban Kerja dan Kelelahan Kerja dengan Stres Kerja Tenaga Kesehatan pada Masa Pandemi Covid-19 di Puskesmas Bandar Khalipah Kabupaten Deli Serdang. In *Jurnal KESMAS* (Vol. 11, Issue 5).
- Tosepu, R., Effendy, D. S., Ode, L., & Imran, A. (2020). The First Confirmed Cases of Covid-19 in Indonesian Citizens. *Public Health of Indonesia*, 6(2), 70–71. <https://doi.org/https://doi.org/10.36685/phi.v6i2.337>.
- Varadarajan, V., Shabani, M., Ambale Venkatesh, B., & Lima, J. A. C. (2021). Role of Imaging in Diagnosis and Management of COVID-19: A Multiorgan Multimodality Imaging Review. *Frontiers in Medicine*, 8(November), 1–11. <https://doi.org/10.3389/fmed.2021.765975>.
- Zhao, W. (2017). Research on the Deep Learning of the Small Sample Data Based on Transfer Learning. *AIP Conference Proceedings*, 1864. <https://doi.org/10.1063/1.4992835>.
- Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., van Ginneken, B., Madabhushi, A., Prince, J. L., Rueckert, D., & Summers, R. M. (2020). *A Review of Deep Learning in Medical Imaging: Imaging Traits, Technology Trends, Case Studies with Progress Highlights, and Future Promises*. <https://doi.org/10.1109/JPROC.2021.3054390>.