

Artificial Intelligence

Klasifikasi Penyakit *Tuberculosis* Berdasarkan Citra Rontgen Thorax Menggunakan *Multi-Scale Convolutional Neural Network*

Bondan Surya Nusantara, Mutaqin Akbar

Fakultas Teknologi Informasi, Program Studi Informatika, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia



INFORMASI ARTIKEL

Diterima Redaksi: 25 Maret 2024
Revisi Akhir: 17 Mei 2024
Diterbitkan Online: 19 Mei 2024

KATA KUNCI

Tuberculosis; Convolutional Neural Network;
Multi-Scale; Thorax; X-Ray

KORESPONDENSI

Phone: +62 896-1325-8527
E-mail: 191110140@student.mercubuana-yogya.ac.id

A B S T R A K

Tuberculosis (TB) merupakan penyakit menular yang disebabkan oleh bakteri *mycobacterium tuberculosis*, patogen yang paling sukses menginfeksi paru-paru. Teknik diagnosis penyakit TB yang paling sering digunakan adalah melalui pemeriksaan rontgen thorax (paru-paru). Hasil rontgen dapat dilihat secara citra/visual oleh dokter untuk melihat apakah terdapat ciri dan pola adanya penyakit TB pada pasien. Pada penelitian ini befokus pada *Artificial Intelligence* (AI) untuk membantu dokter dan memberikan alternatif solusi yang efisien dalam mendiagnosa pasien, apakah pasien tersebut menderita TB atau tidak dengan lebih cepat. Penelitian ini dirancang menggunakan *Multi-Scale Convolutional Neural Network* (CNN) untuk mengklasifikasi penyakit *tuberculosis* berdasarkan citra rontgen thorax. Data yang digunakan berupa citra X-ray thorax yang digunakan sebagai input untuk proses *image processing*. Dataset yang dikumpulkan berjumlah 1400 data yang terdiri dari 2 kelas yaitu paru-paru normal dan paru-paru penderita *tuberculosis*. Model CNN terdiri dari 3 lapisan konvolusi yang berukuran 3x3, 3 lapisan penggabungan (*Maxpool*) berukuran 2x2 dan 1 lapisan *fully connected* yang menggunakan aktivasi *softmax*. Filter yang digunakan pada setiap lapisan konvolusi adalah 128. Penelitian ini menggunakan algoritma *Adam Optimizer*. Dataset dibagi menjadi 1120 data pada skenario 1 dan 978 data pada skenario 2 untuk training atau latih dan 280 data pada skenario 1 dan 422 data pada skenario 2 untuk testing atau uji. Dalam proses pelatihan, digunakan nilai *epoch* 20 diperoleh nilai akurasi sebesar 100% pada semua skenario. Pada tahap pengujian dihasilkan nilai akurasi sebesar 99,29% pada skenario 1 dan 97,67% pada skenario 2.

PENDAHULUAN

Pada tahun 2019, sekitar 9,96 juta orang terserang *tuberculosis* (TB) di seluruh dunia. Jumlah tertinggi dari kasus baru *tuberculosis* terjadi di *World Health Organization* (WHO) Region Asia Tenggara yang menyumbang sebanyak 44% dari kasus tersebut [1]. Di Indonesia sendiri, pada tahun 2020 jumlah kasus *tuberculosis* (TB) yang ditemukan sebanyak 351.936 kasus, Jumlah kasus tertinggi berada pada provinsi Jawa Barat, Jawa Timur, dan Jawa Tengah [2].

Tuberculosis (TB) merupakan penyakit menular yang disebabkan oleh bakteri *mycobacterium tuberculosis*, patogen yang paling sukses menginfeksi paru-paru [3]. Pemeriksaan diagnosis pada penyakit *tuberculosis* dapat dilakukan dengan melihat keluhan/gejala klinis, pemeriksaan biakan, pemeriksaan mikroskopis, radiologi dan tuberculin test. Deteksi awal terhadap *tuberculosis* (TB) dapat meningkatkan hasil pengobatan, mengurangi penularan, dan memungkinkan pengendalian resistensi obat dan TB yang resisten terhadap obat [4].

Penanganan penyakit TB dilakukan selama 6-9 bulan lamanya, dengan paling tidak 3 macam obat. Masyarakat masih sering menganggap batuk selama berbulan-bulan adalah batuk biasa, apabila diamati batuk dalam jangka waktu lama adalah salah satu gejala yang ditimbulkan oleh penyakit TB.

Teknik diagnosis penyakit TB yang paling sering digunakan adalah melalui pemeriksaan rontgen thorax (paru-paru). Hasil rontgen dapat dilihat secara citra/visual oleh dokter untuk melihat apakah terdapat ciri dan pola adanya penyakit TB pada pasien. Permasalahan yang sering terjadi adalah proses yang memerlukan waktu lama untuk pasien mendapatkan hasil, juga dokter dalam melakukan diagnosis apakah pasien tersebut terjangkit penyakit TB atau tidak karena memang cukup banyak antrian pemeriksaan pasien yang ingin melakukan skrining TB di Rumah Sakit karena adanya program dari pemerintah untuk melakukan skrining TB secara gratis untuk penderita dan keluarga penderita apakah mereka juga ada kemungkinan tertular penyakit TB.

Akhir-akhir ini dalam beberapa tahun terjadi lonjakan dalam penggunaan pembelajaran *Machine Learning* (ML) untuk berbagai tujuan, diantaranya penelitian hingga aplikasi praktis, termasuk *text mining*, *spam detection* (deteksi spam), rekomendasi video, kategorisasi gambar, dan pengambilan ide multimedia [5]. *Deep Learning* (DL) adalah salah satu pendekatan dari *Machine Learning* (ML) yang umum digunakan. DL adalah bagian dari ML dan *Artificial Intelligence* (AI). Oleh sebab itu DL dapat dilihat sebagai fungsi dari AI yang dapat meniru cara kerja otak manusia dalam memproses informasi [5].

Salah satu Teknik DL yang paling baik adalah *Convolutional Neural Network* (CNN) yang merupakan turunan dari jaringan saraf tiruan. CNN sangat berguna untuk keperluan pencitraan medis karena dapat mendeteksi tumor dan kelainan lainnya dengan lebih akurat pada X-Ray dan MRI. CNN dapat menganalisa citra/gambar dari komponen tubuh manusia seperti, paru-paru dan dapat mengidentifikasi potensi lokasi terjadinya tumor serta kelainan lainnya seperti patah tulang pada gambar rontgen berdasarkan pengolahan citra sebelumnya [6].

Berdasarkan latar belakang tersebut maka akan diterapkan klasifikasi penyakit *tuberculosis* berdasarkan citra rontgen thorax. Dengan menggunakan CNN, corak atau pola yang terdapat pada rontgen thorax (paru-paru) dapat dianalisa dan dijadikan acuan untuk mengidentifikasi kemungkinan pasien menderita penyakit *tuberculosis* atau tidak. Diharapkan dengan dibuatnya klasifikasi penyakit *tuberculosis* ini dapat membantu dokter untuk menjadi alternatif solusi yang efisien dalam mendiagnosa pasien, apakah pasien tersebut menderita TB atau tidak dengan lebih cepat.

TINJAUAN PUSTAKA

Beberapa studi literatur terkait dengan penelitian menggunakan tema serupa diantaranya [7], penelitian ini menghasilkan proses klasifikasi penyakit *tuberculosis* menggunakan CNN dengan arsitektur *MobileNet*. Penelitian ini melakukan klasifikasi penyakit pada paru-paru dengan menggunakan 3 kelas diantaranya normal, *tuberculosis* kanan, dan *tuberculosis* kanan kiri dengan hasil akurasi cukup tinggi yaitu 98,414% untuk akurasi latih, 94,358% untuk akurasi uji.

Berikutnya, pada penelitian [8] adalah sebagai betuk pengembangan dari penelitian sebelumnya yang berjudul “Arsitektur Convolutional Neural Network InceptionResNet-V2” dengan membuat pembuktian apakah dengan menambah parameter yang ada didalam *Machine Learning* dapat menunjukan bahwa mesin dapat memperoleh pengetahuan yang semakin meningkat, penelitian ini menghasilkan akurasi sebesar 87,88% untuk 1.059.106 parameter yang dipelajari, jika menggunakan parameter lebih banyak lagi yaitu 3.824.486, maka akurasi yang dihasilkan mendekati 100%.


Selanjutnya, pada penelitian [9] mengklasifikasikan jenis kanker paru apakah termasuk dalam kelas lung adenocarcinoma, benign lung tissue, lung *squamous cell carcinoma* berdasarkan citra histopatologi menggunakan CNN arsitektur *GoogLeNet* dan reduksi fitur *PCA*. Pada penelitian [10], dilakukan perbandingan kemampuan klasifikasi menggunakan *Transfer Learning ResNet-50* dan *VGG-16* dalam kasus klasifikasi citra X-ray paru-paru, hasil dari penelitian ini adalah *VGG-16* memiliki kemampuan klasifikasi yang lebih baik dibandingkan *ResNet-50* dalam kasus ini namun tidak terdapat perbedaan yang signifikan diantara keduanya. Berikutnya pada penelitian ini [11], menggunakan CNN dengan arsitektur *ResNet152V2* untuk membuat klasifikasi citra X-Ray paru-paru *Pneumonia* dan *Non-Pneumonia* menggunakan sebanyak 3000 data latih atau 80% dan 590 data validasi atau 20% dengan melakukan pengujian sebanyak 20 kali dengan ukuran *batch* 32, penelitian ini menghasilkan akurasi 91,4% dan memiliki nilai *loss* 0,18.

Selanjutnya pada penelitian [12] dilakukan klasifikasi 2 kelas data citra CT *Scan* paru-paru yaitu kelas *covid-19* dan normal menggunakan CNN. Pengujian dilakukan dengan menggunakan 3126 data citra dan diambil 20% untuk data uji. Berdasarkan pengujian nilai akurasinya semakin meningkat mulai dari *epoch* pertama yaitu 91,64% hingga stabil mulai dari *epoch* 9 hingga *epoch* 50 dengan akurasi 100%. Sementara *epoch* lainnya dimulai dari 89,04%, 91,14%, dan 83,98%, selain itu pada *epoch* ke 6 akurasi mulai 100% dibandingkan dengan *epoch* lainnya. Namun berdasarkan hasil uji coba terhadap data baru yang tidak termasuk dalam proses pengujian dan pelatihan dapat di lihat ada data yang salah.

METODOLOGI

Tahapan Penelitian

Penelitian dimulai dengan melakukan studi literatur kemudian mengumpulkan dataset yang diperlukan, setelah itu masuk ke proses pemrograman dengan melakukan pelabelan dataset, kemudian *splitting* atau memisah dataset berdasarkan kategorinya, lalu melakukan *rescaling* dan *grayscale* pada citra, kemudian mengimplementasikan model CNN dan melakukan evaluasi hasil sehingga dapat menghasilkan hasil akhir yang diharapkan.



Gambar 1. Tahapan Penelitian

Pengumpulan Data

Tabel 1. Sampel Dataset

Citra Rontgen Paru-Paru Normal	Citra Rontgen Paru-Paru Tuberculosis
	
	
	

Pada penelitian ini data diperoleh dari situs Kaggle[13]. Data yang diperoleh sebanyak 4200 gambar yang terbagi atas 2 kategori, yaitu gambar rontgen paru-paru normal sebanyak 3500 gambar dan gambar rontgen paru-paru *tuberculosis*

sebanyak 700 gambar, seperti terlihat pada Tabel 1. File tersebut kemudian dilakukan pelabelan dengan menggunakan format “d-i” dimana I adalah angka dari 0 sampai dengan total jumlah gambar yang tersedia.


Splitting Data

Dataset dibagi menjadi 2 bagian yaitu *training* dan *testing*. Pembagian data dilakukan menggunakan library dari bahasa pemrograman *Python* yaitu *split-folders*. Dataset dibagi dengan rasio 80% untuk data *testing* dan 20% untuk data *training* untuk skenario 1 dan 70% data *testing* dan 30% data *training* untuk skenario 2.

Preprocessing

Pada tahapan *preprocessing* ini dilakukan *rescaling* dan *grayscale* pada citra. Semua citra dilakukan *rescaling* pada daerah yang menjadi perhatian (*region of interest/ROI*) dengan ukuran piksel citra menjadi 256x256. Kemudian citra-citra tersebut dilakukan *grayscale*, yaitu proses merubah ruang warna dari ruang warna *Red Green Blue* (RGB) menjadi ruang warna aras keabuan (*grayscale*) dan juga untuk menyeragamkan warna dan *channel* pada citra.

Arsitektur CNN



Gambar 2. Arsitektur CNN yang diusulkan

Pada tahun 1989, Yann LeCun dkk memperkenalkan algoritma pelatihan yang digunakan untuk memahami muatan-muatan pada citra dan terbukti menunjukkan performa yang baik pada deteksi, klasifikasi, dan segmentasi citra yang diberi nama CNN. CNN adalah salah satu jaringan saraf tiruan dengan menerapkan pelatihan disupervisi [14]. CNN dilatih menggunakan dataset (kumpulan data) yang terdiri dari masukan dan target dimana target tersebut terafiliasi dengan masukan. CNN menggunakan target untuk menentukan seberapa baik performa dari proses pelatihan dan sebagai acuan adaptasi dari nilai bobot untuk mengurangi nilai *loss* yang diperoleh dalam proses.

CNN terdiri dari beberapa *layers* atau lapisan diantaranya yaitu lapisan *input*, lapisan konvolusi, lapisan pooling (*maxpool*) dan juga lapisan *fully-connected* diantaranya *flatten*, *concat*, *softmax* dan lapisan *output*. Jumlah nilai filter yang digunakan dalam CNN tidak dibatasi, tetapi yang biasanya digunakan adalah 8, 16, 32, 64 dan seterusnya. Ukuran *filter* yang digunakan juga biasanya berukuran 3x3, 5x5, 7x7 dan seterusnya.

Pada CNN, lapisan awal bernama lapisan konvolusi. Konvolusi adalah bentuk matematis dalam memadukan dua buah sinyal sehingga membentuk sinyal ketiga [15]. Sinyal pertama disebut sinyal *input*, sedangkan sinyal kedua sering disebut sebagai *filter*. Kemudian sinyal ketiga atau sinyal terakhir merupakan sinyal *output*.

Selanjutnya setelah proses konvolusi *output* yang dihasilkan akan melalui lapisan berikutnya yaitu lapisan penggabungan. Lapisan penggabungan bertujuan untuk mencapai invariasi spasial dengan cara mengurangi resolusi matriks dengan memangkas elemen dari ketetangaan spasial yang memiliki nilai yang lebih kecil [16]. Pada penelitian ini digunakan

operasi penggabungan dengan mengambil nilai maksimal dan menyingkirkan nilai yang lebih kecil menggunakan *maxpool*.

Setelah melewati proses penggabungan, *output* akan menjadi masukan (*input*) pada lapisan berikutnya yaitu lapisan *fully-connected*. Dalam lapisan ini terdapat beberapa proses seperti *flatten* Dimana input akan melalui proses perataan. Setelah melalui proses perataan akan dilakukan proses klasifikasi. Pada proses ini diperlukan sebuah fungsi aktivasi, Dimana terdapat berbagai opsi seperti *linear*, *step*, *ramp*, *sigmoid*, *hyperbolic*, *Gaussian*, *softmax*, dan sebagainya [17]. Pada penelitian ini, fungsi yang digunakan pada lapisan ini adalah fungsi aktivasi *softmax*. Fungsi *softmax* itu sendiri akan menghitung distribusi probabilitas dari kelas-kelas yang ada [18]. Setelah mendapatkan probabilitas, maka akan dihitung galat atau *loss* dari perhitungan berdasarkan target yang dituju dengan menerapkan fungsi galat *cross-entropy*. Proses pelatihan atau *training* pada CNN dilakukan dengan melakukan pengaturan dan juga penyesuaian terhadap parameter sehingga dicapai nilai *loss* yang seminimal mungkin.

Seperti Gambar 2, penelitian ini diterapkan 3 lapisan konvolusi yang berukuran 3x3. Kemudian dalam operasi penggabungan yang digunakan merupakan operasi penggabungan yang mengambil nilai maksimal dan membuang nilai yang lebih kecil (*Maxpool*). Fungsi yang digunakan untuk mengambil nilai maksimal ketetapan spasial yaitu fungsi jendela 2x2. Kemudian pada setiap *output* dari lapisan penggabungan *Maxpool* akan melalui proses *flatten* (pemerataan). Setelah melewati proses *flatten*, vektor-vektor yang dihasilkan akan digabungkan pada lapisan *Concat* menjadi sebuah vektor. Setelah itu vektor akan diklasifikasikan menggunakan fungsi aktivasi *Softmax* kedalam 2 kelas.

HASIL DAN PEMBAHASAN

Pada bagian ini akan dijabarkan dua sub-bagian yaitu yang pertama pelatihan atau *training* dan yang kedua adalah pengujian atau *testing*. Bahasa pemrograman yang digunakan adalah python dengan memanfaatkan Pustaka *tensorflow*. Jumlah data yang digunakan dalam penelitian ini terdiri dari 2 bagian dengan total data sebanyak 1400 citra. Dalam penelitian ini digunakan 2 skenario pelatihan dan pengujian, diantaranya pada skenario 1 data yang digunakan untuk proses pelatihan atau *training* adalah sebanyak 1120 data citra, sedangkan data yang digunakan untuk proses pengujian atau *testing* adalah sebanyak 280 data citra. Pada skenario 2 data yang digunakan untuk proses pelatihan atau *training* adalah sebanyak 978 data citra, sedangkan data yang digunakan untuk proses pengujian atau *testing* adalah sebanyak 422 data citra.


Proses Training

Tabel 2. Hasil Pelatihan untuk Setiap Skenario


epoch	Skenario 1		Skenario 2	
	Loss	Accuracy (%)	Loss	Accuracy (%)
1	0,3175	89,98	0,3315	89,91
2	0,1040	96,32	0,0945	96,96
3	0,0457	98,88	0,0672	97,68
4	0,0459	98,36	0,0344	98,84
5	0,0126	99,80	0,0240	99,20
6	0,0582	98,36	0,0027	100
7	0,0081	99,80	0,0010	100
8	0,0098	99,69	0,0003	100
9	0,0198	99,39	0,0001	100
10	0,0134	99,49	0,00008	100
11	0,0092	99,49	0,00005	100
12	0,0019	99,90	0,0254	99,82
13	0,0004	100	0,0567	98,39
14	0,0002	100	0,0017	100
15	0,00009	100	0,0005	100
16	0,00005	100	0,0002	100
17	0,00002	100	0,000005	100
18	0,00002	100	0,000006	100
19	0,000008	100	0,000003	100
20	0,000006	100	0,000002	100

Proses pelatihan atau *training* menggunakan model CNN dilakukan dengan menggunakan parameter *loss* dan *accuracy*. Pada skenario 1 Proses *training* data menggunakan 1120 *step* dengan jumlah *epoch* 20 dan waktu yang dibutuhkan untuk proses training ini adalah 6 menit. Sedangkan untuk skenario 2 proses training menggunakan 978 *step* dengan jumlah *epoch* 20. Arsitektur CNN yang digunakan dalam penelitian ini tersusun dari 3 lapisan konvolusi yang diikuti dengan lapisan penggabungan *Maxpool*. Jumlah filter yang digunakan adalah 128 buah dan *filter* tersebut berukuran 3x3. Pada lapisan *Maxpool* digunakan fungsi jendela 2x2.

Setiap *output* dari lapisan gabungan *Maxpool* akan melewati proses perataan. Setelah melewati proses tersebut vektor yang dihasilkan kemudian digabungkan menjadi sebuah vektor yang terdapat pada lapisan *Concat*. Setelah itu vektor diklasifikasikan kedalam 2 kelas menggunakan aktivasi *Softmax*. Dapat dilihat pada Tabel 2 proses training data untuk skenario 1 pada *epoch* ke-1 memiliki nilai *loss* 0,3315 dan *accuracy* 89,91%. Kemudian mengalami kenaikan *accuracy* pada *epoch-epoch* selanjutnya. pada *epoch* ke-14 *accuracy* stabil pada nilai 100% sampai *epoch* terakhir mampu mendapatkan nilai *accuracy* 100% dan *loss* 0,000019. Pada training menggunakan skenario 2 *epoch* ke-1 memiliki nilai *loss* 0,3175 dengan *accuracy* 89,98%. Kemudian mulai stabil pada *epoch* ke-13 sampai terakhir yaitu *epoch* ke-20 dengan mendapatkan nilai *accuracy* sebesar 100%.



Gambar 3. Hasil Pelatihan Skenario 1



Gambar 4. Hasil Pelatihan Skenario 2

Proses Testing

Tabel 3. Hasil Pengujian Tiap Skenario

Skenario	Loss	Accuracy (%)
Skenario 1	0,02	99,29
Skenario 2	0,10	97,63

Tabel 3 menunjukkan hasil dari proses pengujian atau *testing* menggunakan model CNN yang sudah melewati proses *training*, pada skenario 1 dilakukan menggunakan 280 data citra dan skenario 2 dilakukan menggunakan 422 data citra yang berbeda dari data latih yang digunakan pada proses training. Model CNN yang terdiri dari bobot dan bias yang sudah melewati proses training dicoba untuk mengenali data testing yang berjumlah 280 data citra pada skenario 1 dan 422 data citra pada skenario 2. Pada skenario 1 menghasilkan nilai *accuracy* 99,29% dengan nilai *loss* 0,02. Sedangkan pada skenario 2 hanya menghasilkan nilai *accuracy* 97,63% dengan nilai *loss* 0,10.

KESIMPULAN DAN SARAN

Klasifikasi penyakit *tuberculosis* berdasarkan citra rontgen thorax menggunakan *Multi-Scale Convolutional Network* telah disajikan. Hasil dari penelitian ini adalah penggunaan model *Multi-Scale CNN* mendapatkan hasil yang sudah cukup baik dalam melakukan klasifikasi penyakit *tuberculosis* berdasarkan citra rontgen thorax. Hasil yang diperoleh menggunakan 2 skenario pada pelatihan atau *training* data menggunakan 1120 data citra pada skenario 1 dan 978 data citra pada skenario 2 menggunakan *epoch* 20, jumlah *filter* disetiap lapisan konvolusi sebesar 128 pada skenario 1 dihasilkan akurasi sebesar 100% stabil pada *epoch* ke-14 hingga *epoch* ke-20, kemudian pada proses pengujian didapatkan nilai *loss* 0,02 dan *accuracy* 99,29%. Sedangkan pada skenario 2 dihasilkan akurasi sebesar 100% stabil pada *epoch* ke-13 sampai *epoch* ke-20, kemudian pada proses pengujian hanya didapatkan nilai *loss* 0,10 dan *accuracy* 97,63%.

DAFTAR PUSTAKA

- [1] World Health Organization, *Regional strategic plan towards ending TB in the WHO South-East Asia Region: 2021–2025*. 2021.
- [2] M. Halim, A. Sabrina, and M. Aris, “KEPATUHAN PASIEN RAWAT JALAN POLI PARU DALAM PENGGUNAAN OBAT ANTI TUBERKULOSIS (OAT) DI RUMAH SAKIT KARTIKA HUSADA JATIASIH BEKASI,” *Jurnal Farmasi IKIFA*, vol. 2, pp. 30–37, Apr. 2023.
- [3] K. C. Rahlwes, B. R. S. Dias, P. C. Campos, S. Alvarez-Arguedas, and M. U. Shiloh, “Pathogenicity and virulence of *Mycobacterium tuberculosis*,” *Virulence*, vol. 14, no. 1, pp. 1–29, Dec. 2023, doi: 10.1080/21505594.2022.2150449.
- [4] D. E. Juliando and A. Setiari, “Identifikasi Bakteri pada Citra Dahak Penderita Tuberculosis (TBC) Menggunakan Metode Watershed,” *JEECAE (Journal of Electrical, Electronics, Control, and Automotive Engineering)*, vol. 2, no. 1, pp. 83–88, May 2017, doi: 10.32486/jeecae.v2i1.60.
- [5] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput Sci*, vol. 2, no. 3, pp. 1–21, May 2021, doi: 10.1007/s42979-021-00592-x.
- [6] M. M. Taye, “Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions,” *Computation*, vol. 11, no. 3, pp. 1–23, Mar. 2023, doi: 10.3390/computation11030052.
- [7] A. Rasyid and L. Heryawan, “Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN),” *Jurnal Manajemen Informasi Kesehatan Indonesia (JMIKI)*, vol. 11, no. 1, Mar. 2023, doi: 10.33560/jmiki.v11i1.484.
- [8] I. Bakti and M. Firdaus, “Classification of Image Files of Lung X-Ray Results with Architecture Convolution Neural Network (CNN),” *Journal of Information Technology*, vol. 3, no. 1, pp. 26–34, Mar. 2023, doi: 10.46229/jifotech.v3i1.590.
- [9] S. N. Fadilah, D. C. R. Novitasari, and L. Hakim, “Pengaruh Reduksi Fitur Pada Klasifikasi Kanker Paru Menggunakan CNN Dengan Arsitektur GoogLeNet,” *Jurnal Fourier*, vol. 12, no. 1, pp. 20–32, Apr. 2023, doi: 10.14421/fourier.2023.121.20-32.
- [10] T. Berliani, E. Rahardja, and L. Septiana, “Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16,” *Journal of Medicine and Health*, vol. 5, no. 2, pp. 123–135, Aug. 2023, doi: 10.28932/jmh.v5i2.6116.
- [11] M. Ramadhan, D. Iskandar Mulyana, M. Betty Yel, and S. Tinggi Ilmu Komputer Cipta Karya Informatika Jl Raden, “OPTIMASI ALGORITMA CNN MENGGUNAKAN METODE TRANSFER LEARNING UNTUK KLASIFIKASI CITRA X-RAY PARU-PARU PNEUMONIA DAN NON-PNEUNOMIA,” *Jurnal Teknik Informatika Kaputama (JTik)*, vol. 6, no. 2, 2022.
- [12] Y. F. Riti and S. S. Tandjung, “Klasifikasi Covid-19 Pada Citra CT Scans Paru-Paru Menggunakan Metode Convolution Neural Network,” *Progresif: Jurnal Ilmiah Komputer*, vol. 18, no. 1, p. 91, Feb. 2022, doi: 10.35889/progresif.v18i1.784.
- [13] T. Rahman, M. Chowdhury, and A. Khandakar, “Tuberculosis (TB) Chest X-ray Database,” <https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset>.
- [14] M. Akbar, A. S. Purnomo, and S. Supatman, “Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 11, no. 3, pp. 310–315, Dec. 2022, doi: 10.32736/sisfokom.v11i3.1452.

- [15] W. S. Smith, *The Scientist and Engineer's Guide to Digital Signal Processing*. California Technical Publishing, 1999.
- [16] D. Scherer, A. Müller, and S. Behnke, "Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition," 2010, pp. 92–101. doi: 10.1007/978-3-642-15825-4_10.
- [17] A. P. Engelbrecht, *Computational Intelligence*. Wiley, 2007. doi: 10.1002/9780470512517.
- [18] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation Functions: Comparison of trends in Practice and Research for Deep Learning," Nov. 2018, [Online]. Available: <http://arxiv.org/abs/1811.03378>