

Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network

(Classification of Pneumonia Based on Lung X-rays Images using Convolutional Neural Network)

I Md. Dendi Maysanjaya¹

Abstract—Pneumonia is a lung disease that could be caused by bacteria, viruses, fungi, or parasites. The pulmonary cysts are filled with fluid, causing croup and mucus cough. Usually, observation of the patient's lung condition is performed through X-rays. However, the quality of X-ray images tends to be less than optimal. Therefore, a CAD-based automation system was developed. In this paper, a new chest X-rays dataset for pneumonia cases is classified by using Convolutional Neural Network (CNN). This study examines the CNN performance in handling the new dataset. The data were obtained from the Kaggle platform. In total, there were 5,840 images occupied in this study, consisting of 1,575 normal lung images and 4,265 pneumonia lung images. The data were divided into training and testing data, with the amount of data 5,216 and 624 images on each, respectively. The CNN activation function applied the Rectifier Linear Unit (ReLU) function, Adam optimization function, and epoch as many as 200 times. Based on the test results, the average accuracy and loss values are sequentially at 89.58% and 47.43%. The results of this test indicate that the CNN method is quite capable of classifying the pneumonia cases.

Intisari—Pneumonia merupakan salah satu penyakit paru-paru yang disebabkan oleh bakteri, virus, jamur, ataupun parasit. Kantung udara dipenuhi oleh cairan sehingga menyebabkan sesak dan batuk berdarah. Pengamatan kondisi paru-paru pasien dilakukan paramedis melalui foto rontgen (*X-rays*). Namun, kualitas citra rontgen terkadang kurang optimal, sehingga dikembangkan sistem otomatisasi berbasis CAD. Pada makalah ini, ditawarkan sebuah *dataset* baru tentang citra foto toraks untuk kasus pneumonia. Citra diklasifikasi menggunakan metode *Convolutional Neural Network* (CNN). Tujuan dari makalah ini adalah menguji kinerja CNN dalam menangani *dataset* baru. Data diperoleh dari platform Kaggle sejumlah 5.840 citra, yang terdiri atas 1.575 citra paru-paru normal dan 4.265 citra paru-paru pneumonia. Data dibagi menjadi data latih dan data uji, dengan jumlah data secara berurutan 5.216 citra dan 624 citra. Fungsi aktivasi CNN menggunakan fungsi *Rectifier Linear Unit* (ReLU), fungsi optimasi *Adam*, dan *epoch* sebanyak 200. Berdasarkan hasil pengujian, diperoleh rata-rata nilai akurasi dan rata-rata nilai *loss* secara sekuensial sebesar 89,58% dan 47,43%. Hasil pengujian ini menunjukkan bahwa metode CNN cukup mampu untuk melakukan klasifikasi kasus pneumonia.

Kata Kunci— Identifikasi, Pneumonia, Citra X-rays, Paru-paru, Convolutional Neural Network.

I. PENDAHULUAN

Citra medis memiliki peran penting untuk mengklasifikasi atau mengidentifikasi suatu penyakit. Salah satu teknik yang paling sering digunakan adalah foto rontgen (sering dikenal juga dengan istilah foto *X-rays*). Teknik ini digunakan oleh ahli radiologi untuk dapat melihat kondisi dalam tubuh pasien. Selain itu, foto rontgen ini memiliki kelebihan, yakni mudah digunakan dan memiliki nilai ekonomis yang tinggi.

Citra foto toraks merupakan pemanfaatan foto rontgen untuk melihat kondisi area dada pasien. Hasil foto toraks ini menampilkan kondisi dada, paru-paru, jantung, dan trakea (saluran pernafasan) [1]. Infeksi pada area paru-paru yang disebabkan oleh virus, bakteri, fungi, ataupun parasit lainnya akan ditandai dengan area berwarna putih kelabu. Area ini yang dapat dicurigai dokter untuk mengidentifikasi penyakit yang mungkin diderita pasien, misalnya pneumonia [2].


Pneumonia merupakan penyakit infeksi saluran pernafasan akut (ISPA) bagian bawah yang disebabkan adanya peradangan pada jaringan dan kantung udara di paru-paru. Kantung udara dipenuhi oleh cairan yang dapat menyebabkan batuk berdarah, demam, menggigil, dan kesulitan bernafas [3]. Gbr. 1 merupakan contoh pasien yang menderita pneumonia.

Pada Gbr. 1, area lingkaran merah merupakan *pulmonary* yang mengalami inflamasi akibat virus, sehingga menyebabkan terjadinya pneumonia. Area tersebut berwarna putih kelabu, karena *pulmonary* dipenuhi cairan. Kondisi ini berbeda dengan paru-paru normal yang ditunjukkan pada Gbr. 2. Kondisi paru-paru yang ditampilkan pada Gbr. 2 terlihat bersih dengan kondisi *pulmonary* yang terlihat dengan jelas dan tidak ada area yang berwarna putih kelabu seperti pada Gbr. 1.

Meskipun kondisi peradangan paru-paru dapat dilihat dengan mudah melalui foto rontgen, tetapi kualitas citra yang dihasilkan tidaklah selalu bagus, bahkan cenderung samar dan memiliki kemiripan yang sama antar jenis penyakit *pulmonary*, seperti pneumonia, tuberkulosis, *pneumothorax*, infiltrasi, *nodule*, kanker paru-paru, dan lainnya. Hal ini merupakan tantangan bagi dokter radiologi untuk menentukan jenis penyakit yang menyebabkan peradangan pada area *pulmonary*.

Guna meminimalkan permasalahan yang dihadapi oleh dokter radiologi dalam menentukan kondisi peradangan *pulmonary*, saat ini telah banyak dikembangkan sistem otomatisasi berbasis *computer aided diagnostic (automated CAD-based system)* [4]. Kondisi ini memotivasi para peneliti untuk mengembangkan berbagai jenis algoritme *machine learning*, terlebih perkembangan saat ini sudah memasuki tahap

¹ Prodi Sistem Informasi, Jurusan Teknik Informatika, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha – Kampus Tengah Undiksha, Jalan Udayana No. 11 Singaraja 81116 Indonesia (tlp: +6232627213; fax: +6236225571; e-mail: dendi.ms@undiksha.ac.id)



Gbr. 1 Paru-paru pneumonia.



Gbr. 2 Paru-paru normal.

implementasi *deep learning*, yang merupakan penyempurnaan metode-metode *machine learning* konvensional.

Sehubungan dengan hal tersebut, pada makalah ini dipaparkan implementasi salah satu metode *deep learning*, yakni *Convolutional Neural Network* (CNN) dalam mengidentifikasi paru-paru normal dengan paru-paru pneumonia. CNN dipilih karena memiliki kelebihan seperti fitur yang terdapat pada citra dapat ditentukan secara otomatis serta secara spesifik ditujukan untuk mengklasifikasikan citra. Selain itu, tujuan utama makalah ini adalah menguji kinerja CNN dalam mengklasifikasi citra paru-paru normal dengan citra paru-paru dengan pneumonia, pada sebuah *dataset* baru, serta melakukan modifikasi terhadap rancangan arsitektur CNN berdasarkan penelitian-penelitian yang telah dilakukan sebelumnya.

Paparan berikutnya pada makalah ini terbagi ke dalam empat bagian. Bagian II membahas sistem ataupun kajian yang telah dikembangkan terkait identifikasi dan klasifikasi terkait penyakit *pulmonary*, dilanjutkan pemaparan *dataset* pada bagian III. Paparan tentang metode CNN disajikan pada bagian IV, sedangkan hasil dan pembahasan disampaikan pada bagian V dan paparan ditutup melalui kesimpulan pada bagian VI.

II. SISTEM IDENTIFIKASI PENYAKIT *PULMONARY*

Sistem otomatisasi berbasis CAD saat ini banyak digunakan untuk membantu paramedis dalam melakukan diagnosis terhadap suatu penyakit, termasuk dalam mengidentifikasi jenis penyakit *pulmonary*. Telah dilakukan sebuah penelitian untuk mengembangkan sistem *screening* otomatis untuk penyakit

pulmonary, termasuk di dalamnya tuberkulosis, berbasis citra foto toraks [5].

Pada tahun 2016, diajukan sebuah ide dengan mengombinasikan fitur tekstur dan bentuk untuk penyakit tuberkulosis dan pneumonia [6]. Penelitian lain menggunakan *dataset* “*ChestX-ray8*” untuk mengklasifikasi berbagai jenis penyakit toraks dengan metode CNN [7]. Berdasarkan penelitian yang dilakukan, kasus pneumonia dengan model usulan ResNet-50 memperoleh akurasi 63,33%. Penelitian lain sejenis berfokus pada keterhubungan antara berbagai jenis penyakit toraks, dengan akurasi 71,30% [8], serta penelitian yang mengusulkan pendekatan *deep learning* dengan menggunakan 121-layered CNN dengan hasil akurasi sebesar 76,80% [9].

Terdapat beragam penelitian terkait identifikasi penyakit toraks yang telah dilakukan dengan hasil yang beragam pula [2], [10]–[15]. Secara umum, semua penelitian ini bertujuan menghasilkan formulasi metode ataupun algoritme yang dapat digunakan untuk meningkatkan kinerja sistem dalam mengidentifikasi penyakit toraks, yang salah satunya adalah pneumonia.

Sehubungan dengan hal tersebut, dibentuklah sebuah *dataset* baru dengan tujuan klasifikasi paru-paru normal dengan paru-paru yang menderita pneumonia. Penyusunan *dataset* ini sebagai bentuk kontribusi dalam meningkatkan kualitas sistem klasifikasi penyakit pneumonia pada citra foto toraks. Metode CNN dipilih sebagai metode klasifikasi guna memastikan kinerja CNN cukup andal untuk digunakan pada *dataset* baru ini, seperti hasil-hasil penelitian yang telah banyak menggunakan CNN. Paparan terkait *dataset* disajikan lebih detail pada bagian III.

III. DATASET

Dataset yang digunakan pada makalah ini adalah citra paru-paru yang terdiri atas dua kelas, yakni citra paru-paru normal (contoh pada Gbr. 2) dan citra paru-paru pneumonia (contoh pada Gbr. 1). Data ini merupakan data sekunder yang telah dikumpulkan dalam [16] dan bersumber dari [10]. Jumlah data yang diperoleh sebanyak 5.840 citra, yang terdiri atas 1.575 citra paru-paru normal dan 4.265 citra paru-paru pneumonia. Dipilihnya *dataset* ini sebagai bahan penelitian karena merupakan bagian dari kompetisi dalam platform Kaggle. *Dataset* ini dikompetisikan karena merupakan *dataset* baru yang berhasil dikumpulkan, sehingga sangat berguna untuk menguji kinerja metode yang sudah banyak dikembangkan dalam mengklasifikasi kasus pneumonia, khususnya metode CNN.

Keseluruhan *dataset* kemudian dibagi ke dalam dua jenis, yakni data latih dan data uji. Jumlah data latih sebanyak 5.216 citra, yang terdiri atas 1.341 untuk kelas paru-paru normal dan 3.875 untuk kelas paru-paru pneumonia. Data uji berjumlah 624 citra, terbagi ke dalam kelas paru-paru normal sebanyak 234 citra serta 390 citra untuk kelas paru-paru pneumonia. Jika dilihat, perbandingan antara kelas paru normal dengan paru pneumonia tidaklah seimbang. Namun, dalam makalah ini hal tersebut diabaikan karena merupakan ketentuan dari kompetisi untuk menggunakan *dataset* sesuai yang diberikan. Oleh karena

itu, fokus utama makalah ini adalah menguji kinerja CNN dalam menangani kondisi *dataset* seperti yang diberikan.

IV. CONVOLUTIONAL NEURAL NETWORK

CNN merupakan salah satu arsitektur jaringan saraf (*neural network*) yang secara spesifik ditujukan untuk klasifikasi citra. CNN dapat dikatakan sebagai inovasi baru dalam mengklasifikasikan citra. Karena merupakan bagian dari jaringan saraf, CNN dikembangkan berdasarkan inspirasi dari jaringan otak manusia.

Pengenalan pola citra sesuai konsep *computer vision* tentunya memerlukan tahap ekstraksi fitur pola. Ekstraksi fitur pola ini bertujuan memperoleh fitur-fitur yang dapat merepresentasikan pola citra yang harus dikenali. Tahap ekstraksi fitur pola ini tentu memerlukan pengetahuan mendasar terhadap pola yang harus dikenali. Sebagai contoh, dalam ekstraksi fitur citra medis diperlukan bantuan tenaga medis untuk membantu mempelajari pola citra medis tersebut. Tentu saja proses ini menjadi tantangan jika tidak tersedia tenaga medis yang dapat dijadikan sebagai pakar untuk membantu. Selain itu, terkadang fitur yang dianggap penting pada citra dengan label tertentu belum tentu dianggap penting juga pada citra dengan label lain, sehingga kondisi ini menyebabkan proses ekstraksi fitur pola merupakan tahapan yang relatif menantang untuk dilakukan.

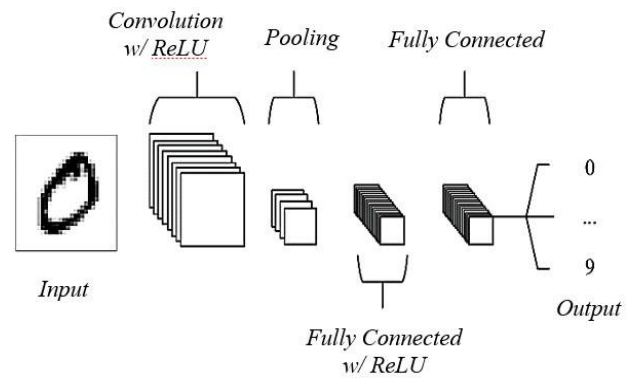
CNN memiliki kelebihan ‘mengeliminasi’ tahapan ekstraksi fitur pola yang memerlukan bantuan adanya seorang pakar. Untuk dapat melakukan hal ini, CNN menggunakan sebuah lapisan (*layer*) yang dikenal dengan istilah *convolution* guna mengekstrak pola fitur secara otomatis. CNN dapat mengeksekusi fitur yang dihasilkan hingga proses klasifikasi. Gbr. 3 merupakan ilustrasi proses CNN.

CNN dalam makalah ini menggunakan dua *convolution layer*, dua *polling layer*, serta *fully connected layer*. *Convolution layer* berfungsi sebagai *kernel* untuk proses *filter* citra menjadi ukuran matriks yang lebih kecil. Selanjutnya, *polling layer* bertugas untuk mengurangi atau melakukan *downsampling* lebih lanjut terhadap ukuran matriks, sedangkan *fully connected layer* merupakan struktur *Multi-layer Perceptron* (MLP) pada umumnya.

Bagian *convolution layer* dibantu fungsi aktivasi (*activation function*) yang bertujuan membantu proses konvolusi. Fungsi aktivasi yang digunakan adalah algoritme *Rectified Linear Unit* (ReLU) dengan ilustrasi seperti Gbr. 4. Algoritme ReLU sendiri memiliki kelebihan dalam efisiensi waktu untuk proses pelatihan (*training*) dan pengujian (*testing*).


Pada bagian *fully connected layer* digunakan algoritme ReLU dan *sigmoid*. Fungsi *sigmoid* adalah untuk mentransformasikan nilai masukan ke dalam sebuah nilai baru dengan rentang dari 0 hingga 1, dengan bentuk kurva seperti Gbr. 5.

Dalam proses optimasi pembaharuan bobot dari CNN, digunakan metode *Adam*. Metode ini memiliki proses komputasi yang relatif efisien (dari segi waktu dan kebutuhan memori), tidak berubah terhadap skala gradien, serta cocok digunakan untuk jumlah data ataupun parameter yang banyak. Diketahui terdapat dua parameter utama dalam metode *Adam*, yakni bobot ($\omega^{(t)}$) dan *loss function* ($L^{(t)}$), dengan indeks t



Gbr. 3 Konfigurasi *Convolutional Neural Network* (CNN).

ReLU Function



Gbr. 4 Fungsi aktivasi ReLU.

merupakan iterasi pelatihan yang sedang berjalan [17]. Persamaan (1) dan (2) secara berurutan merupakan proses awal dari formula metode *Adam*, yakni bertujuan mencari nilai *moving average of gradient* (m_ω) dan nilai *moving average of squared gradient* (v_ω).

$$m_\omega^{(t+1)} \leftarrow \beta_1 m_\omega^{(t)} + (1 - \beta_1) \nabla_\omega L^{(t)} \quad (1)$$

$$v_\omega^{(t+1)} \leftarrow \beta_2 v_\omega^{(t)} + (1 - \beta_2) (\nabla_\omega L^{(t)})^2 \quad (2)$$

dengan:

β_1 = *first moment exponential decay rate* (misalnya 0,9)

β_2 = *second moment exponential decay rate* (misalnya 0,999)


$\nabla_\omega L^{(t)}$ = *gradient on current mini-batch*.

Persamaan (1) dan (2) selanjutnya masing-masing digunakan untuk menentukan nilai *bias corrected estimator* untuk *first moment* (\hat{m}_ω) dan *second moment* (\hat{v}_ω) seperti pada (3) dan (4).

$$\hat{m}_\omega = m_\omega^{(t+1)} / (1 - \beta_1^{(t+1)}) \quad (3)$$

$$\hat{v}_\omega = v_\omega^{(t+1)} / (1 - \beta_2^{(t+1)}) \quad (4)$$

Untuk menghasilkan pembaharuan bobot, (3) dan (4) selanjutnya diformulasikan sehingga dihasilkan bobot akhir (5). Adapun ringkasan parameter arsitektur CNN yang digunakan pada makalah ini disajikan pada Tabel I.



Gbr. 5 Kurva fungsi sigmoid.

TABEL I
RINGKASAN PARAMETER ARSITEKTUR CNN

| Layer (Type) | Output Shape | Param # |
|--------------------------------|--------------------|---------|
| input_shape | (None, 64, 64, 3) | 0 |
| conv2d_1 (Conv2D) | (None, 62, 62, 32) | 896 |
| max_pooling2d_1 (MaxPooling2D) | (None, 31, 31, 32) | 0 |
| conv2d_2 (Conv2D) | (None, 29, 29, 32) | 9248 |
| max_pooling2d_2 (MaxPooling2D) | (None, 14, 14, 32) | 0 |
| flatten_1 (Flatten) | (None, 6272) | 0 |
| dense_1 (Dense) | (None, 128) | 802944 |
| dense_2 (Dense) | (None, 1) | 129 |
| Total params: 813,217 | | |
| Trainable params: 813,217 | | |
| Non-trainable params: 0 | | |

$$\omega^{(t+1)} \leftarrow \omega^{(t)} - \eta \frac{\hat{m}_\omega}{\sqrt{\hat{v}_\omega}} + \epsilon \tag{5}$$

dengan:

$\omega^{(t+1)}$ = nilai bobot baru


$\omega^{(t)}$ = nilai bobot lama

η = step size (tergantung pada jumlah iterasi)

ϵ = epsilon untuk menghindari kondisi *division by zero*.

V. HASIL DAN PEMBAHASAN

Pada makalah ini, parameter yang dijadikan acuan untuk dievaluasi adalah *epoch*. Satu *epoch* merupakan kondisi ketika seluruh *dataset* melewati satu kali proses *forward* dan *backward* dalam jaringan saraf. Jika hanya digunakan satu *epoch*, kondisi ini tentu sangat besar bila dimasukkan ke dalam jaringan saraf dalam sekali waktu, sehingga *dataset* dibagi ke dalam *sub-dataset* yang dikenal dengan istilah *batch*. Sesuai parameter arsitektur CNN pada Tabel I, *dataset* dibagi ke dalam 32 *batch*. Hal ini berarti ada 32 data latih yang digunakan dalam satu *batch*.



Gbr. 6 Perbandingan kurva jenis hasil klasifikasi.

TABEL II
NILAI AKURASI DAN LOSS UNTUK PELATIHAN DAN PENGUJIAN

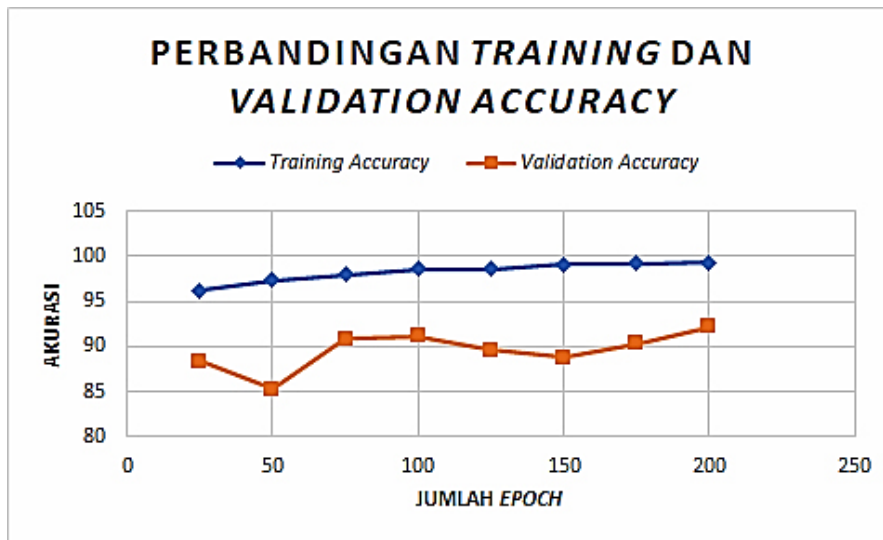
| Epoch | Akurasi (%) | | Loss (%) | |
|--------|-------------|-----------|-----------|-----------|
| | Pelatihan | Pengujian | Pelatihan | Pengujian |
| 25 | 96,18 | 88,44 | 9,76 | 36,16 |
| 50 | 97,37 | 85,27 | 7,22 | 49,24 |
| 75 | 98,01 | 90,84 | 5,21 | 34,97 |
| 100 | 98,56 | 91,18 | 3,67 | 32,87 |
| 125 | 98,65 | 89,61 | 3,17 | 56,73 |
| 150 | 99,14 | 88,79 | 2,39 | 64,80 |
| 175 | 99,18 | 90,38 | 2,51 | 59,55 |
| 200 | 99,35 | 92,16 | 1,71 | 45,08 |
| Rerata | 98,31 | 89,58 | 4,46 | 47,43 |

Kondisi lain yang perlu diperhatikan dalam penentuan jumlah *epoch* adalah kasus *underfitting* maupun *overfitting*. Kondisi *underfitting* terjadi karena model pelatihan data tidak mewakili keseluruhan data yang digunakan dan model masih mempelajari struktur dari data. Hal ini terjadi ketika jumlah *epoch* yang ditentukan terlalu sedikit. Sebaliknya, jika jumlah *epoch* terlalu banyak, terjadi kasus *overfitting*. *Overfitting* merupakan kondisi ketika data latih yang digunakan adalah yang ‘terbaik’, sehingga ketika digunakan untuk mengenali data berbeda akan menurunkan akurasi. Perbandingan kurva jenis klasifikasi ditunjukkan pada Gbr. 6.

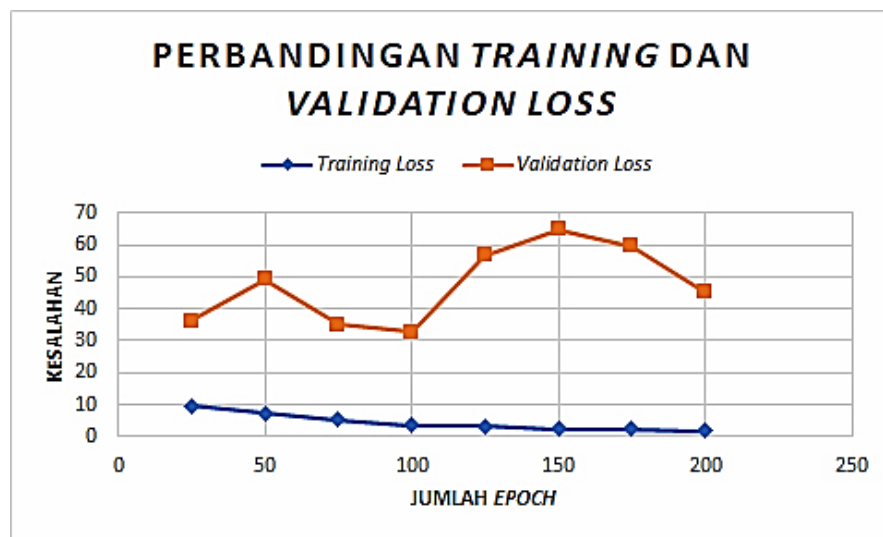
Jumlah *epoch* yang digunakan dalam makalah ini adalah 200 *epoch* dan nilai *epoch* yang diuji mulai dari *epoch* 25 hingga *epoch* 200, dengan interval pengamatan setiap 25 *epoch*. Eksperimen ini dilakukan untuk menemukan jumlah *epoch* terbaik yang dapat menghasilkan nilai akurasi yang seimbang antara proses pelatihan dan pengujian. Terdapat dua perbandingan yang dilakukan, yakni perbandingan tingkat akurasi antara pelatihan dan pengujian, serta perbandingan tingkat kesalahan (*loss*) antara pelatihan dan pengujian, dengan hasil secara grafik diperlihatkan pada Gbr. 7 dan Gbr. 8, sedangkan hasil secara kuantitatif disajikan pada Tabel II.

Pada Gbr. 7 dan Gbr. 8 ditunjukkan perbandingan nilai akurasi dan nilai *loss* yang diperoleh saat tahap pelatihan dan pengujian. Akurasi merupakan tingkat keberhasilan dalam mengenali objek, sedangkan *loss* menyatakan kesalahan yang dilakukan saat klasifikasi pada tiap *epoch*. Nilai *loss* dapat digunakan sebagai acuan untuk melihat kualitas model *machine learning* yang digunakan. Semakin kecil nilai *loss*, semakin baik model *machine learning* yang terbentuk, dan demikian pula sebaliknya.

Dari grafik pada Gbr. 7 diperoleh informasi bahwa pada *epoch* 50, model CNN yang digunakan cukup kesulitan dalam mengklasifikasi data pengujian, tetapi perlahan meningkat hingga *epoch* 100. Setelah *epoch* 100 hingga *epoch* 150,



Gbr. 7 Grafik perbandingan nilai akurasi pelatihan dan pengujian.



Gbr. 8 Grafik perbandingan nilai loss pelatihan dan pengujian.

akurasi mengalami penurunan, meskipun tidak melebihi penurunan pada *epoch* 50, dan perlahan meningkat lagi hingga *epoch* 200. Hasil ini didukung dengan kondisi nilai *loss* pada Gbr. 8.

Berdasarkan kedua grafik tersebut, diperoleh informasi bahwa model CNN yang dibangun mengalami kondisi *overfitting*, yakni kondisi ketidakmampuan model dalam mengenali data pengujian sebaik pengenalan data pelatihan. Akan tetapi, dari *epoch* 150 hingga *epoch* 200 grafik menunjukkan perubahan yang cukup baik (nilai akurasi meningkat dan nilai *loss* menurun sesuai Tabel II), sehingga dapat dikatakan bahwa model mencoba mengingat pola *dataset* dan cukup berhasil.

Secara detail, nilai dari grafik pada Gbr. 7 dan Gbr. 8 disajikan pada Tabel II. Dari delapan *epoch* yang dijadikan sampel, diperoleh rerata akurasi untuk pelatihan dan pengujian secara terurut sebesar 98,31% dan 89,58%, sehingga terdapat selisih akurasi sebesar 8,72%. Pada nilai *loss* terdapat gap

sebesar 42,97%. Selisih yang cukup besar ini mengindikasikan bahwa model CNN belum optimal dalam mengenali karakteristik data pengujian, sehingga terjadi kasus *overfitting*.

Kondisi ini terjadi karena pengaruh beberapa faktor, antara lain kondisi *dataset*, formulasi metode CNN yang belum optimal, dan jumlah *epoch*. Meskipun demikian, hasil yang diperoleh dapat dijadikan sebagai kontribusi dalam pengembangan sistem CAD untuk klasifikasi pneumonia.

VI. KESIMPULAN

Berdasarkan hasil yang diperoleh, dapat dikatakan bahwa metode CNN cukup mampu digunakan untuk mengklasifikasi pneumonia pada citra *X-rays* paru-paru, dengan akurasi sebesar 89,58%. Hasil ini lebih tinggi dibandingkan penelitian serupa yang sama-sama menggunakan *deep learning*, sehingga hasil ini diharapkan dapat memberikan kontribusi untuk pengembangan keilmuan, khususnya untuk mengklasifikasi pneumonia pada citra *X-rays* paru-paru.

Untuk pengembangan berikutnya, dapat difokuskan pada penanganan kasus *overfitting* yang timbul, konfigurasi pada arsitektur CNN, serta jumlah *epoch*. Tidak menutup kemungkinan juga dengan mengimplementasikan beberapa metode *deep learning* yang lain. Selain itu, ada baiknya data disegmentasi terlebih dahulu, sehingga dapat diperoleh *region of interest* (RoI) pneumonia, agar dapat dihasilkan nilai akurasi yang lebih optimal. Perlu diperhatikan juga penanganan kasus ketidakseimbangan pada jumlah *dataset* untuk tiap kelasnya, karena akan berpengaruh pada sensitivitas sistem dalam melakukan klasifikasi.

UCAPAN TERIMA KASIH

Dalam kesempatan ini, diucapkan terima kasih kepada Mooney dan Kermany *et al.* atas *dataset* yang didistribusikan secara terbuka melalui platform Kaggle.

REFERENSI

- [1] Y. Dong, Y. Pan, J. Zhang, dan W. Xu, "Learning to Read Chest X-Ray Images from 16000+ Examples Using CNN," *2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, 2017, hal. 51-57.
- [2] T.B. Chandra dan K. Verma, "Pneumonia Detection on Chest X-Ray Using Machine Learning Paradigm," *Proceedings of 3rd International Conference on Computer Vision and Image Processing*, 2020, hal. 21-33.
- [3] A. Mujahidin dan D. Pribadi, "Penerapan Algoritma C4.5 Untuk Diagnosa Penyakit Pneumonia pada Anak Balita Berbasis Mobile," *J. Swabumi*, Vol. 5, No. 2, hal. 155-161, 2017.
- [4] B. van Ginneken, B.M. ter Haar Romeny, dan M.A. Viergever, "Computer-aided Diagnosis in Chest Radiography: A Survey," *IEEE Trans. Med. Imaging*, Vol. 20, No. 12, hal. 1228-1241, 2001.
- [5] S. Antani, "Automated Detection of Lung Diseases in Chest X-Rays," *IEEE Trans. Med. Imaging*, Vol. 33, No. 1, hal. 1-26, 2015.
- [6] A. Karargyris, J. Siegelman, D. Tzortzis, S. Jaeger, S. Candemir, Z. Xue, K.C. Santosh, S. Vajda, S. Antani, L. Folio, dan G.R. Thoma, "Combination of Texture and Shape Features to Detect Pulmonary Abnormalities in Digital Chest X-rays," *Int. J. Comput. Assist. Radiol. Surg.*, Vol. 11, hal. 99-106, 2016.
- [7] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, dan R.M. Summers, "ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, hal. 3462-3471.
- [8] L. Yao, E. Poblens, D. Dagunts, B. Covington, D. Bernard, dan K. Lyman, "Learning to Diagnose from Scratch by Exploiting Dependencies Among Labels," *arXiv Prepr.*, hal. 1-12, 2017.
- [9] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, R.L. Ball, C. Langlotz, K. Shpanskaya, M.P. Lungren, dan A.Y. Ng., "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," *arXiv Prepr.*, hal. 3-9, 2017.
- [10] D.S. Kermany, M. Goldbaum, W. Cai, dan M.A. Lewis, "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning Resource Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, Vol. 172, No. 5, hal. 1122-1131.e9, 2018.
- [11] J-E. Bourcier, J. Paquet, M. Seinger, E. Gallard, J-P. Redonnet, F. Cheddadi, D. Garnier, J-M. Bourgeois, dan T. Geeraerts, "Performance Comparison of Lung Ultrasound and Chest X-ray for the Diagnosis of Pneumonia in the ED," *Am. J. Emerg. Med.*, Vol. 32, No. 2, hal. 115-118, 2014.
- [12] I. Sirazitdinov, M. Kholiavchenko, T. Mustafae, Y. Yixuan, R. Kuleev, dan B. Ibragimov, "Deep Neural Network Ensemble for Pneumonia Localization from a Large-scale Chest X-ray Database," *Comput. Electrical Eng.*, Vol. 78, hal. 388-399, 2019.
- [13] W.W. Chapman, M. Fizman, B.E. Chapman, dan P.J. Haug, "A Comparison of Classification Algorithms to Automatically Identify Chest X-Ray Reports That Support Pneumonia," *J. Biomed. Inform.*, Vol. 34, No. 1, hal. 4-14, 2001.
- [14] A.K. Jaiswal, P. Tiwari, S. Kumar, D. Gupta, A. Khanna, dan J.J.P.C. Rodrigues, "Identifying Pneumonia in Chest X-rays: A Deep Learning Approach," *Measurement*, Vol. 145, hal. 511-518, 2019.
- [15] B. Biswas, S.Kr. Ghosh, S. Bhattacharyya, J. Platos, V. Snasel, dan A. Chakrabarti, "Chest X-ray Enhancement to Interpret Pneumonia Malformation Based on Fuzzy Soft Set and Dempster - Shafer Theory of Evidence," *Appl. Soft Comput. J.*, Vol. 86, hal. 105889, 2020.
- [16] P. Mooney (2018) "Chest X-Ray Images (Pneumonia)," [Online], <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>, tanggal akses: 12-Jan-2020.
- [17] D.P. Kingma dan J. Ba, "Adam: A Method for Stochastic Optimization," *arXiv Prepr.*, hal. 1-15, 2014.