Skip to Main Content

Klasifikasi Pneumonia pada Citra Thorax dengan Convolutional Neural Network

by M M

FILE	UMONIA_PADA_CITRA_THORAX_DENGAN_CONVOLUTIONAL_NEURAL_NETWORK.DOC (1.02M)		
TIME SUBMITTED	22-JUN-2020 08:48AM (UTC+0700)	WORD COUNT	3506
SUBMISSION ID	1347699530	CHARACTER COUNT	22473

Jurnal INFORM Vol.xx No.xx, Bulan Tahun, ISSN : 2502-3470

Klasifikasi Pneumonia pada Citra Thorax dengan Convolutional Neural Network

Mahmud Suyuti[1], Endang Setyati[2]

[1,2] *Program Studi Teknologi Informasi, Fakultas Sains dan Teknologi, Institut Sains dan Teknologi Terpadu Surabaya*

[1] mahmudsuyuti@istts.onmicrosoft.com (*)

[2] endang@stts.edu

Abstract— Digital image processing technique is one of the computational technology development product. Computer-based medical image data processing is a product of computational technology development which can assist doctors to complete disease diagnoses and observe patients' conditions. This study aims to classify the thorax image using Convolutional Neural Network (CNN). The data which is used in this study are the chest thorax images data that has previously been diagnosed by doctor in two classes, namely normal and pneumonia. The amount of data are 2,200, 1,760 data for training and 440 for testing. There are three stages which is used in the image processing (image processing), namely scaling, grayscaling, and scretching. In this study the architecture that is used is ResNet-50 with Adaptive Moment (Adam) optimization. This study used the 2018a matlab programming language. The results showed that the classification of the thorax image by using ResNet-50 that has been optimized with Adaptive Moment (Adam) produced an accuracy of 97.5%.

Keywords— Pneumonia, Pneumonia Classification, Thorax Image, CNN.

Abstrak— Teknik pengolahan citra digital adalah salah satu produk pengembangan teknologi komputasi. Pengolahan data citra medis berbasis komputer merupakan produk pengembangan teknologi komputasi yang dapat membantu dokter dalam melengkapi diagnosa penyakit dan observasi kondisi tubuh pasien. Penelitian ini bertujuan untuk melakukan klasifikasi pada citra thorax dengan menggunakan Convolutional Neural Network (CNN). Data yang digunakan pada penelitian ini adalah data citra thorax paru-paru yang sebelumnya sudah didiagnosa oleh dokter dengan dua kelas yaitu normal dan pneumonia. Jumlah data adalah 2.200 dengan rincian 1.760 untuk pembelajaran dan 440 untuk pengujian. Ada tiga tahapan yang digunakan dalam pengolahan citra (image processing) yaitu scaling, grayscaling, dan scretching. Pada penelitian ini arsitektur yang digunakan oleh penulis adalah ResNet50 dengan optimasi Adaptive Moment (Adam). Penelitian ini menggunakan bahasa pemrograman matlab 2018a. Hasil dari penelitin ini adalah klasifikasi citra thorax dengan model arsitektur ResNet-50 yang sudah dioptimasi dengan menggunakan Adaptive Moment (Adam) menghasilkan akurasi mencapai 97,5%.

Kata kunci— Pneumonia, Klasifikasi Pneumonia, Citra Thorax ,CNN.

I. PENDAHULUAN

Pneumonia merupakan penyakit infeksi saluran pernafasan akut yang terjadi pada jaringan paru (*alveoli*). Infeksi yang terjadi pada jaringan paru tersebut disebabkan oleh bakteri, virus jamur ataupun parasit [1]. Penyakit ini dapat menyebabkan demam tinggi, sesak nafas atau kesulitan bernafas serta pucat apabila telah mengalami kekurangan oksigen. Terdapat banyak faktor penyebab *pneumonia* yaitu kondisi individu, perilaku gaya hidup dan yang paling utama adalah keadaan lingkungan. *Pneumonia* menjadi penyebab kematian balita terbesar 20% di Indonesia (Riskesdas, 2019). Pada pasien dewasa penyakit pneumonia paling tinggi terjadi pada kelompok usia 56-65 tahun. Hal tersebut bisa terjadi karena adanya perubahan anatomi fisiologi akibat proses penuaan yang menimbulkan konsekuensi penting cadangan fungsional paru dan penurunan daya tahan tubuh. Pada umumnya diagnosa penyakit *pneumonia* dilakukan secara klinis atau pemeriksaan gejala fisik oleh dokter. Selain itu pemeriksaan lanjutan yang bisa dilakukan adalah x-ray thorax dengan tujuan untuk memperoleh gambar bagian paru-paru yang mengalami ketidaknormalan. Pemeriksaan x-ray thorax merupakan tes pencitraan menggunakan jenis radiasi yang disebut gelombang elektromaknetik [2]. Hasil pemeriksaan tersebut akan menghasilkan sebuah citra atau disebut juga dengan citra thorax yang menampilkan penampang organ tubuh bagian dalam manusia khususnya pada bagian rongga dada.

Citra thorax merupakan alat investigasi yang efisien dalam mengungkapkan perubahan patologi[3]. Pemeriksaan yang lebih teliti diperlukan dari setiap perubahan pada organ-organ yang ada di rongga dada, terutama paru-paru. Namun, citra yang diamati secara manual kurang efektif dalam menentukan suatu diagnosa, sehingga menyebabkan analisis secara visual untuk objek jaringan atau organ yang menjadi perhatian sulit dilakukan. Hal tersebut dipengaruhi oleh beberapa faktor seperti kesamaan visual yang tinggi antara sejumlah patologi[4], nois sensor, gangguan elektronik, dan posisi pasien yang dapat merubah visualisasi citra thorax yang sebenarnya[5]. Munculnya permasalahan pada penalaran kompleks membutuhkan pengamatan yang cermat dan keahlian khusus tentang prinsip-prinsip anatomi fisiologi dan patologi [6]. Sehingga memerlukan waktu yang lama sebelum tenaga medis atau dokter mendiaknosa penyakit yang diderita oleh pasien.

Dengan demikian diperlukan sebuah teknik yang dapat mempermudah dokter untuk mencermati suatu keabnormalan dengan cepat dan tepat. Teknik pengolahan citra digital merupakan salah satu produk pengembangan dari teknologi komputasi. Pengolahan data citra medis berbasis komputer

atau sebuah sistem yang dapat mengklasifikasikan citra thorax kedalam kelas tertentu akan sangat membantu dokter dalam melengkapi diagnosa penyakit dan observasi kondisi tubuh pasien. Konsep *machine learning* dapat digunakan untuk menyelesaikan permasalahan seperti ini. *Machine learning* menerapkan konsep yaitu sebuah komputer belajar hal-hal yang belum pernah dia kenal yang berasal dari banyak data [7]. Metode yang digunakan untuk memproses data adalah *Convulutional Neural Network* (CNN). CNN merupakan pengembang dari *Multilayer Perceptron* (MLP) dan termasuk ke dalam jenis *Deep Neural Network* karena tingkat kedalaman jaringan yang tinggi dan merupakan salah satu model *neural network* yang banyak digunakan untuk keperluan pengolahan citra[8].

Proses klasifikasi dilakukan untuk menemukan sebuah model atau fungsi yang menjelaskan dan mencirikan konsep atau kelas untuk kepentingan tertentu[9]. Metode klasifikasi CNN memiliki beberapa model arsitektur populer yang banyak digunakan antara lain AlexNet, DenSeNet, GoogLeNet, VGGNet, dan ResNet. Beberapa penelitian sebelumnya telah dilakukan untuk menyelesaikan kasus klasifikasi menggunakan model metode ini. Wang, Xiaosong et al. [10] melakukan komparasi terhadap 4 model CNN sekaligus yaitu AlexNet, GoogLeNet, VGGNet, dan ResNet. Keempat model digunakan untuk menyesaikan klasifikasi terhadap 14 kelas patologi pada citra ChestX-ray. Dimpy Varshni et al. [11] melakukan studi tentang pendeteksian *pnemonia* menggunakan model CNN DeseNet dengan capaian akurasi 75%. Model CNN ResNet telah digunakan [12] untuk deteksi pneumonia pada x-ray dengan hasil akurasi 94,23%.

Akan tetapi, pada penelitian sebelumnya arsitektur CNN yang digunakan masih perlu ditingkatkan akurasinya sehingga perlu untuk dikembangkan. Pada penelitian ini, ada beberapa teknik yang akan digunakan untuk meningkatkan hasil akurasi sebuah arsitektur CNN salah satunya adalah *Adaptive Moment* (Adam). *Adaptive Moment* (Adam) merupakan algoritma optimasi tingkat pembelajaran adaptif [13] Model CNN yang akan dioptimalkan adalah arsitektur ResNet dikarenakan pada penlitian [10] dan [11] pada model arsitektur ResNet menunjukan tingkat rata-rata akurasi tertinggi.

Penelitian ini bertujuan untuk mengklasifikasikan citra thorax dengan memanfaatkan metode CNN yang dioptimalkan dengan Adam. Klasifikasi dilakukan pada citra thorax dengan 2 kelas *pneumonia* dan normal. Kedua arsitektur CNN (Alexnet dan ResNet) digunakan sebagai pembanding untuk mengetahui kinerja arsitektur ResNet yang telah dioptimasi.

II. METODOLOGI PENELITIAN

Kerangka penelitian pada Gambar 1 menjelaskan alur kerja dalam kajian ini. Secara garis besar, penelitian ini terdiri dari 3 tahap, yaitu *image preprocesssing*, proses pembelajaran, dan klasifikasi dengan optimasi Adam. Dataset yang digunakan dalam penelitian ini adalah citra thorax dalam bentuk gambar digital dari mesin x-ray sebanyak 2.200 citra thorax yang telah didiagnosa oleh dokter sebelumnya. Data tersebut dibagi untuk keperluan pembelajaran sebanyak 1.760 sampel dengan rincian 880 citra thorax paru-paru normal, 880 sampel citra thorax paru-paru *pneumonia*. Untuk keperluan pengujian sebanyak 440 sampel dengan rincian 220 sampel citra thorax normal dan 220 sampel citra thorax *pneumonia*. Sebaran data pada dataset berdasarkan label kondisi disajikan pada Tabel 1.

Tabel 1. Sebaran data pada dataset berdasarkan label kondisi

Bagian	Jumlah Data	Kondisi	Jumlah
Data pembelajaran	1760	Normal	880
		Pneumonia	880
Data Uji	440	Normal	220
		Pneumonia	220
	Total		**2200**

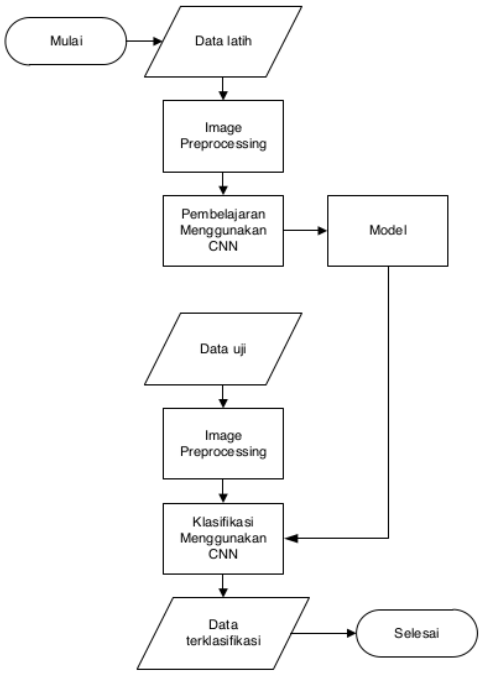

Gambar 1. Kerangka penelitian

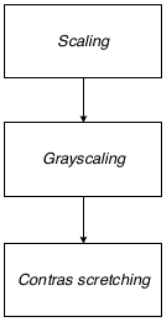

Gambar 2. Tahapan *image preprocessing*

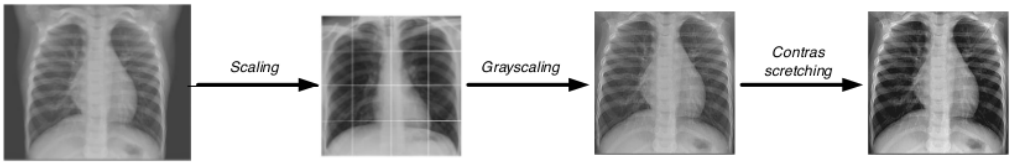

Gambar 4. Pemodelan klasifikasi ResNet-50

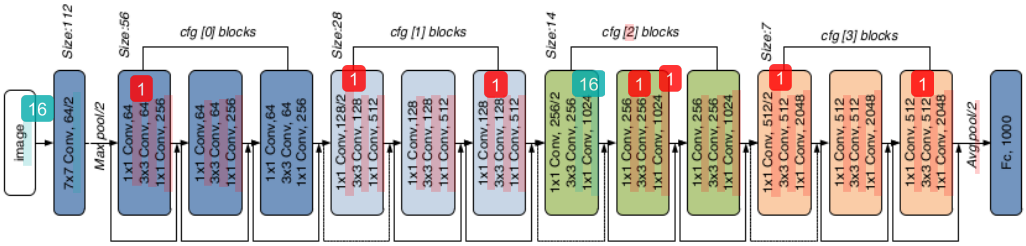

Gambar 3. Pemodelan *image preprocessing*

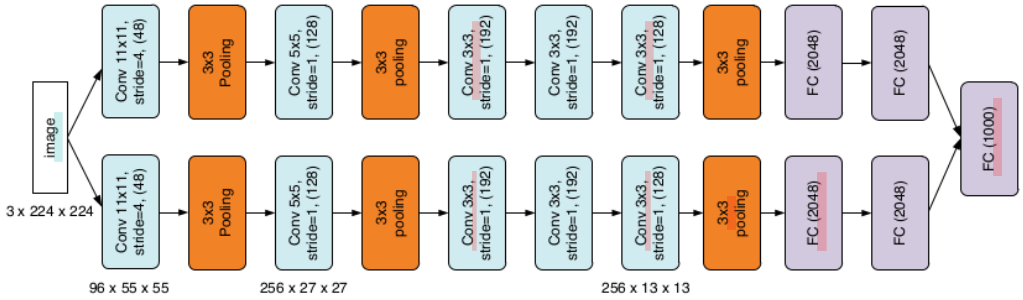

Gambar 5. Pemodelan klasifikasi Alexnet

Dataset citra thorax yang diperoleh dalam bentuk digital merupakan data mentah sehingga dibutuhkan tahap *image preprocessing* untuk menyiapkan dataset tersebut sebelum dilakukan proses pembelajaran dengan CNN. Tahapan *image preprocessing* yang dilakukan pada penelitian ini meliputi *scaling, grayscaling*, dan *scretching* yang disajikan pada gambar 2. *Scaling* merupaka tahap yang dibutuhkan untuk mengatur ukuran piksel pada citra. Semakin banyak jumlah piksel maka akan semakin banyak waktu untuk proses pengolahan citra.

Setelah dilakukan *scaling*, kemudian citra diubah menjadi *grayscale* dimana tahapan ini bertujuan untuk menyeragamkan warna keabuan pada citra yang akan diproses. Tahap terakhir adalah *contrast scretching* tahap ini bertujuan untuk mendapatkan citra baru dengan kontras yang lebih bagus daripada citra asalnya. Perbaikan citra dengan *contras stretching* merupakan operasi titik pada citra asli, dengan kata lain proses ini hanya tergantung pada nilai intensitas (*gray level*) satu piksel dan tidak tergantung pada piksel lain disekitarnya. Proses dari *contrasr stretching* dilakuakn dengan meningkatkan bidang dinamika *gray level* pada citra yang akan diproses. Pemodelan *image preprocessing* disajikan pada Gambar 3.

Data citra yang melalui proses pembelajaran merupakan citra yang telah diperbaiki kualitasnya. Model proses pembelajaran untuk ektraksi fitur dibangun berdasarkan arsitektur ResNet-50 dan Alexnet. Dalam penelitian ini, model arsitektur ResNet-50 dipilih sebagai arsitektur standar karena merupakan arsitektur klasifikasi CNN yang memiliki jaringan dalam dengan fitur jaringan saraf *residual* yang memanfatkan koneksi skip atau jaringan pintas untuk melompati beberapa layer[14]. Jaringan ini berfungsi untuk menghindari masalah hilangnya gradien, dengan mengunakan kembali aktivasi dari jaringan sebelumnya sampai pada lapisan yang berdekatan dapat mempelajari bobotnya. Selain itu, arsitektur ResNet-50 memiliki performa yang baik dalam beberapa kasus klasifikasi gambar[10]. Pemodelan arsitektur ResNet-50 disajikan pada Gambar 4. Arsitektur Alexnet digunakan sebagai arsitektur pembanding untuk arsitektur standar ResNet-50. Pemodelan arsitektur Alexnet disajikan pada Gambar 5.

$$(i,j) = (I * K(i,j) = \sum_m \sum_n I(i+m, j+n)K(m,n) \quad \ldots\ldots(1)$$

Pada tahap pembelajaran, pertama dilakukan konvolusi pada input gambar. Hasil konvolusi akan membentuk filter 64 buah, kemudian operasi konvolusi disajikan pada persamaan (1). Setiap elemen pada metrik *I* dan *K* mengalami perkalian

sehingga menghasilkan filter *S*. Pada tahap ini model belum memasuki modul *residual*. Setelah tahap ini selesai, gambar akan memasuki *pooling layer*. *Pooling layer* adalah lapisan yang bertugas untuk mengurang resolusi dari suatu gambar yang telah diproses, *pooling layer* berfungsi untuk mengurang nois yang ada dalam gambar tersebut. Terdapat dua jenis *pooling*, yaitu *max pooling* dan *average pooling,* ilustrasi operasi tersebut disajikan pada gambar 6.

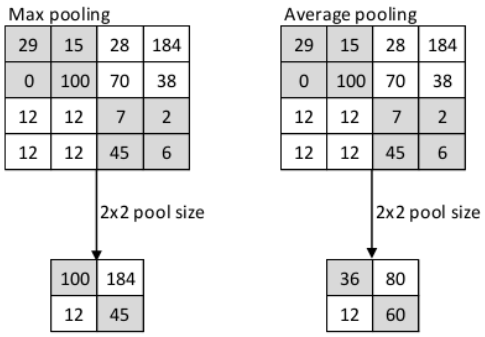

Gambar 6. Ilustrsi operasi *pooling layer*.

Pada tahapan modul *residual,* tiga modul *residual* ditumpuk di atas masing-masing layer dan setiap layer akan mempelajari 64 filter untuk setiap proses konvolusi. Dimensi spasial pada gambar akan berkurang, kemudian akan ditumpuk kembali 3 buah modul *residual*. Setiap modul akan mempelajari 128 filter. Tahap selanjutnya ditumpuk kembali 3 buah modul *residual*, dengan setiap modul akan mempelajari 256 filter. Pada tahap terakhir, dimensi spasial akan dikurangi lagi dengan menumpuk 3 buah modul *residual*. Setiap layer akan mempelajari 512 filter. Hasil dari setiap filter ini akan melewati *average pooling* dan masuk ke dalam jaringan *fully connected* dengan fungsi aktivasi *softmax* untuk diketahui hasil klasifikasinya.

Dalam proses *fully connected* dilakukan proses klasifikasi sesuai kelas yang sudah dideklarasikan. Pada tahap ini seluruh lapisan neuron saling terhubung. Untuk menghitung probabilitas dalam pemilihan kelas digunakan *softmax*. *Softmax* berguna untuk mengubah output dari lapisan terakhir dalam *fully connected* layer menjadi distribusi probabilitas. Keunggulan menggunakan softmax adalah rentang nilai keluaran yang diberikan antara 0 hingga 1 dan jumlah semua probabilitasnya sama dengan satu. Hasil klasifikasi arsitektur ResNet-50 dioptimasi menggunakan Adam *(adaptive moments)*. Adam merupakan kombinasi RMSProp dan momentum dengan beberapa perbedaan penting. Pertama, momentum digabungkan secara langsung sebagai perkiraan momen orde pertama (dengan bobot eksponensial) dari gradien. Kedua, Adam memasukkan koreksi-koreksi bias ke estimasi momen-momen orde pertama (*momentum term*) dan momen-momen orde kedua (tidak terpusat) untuk menjelaskan inisiasi *origin*. Output dari pemilihan jumlah *epochs* optimasi adalah meningkatnya akurasi serta menurunnya *loss function* pada data pembelajaran walaupun dengan menggunakan CNN yang sama. Teknik pengujian dilakukan dengan proses *K-Fold cross validation*. Pada tahapan teknik pengujian 80% data digunakan untuk data pembelajaran dan 20% data untuk data uji. Evaluasi model pada penelitian ini digunakan untuk mengukur keakuratan arsitektur CNN dalam klasifikasi. Seluruh kinerja arsitektur CNN untuk klasifikasi dievaluasi menggunakan matriks konfusi untuk mendapatkan nilai *akurasi, percision dan recall*. Implementasi kerangka penelitian ini menggunakan perangkat lunak Matlab 2018a.

III. HASIL DAN PEMBAHASAN

Proses pembelajaran menggunakan data 2.200 citra thorax yang telah didiagnosa oleh dokter sebelumnya. Data tersebut dibagi untuk keperluan pembelajaran sebanyak 1.760 sampel dengan rincian 880 citra thorax paru-paru normal, 880 sampel citra thorax paru-paru *pneumonia*. Untuk keperluan pengujian sebanyak 440 sampel dengan rincian 220 sampel citra thorax normal dan 220 sampel citra thorax *pneumonia*. Tahap pertama data pembelajaran diproses dengan metode CNN dengan model arsitektur standar ResNet-50 dan Alexnet.

Arsitektur ResNet-50 menghasilkan rata-rata *class precision* sebesar 94,1% dan rata-rata *class recall* sebesar 94,3%. Seperti ditunjukan pada Tabel 2. Nilai akurasi yang diperoleh dari model arsitektur ResNet-50 sebesar 94,1% dengan durasi komputasi 35 menit 40 detik.

Tabel 2. Matriks konfusi klasifikasi citra thorax dengan model arsitektur ResNet-50

		Nilai Benar		
		Normal	**Pneumonia**	**Class Precision**
Nilai Prediksi	Normal	215	5	97,7%
	Pneumonia	21	199	90,5%
	Class Recall	91,1%	97,5%	

Tabel 3 menunjukan matriks konfusi yang dihasilkan dengan model arsitektur Alexnet sebagai metode pembanding. Metode ini menghasilkan rata-rat *class precision* sebesar 96,8% dan rata-rat *class recall* 96,9%. Nilai akurasi yang didapatkan mencapai 96,8% dengan durasi komputasi 10 menit 15 detik.

Tabel 3. Matriks konfusi klasifikasi citra thorax dengan model arsitektur Alexnet

		Nilai Benar		
		Normal	**Pneumonia**	**Class Precision**
Nilai Prediksi	Normal	209	11	95,0%
	Pneumonia	3	217	98,6%
	Class Recall	98,6%	95,2%	

Perbandingan akurasi model arsitektur ResNet-50 dan model Arsitektur Alexnet disajikan pada Tabel 4. Model arsitektur Alexnet memberikan nilai yang lebih baik dari pada model arsitektur ResNet-50, yaitu dengan nilai akurasi mencapai 96.8% dengan durasi waktu 10 menit 15 detik. Hal ini tidak sejalan dengan[12] yang menyatakan bahwa ResNet-50 lebih unggul daripada Alexnet dengan nilai akurasi ResNet-50 sebesar 94,23% dibandingkan Alexnet sebesar 92,86%. Kajian tersebut nengklasifikasikan citra x-ray dengan dua kelas yaitu *pneumonia* dan normal. Model arsitektur ResNet-50 mendapatkan akurasi yang baik karena memiliki kedalaman layer yang tinggi dan menggunakan sebuah jaringan bernama *residual blok*. Pada jaringan ini dapat menghindari masalah hilangnya gradien pada tingkat kedalam tertentu pada suatu jaringan sehingga dapan meningkatkan akurasi. Sedangkan pada Alexnet memiliki jaringan dengan tingkat kedalaman sederhana dengan 8 layer. Alexnet memiliki kelebihan pada durasi komputasi yang lebih cepat karena dapat bekerja pada dua GPU yang berbeda.

Tabel 4. Hasil perbandingan model arsitektur ResNet-50 dan model arsitektur Alexnet.

Parameter	Resnet-50	Alexnet
Akurasi	94,1%	96,8%
Waktu (m)	35:40	10:15

Hasil klasifikasi ResNet-50 yang lebih rendah daripada Alexnet (Tabel 4). Hal ini dapat disebabkan karena ResNet-50 tidak begitu akurat pada data yang memiliki variasi visual yang sangat banyak pada kelas tertentu dengan jumlah data yang sedikit, hal ini sejalan dengan [10]. Dalam kajian tersebut pada kelas patologi "mass" dengan jumlah 2.139 data, ResNet-50 memiliki akurasi yang lebih rendah dibandingkan Alexnet. Oleh karena itu pada penelitian ini dilakukan optimasi pada model arsitektur ResNet-50 menggunakan algoritma Adam dengan membandingkan beberapa jumlah *epoch* untuk mendapatkan akurasi yang maksimal. Optimasi Adam digunakan karena memiliki teknik *bias corection* yang memberikan aproksimasi lebih baik dibandingkan dengan algoritma optimasi lainnya.

Tahap kedua penerapan optimasi terhadap model arsitektur standar ResNet-50. Penerapan optimasi mengacu pada penentuan jumlah *epoch* pada saat proses pembelajaran dengan memperhatikan durasi komputasi. Pemilihan jumlah *epoch* yang optimal dapat membentuk optimasi yang ideal untuk pemcahan masalah ini. Untuk mendapatkan jumlah *epoch* terbaik, pengujian optimasi dilakukan dengan jumlah *epoch* 5, 10, dan 15. Pengujian pertama akan dilakukan dengan algoritma optimasi Adam, sedangkan pengujian kedua sebagai pembanding akan digunakan algoritma optimasi lain yaitu RMSProp.

Hasil pengujian pertama pada model arsitektur ResNet-50 dengan optimasi Adam disajikan pada Tabel 5. Dengan jumlah *epoch* 15 memperoleh hasil terbaik dengan akurasi 97,5% dengan waktu komputasi 49 menit 43 detik. Waktu komputasi meningkat saat jumlah *epoch* ditingkatkan, walaupun nilai akurasi yang diperoleh tidak selalu meningkat.

Hasil pengujian kedua pada model arsitektur ResNet-50 dengan optimasi RMSProp disajikan pada tabel 6. Hasil terbaik justru sebaliknya diperoleh pada jumlah *epoch* terkecil yaitu 5 *epoch* denga akurasi 96,36% dengan durasi komputasi 15 menit 17 detik. Hasil tersebut masih dibawah akurasi dari model arsitektur ResNet-50 dengan optimasi Adam. Matriks konfusi model arsitektur ResNet-50 menggunakan optimasi Adam dengan jumlah *epoch* terbaik disajikan pada Tabel 7.

Tabel 5. Hasil pengujian model arsitektur ResNet-50 dengan optimasi Adam

Epoch	Akurasi	Waktu (menit)
5	96,36%	18:51
10	95,23%	33:02
15	97,5%	49:43

Tabel 6. Hasil pengujian model arsitektur ResNet-50 dengan optimasi RMSProp

Epoch	Akurasi	Waktu (menit)
5	96,36%	15:17
10	94,77%	26:33
15	95%	40:36

Berdasarkan evaluasi proses pengujian optimasi pertama dan kedua menggunakan *K-fold cross validation* dapat dinyataka bahwa metode optimasi Adam terbukti dapat meningkatkan hasil akurasi. Dalam model arsitektur ResNet-50 diberikan kombinasi yang ideal dengan pemilihan jumlah *epoch* yang tepat walaupun waktu komputasi berjalan lebih lama. Hal ini sejalan dengan [15] bahwa dengan optimasi Adam dapat meningkatkan hasil akurasi karena memiliki teknik *bias corection* yang memberikan aproksimasi lebih baik yang dapat meningkatkan akurasi.

Tabel 7. Matrik konfusi klasifikasi citra thorax menggunakan model arsitektur ResNet-50 dengan optimasi Adam

		Nilai Benar		
		Normal	**Pneumonia**	**Class Precision**
Nilai Prediksi	Normal	216	4	98,2%
	Pneumonia	9	211	95,9%
	Class Recall	96,0%	98,1%	

Perbandingan matrik konfusi dengan model arsitektur standar (ResNet-50 dan Alexnet) dan metode optimasi terbaik (ResNet-50 + Adam) disajikan pada Tabel 8 berdasarkan Tabel 2, Tabel 3, dan Tabel 7. Model arsitektur ResNet-50 dengan menggunakan optimasi Adam dapat meningkatkan akurasi klasifikasi citra thorax sebesar 3,61% dari akurasi 94,1% yang menggunakan model arsitektur ResNet-50 standar. Hasil optimasi ResNet-50 menggunakan Adam juga lebih baik dibandingkan dengan hasil akurasi dari model arsitektur Alexnet. Dari Tabel 8 dapat digambarkan grafik perbandingan

akurasi klasifikasi dari model arsitektur tersebut yang disajikan pada Gambar 7.

Tabel 8. Hasil perbandingan model arsitektur ResNet-50, Alexnet dan ResNet-50+Adam.

Parameter	Alexnet	ResNet-50	ResNet-50 +Adam
Epoch	15	15	15
Iterasi	825	795	825
Waktu (m)	10:15	35:40	49:43
Akurasi	96,8%	94,1%	97,5%
Presisi	96,8%	94,1 %	97,5%
Recall	96,9%	94,3 %	97,05%

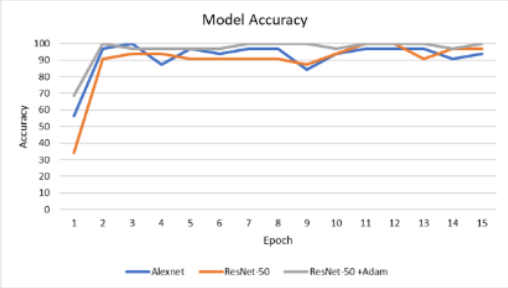

Gambar 7. Grafik perbandingan akurasi Alexnet, ResNet-50 dan ResNet-50 + Adam.

Pada Gambar 7, grafik menunjukkan proses pembelajaran pada ketiga model arsitektur Alexnet, ResNet-50 dan ResNet-50 dengan optimasi Adam mengalami peningkatan akurasi yang signifikan pada *epoch* 2. Pada *epoch* selanjutnya semua jaringan terjadi kenaikan akurasi secara perlahan, namun pada ResNet-50 kenaikan tidak signifikan hanya pada *epoch* 11 dan 12 yang memiliki akurasi tinggi. Hasil akhir akurasi rata-rata mencapai 94,1%. Pada Alexnet kenaikan akurasi tertinggi terjadi pada *epoch* 3, namun pada *epoch* selanjutnya akurasi cenderung naik turun. Akan tetapi, akurasi Alexnet masih diatas rata-rata akurasi ResNet-50 dengan hasil akhir rata-rata akurasi mencapai 96,8%. ResNet-50 dengan optimasi Adam menunjukkan grafik peningkatan akurasi paling konsisten pada setiap *epoch* diantara ketiga model arsitektur tersebut dengan capaian hasil akhir rata-rata akurasi mencapai 97,5%. Hasil tersebut menunjukkan bahwa Model arsitektur ResNet-50 dengan optimasi Adam dapat meningkatkan akurasi yang lebih tinggi dan memiliki tingkat akurasi yang lebih konsisten disetiap *epoch* dibandingkan dengan model arsitektur standar Alexnet dan ResNet-50.

IV. Conclusion

Metode CNN dengan model arsitektur ResNet-50 dan optimasi Adam *(Adaptive Moment)* dapat meningkatkan akurasi dalam malakukan klasifikasi pada citra thorax dibandingkan dengan model arsitektur ResNet-50 dan Alexnet standar. Model pada kajian ini dapat dipertimbangkan untuk diterapkan pada kasus klasifikasi citra thorax agar *pneumonia* dapat segera terdeteksi. Dengan demikian teknik tersebut dapat mempermudah dokter untuk mencermati suatu keabnormalan dengan cepat dan tepat dalam melengkapi diagnosa penyakit serta observasi kondisi tubuh pasien agar dapat segera ditangani.

Reference

[1] Puddy and C. Hill, "Interpretation of the chest radiograph," *Contin. Educ. Anaesthesia, Crit. Care Pain*, vol. 7, no. 3, pp. 71–75, 2007, doi: 10.1093/bjaceaccp/mkm014.

[2] B. Kelly, "The chest radiograph," *Ulster Med. J.*, vol. 81, no. 3, pp. 143–148, 2012, doi: 10.1016/b978-0-323-39952-4.00004-4.

[3] N. Singh, "Wavelet Transform Based Pneumonia Classification of Chest X- Ray Images," *2019 Int. Conf. Comput. Power Commun. Technol.*, pp. 540–545, 2019.

[4] A. Sharma, D. Raju, and S. Ranjan, "Detection of pneumonia clouds in chest X-ray using image processing approach," *2017 Nirma Univ. Int. Conf. Eng. NUiCONE 2017*, vol. 2018-Janua, pp. 1–4, 2018, doi: 10.1109/NUICONE.2017.8325607.

[5] B. Li, G. Kang, K. Cheng, and N. Zhang, "Attention-Guided Convolutional Neural Network for Detecting Pneumonia on Chest X-Rays," *2019 41st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, pp. 4851–4854, 2019, doi: 10.1109/embc.2019.8857277.

[6] S. Sedai, D. Mahapatra, Z. Ge, R. Chakravorty, and R. Garnavi, *Deep multiscale convolutional feature learning for weakly supervised localization of chest pathologies in X-ray images*, vol. 11… LNCS. Springer, 2018.

[7] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," *Proc. 2017 Int. Conf. Eng. Technol. ICET 2017*, vol. 2018-Janua, no. August, pp. 1–6, 2018, doi: 10.11…ICEngTechnol.2017.8308186.

[8] S. J. Heo *et al.*, "Deep learning algorithms with demographic information help to detect tuberculosis in chest radiographs in annual workers' health examination data," *Int. J. Environ. Res. Public Health*, vol. 16, no. 2, 2019, doi: 10.3390/ijerph16020250.

[9] S. Defiyanti, "Integrasi metode klasifikasi dan clustering dalam data mining," 2017, pp. 33–34.

[10] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "ChestX-ray: Hospital-Scale Chest X-ray Database and Benchmarks on Weakly Supervised Classification and Localization of Common Thorax Diseases," *Adv. Comput. Vis. Pattern Recognit.*, pp. 369–392, 2019, doi: 10.1007/978-3-030-13969-8_18.

[11] D. Varshni, K. Thakral, L. Agarwal, R. Nijhawan, and A. Mittal, "Pneumonia Detection Using CNN based Feature Extraction," *Proc. 2019 3rd IEEE Int. Conf. Electr. Comput. Commun. Technol. ICECCT 2019*, pp. 1–7, 2019, doi: 10.1109/ICECCT.2019.8869364.

[12] V. Chouhan *et al.*, "A novel transfer learning based approach for pneumonia detection in chest X-ray images," *Appl. Sci.*, vol. 10, no. 2, 2020, doi: 10.3390/app10020559.

[13] V. Srinivasan, A. R. Sankar, and V. N. Balasubramanian, "ADINE: An adaptive momentum method for stochastic gradient descent," *ACM Int. Conf. Proceeding Ser.*, no. December 2017, pp. 249–256, 2018, doi: 10.1145/3152494.3152515.

[14] K. H. Mahmud, Adiwijaya, and S. Al Faraby, "Klasifikasi Citra Multi-Kelas Menggunakan Convolutional Neural Network," *e-Proceeding Eng.*, vol. 6, no. 1, pp. 2127–2136, 2019.

[15] R. Poojary and A. Pai, "Comparative Study of Model Optimization Techniques in Fine-Tuned CNN Models," in *2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA)*, 2019, pp. 1–4, doi: 10.1109/ICECTA48151.2019.8959681.

Klasifikasi Pneumonia pada Citra Thorax dengan Convolutional Neural Network

ORIGINALITY REPORT

%15	%13	%8	%0
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	web.cs.hacettepe.edu.tr Internet Source	%2
2	journal.stats.id Internet Source	%2
3	ejournal.unitomo.ac.id Internet Source	%2
4	export.arxiv.org Internet Source	%1
5	etheses.uin-malang.ac.id Internet Source	%1
6	Rogelio Ruzcko Tobias, Luigi Carlo De Jesus, Matt Ervin Mital, Sandy Lauguico et al. "Android Application for Chest X-ray Health Classification From a CNN Deep Learning TensorFlow Model", 2020 IEEE 2nd Global Conference on Life Sciences and Technologies (LifeTech), 2020 Publication	%1

7	Suhono Harso Supangkat, Fadhil Hidayat, Iqbal Ahmad Dahlan, Faqih Hamami. "The Implementation of Traffic Analytics Using Deep Learning and Big Data Technology with Garuda Smart City Framework", 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE), 2019 Publication	%1
8	ejournal.uin-malang.ac.id Internet Source	<%1
9	www.researchgate.net Internet Source	<%1
10	id.scribd.com Internet Source	<%1
11	Karthik D Patel, Siddesh M G, Ayushi Agarwal, Akshay Nihalani, M B Nirmala, Kavitha H. "Autonomous Malicious Video Content Categorization Using Convolutional Neural Networks", 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS), 2020 Publication	<%1
12	Peng Gang, Wang Zhen, Wei Zeng, Yuri Gordienko, Yuriy Kochura, Oleg Alienin, Oleksandr Rokovyi, Sergii Stirenko. "Dimensionality reduction in deep learning for	<%1

chest X-ray analysis of lung cancer", 2018 Tenth International Conference on Advanced Computational Intelligence (ICACI), 2018
Publication

13	Suprijanto ., Farida I Muchtadi, Irwan Setiawan. "SEGMENTASI CITRA SECARA SEMI-OTOMATIS UNTUK VISUALISASI VOLUMETRIK CITRA CT-SCAN PELVIS", MAKARA of Technology Series, 2010 Publication	<%1
14	sim.stts.edu Internet Source	<%1
15	www.ijitee.org Internet Source	<%1
16	Brendan Jou, Shih-Fu Chang. "Deep Cross Residual Learning for Multitask Visual Recognition", Proceedings of the 2016 ACM on Multimedia Conference - MM '16, 2016 Publication	<%1
17	Mohd Hanafi Ahmad Hijazi, Stefanus Kieu Tao Hwa, Abdullah Bade, Razali Yaakob, Mohammad Saffree Jeffree. "Ensemble deep learning for tuberculosis detection using chest X-ray and canny edge detected images", IAES International Journal of Artificial Intelligence (IJ-AI), 2019 Publication	<%1

18	collections.lib.utah.edu Internet Source	<%1
19	Bambang Krismono Triwijoyo. "Model Fast Tansfer Learning pada Jaringan Syaraf Tiruan Konvolusional untuk Klasifikasi Gender Berdasarkan Citra Wajah", MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, 2019 Publication	<%1
20	genesis.ukdw.ac.id Internet Source	<%1
21	www.scribd.com Internet Source	<%1
22	Nur Wakhidah. "PERBAIKAN KUALITAS CITRA MENGGUNAKAN METODE CONTRAST STRETCHING", Jurnal Transformatika, 2011 Publication	<%1
23	digilib.unila.ac.id Internet Source	<%1
24	pt.scribd.com Internet Source	<%1
25	media.neliti.com Internet Source	<%1
26	www.sifloresta.ufv.br Internet Source	<%1

27	iith.ac.in Internet Source	<%1
28	www.mdpi.com Internet Source	<%1

EXCLUDE QUOTES	ON	EXCLUDE MATCHES	OFF
EXCLUDE BIBLIOGRAPHY	OFF		