

KLASIFIKASI PNEUMONIA DENGAN METODE CONVOLUTIONAL NEURAL NETWORK

Ahmad Nabil Dzul Afkar, Aeri Rachmad, Eka Mala Sari Rochman

Sistem Informasi, Universitas Trunojoyo Madura

Jl. Raya Telang, Perumahan Telang Indah, Telang, Kamal, Kabupaten Bangkalan

Nbldzul19@gmail.com

ABSTRAK

Pneumonia adalah infeksi akut pada paru-paru yang disebabkan oleh mikroorganisme seperti virus, bakteri, jamur, dan parasit. Penyakit ini dapat menyerang berbagai usia, terutama balita dan orang tua, namun, balita dan orang tua yang paling sering terdampak. Diagnosis pneumonia masih bergantung pada tenaga medis yang berpengalaman, sehingga diperlukan metode otomatis yang dapat meningkatkan akurasi dan efisiensi dalam deteksi pneumonia. Dengan memanfaatkan pendekatan *Deep Learning*, khususnya *Convolution Neural Network* (CNN) yang menjadi pilihan populer dalam klasifikasi gambar dan analisis visual, Penelitian ini bertujuan mengembangkan model CNN berbasis ResNet50 untuk mengklasifikasikan gambar rontgen dalam mendeteksi pneumonia. Model ini dapat memberikan solusi otomatis yang lebih efisien dalam membantu tenaga medis, serta meningkatkan akurasi diagnosis penyakit pneumonia menggunakan ResNet50. Dalam penelitian ini klasifikasi pneumonia menggunakan dataset Chest X-Ray Images yang di ambil dari kaggle dengan format JPG. Dataset berisi citra x-ray dada normal dan pneumonia. Data berjumlah 5.856 gambar yang terbagi kedalam 2 kelas yakni, 1.583 normal dan 4.273 pneumonia. Hasil eksperimen menunjukkan bahwa model ResNet50 dengan *optimizer* yang digunakan adalah *Stochastic Gradient Descent Momentum* (SGD-M) dengan *learning rate* 0.1 menghasilkan penelitian data train di dapat akurasi sebesar 95.43%, sedangkan tahap pelatihan data test mendapatkan akurasi sebesar 92.25% tingkat akurasi sudah cukup layak.

Kata kunci : pneumonis, klasifikasi, convolutional neural network, resnet50

1. PENDAHULUAN

Pneumonia adalah infeksi atau peradangan akut pada jaringan paru-paru yang disebabkan oleh berbagai mikroorganisme, termasuk virus, jamur, bakteri, parasite, jajanan yang mengandung bahan kimia, atau kerusakan pada paru-paru[1].

Pneumonia dapat menyerang berbagai usia, seperti anak-anak, remaja, dewasa, dan orang tua, namun, balita dan orang tua yang paling sering terdampak[2].

Angka kasus *Pneumonia* lebih sering di temukan di negara berkembang. Berdasarkan RISKESDES tahun 2018, prevalensi pneumomonia berdasarkan diagnosis tenaga keseharan yaitu sekitar 2%, sedangkan tahun 2013 adalah 1,8%. Berdasarkan data kemenkes 2014, jumlah penderita pneumonia di Indonesia tahun 2013 sekitar 23%-27% dengan kematian akibat pneumonia di indonesia sebesar 1,19%[3].

Dalam hal ini diagnosis pneumonia melalui citra rontgen masih bergantung pada tenaga medis yang berpengalaman, sehingga diperlukan metode otomatis yang dapat meningkatkan akurasi dan efisiensi dalam deteksi pneumonia.

Pada era digital saat ini menawarkan kemajuan Teknologi Informasi (TI) yang pesat, terutama dalam bidang computer vision. Potensi ini dapat dimanfaatkan untuk pendeteksian otomatis objek tertentu, seperti penyakit pneumonia [4].

Pendekatan yang banyak digunakan dalam bidang computer saat ini menggunakan *Deep learning*, khususnya *Convolution Neural Network* (CNN) yang

menjadi pilihan populer dalam klasifikasi gambar dan analisis visual[5].

Metode *Convolution Neural Netwok* merupakan algoritma deep learning, yang dirancang untuk memproses data citra dan secara otomatis mengekstraksi fitur spasial tanpa perlu intervensi manual dalam pemrograman fitur[6].

CNN telah diterapkan dalam berbagai bidang, seperti pengenalan wajah, deteksi objek, dan klasifikasi warna, berkat kemampuannya yang kuat dalam menganalisis citra[7].

Untuk penelitian terkait klasifikasi pneumonia telah banyak dilakukan dengan menggunakan berbagai metode yang beragam. Penelitian ini dilakukan Klasifikasi *Pneumonia* dengan *Deep Learning* *Faster Region Convolutional Neural Network* *Arsitektur VGG16* Dari pelatihan yang dilakukan arsitektur VGG16 mempunyai nilai akurasi sebesar 70,3% dengan loss sebesar 2,712[8].

Sedangkan penelitian lainya yang dilakukan menggunakan metode *Support Vector Machine* (SVM) hasil menunjukkan bahwa akurasi terbaik yang dapat di capai sebesar 62,66%[9].

Berdasarkan penelitian yang sudah ada banyak peran penelitian yang memakai metode *Convolutional Neural Network* (CNN) untuk pengenalan objek citra atau gambar, terutama pada penyakit pneumonia penelitian bertujuan untuk menerapkan teknolgi citra digital dengan metode *Convolution Neural Network* untuk mengklasifikasikan gambar paru-paru dalam mendeteksi pneumonia. CNN sendiri memiliki sendiri memiliki banyak arsitektur yang telah dibuat oleh

peneliti-peneliti terdahulu. Pada penelitian ini akan menggunakan model arsitektur ResNet50 dalam mengerjakan klasifikasi *pneumonia*, dengan cara mengambil data dari citra rogenten paru-paru yang akan di proses dengan model arsitektur ResNet50 sehingga mendapatkan hasil yang dapat membedakan paru-paru penderita *pneumonia* dan paru-paru normal.


2. TINJAUAN PUSTAKA

2.1. Anatomi paru-paru

Salah satu organ penting tubuh manusia adalah paru-paru. Tepatnya adalah organ pernapasan (respirasi) yang terhubung dengan sistem pernapasan dan sirkulasi darah. Salah satu fungsi utama organ ini adalah menukar oksigen dari udara dengan karbon dioksida dari darah, jika fungsi organ ini terganggu, maka akan berdampak pada kesehatan manusia secara keseluruhan[10].

Paru-paru terdiri dari paru-paru kanan dan paru-paru kiri, namun masing-masing memiliki fungsi yang berbeda. Misalnya paru-paru kiri orang dewasa secara umum memiliki berat 325-550 gram, sedangkan bagian kanan memiliki berat 375-600 gram. Normalnya paru-paru terbagi menjadi beberapa bagian yaitu : pleura, bronkus, bronkiolus, dan alveoli[11].

Seperti organ tubuh lainnya banyak penyakit juga dapat menyerang organ paru-paru, kondisi tersebut dapat menimbulkan gejala seperti sesak nafas, dan batuk tidak kunjung berhenti. Gangguan pada organ paru-paru biasanya bersifat akut (sementara) atau kronis (jangka panjang). Beberapa penyakit yang dapat menyerang organ paru-paru dan system pernapasan, antara lain : bronkitis, pneumonia, tuberculosis, asbetoris, asma, bronkiektasis, penyakit paru obstruktif kronis (PPOK), Covid-19, croup, emboli paru, fibrosis kistik, dan lain-lain.[12]




Gambar 1. Anatomi Paru-Paru


2.2. Pneumonia

Pneumonia adalah kondisi inflamasi yang terjadi saat paru-paru mengalami infeksi kantung udara. Untuk kondisi infeksi itu sendiri dapat menyebabkan peradangan pada kantung udara yang dimanakan alveoli sehingga dapat berakibat kantung udara dipenuhi cairan atau nanah sehingga mengakibatkan sulit untuk bernafas. Gangguan ini dapat menyebabkan

batuk berdahak atau bernanah, menggigil, demam, dan kesulitan bernafas.[13]



Gambar 2. Pneumonia



Gambar 3. Contoh rogenten pneumonia

2.3. Google Colaboratory

Google Colaboratory atau dikenal juga sebagai google colab adalah *tools* penelitian gratis dan berbasis *cloud* yang disediakan oleh google[14].

Bagi peneliti yang ingin menggunakan *machine learning* atau *deep learning* untuk mempelajari dan mengiliah data, google colab sangat membantu bagi peneliti yang memiliki keterbatasan dengan perangkat yang mereka gunakan. Pengguna akan memiliki akses ke *cloud* computer dengan google *cloud*, peneliti juga diberikan akses untuk menggunakan GPU secara gratis yang memungkinkan program berjalan selama 12 jam[15].

Google colab dibuat dengan menggunakan lingkungan jupyter notebook, yang hampir mirip dengan jupyter notebook yang menggunakan Bahasa pemrograman python, google colab juga mendukung hampir semua library umum untuk *machine learning*. Google colab dapat di integrasikan dengan google drive, yang memungkinkan pengguna untuk mengakses atau menyimpan data ke dalam google drive.[16]

2.4. Deep Learning

Deep Learning merupakan salah satu algoritma dalam machine learning, yang merupakan cabang dari *artificial intelligence* (AI) atau kecerdasan buatan. Di era modern, AI memainkan peran yang signifikan dalam berbagai aspek kehidupan. Algoritma deep learning memanfaatkan berbagai jenis jaringan saraf untuk menyelesaikan berbagai tugas, di mana masing-masing algoritma memiliki mekanisme kerja yang berbeda[17].

Deep learning sendiri merujuk pada jaringan saraf lebih dari dua lapisan. Saat ini, para peneliti terus mengembangkan model yang lebih canggih dengan memperbarui konsep dan gagasan yang telah ada sebelumnya, seperti jaringan saraf konvolusional (CNN), jaringan kapsul (CapsNet), hingga pembelajaran penguatan berbasis jaringan dalam (DRL). Berbagai model Deep Learning modern ini telah menunjukkan efektivitas luar biasa dalam menganalisis kumpulan data berskala besar.[13]

2.5. Convolution Neural Network

Convolution Neural Network adalah algoritma turunan dari *deep learning*. CNN terdiri dari berbagai lapisan representasi yang memungkinkan algoritma ini secara otomatis mempelajari karakteristik data melalui transformasi nonlinier yang diestimasi dengan fungsi nonlinier. Struktur CNN mencakup tahapan ekstraksi fitur, yang melibatkan convolutional layer diikuti oleh pooling layer, serta lapisan klasifikasi softmax[18].

Convolutional layer berfungsi untuk mengekstraksi fitur dari citra, sementara pooling layer bertugas mengurangi dimensi data dan mempercepat proses komputasi, dengan arsitektur yang dirancang demikian, CNN mampu melakukan regulasi secara otomatis. Fitur-fitur yang telah diekstraksi kemudian di proses lebih lanjut pada lapisan softmax untuk melakukan klasifikasi.[19].


2.6. ResNet

Residual Network (ResNet) merupakan sebuah arsitektur model yang dikembangkan oleh He et al. pada tahun 2016. Model ini dirancang untuk mengatasi permasalahan dalam pelatihan deep learning, khususnya terkait waktu pelatihan yang lama serta keterbatasan jumlah lapisan yang dapat digunakan. Salah satu karakteristik utama yang membedakan ResNet dari arsitektur lainnya adalah penerapan *skip connection* atau *shortcut*, yang memungkinkan informasi melewati beberapa lapisan tanpa mengalami degradasi. Keunggulan utama ResNet dibandingkan dengan arsitektur lainnya terletak pada kemampuannya mempertahankan performa meskipun jumlah lapisan yang digunakan semakin dalam. Model ResNet tersedia dalam beberapa varian yang diklasifikasikan berdasarkan jumlah lapisan, yaitu 18, 34, 50, 101, dan 152 lapisan.[20]

2.7. ResNet50 Model Architecture

ResNet50 adalah jaringan saraf konvolusional 50-layer (48 lapisan konvolusional, satu lapisan MaxPool, dan satu lapisan kolom rata-rata)[21].

Jaringan saraf residual adalah jenis jaringan saraf tiruan yang membentuk jaringan dengan menumpuk blok residu.




Gambar 4. ResNet50 Model Architecture

Pada stage 1, lapisan convolutional dengan ukuran filter 7×7 mengkonvolusi gambar, yang menghasilkan map fitur yang kemudian dinormalisasi oleh normalisasi batch. Nilai-nilai output dari lapisan sebelumnya yang sangat berbeda diubah menjadi skala yang sama dengan normalisasi. Ini dapat mempercepat proses pembelajaran karena beban komputasi berkurang. Setelah normalisasi, lapis aktivasi menerima hasilnya. Di lapis aktivasi ini, fungsi aktivasi unit linier yang directificated (ReLU) digunakan untuk membuat hasil ekstraksi fitur menjadi non-linier. Sebelum melanjutkan ke stage 2, lapisan maxpooling mengurangi nilai keluaran fungsi aktivasi.

Dari stage 2 hingga stage 5, kombinasi susunan antara blok convolutional dan blok identitas melakukan proses ekstraksi fitur. Pada blok-blok ini, gambar diperbesar dan berukuran lebih besar. Hal ini disebabkan oleh tipe arsitektur blok, yang terdiri dari tiga tahapan konvolusi dengan ukuran filter 1×1 , 3×3 , dan 1×1 , yang dikenal sebagai "bottleneck" dan dimaksudkan untuk mengurangi jumlah waktu yang diperlukan untuk proses komputasi. Setelah proses ekstraksi fitur selesai, peta fitur diproses ke dalam lapisan yang benar-benar terhubung untuk melakukan proses prediksi dengan bantuan fungsi aktivasi sigmoid. Saat melakukan pelatihan, total 23,589,761 parameter dibuat.[22].

2.8. Convolutional Layer


Lapisan konvolusi (*convolutional layer*) terdiri dari neuron-neuron yang disusun sedemikian rupa sehingga membentuk suatu filter dengan ukuran tertentu dalam bentuk panjang dan tinggi (piksel). Proses konvolusi dilakukan dengan menggunakan kernel dan *stride*, di mana proses ini melibatkan kombinasi antara dua matriks berbeda untuk menghasilkan matriks baru. Dalam pengolahan citra, konvolusi mengacu pada penerapan sebuah kernel (ditandai dengan kotak kuning) ke seluruh area citra pada setiap posisi offset yang memungkinkan, sebagaimana diilustrasikan pada Gambar 6 berikut.[23].



Gambar 5. Operasi konvolusi

2.9. MaxPooling Layer

MaxPooling digunakan untuk mengurangi dimensi fitur sambil mempertahankan informasi penting. Proses ini membantu mengurangi kompleksitas komputasi dan risiko overfitting dalam model[24].



Gambar 6. pooling layer

Lapisan *classification* terdapat beberapa lapisan antara lain sebagai berikut :


- Flatten**
Flatten adalah proses mengubah output *feature learning* dari 2 dimensi menjadi 1 dimensi[24].
- Dropout**
Dropout adalah proses menghilangkan neuron selama pelatihan untuk mencegah overfitting dan meningkatkan kemampuan generalisasi model[24].
- Fully Connected Layer**
Pada *Fully Connected layer* menghubungkan jaringan saraf neuron menjadi 1 dimensi dari hasil *feature learning* yang telah di *flattening* ke bentuk vektor[24].
- Softmax**
Softmax adalah fungsi aktivasi yang mengubah output jaringan saraf menjadi distribusi probabilitas, dimana setiap nilai output dinormalisasi agar berada dalam rentang 0 hingga 1[24].

2.10. Evaluasi Model

Setelah latihan model selesai, evaluasi dilakukan untuk mengetahui seberapa baik performanya. Proses evaluasi ini menggunakan data uji yang telah disiapkan sebelumnya. Tujuan dari evaluasi ini adalah untuk mengevaluasi seberapa baik model dapat mengidentifikasi gambar di luar dataset pelatihan. Confusion matrix adalah teknik evaluasi yang membantu menganalisis kinerja model[25].

3. METODE PENELITIAN


Klasifikasi yang dilakukan terhadap penyakit *pneumonia* menggunakan *Convolutional Neural Network* terdiri dari beberapa tahap. Berikut merupakan blok diagram alur penelitian yang di tunjukkan pada Gambar dibawah ini.



Gambar 7. Diagram Alur

3.1. Dataset

Dataset yang digunakan adalah dataset Chest X-Ray Images by paul yang di ambil dari kaggle (<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia/data>) dengan format JPG. Dataset berisi citra x-ray dada normal dan pneumonia. Data berjumlah 5.856 gambar yang terbagi kedalam 2 kelas yakni, 1.583 normal dan 4.273 pneumonia. Contoh gambar dataset pada gambar 8.



Gambar 8. Jenis Gambar Dalam Dataset, kiri normal dan kanan pneumonia

Tabel 1. Jumlah Dataset

Kelas	Training	Test	Validation	Total
Normal	1.341	234	8	1.583
Pneumonia	3.875	390	8	4.273
Total	5.216	624	16	5.856

3.2. Preprocessing

Pada bagian ini, diterapkan transformasi pada data. Ini termasuk mengubah ukuran gambar menjadi 224 x 224 pixel dengan menggunakan Resize dan menormalisasi nilai pixel agar sesuai dengan distribusi model yang diatur seperti ResNet dengan menggunakan Normalize. Dengan menggunakan ImageFolder, dataset kemudian diatur. Ini secara otomatis mengelompokkan data berdasarkan struktur

folder, dengan kelas yang diwakili oleh setiap subfolder.

3.3. Pembagian Trainset dan Testset

Sebelum *dataset* digunakan dalam tahap selanjutnya, *dataset* dilakukan pembagian ulang karena perbandingan antara jumlah data tiap folder terlalu jauh atau tidak seimbang, dengan cara mengambil 1.600 data *pneumonia* secara acak dan mengambil semua data normal. Hasilnya *dataset* dibagi menjadi tiga bagian, yaitu *trainset*, *testset*, dan *valset* dengan pembagian 72.2% untuk pelatihan, 15.0% untuk uji dan 12.8% untuk validasi.

Tabel 2. Pembagian Dataset

Total Gambar	Data Latih (72.25%)	Data Uji (15.2%)	Data Validasi (12.76%)
3.183	2.299	478	406

3.4. Arsitektur ResNet50

Pada penelitian ini, model arsitektur yang digunakan adalah ResNet-50. Fungsi *loss* yang diterapkan adalah *CrossEntropyLoss*, yang umum digunakan dalam tugas klasifikasi. Dan *optimizer* yang digunakan adalah *Stochastic Gradient Descent Momentum* (SGD-M) dengan *learning rate* 0.1 untuk memperbarui bobot selama pelatihan.

3.5. Pelatihan Model

Dalam pelatihan model pada penelitian ini, setiap *epoch* terdiri dari beberapa langkah. *Batch* data diambil oleh setiap *epoch*. Kemudian, *forward pass* dilakukan untuk menghasilkan prediksi model, menghitung kehilangan, dan *backward pass* dilakukan untuk menghitung gradien dan memperbarui bobot model menggunakan *optimizer*. Selanjutnya *train loss* dan *validation accuracy* dihitung untuk seluruh *dataset*. Ini dilakukan dengan menghitung seberapa banyak prediksi model yang benar dibandingkan dengan label yang sebenarnya. Seiring berjalannya waktu, tujuan pelatihan ini adalah untuk mengoptimalkan model untuk mengurangi kehilangan dan meningkatkan akurasi.

3.6. Analisis Hasil

Tujuan analisis hasil adalah untuk mengevaluasi model pada mode pengujian, yang menunjukkan prediksi kelas dan *matrix confusion* untuk masing-masing kelas dalam *dataset*.

4. HASIL DAN PEMBAHASAN

Setelah semua rangkaian yang dilakukan oleh peneliti melalui *training data*, peneliti memulai proses hasil *test* yang akan menghasilkan grafik validasi akurasi dan *validation loss* dengan *epoch*. Selanjutnya peneliti melakukan *test data* sehingga peneliti dapat *test loss* dan akurasi. Setelah itu peneliti melakukan *random simple testing* model *kaggle* dan *testing model aplikasi* dari *dataset*, kesimpulannya adalah

bahwa dari semua rangkaian yang sudah di jalani dapat memperoleh hasil prediksi yang benar dari data yang sesuai dengan hasil prediksi pada sampel acak.


Pengujian dilakukan menggunakan gambar paru-paru x-ray, dengan menguji 3.183 gambar. Dengan mengukur kinerja arsitektur ResNet50 menggunakan *confusion matrix* yang akan mengukur kinerja sistem secara keseluruhan seperti *accuracy*, *precision*, *recall*, dan *f-measure*.

Pada tabel 3 ditampilkan *training loss*, *validation loss*, dan *validation accuracy* yang dihasilkan pada *training* yang memperlihatkan proses *epoch*. Dari 100 *epoch* yang di jalankan berhenti pada 32 *epoch* di karenakan menggunakan *early stopping* dengan Syarat jika *validasi loss* tidak turun dalam 7 *epoch* maka *running* akan berhenti.


Dari tabel 3 menunjukkan terjadi penurunan pada *loss* setiap data *training* dengan data *validation* juga. Nilai *epoch* 1 ketika saat di *training* memiliki nilai *training loss* 242.6584 dan *validation loss* 1.0434. peningkatan *accuracy* mengalami peningkatan pada *epoch* 25.

Tabel 3. Hasil Training

No.	Training Loss	Validation Loss	Validation Accuracy
1	242.6584	1.0434	0.5616
2	130.6407	37.7274	0.4778
3	34.3741	0.4996	0.7660
4	54.2021	0.6841	0.7635
5	27.1284	0.3126	0.8719
6	25.7988	0.3029	0.8818
7	21.4543	0.3059	0.8867
8	22.5970	98.5805	0.5049
9	22.8922	0.3088	0.8719
10	20.7531	0.5647	0.7660
11	18.5405	0.2212	0.9212
12	16.7463	0.2972	0.8867
13	20.2454	0.3457	0.8719
14	14.5473	0.2100	0.9015
15	14.2231	0.3811	0.8719
16	15.5798	0.3807	0.8842
17	14.6352	0.2895	0.8818
18	13.2552	0.1979	0.9113
19	14.4891	0.3822	0.8473
20	12.6681	0.2992	0.8719
21	13.5371	0.2573	0.9089
22	12.2895	0.3322	0.8892
23	13.5381	0.2405	0.9113
24	11.5182	0.2110	0.9236
25	11.5036	0.1822	0.9310
26	9.9605	0.1850	0.9261
27	9.2515	0.1954	0.9212
28	8.5138	0.1982	0.9236
29	8.8579	0.1934	0.9187
30	8.7014	0.1980	0.9261
31	9.7283	0.1959	0.9236
32	8.4111	0.1948	0.9187



Gambar 9. Grafik Training dan Validation Loss




Gambar 10. Grafik Training Dan Validation Accuracy

Di lihat pada gambar 9 dan 10 menunjukkan kalau akurasi meningkat dan *loss* menurun, *loss* adalah fungsi untuk mengukur seberapa baik sebuah prediksi dengan mengukur jarak hasil output prediksi dengan nilai target. Pada hasil pelatihan data uji didapatkan akurasi sebesar 95.43%, sedangkan tahap pelatihan data test mendapatkan akurasi sebesar 92.25%.

	precision	recall	f1-score	support
0	0.91	0.93	0.92	238
1	0.93	0.91	0.92	240
accuracy			0.92	478
macro avg	0.92	0.92	0.92	478
weighted avg	0.92	0.92	0.92	478


Gambar 11. Classification

Pada gambar 11 evaluasi model yang menunjukkan nilai presisi, *recall*, *F1-score*, *support*, akurasi untuk tiap kelasnya. Yang terbagi menjadi 2 kelas yaitu normal dianotasikan = 0 dengan nilai presisi 0.91 (91%), *recall* 0.93 (93%), *F1-score* 0.92 (92%); *Pneumonia* = 1 dengan nilai presisi 0.93 (93%), *recall* 0.91 (91%), *F1-score* 0.92 (92%) dan rata-rata akurasi untuk setiap kelasnya 0.92 (92%).



Gambar 12. Confusion Matrix

Gambar 12 berikut merupakan plot confusion matrix dan dapat disimpulkan bahwa terdapat 222 prediksi benar Normal, dan 219 prediksi benar Pneumonia. Hasil yang diperoleh pada pengklasifikasian jenis beras menggunakan model ResNet50 dapat dilihat pada gambar berikut ini berdasarkan data yang telah di uji :



Gambar 13. Gambar hasil klasifikasi

Gambar ini menunjukkan bagaimana model berhasil memprediksi masing-masing kelas.

5. KESIMPULAN DAN SARAN

Dari penelitian yang telah dilakukan uji coba mendapatkan hasil arsitektur terbaik dalam melakukan klasifikasi pneumonia dengan menggunakan convolutional neural network model arsitektur ResNet50. Dari penelitian ini juga dapat disimpulkan sistem berjalan dengan baik, pada hasil penelitian data train di dapat akurasi sebesar 95.43%, sedangkan tahap pelatihan data test mendapatkan akurasi sebesar 92.25%. tingkat akurasi ini sudah cukup baik dan layak digunakan sebagai rujukan

dalam membangun sebuah aplikasi pengenalan penyakit pneumonia secara umum.

DAFTAR PUSTAKA

- [1] D. W. Andriani, A. Hadi Endaryanto, D. P. Priasmoro, and A. Abdullah, "Jurnal Keperawatan Muhammadiyah Pengaruh Latihan Jalan 6 Menit Terhadap Tingkat Kebugaran Pasien Pneumonia Ringan Dan Sedang Di RS Husada Utama Surabaya," *J. Keperawatan Muhammadiyah*, vol. 7, no. 1, p. 2022, 2022.
- [2] F. N. Utami, "Kontribusi Faktor Lingkungan dan Perilaku terhadap Kejadian Penyakit Pneumonia Balita," *Higeia J. Public Heal. Res. Dev.*, vol. 4, no. 2, pp. 437–447, 2020, [Online]. Available: <http://journal.unnes.ac.id/sju/index.php/higeia>
- [3] Perhimpunan Dokter Paru Indonesia, "Pneumonia: Pedoman Diagnosis dan Tata Laksana Medis," *Ikat. Dr. Indones.*, no. 19, pp. 19–22, 2020.
- [4] D. Nurhamzah, I. W. Sariyanto, N. Luh, and G. Pivin, "Identifikasi Pneumonia pada Citra Rontgen Paru-paru Menggunakan Convolutional Neural Network," vol. 1, no. 3, pp. 72–77, 2024.
- [5] P. Pneumonia and B. Citra, "Pengembangan artificial intelligence untuk deteksi penyakit pneumonia berdasarkan citra x-ray," pp. 39–54, 2022.
- [6] J. Algoritme *et al.*, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," vol. 1, no. 1, 2020.
- [7] D. P. Andika, N. Wiliyani, U. Pancasila, K. Warna, and P. Citra, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORKS FOR STRAW," vol. 09, no. 2, pp. 1–6, 2024, doi: 10.47007/komp.v7i01.xxxxx.
- [8] H. D. Hekmaty, W. A. Saputra, and C. Ramdani, "Klasifikasi Pneumonia Dengan Deep Learning Faster Region Convolutional Neural Network Arsitektur VGG16 dan ResNet50," *InComTech J. Telekomun. dan Komput.*, vol. 12, no. 3, p. 186, 2022, doi: 10.22441/incomtech.v12i3.15112.
- [9] R. A. Wati, H. Irsyad, and M. E. A. R. Rivan, "Klasifikasi Pneumonia Menggunakan Metode Support Vector Machine," *J. Algoritm.*, vol. 1, no. 1, pp. 21–32, 2020, [Online]. Available: <http://download.garuda.kemdikbud.go.id/article.php?article=2652619&val=24585&title=KLASIFIKASI PNEUMONIA MENGGUNAKAN METODE SUPPORT VECTOR MACHINE>
- [10] C. R. Sihombing, I. Dewa, and A. Eka, "Pengenalan Anatomi Paru-Paru Pada Tubuh Manusia Berbasis Augmented Reality," *J. TISI*, vol. 1, no. 3, pp. 128–143, 2018.
- [11] A. W. Wasid and N. M. Soleh Ridwan, "Pengukuran Volume Paru-Paru Berbasis Mikrokontroler Arduino Dengan Memanfaatkan Sensor Mpx5700Dp," *J. Inform. dan Komputasi Media Bahasan, Anal. dan Apl.*, vol. 15, no. 01, pp. 16–24, 2021, doi: 10.56956/jiki.v15i01.88.
- [12] dr. F. R. Makarim, "Paru paru." [Online]. Available: https://www.halodoc.com/kesehatan/paru-paru?srsId=AfmBOor8pc1JWop9Anb3HDzbHoWV7IkLGLuoX6JSWxSPX1_DVsPX8dor
- [13] A. A. Adiwijaya *et al.*, "Peningkatan Citra Untuk Klasifikasi Gangguan Paru-Paru Menggunakan Deep Learning," vol. 10, no. 3, pp. 830–837, 2024.
- [14] Haana Udtari Anjani, Vitriani Vitriani, and Mulya Hastuti, "Pemanfaatan Media Google Colaboratory Pada Mata Pelajaran Informatika di SMA Negeri 5 Pekanbaru," *SOKO GURU J. Ilmu Pendidik.*, vol. 4, no. 1, pp. 101–108, 2024, doi: 10.55606/sokoguru.v4i1.3613.
- [15] G. I. E. Soen, M. Marlina, and R. Renny, "Implementasi Cloud Computing dengan Google Colaboratory pada Aplikasi Pengolah Data Zoom Participants," *JITU J. Inform. Technol. Commun.*, vol. 6, no. 1, pp. 24–30, 2022, doi: 10.36596/jitu.v6i1.781.
- [16] P. Sarjana, D. T. Biomedik, F. Teknologi, E. Dan, and I. Cerdas, "DETEKSI PNEUMONIA PADA ANAK-ANAK DARI CITRA X-RAY BERBASIS CONVOLUTIONAL NEURAL DETEKSI PNEUMONIA PADA ANAK-ANAK DARI CITRA X-RAY BERBASIS CONVOLUTIONAL NEURAL," 2020.
- [17] J. Nurhakiki, "Studi Kepustakaan : Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya," no. 1, 2024.
- [18] R. A. D. I. Putra, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," vol. 11, no. 2, pp. 466–478, 2023.
- [19] A. R. Pratama and A. F. Cobantoro, "KLASIFIKASI CITRA PNEUMONIA MENGGUNAKAN ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK (CNN) PNEUMONIA IMAGE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK (CNN) ARCHITECTURE," vol. 8, no. 2, pp. 133–144, 2023.
- [20] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, "Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer," *Procedia Comput. Sci.*, vol. 179, no. 2019, pp. 423–431, 2021, doi: 10.1016/j.procs.2021.01.025.
- [21] M. F. D. Ryandra, "Perbandingan Arsitektur Resnet-50 dan Inceptionv3 dalam Klasifikasi Covid 19 Berdasarkan Citra X Ray," p. 35, 2022, [Online]. Available:

- <https://repositori.uma.ac.id/handle/123456789/17072%0Ahttps://repositori.uma.ac.id/jspui/bitstream/123456789/17072/1/178160047> - Muhammad Farhan Dwi Ryandra - Fulltext.pdf
- [22] W. Christanto, "Klasifikasi Pneumonia Menggunakan Convolutional Neural Network," *Skripsi*, pp. 233–244, 2018.
- [23] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [24] M. Sholawati, K. Auliasari, and F. Ariwibisono, "Pengembangan Aplikasi Pengenalan Bahasa Isyarat Abjad Sibi Menggunakan Metode Convolutional Neural Network (Cnn)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 1, pp. 134–144, 2022, doi: 10.36040/jati.v6i1.4507.
- [25] Kade Bramasta Vikana Putra, I Putu Agung Bayupati, and Dewa Made Sri Arsa, "Klasifikasi Citra Daging Menggunakan Deep Learning dengan Optimisasi Hard Voting," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 4, pp. 656–662, 2021, doi: 10.29207/resti.v5i4.3247.