

Analisis Performa Model ResNet-50 Pada Diagnosis Pneumonia Balita Berdasarkan Citra Radiografi Thorax

Ami Rahmawati^{1*}, Ita Yulianti², Siti Nurajizah³, Taufik Hidayatulloh⁴, Ani Oktarini Sari⁵

^{1,5}Universitas Nusa Mandiri
Jl. Raya Jatiwaringin No.2, RT.8/RW.13, Cipinang Melayu, Kec. Makasar, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta 13620, Indonesia

^{2,3,4}Universitas Bina Sarana Informatika
Jl. Kramat Raya No.98 Kwitang, Kec. Senen, Jakarta Pusat, Indonesia

e-mail: ¹ami.amv@nusamandiri.ac.id, ²ita.iyi@bsi.ac.id, ³siti.snz@bsi.ac.id, ⁴taufik.tho@bsi.ac.id, ⁵ani.aos@nusamandiri.ac.id

(*) Corresponding Author

Artikel Info : Diterima : 06-12-2024 | Direvisi : 22-01-2025 | Disetujui : 31-01-2025

Abstrak - Salah satu komplikasi paling serius dari ISPA adalah pneumonia, dimana penyakit ini menyebabkan penderita mengalami nyeri saat bernafas dan keterbatasan intake oksigen. Menurut World Health Organization (WHO), pneumonia diklasifikasikan sebagai penyakit yang mengancam karena tingginya tingkat kematian yang disebabkan. Untuk dapat mendiagnosis penyakit ini, biasanya pasien akan melakukan berbagai metode pemeriksaan medis, salah satunya melalui radiografi thorax. Namun, yang menjadi tantangan dalam mendiagnosis penyakit pneumonia umumnya terletak pada kompleksitas dan ketidakpastian dalam menginterpretasi hasil dari metode tersebut. Oleh karena itu, penelitian ini dilakukan dengan tujuan untuk membangun model klasifikasi citra berdasarkan dataset Radiografi thorax dari pasien kelompok balita menggunakan arsitektur ResNet-50, yang merupakan varian dari algoritma *Convolutional Neural Networks* (CNN). Kombinasi dari kedua metode tersebut diterapkan untuk menganalisis dan memproses citra serta mendapatkan pengenalan pola dengan akurasi yang tinggi. Adapun metode penelitian yang digunakan meliputi penerapan data *augmentation*, perancangan arsitektur CNN, pelatihan model, dan evaluasi kinerjanya. Hasil evaluasi menunjukkan bahwa model memiliki performa yang cukup baik dengan akurasi mencapai 85%, yang menandakan kemampuan model dalam mengklasifikasikan citra dengan tingkat akurasi yang cukup tinggi, serta berpotensi membantu proses diagnosis pneumonia dengan lebih efisien dan akurat.

Kata Kunci : Radiografi Thorax, Pneumonia, ResNet-50

Abstracts - One of the most serious complications of ARI is pneumonia, where this disease causes sufferers to experience pain when breathing and limited oxygen intake. According to the World Health Organization (WHO), pneumonia is classified as a life-threatening disease due to the high mortality rate caused. To be able to diagnose this disease, patients usually undergo various medical examination methods, one of which is through chest radiography. However, the challenge in diagnosing pneumonia generally lies in the complexity and uncertainty in interpreting the results of these methods. Therefore, this study was conducted with the aim of building an image classification model based on the Chest radiography dataset from toddler patients using the ResNet-50 architecture, which is a variant of the *Convolutional Neural Networks* (CNN) algorithm. The combination of the two methods is applied to analyze and process images and obtain pattern recognition with high accuracy. The research methods used include the application of data *augmentation*, CNN architecture design, model training, and performance evaluation. The evaluation results show that the model has quite good performance with an accuracy of 85%, which indicates the model's ability to classify images with a fairly high level of accuracy, and has the potential to help the pneumonia diagnosis process more efficiently and accurately..

Keywords : Thorax Radiography, Pneumonia, ResNet-50



PENDAHULUAN

Penyakit Infeksi Saluran Pernafasan Akut (ISPA) kondisi patogenik yang sering diabaikan (Hidayatulloh & Suharsono, 2023) juga seringkali dianggap remeh oleh sebagian masyarakat karena gejalanya yang terlihat ringan. Padahal, jika tidak ditangani secara tepat penyakit ini dapat berkembang menjadi komplikasi yang berakhir fatal (Onibala & Purnomo, 2024). Salah satu komplikasi paling serius dari ISPA adalah pneumonia, dimana penyakit ini menyebabkan penderita mengalami nyeri saat bernafas dan keterbatasan intake oksigen (Halim & Anraeni, 2021). Penyebabnya bisa dikarenakan oleh berbagai jenis patogen seperti bakteri, virus, dan jamur yang menginfeksi saluran pernapasan sehingga kantung darah dalam paru-paru meradang dan terisi cairan (Zalukhu, 2024). Pneumonia memiliki ciri visual yang sama dengan penyakit pernapasan lainnya, seperti tuberkulosis, yang dapat menyulitkan untuk membedakannya (Reshan et al., 2023).

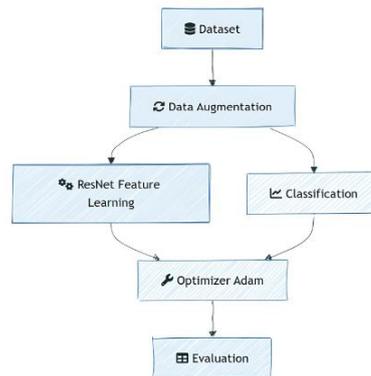
Pada Tahun 2017, Organisasi Kesehatan Dunia (WHO) mengungkapkan sebanyak 800.000 anak meninggal akibat pneumonia, sehingga penyakit ini diklasifikasikan menjadi penyakit yang mengancam karena tingginya tingkat kematian yang disebabkan (Nurjannah et al., 2022). Pneumonia memang bisa mengancam siapapun, namun anak-anak dan orang yang memiliki gangguan sistem pada imunitas lebih rentan terserang oleh penyakit tersebut (Praskatama et al., 2023). Pneumonia pada anak masih menjadi masalah klinis dan kesehatan masyarakat yang signifikan (Yadav & Awasthi, 2023). Untuk dapat mendiagnosis penyakit pneumonia, ada berbagai jenis metode pemeriksaan medis yang dapat dilakukan. Radiografi thorax atau rontgen dada merupakan metode yang paling umum digunakan di Indonesia, karena hampir semua fasilitas layanan kesehatan menyediakan teknologi tersebut (Adzkie et al., 2022). Namun, yang menjadi tantangan bagi tenaga medis salah satunya adalah kompleksitas dan ketidakpastian dalam menginterpretasi hasil dari metode tersebut akibat gejala yang ditimbulkan seringkali bervariasi dan tumpang tindih dengan penyakit lain (Fadhilah & Triayudi, 2024). Oleh karena itu, biasanya proses ini memerlukan waktu yang cukup lama dan resiko kesalahan mungkin tidak dapat dihindarkan (Widiarto et al., 2021).

Dengan semakin berkembangnya teknologi, saat ini bidang deep learning menjadi solusi inovatif dalam pemodelan otomatis untuk mendeteksi berbagai jenis penyakit (Sulistio & Lubis, 2023). Penggunaan algoritma deep learning, terutama Convolutional Neural Networks (CNN), tidak hanya dapat mempercepat diagnosis tetapi juga dapat menghasilkan performa akurasi yang optimal dalam mengklasifikasikan citra medis berdasarkan representasi fitur (Goyal & Singh, 2023). Beberapa penelitian telah menunjukkan bahwa algoritma CNN dapat diterapkan dalam berbagai macam studi kasus, diantaranya penelitian dari (Prasetyo et al., 2023) yang melakukan perbandingan 2 algoritma yaitu SVM dan CNN dalam mendeteksi penyakit katarak berdasarkan 3 target kelas yang diuji, yaitu citra mata normal, imatur dan matur. Dari hasil eksperimen didapatkan kesimpulan bahwa performa dari algoritma CNN lebih unggul dibandingkan dengan SVM. Selanjutnya, (Sulistio & Lubis, 2023) menerapkan model CNN dan MobileNet untuk mengklasifikasikan penyakit pneumonia dan Covid-19 sehingga diperoleh hasil akurasi sebesar 95% dengan menggunakan Optimizer Nadam. Kemudian, penelitian yang dilakukan oleh 2024 (Zahir & Adi Saputra, 2024) yang bertujuan untuk mendeteksi penyakit diabetes berdasarkan citra fundus mata, dengan hasil penelitian menunjukkan bahwa penggunaan model CNN dinilai efektif sebab mampu menghasilkan nilai akurasi 96%.

Berdasarkan keberhasilan dari penelitian-penelitian sebelumnya, maka penelitian ini bertujuan untuk mengimplementasikan algoritma Convolutional Neural Networks (CNN) untuk klasifikasi pneumonia menggunakan dataset citra Radiografi thorax dari pasien anak-anak khususnya balita. Penggunaan model CNN lebih ringan dilakukan pada area lapisan terbatas, namun semakin dalam arsitektur yang diciptakan, semakin kompleks pula model yang dihasilkan, sehingga bobot pada lapisan awal cenderung sulit diperbarui dan menyebabkan masalah vanishing gradient (Borawar & Kaur, 2023). Oleh karena itu, untuk meminimalisir terjadinya masalah *vanishing gradient* maka pemilihan arsitektur ResNet juga diterapkan dengan harapan dapat mencapai akurasi tinggi bahkan pada jaringan yang dalam (Goyal & Singh, 2023). Arsitektur ini menjadi model standar yang seringkali diaplikasikan untuk menangani tugas dalam klasifikasi citra (Pranatha et al., 2024). Melalui penelitian ini, diharapkan dapat memberikan kontribusi berupa pembangunan model yang lebih akurat dan andal berdasarkan identifikasi pola visual, sehingga dapat berfungsi sebagai alat bantu bagi tenaga medis dalam mempercepat proses deteksi pneumonia khususnya bagi kelompok usia balita.

METODE PENELITIAN

Penelitian ini menganalisis dataset citra Radiografi thorax dengan menggunakan pendekatan eksperimen untuk mengklasifikasikan penyakit pneumonia pada balita. Agar memastikan setiap proses yang dilakukan dalam penelitian ini sistematis, maka disusun kerangka kerja yang dapat dilihat pada gambar berikut:



Sumber: Hasil Penelitian (2024)

Gambar 1. Kerangka Kerja Penelitian

1. Dataset

Tahapan pertama yaitu pengumpulan dataset yang sesuai dengan tujuan utama penelitian. Dataset yang digunakan adalah dataset citra medis yakni citra Radiografi thorax pada kelompok usia balita yang mencakup dataset pasien dengan diagnosa pneumonia dan tanpa pneumonia. Dataset tersebut diperoleh dari Kaggle Repository yang dapat diakses pada tautan berikut: <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>. Dataset ini kemudian diseleksi dan menjadi dasar bagi seluruh tahapan selanjutnya.

2. Data Augmentation

Pada tahapan ini dan seterusnya dataset diproses dengan menggunakan bahasa pemrograman python melalui *Google Colaboratory*. Proses *data augmentation* dilakukan dengan tujuan untuk meningkatkan keberagaman dari citra dan mengurangi kemungkinan terjadinya model *overfitting*. Adapun teknik-teknik yang umum digunakan meliputi normalisasi, rotasi, pergeseran horizontal dan vertikal, *shearing*, *zooming*, dan *flipping* horizontal (Nurjannah et al., 2022). Semua teknik ini digunakan secara bersamaan menggunakan *library TensorFlow* dan *Torch* agar menghasilkan proses augmentasi yang baik. Contoh hasil dari proses ini disajikan pada gambar 2.

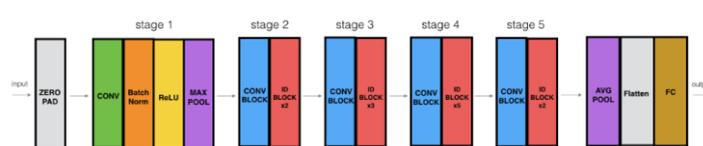


Sumber: Hasil Penelitian (2024)

Gambar 2. Hasil Data Augmentation

3. ResNet Feature Learning

ResNet adalah arsitektur CNN yang biasa dimanfaatkan untuk ekstraksi fitur dengan menambahkan *skip connection* atau *identity mapping* pada jaringan CNN sehingga dapat mengatasi resiko terjadinya masalah *vanishing gradient* pada jaringan neural yang sangat dalam (Sholihah, 2021). Beberapa jenis dari ResNet yang umum digunakan antara lain ResNet-18, ResNet-34, ResNet-50, ResNet-101 hingga ResNet-152. Jenis ResNet yang dipilih untuk penelitian ini yaitu ResNet-50, dimana jenis ResNet ini memiliki 50 lapisan yang mampu menangkap fitur yang kompleks dari berbagai jenis data, sehingga hal ini menjadi pilihan yang ideal terutama dalam analisis klasifikasi penyakit pneumonia. Berikut ini gambar 3 yang menunjukkan proses konvolusi pada ResNet-50:



Sumber : (Berliani et al., 2023)

Gambar 3. Arsitektur ResNet-50

4. Classification

Setelah fitur diekstrak melalui proses ResNet50, maka lapisan akhir dari CNN digunakan pada proses klasifikasi. Lapisan *fully connected (dense layer)* pada bagian akhir menjadi komponen utama dalam memetakan fitur-fitur yang telah diperoleh menjadi output berupa probabilitas prediksi untuk setiap kelas targetnya. Adapun proses klasifikasi ini dilakukan dengan menggunakan *softmax* di lapisan akhir model sehingga menghasilkan probabilitas kelas pneumonia atau tidak.

5. Optimizer Adam

Untuk meningkatkan akurasi dalam proses klasifikasi, penelitian ini menggunakan algoritma *Optimizer Adam* selama pelatihan model. Algoritma ini berperan dalam meminimalkan *loss function*, sehingga mempercepat dan menstabilkan proses pembaruan parameter model. Adam secara adaptif menyesuaikan laju pembelajaran untuk setiap parameter, yang membantu mempercepat konvergensi dan mengurangi risiko osilasi. Selain itu, Adam memiliki ketahanan terhadap gradien bising dan fleksibilitas yang tinggi, sehingga cocok digunakan pada berbagai jenis arsitektur dan tugas jaringan saraf (Truong et al., 2023)

6. Evaluation

Tahapan terakhir yaitu melakukan evaluasi pada model yang dibangun. Performa model pada penelitian ini diukur menggunakan *confusion matrix* yang menunjukkan visualisasi lengkap mengenai kemampuan model dalam mengklasifikasikan dataset citra pneumonia.

HASIL DAN PEMBAHASAN

Dataset Chest X-Ray *Images (Pneumonia)* digunakan untuk melakukan klasifikasi pneumonia berdasarkan citra sinar-X (X-ray) dada. Dataset ini terbagi menjadi dua kelas, yaitu kelas Normal yang terdiri dari 1.349 data yang merepresentasikan struktur paru-paru sehat tanpa adanya tanda-tanda abnormalitas, seperti bercak putih atau area buram. Sementara itu, kelas Pneumonia terdiri dari 3.883 data yang menggambarkan tanda-tanda infeksi pada paru-paru, baik akibat infeksi bakteri maupun virus. Gambar 4 dan 5 menunjukkan contoh data dari setiap kelas.



Sumber: (Mooney, 2017)

Gambar 4. Contoh Citra Pneumonia



Sumber: (Mooney, 2017)

Gambar 5. Contoh Citra Normal

Dalam penelitian ini, klasifikasi pneumonia dilakukan menggunakan arsitektur *Convolutional Neural Network (CNN)* ResNet-50. Pemilihan model ini didasarkan pada kemampuannya yang unggul dalam mengekstraksi fitur-fitur kompleks dari citra, seperti pola-pola yang terlihat pada X-ray dada, yang dapat menunjukkan adanya pneumonia. Dengan arsitektur jaringan yang dalam serta penggunaan *skip connections*, ResNet-50 mampu mengurangi masalah *vanishing gradient* dan meningkatkan kinerja model dalam mempelajari representasi data. Model ini dilatih untuk mengklasifikasikan citra ke dalam dua kelas, yaitu Normal dan Pneumonia, untuk mendukung proses identifikasi dan diagnosis penyakit dengan lebih tepat.

Pada tahap pemodelan, data dibagi menjadi tiga bagian, yaitu data pelatihan, data pengujian, dan data validasi, dengan proporsi masing-masing 70% untuk pelatihan, 15% untuk pengujian, dan 15% untuk validasi.

Tidak ada aturan khusus mengenai pembagian data tersebut, namun rasio ini dipilih sesuai dengan jumlah dataset dan kebutuhan penelitian. Tujuan dari proses pembagian dataset ini dilakukan untuk memastikan model dapat diuji dan divalidasi pada setiap epoch atau iterasi, sehingga potensi overfitting pada model CNN dapat terdeteksi lebih awal.

Langkah selanjutnya adalah melakukan eksperimen guna menemukan parameter optimal bagi model. Pada tahapan ini, model dilatih dengan menggunakan parameter loss berupa *binary_crossentropy*, ukuran *batch* 32, *learning rate* 0.0001, dan jumlah *epoch* sebanyak 50. Eksperimen dilakukan dengan mengaktifkan fitur penghentian dini, yang berarti pelatihan akan dihentikan lebih awal jika akurasi validasi tidak mengalami peningkatan selama 3 *epoch* berturut-turut, untuk membantu mengurangi dimensi serta mengelola kompleksitas dan jumlah parameter. Setiap model yang telah dibangun dijalankan menggunakan Adam sebagai *optimizer* guna mengatur proses pembelajaran dengan cepat dan efisien, mengurangi waktu pelatihan, menjaga kestabilan proses pembelajaran, serta memungkinkan model mencapai performa optimal.

Untuk mengukur kinerja model yang telah dijalankan, maka selanjutnya perlu dilakukan proses evaluasi. Pada penelitian ini evaluasi model dieksekusi menggunakan fungsi *model.evaluate* (*validation_generator*) yang menghasilkan nilai loss dan akurasi. Nilai loss menunjukkan seberapa besar kesalahan model sementara akurasi menunjukkan nilai prediksi yang benar. Berdasarkan eksperimen tersebut diperoleh hasil loss sebesar 0.336 dan hasil akurasi sebesar 0.85 yang dapat dilihat pada gambar 6.

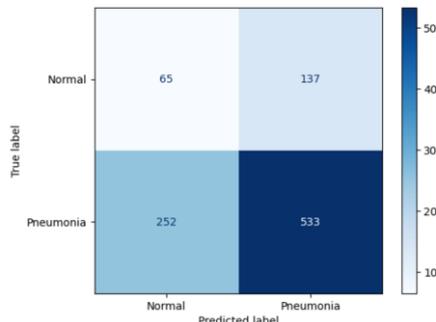
```
# Mengevaluasi performa model pada data validasi atau data uji
eval_results = model.evaluate(validation_generator)
print(f"Loss: {eval_results[0]}")
print(f"Accuracy: {eval_results[1]}")
```

31/31 ————— 104s 3s/step - accuracy: 0.8510 - loss: 0.3388
 Loss: 0.336134672164917
 Accuracy: 0.8530901670455933

Sumber: Hasil Penelitian (2024)

Gambar 6. Hasil Evaluasi

Dari gambar diatas, hasil evaluasi model menunjukkan bahwa akurasi mencapai sebesar 85%. Akurasi ini menggambarkan kemampuan model untuk mengklasifikasikan data dengan cukup baik, khususnya dalam membedakan antara kategori Normal dan Pneumonia pada citra X-ray dada. Hasil tersebut kemudian dievaluasi lebih lanjut menggunakan *confusion matrix*. Gambar 7 menampilkan *confusion matrix* yang digunakan dalam pengujian ini.

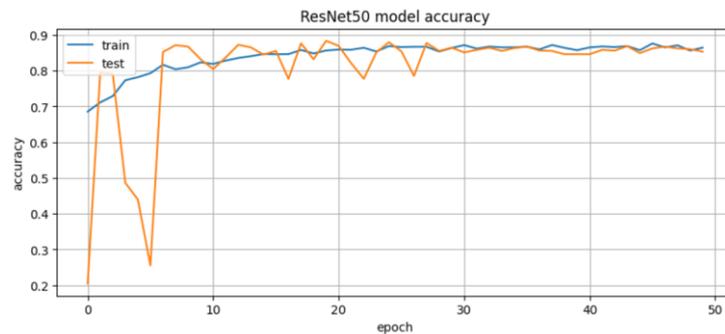


Sumber: Hasil Penelitian (2024)

Gambar 7. *Confusion Matrix*

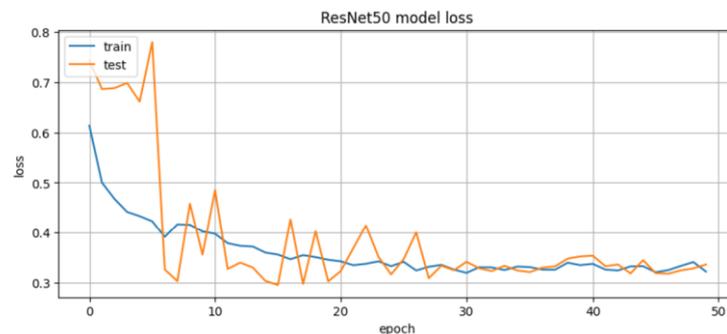
Gambar 7 menyajikan hasil prediksi model yang memberikan gambaran rinci tentang kinerja klasifikasi pada masing-masing kategori. *Confusion matrix* terdiri dari empat komponen utama, yaitu *True Positive* (TP) sebanyak 533, yang menunjukkan jumlah kasus di mana model berhasil memprediksi Pneumonia dengan benar sesuai label sebenarnya. Kemudian, *True Negative* (TN) sebanyak 65, yang menunjukkan model berhasil memprediksi Normal dengan benar sesuai label aktual. Selain itu, terdapat *False Positive* (FP) sebanyak 137, yaitu kasus di mana model salah memprediksi Pneumonia, padahal label sebenarnya adalah Normal. Terakhir, *False Negative* (FN) sebanyak 252, yang menggambarkan kesalahan prediksi ketika model memprediksi Normal, tetapi label aktualnya adalah Pneumonia.

Setelah menganalisis hasil *confusion matrix*, selanjutnya adalah melakukan evaluasi menyeluruh terhadap kinerja model melalui grafik visualisasi akurasi dan loss yang dihasilkan selama proses pelatihan dan validasi, seperti yang ditunjukkan pada Gambar 8 dan 9. Grafik-grafik ini memberikan gambaran tentang bagaimana model berkembang dalam memproses data dan melakukan klasifikasi dengan akurat seiring berjalannya waktu.



Sumber: Hasil Penelitian (2024)

Gambar 8. Grafik Akurasi



Sumber: Hasil Penelitian (2024)

Gambar 9. Grafik Loss

Gambar 8 menampilkan akurasi model ResNet-50 pada data pelatihan dan pengujian selama proses pelatihan hingga mencapai 50 *epoch*. Kurva akurasi untuk data pelatihan menunjukkan peningkatan yang konsisten dan stabil di sekitar 0.85–0.90 setelah beberapa *epoch*, menandakan bahwa model berhasil belajar dengan baik dari data pelatihan. Di awal pelatihan, akurasi pada data pengujian terlihat fluktuatif dengan perubahan yang cukup signifikan. Namun, seiring berjalannya waktu, akurasi pengujian menunjukkan tren peningkatan yang lebih stabil dan mendekati tingkat akurasi data pelatihan. Hal ini menunjukkan kemampuan model untuk menggeneralisasikan dengan cukup baik pada data yang tidak terlihat sebelumnya. Konsistensi dan kesamaan antara akurasi data pelatihan dan pengujian setelah beberapa *epoch* menandakan bahwa masalah *overfitting* telah berhasil diatasi, yang menunjukkan bahwa model dapat membuat prediksi yang akurat.

Sedangkan gambar 9 memperlihatkan grafik yang menggambarkan tren penurunan loss secara konsisten seiring bertambahnya jumlah *epoch*, yang sesuai dengan harapan karena model terus berupaya mengurangi kesalahan pada data pelatihan. Di awal proses pelatihan, loss pada data testing menunjukkan peningkatan yang tajam dan fluktuasi yang signifikan, yang mungkin disebabkan oleh kondisi awal model yang masih dalam tahap penyesuaian. Namun, seiring waktu, loss testing mulai menurun dan akhirnya mencapai kestabilan, menunjukkan bahwa model mulai memahami pola pada data testing dengan lebih baik. Ketika loss pada data training dan testing semakin mendekati, hal ini menunjukkan kemampuan model dalam menggeneralisasi pola-pola dari data pelatihan ke data yang belum pernah ditemui sebelumnya. Secara keseluruhan, model menunjukkan bahwa tidak ada indikasi *overfitting* yang signifikan, karena loss pada data testing tidak mengalami kenaikan drastis di akhir pelatihan. Ini menandakan bahwa model memiliki performa yang baik dalam membuat prediksi yang akurat tanpa terperangkap pada pola spesifik dari data pelatihan.

KESIMPULAN

Hasil evaluasi model menunjukkan kinerja yang cukup baik, dengan tingkat akurasi mencapai 85%. Grafik akurasi dan loss menunjukkan bahwa model mampu belajar secara efektif dari data pelatihan, di mana akurasi pelatihan terus meningkat dengan konsisten dan stabil, sedangkan loss mengalami penurunan seiring bertambahnya *epoch*. Selain itu, tidak ditemukan indikasi *overfitting* yang signifikan, karena loss pada data testing tetap terjaga dan tidak mengalami lonjakan yang besar. Oleh karena itu, penelitian selanjutnya disarankan untuk melakukan pendekatan dengan teknik regularisasi yang berbeda agar mencapai akurasi yang lebih tinggi dan stabil, serta mampu beradaptasi lebih baik dengan berbagai kondisi data.

REFERENSI

- Adzkia, M., Arland, F., Setiawan, A. W., & Korespondensi, P. (2022). *Deteksi Pneumonia Menggunakan Citra Sinar-X Paru Berbasis Residual Network Detection of Pneumonia Using Residual Network Bases Lung X-Ray Image*. 9(2), 373–380. <https://doi.org/10.25126/jtiik.202295626>
- Berliani, T., Rahardja, E., & Septiana, L. (2023). Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16. *Journal of Medicine and Health*, 5(2), 123–135. <https://doi.org/10.28932/jmh.v5i2.6116>
- Borawar, L., & Kaur, R. (2023). ResNet: Solving Vanishing Gradient in Deep Networks. In R. P. Mahapatra, S. K. Peddoju, S. Roy, & P. Parwekar (Eds.), *Proceedings of International Conference on Recent Trends in Computing* (pp. 235–247). Springer Nature Singapore.
- Fadhilah, M. R., & Triayudi, A. (2024). Penerapan Metode Dempster Shafer dalam Mendiagnosa Penyakit Pneumonia. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(2).
- Goyal, S., & Singh, R. (2023). Detection and classification of lung diseases for pneumonia and Covid-19 using machine and deep learning techniques. *Journal of Ambient Intelligence and Humanized Computing*, 14(4), 3239–3259. <https://doi.org/10.1007/s12652-021-03464-7>
- Halim, A. A. D., & Anraeni, S. (2021). Analisis Klasifikasi Dataset Citra Penyakit Pneumonia menggunakan Metode K-Nearest Neighbor (KNN). *Indonesian Journal of Data and Science*, 2(1), 01–12. <https://doi.org/10.33096/ijodas.v2i1.23>
- Hidayatulloh, M. T., & Suharsono, T. N. (2023). Sistem Pakar Diagnosis Penyakit Infeksi Saluran Pernapasan Akut (ISPA) Menggunakan Metode Dempster Shafer. *Digital Transformation Technology*, 3(2), 489–498. <https://doi.org/10.47709/digitech.v3i2.2894>
- Mooney, P. (2017). *Chest X-Ray Images (Pneumonia)*. Www.Kaggle.Com. <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
- Nurjannah, A. F., Kurniasari, A. S. D., Sari, Z., & Azhar, Y. (2022). Pneumonia Image Classification Using CNN with Max Pooling and Average Pooling. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(2), 330–338. <https://doi.org/10.29207/resti.v6i2.4001>
- Onibala, I. V., & Purnomo, A. S. (2024). Sistem Pakar untuk Diagnosa Penyakit Infeksi Saluran Pernapasan Akut (ISPA) Menggunakan Metode Naive Bayes. *INNOVATIVE: Journal Of Social Science Research*, 4(3), 14666–14685. <https://j-innovative.org/index.php/Innovative/article/view/11755/8309>
- Pranatha, M. D. A., Setiawan, G. H., & Maricar, M. A. (2024). Utilization of ResNet Architecture and Transfer Learning Method in the Classification of Faces of Individuals with Down Syndrome. *Journal of Applied Informatics and Computing (JAIC)*, 8(2), 434–442.
- Prasetyo, A. R., Sussi, & Aditya, B. (2023). Analisis Perbandingan Algoritma Support Vector Machine (Svm) Dan Convolutional Neural Network (Cnn) Untuk Sistem Deteksi Katarak. *Jurnal Ilmiah Teknik Mesin, Elektro Dan Komputer*, 3(1), 1–10. <https://doi.org/10.51903/juritek.v3i1.604>
- Praskatama, V., Sari, C. A., Rachmawanto, E. H., & Mohd Yaacob, N. (2023). Pneumonia Prediction Using Convolutional Neural Network. *Jurnal Teknik Informatika (Jutif)*, 4(5), 1217–1226. <https://doi.org/10.52436/1.jutif.2023.4.5.1353>
- Reshan, M. S. Al, Gill, K. S., Anand, V., Gupta, S., Alshahrani, H., Sulaiman, A., & Shaikh, A. (2023). Detection of Pneumonia from Chest X-ray Images Utilizing MobileNet Model. *Healthcare (Switzerland)*, 11(11). <https://doi.org/10.3390/healthcare11111561>
- Sholihah, L. (2021). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *Seminar Nasional Fortei7-4*, 4(1), 670.
- Sulistio, M. J., & Lubis, C. (2023). Implementasi CNN dan MobileNet untuk Mendeteksi Penyakit Pneumonia dan COVID-19 dengan Menggunakan Aplikasi Smartphone. *Nusantara Journal of Multidisciplinary Science*, 1(4), 736–745.
- Truong, T. X., Nhu, V., Phuong, D. T. N., Nghi, L. T., Hung, N. N., Hoa, P. V., & Bui, D. T. (2023). A New Approach Based on TensorFlow Deep Neural Networks with ADAM Optimizer and GIS for Spatial Prediction of Forest Fire Danger in Tropical Areas. *Remote Sensing*, 15(14), 1–21.
- Widiarto, S. A., Saputra, W. A., & Dewi, A. R. (2021). Klasifikasi Citra X-Ray Toraks Dengan Menggunakan Contrast Limited Adaptive Histogram Equalization Dan Convolutional Neural Network (Studi Kasus: Pneumonia). *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 6(2), 348–359. <https://doi.org/10.29100/jupi.v6i2.2102>
- Yadav, K. K., & Awasthi, S. (2023). Childhood Pneumonia: What's Unchanged, and What's New? In *Indian Journal of Pediatrics* (Vol. 90, Issue 7, pp. 693–699). Springer. <https://doi.org/10.1007/s12098-023-04628-3>
- Zahir, M., & Adi Saputra, R. (2024). Deteksi Penyakit Retinopati Diabetes Menggunakan Citra Mata Dengan Implementasi Deep Learning Cnn. *Jurnal Teknoinfo*, 18(1), 121–132.
- Zalukhu, E. (2024). Analisa Perbandingan Metode Certainly Faktor-Naive Bayes Terhadap Diagnose Penyakit Pneumonia. *ADA Journal of Information System Research*, 1(3).