

ANALISIS PERBANDINGAN OPTIMIZER PADA MODEL CONVOLUTIONAL NEURALNETWORK UNTUK DETEKSI KANKER PARU-PARU

Pratama Andika Setyawan*¹, Alpin Danuarta *², Farhan Nur Alam³, Tinuk Agustin⁴

¹²³⁴Prodi Informatika , STMIK Amikom Surakarta

¹²³⁴Sukoharjo, Indonesia.

Email: ¹pratama.10407@mhs.amikomsolo.ac.id,
²alpin.10386@mhs.amikomsolo.ac.id, ³farhan.10401@mhs.amikomsolo.ac.id,
⁴agustin.amikom@gmail.com

Abstract

This research emphasizes the importance of early detection of lung cancer, which is the leading cause of cancer-related deaths globally. This research underscores the challenges of manual analysis due to limited medical resources and proposes the use of CNNs to automate the detection process. This research compares the effectiveness of various optimizers in training CNN models for lung cancer detection. The total data used is 1097 data divided into 3 classes 561 malignant lung cancer cases, 120 benign lung cancer cases, and 416 ordinary lung cancer cases. The methodology used includes data collection, preprocessing, CNN architecture formation, training, and validation. The results show that the selection of optimizer has a significant impact on model accuracy and convergence speed. The conclusion of this study states that the SGD optimizer is better than the RMSprop optimizer and the RMSprop optimizer produces 97.9% accuracy, and for the SGD optimizer produces 98.5% accuracy.

Keywords: lung cancer, Convolutional Neural Networks (CNN), model accuracy.

Abstraksi

Penelitian ini menekankan pentingnya deteksi dini kanker paru-paru, yang merupakan penyebab utama kematian terkait kanker secara global. Penelitian ini menggarisbawahi tantangan analisis manual akibat terbatasnya sumber daya medis dan mengusulkan penggunaan CNN untuk mengotomatiskan proses deteksi. Penelitian ini membandingkan efektivitas berbagai optimizer dalam melatih model CNN untuk deteksi kanker paru-paru. Jumlah data yang digunakan 1097 data terbagi dalam 3 kelas 561 kasus kanker paru-paru ganas, 120 kasus kanker paru-paru jinak, dan 416 kasus kanker paru-paru biasa. Metodologi yang digunakan mencakup pengumpulan data, preprocessing, pembentukan arsitektur CNN, pelatihan, dan validasi. Hasil menunjukkan bahwa pemilihan optimizer berdampak signifikan pada akurasi model dan kecepatan konvergensi. Kesimpulan penelitian ini menyatakan bahwa optimizer SGD lebih baik dari pada optimizer RMSprop dan optimizer RMSprop menghasilkan akurasi 97.9%, dan untuk optimizer SGD menghasilkan akurasi 98.5%.

Kata Kunci: kanker paru-paru, Convolutional Neural Networks (CNN), akurasi model.

1. PENDAHULUAN

Kanker paru-paru menjadi penyebab utama kematian akibat kanker, dengan sekitar 1,8 juta kematian setiap tahun di dunia (WHO, 2020). Deteksi dini kanker ini sangat penting untuk meningkatkan peluang kesembuhan, namun sering kali sulit, terutama di negara-negara dengan sumber daya medis terbatas. Convolutional Neural Network (CNN), sebagai bagian dari *deep learning*, menunjukkan hasil yang menjanjikan dalam mendeteksi kanker paru-paru dari Citra Tomografi komputer (CT) dengan akurasi tinggi[1]. Perkembangan Convolutional Neural Network (CNN) telah mengubah cara kita dalam menganalisis data medis, terutama untuk mendeteksi kelainan pada citra medis. Pemilihan *optimizer* yang tepat pada model CNN menjadi aspek krusial dalam meningkatkan akurasi deteksi kanker paru-paru[2]. *Optimizer* adalah komponen penting dalam pelatihan model CNN yang dapat mempengaruhi kecepatan dan akurasi konvergensi model. Oleh karena itu, perbandingan kinerja berbagai *optimizer* perlu dilakukan untuk menemukan metode terbaik dalam deteksi kanker paru-paru[3].

Banyak penelitian telah membuktikan bahwa CNN efektif untuk deteksi kanker paru-paru. Namun, pemilihan *optimizer* yang optimal masih menjadi tantangan tersendiri. Studi ini berfokus pada perbandingan berbagai *optimizer* dalam mendeteksi kanker paru-paru menggunakan CNN[4]. Dengan meningkatnya kasus kanker paru-paru, solusi berbasis kecerdasan buatan untuk deteksi dini sangat dibutuhkan. Dalam konteks ini, model CNN dengan pilihan *optimizer* yang tepat dapat membantu meningkatkan akurasi diagnosis[5].

Meskipun CNN telah berhasil dalam bidang deteksi gambar, pemilihan *optimizer* yang efektif sangat penting dalam pelatihan model. Setiap *optimizer* memiliki karakteristik unik yang dapat memengaruhi performa model dalam mendeteksi kanker paru-paru[6]. Beberapa penelitian menunjukkan bahwa optimasi pada model CNN sangat diperlukan untuk meningkatkan akurasi dalam deteksi kanker paru-paru. Optimizer seperti Adam, SGD, dan RMSprop memiliki peran signifikan dalam konvergensi model[7]. Mengingat tingginya kasus kanker paru-paru dan terbatasnya sumber daya medis, sistem berbasis CNN yang dioptimalkan menjadi solusi potensial untuk diagnosis yang lebih cepat dan akurat[8].

Model CNN telah terbukti efektif dalam deteksi kanker paru-paru, namun studi ini menyoroti pentingnya pemilihan *optimizer* yang sesuai untuk meningkatkan kecepatan dan akurasi model dalam mendeteksi sel kanker paru-paru[9]. Penelitian mengenai perbandingan *optimizer* dalam CNN untuk deteksi kanker paru-paru masih terbatas. Melalui penelitian ini, berharap dapat memberikan panduan untuk memilih optimizer yang optimal berdasarkan hasil perbandingan kinerja beberapa metode optimasi[10].

2. TINJAUAN PUSTAKA

Pengenalan Convolutional Neural Network dalam Diagnostik Medis Convolutional Neural Network (CNN) adalah salah satu metode dalam *deep learning* yang telah banyak digunakan dalam bidang medis, khususnya dalam mengenali pola pada citra medis. CNN

memiliki keunggulan dalam mengidentifikasi pola visual yang rumit, sehingga mampu menganalisis gambar medis seperti CT scan atau X-ray dengan efisiensi yang tinggi. Metode ini menjadi sangat berguna dalam deteksi dini kanker paru-paru, karena CNN dapat memproses dan mengenali karakteristik nodul pada paru-paru yang berpotensi menjadi kanker. Teknologi ini dapat mempercepat proses diagnosis dan meningkatkan akurasi deteksi penyakit. Perbandingan *Optimizer* dalam Jaringan Saraf Tiruan[11].

Optimizer dalam jaringan saraf tiruan, seperti CNN, memiliki peran yang penting dalam proses pelatihan model. Beberapa optimizer populer yang sering digunakan dalam CNN meliputi Stochastic Gradient Descent (SGD), Adam, dan RMSprop. Setiap jenis *optimizer* memiliki kelebihan dan kekurangan, yang dapat memengaruhi kecepatan konvergensi dan tingkat akurasi dari model. Dalam deteksi kanker paru-paru, pemilihan *optimizer* yang tepat menjadi krusial karena dapat menentukan seberapa cepat dan akurat CNN dalam mengenali pola kanker dari citra medis[12].

Convolutional Neural Network (CNN) adalah salah satu arsitektur *deep learning* yang sering digunakan untuk analisis citra medis, termasuk deteksi kanker paru-paru. CNN mampu mengekstrak fitur penting dari gambar dengan lapisan konvolusi yang memungkinkan model untuk mengenali pola yang kompleks. CNN telah terbukti efektif dalam berbagai tugas klasifikasi citra, seperti pada deteksi kanker kulit, otak, dan paru-paru, yang memerlukan analisis visual yang mendalam dan akurat [13].

Akurasi CNN dalam Deteksi Kanker Paru-paru melalui Gambar CT Salah satu studi yang dilakukan menunjukkan bahwa implementasi CNN dalam menganalisis gambar CT scan paru-paru memberikan hasil yang lebih akurat dibandingkan dengan metode konvensional. CNN dapat mengenali nodul kecil yang berpotensi menjadi kanker dengan presisi yang tinggi. Dengan kemampuan ini, CNN dapat mendeteksi keberadaan sel kanker dalam gambar medis pada tahap yang lebih awal, yang sangat penting untuk meningkatkan peluang kesembuhan pasien melalui penanganan dini[14].

Adam *Optimizer* dan Performa CNN dalam Citra Medis Adam adalah salah satu *optimizer* yang banyak digunakan dalam pelatihan CNN pada citra medis, termasuk untuk deteksi kanker paru-paru. Adam memiliki keunggulan dalam mempercepat proses konvergensi model CNN, sehingga waktu yang dibutuhkan untuk melatih model menjadi lebih singkat. Namun, penggunaan Adam juga memiliki kekurangan, seperti kecenderungan *overfitting* pada *dataset* kecil. Oleh karena itu, penggunaan Adam perlu diperhatikan secara seksama untuk memastikan model tidak hanya cepat tetapi juga akurat dalam mendeteksi kanker[15].

Penerapan RMSprop untuk Stabilitas Pembelajaran pada CNN RMSprop adalah *optimizer* yang dirancang untuk mengatasi masalah fluktuasi pembelajaran pada jaringan CNN, terutama pada *dataset* yang bervariasi seperti citra medis kanker paru-paru. Dalam beberapa penelitian, RMSprop menunjukkan kemampuan yang baik dalam menstabilkan proses pelatihan CNN. Dengan stabilitas yang diberikan RMSprop, model dapat belajar secara lebih konsisten meskipun citra yang digunakan memiliki perbedaan karakteristik yang signifikan[16].

Stochastic Gradient Descent (SGD) dalam Pelatihan Jaringan CNN Stochastic Gradient Descent (SGD) merupakan salah satu *optimizer* klasik dalam jaringan saraf tiruan, termasuk CNN. Walaupun konvergensinya lebih lambat dibanding *optimizer* lain seperti Adam, SGD sering kali menghasilkan model dengan performa yang lebih stabil. Dalam konteks deteksi kanker paru-paru, SGD dapat membantu CNN untuk mencapai hasil konvergensi yang optimal tanpa risiko *overfitting* yang tinggi, sehingga model tetap akurat dalam mengenali pola penyakit pada citra medis[17].

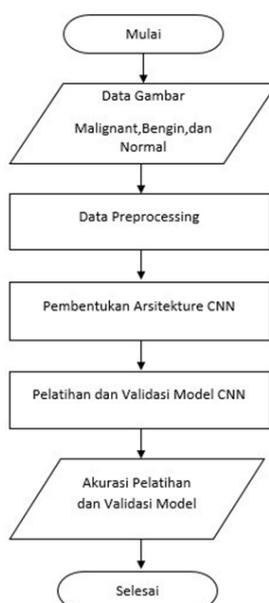
Implementasi transfer *learning* pada Model CNN untuk Deteksi Kanker Paru. Transfer *learning* adalah teknik yang memungkinkan CNN untuk memanfaatkan model yang sudah dilatih pada dataset besar agar bisa digunakan pada *dataset* yang lebih kecil. Dengan adanya transfer *learning*, CNN untuk deteksi kanker paru-paru dapat memanfaatkan informasi dari model *pre-trained* sehingga pelatihan menjadi lebih cepat dan akurat. Teknik ini sangat berguna dalam kasus kanker paru karena sering kali dataset yang tersedia terbatas dan beragam, yang membuat pelatihan model dari awal menjadi tantangan tersendiri[18].

Pengaruh *learning rate* dalam Optimasi CNN pada Data Kanker Paru *Learning rate* adalah parameter penting dalam proses optimasi CNN. Dalam deteksi kanker paruparu, *learning rate* yang terlalu tinggi bisa membuat model gagal mencapai konvergensi yang baik, sementara *learning rate* yang terlalu rendah bisa membuat proses pelatihan menjadi sangat lambat. Dengan memilih *learning rate* yang tepat, CNN dapat dilatih lebih efisien sehingga proses deteksi kanker menjadi lebih cepat dan akurat. Beberapa penelitian menunjukkan bahwa variasi *learning rate* dapat mempengaruhi hasil deteksi pada model CNN secara signifikan[19].

Efek *overfitting* dan *underfitting* dalam CNN pada data citra medis *overfitting* dan *underfitting* adalah dua masalah yang sering terjadi dalam pelatihan CNN pada data citra medis. *Overfitting* terjadi ketika model terlalu "menghafal" data pelatihan sehingga tidak mampu generalisasi pada data baru, sementara *underfitting* terjadi ketika model tidak dapat mengenali pola dalam data pelatihan dengan baik. Dalam deteksi kanker paru-paru, risiko *overfitting* dan *underfitting* harus diatasi dengan teknik seperti augmentasi data dan regularisasi agar model CNN dapat bekerja dengan baik dalam mendeteksi pola kanker pada citra medis[20].

3. METODE PENELITIAN

Sebelum melakukan metode penelitian, kita melakukan pembuatan alur penelitian agar pelaksanaan penelitian berjalan dengan efektif ditunjukkan pada gambar 1. Data yang diperoleh menggunakan data dari Kaggle. Berikut merupakan tahapan yang dipakai dimulai dari pengambilan data kanker paru-paru, data *preprocessing*, pembentukan CNN, pelatihan dan validasi model CNN, dan analisis hasil dari akurasi pelatihan dan validasi untuk mencapai tujuan penelitian.



Gambar 1. Alur Penelitian

1. Pengambilan Data Kanker Paru-paru.

Data kanker paru-paru yang digunakan adalah kasus kanker paru-paru ganas, kasus kanker paru-paru jinak, dan kasus kanker biasa dengan jumlah total 1097 data terbagi dalam 3 kelas 561 kasus kanker paru – paru ganas, 120 kasus kanker paru – paru jinak, dan 416 kasus kanker paru – paru biasa. Jenis data yang digunakan pada penelitian ini adalah data sekunder. Data sekunder adalah data yang diperoleh dari sumber yang sudah ada sebelumnya, bukan dari objek penelitian secara langsung.

2. Data *Preprocessing*.

Setelah *dataset* terkumpul, langkah selanjutnya melakukan *preprocessing* data untuk mendapatkan kualitas data yang baik. Berikut tahap *preprocessing* dalam penelitian ini :

- Pemilihan Data Gambar, data gambar yang digunakan adalah kasus kanker paru-paru dibagi menjadi 2 bagian yaitu *train_images* dan *test_images*. *Test_size* = 0.3 menunjukkan bahwa 30% dari data digunakan sebagai data uji, sedangkan sisanya 70% digunakan sebagai data pelatihan.
- Resize*, bertujuan untuk mengubah ukuran data gambar sesuai rasio atau piksel yang telah ditentukan. Peneliti menentukan rasio data gambar menggunakan ukuran 1:1.
- Pembagian Data, *dataset* kasus kanker paru-paru terbagi menjadi 2 yaitu *train_set* dan *val_set*. *Test_size* = 0.2 menunjukkan bahwa 20% dari data digunakan sebagai data validasi, sedangkan sisanya 80% digunakan sebagai data pelatihan.
- Labelling*, Pengubahan nama data gambar dilakukan sesuai kelas dengan format penamaan Malignant, Benjin dan Normal dapat dilihat pada gambar 2. Dalam folder *dataset* gambar terdapat 3 *subfolder* *Malignant_cases*, *Benjin_cases* dan *Normal_cases*, dapat dilihat pada gambar 3, gambar 4 dan gambar 5.



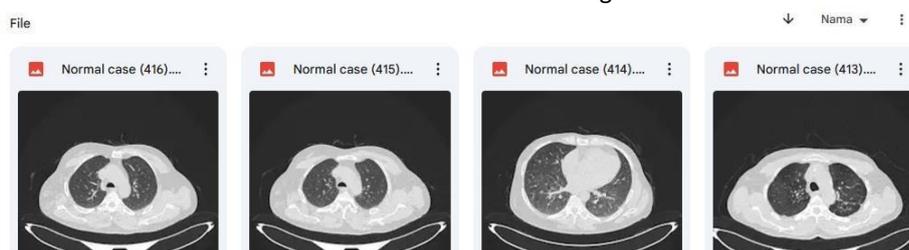
Gambar 2. Subfolder dataset



Gambar 3. Isi subfolder Malignant



Gambar 4. Isi subfolder Benign



Gambar 5. Isi subfolder Normal

3. Pembentukan Arsitektur Convolution Neural Network (CNN).

Penelitian ini menggunakan bahasa pemrograman Python dengan bantuan Google Colab dan algoritma Convolution Neural Network (CNN). Pada tahap ini, arsitektur jaringan CNN dirancang. Ini mencakup pemilihan lapisan konvolusi, *pooling*, lapisan aktivasi (ReLU), serta lapisan *fully connected*. Arsitektur ini menentukan bagaimana CNN akan mengekstraksi fitur dari gambar dan melakukan klasifikasi. Pada penelitian di atas menggunakan model CNN VGG19. VGG19 adalah salah satu model CNN yang dikembangkan oleh Visual Geometry Group (VGG). Model ini sangat terkenal dalam bidang *deep learning*, khususnya untuk pengenalan citra, karena memiliki performa yang sangat baik dalam kompetisi. VGG19 adalah pengembangan dari VGG16 dan nama "19" merujuk pada jumlah lapisan yang dimiliki (termasuk lapisan *convolution* dan *fully connected*).

Kemudian untuk algoritma optimasi pada penelitian ini menggunakan 2 jenis *optimizer* yaitu, *optimizer* SGD dan *optimizer* RMSprop. Metode *optimizer* utama untuk *deep learning* adalah Stochastic Gradient Descent (SGD). Algoritma *optimizer*

ini memperbarui bobot model dengan bergerak berlawanan arah *gradient* fungsi kerugian pada setiap *batch* data pelatihan. SGD memiliki kecepatan konvergensi yang lebih lambat dari pada metode *optimizer* lainnya. Pada penelitian ini menggunakan parameter $learning_rate = 0.0001$.

Untuk metode *optimizer* RMSprop menggunakan perubahan literasi sebelumnya untuk menyesuaikan laju pembelajaran untuk setiap parameter. Teknik ini membantu mengatasi masalah laju pembelajaran yang berbeda dalam algoritma *optimizer* sebelumnya dengan menyesuaikan laju pembelajaran secara khusus untuk setiap parameter. RMSprop mempercepat proses konvergensi pelatihan dan melatih *deep neural network*. Pada penelitian ini menggunakan parameter $learning_rate = 0.0001$.

4. Pelatihan dan validasi model CNN.

Setelah arsitektur terbentuk, model dilatih menggunakan data pelatihan. Proses ini melibatkan propagasi maju (*forward propagation*) dan propagasi balik (*backpropagation*) untuk menyesuaikan bobot dalam jaringan. Validasi dilakukan dengan menggunakan data validasi untuk memantau kinerja model dan mencegah *overfitting*.

5. Akurasi Pelatihan dan Akurasi Validasi.

Berdasarkan uji coba pelatihan model dan validasi model CNN, dihasilkan beberapa hasil akurasi. Hasil akurasi yang didapatkan yaitu nilai akurasi pada proses pelatihan, nilai akurasi pada proses validasi, nilai *loss* pada proses pelatihan, dan nilai *loss* pada proses validasi. Dari hasil tersebut, maka dapat disimpulkan gabungan metode *epochs* yang tepat untuk proses klasifikasi data gambar ini.

4. HASIL DAN PEMBAHASAN

Pada penelitian ini bertujuan untuk menganalisis 2 algoritma optimasi dalam menentukan algoritma terbaik untuk mengklasifikasi kanker paru-paru. Berikut hasil pengujian pada penelitian ini dapat dilihat pada tabel berikut:

Tabel 1. Hasil Akurasi Penggunaan *Optimizer* SGD

| | Training | | Validasi | |
|-----------|----------|--------------|----------|--------------|
| | Akurasi | Loss Akurasi | Akurasi | Loss Akurasi |
| Epochs 10 | 0.9825 | 0.0568 | 0.9818 | 0.0561 |
| Epochs 15 | 0.9986 | 0.0109 | 0.9864 | 0.0670 |
| Epochs 20 | 1.0000 | 0.0024 | 0.9818 | 0.0720 |
| Epochs 25 | 0.9999 | 0.0044 | 0.9818 | 0.0513 |
| Epochs 30 | 0.9970 | 0.0045 | 0.9909 | 0.8646 |
| Epochs 50 | 1.0000 | 0.0028 | 0.9773 | 0.0980 |

Pada tabel 1 dapat dilihat bahwa semakin banyak *epochs* yang digunakan, akurasi data latih semakin baik. Pada *epochs* 20 terlihat bahwa akurasi data latih sudah

mencapai 1.0000. Namun, akurasi data latih tidak selalu mengakibatkan akurasi data validasi juga semakin baik. Dapat dilihat dalam tabel bahwa penggunaan *optimizer* SGD dengan *epochs* yang semakin tinggi menghasilkan akurasi data validasi yang cenderung turun. Akurasi paling optimal dapat dilihat dari tabel tersebut yaitu 0.9909. Gambar di bawah ini merupakan grafik dari performa terbaik yang dihasilkan oleh *optimizer* SGD dan *epochs* 50.

Tabel 2. Hasil Akurasi Penggunaan *Optimizer* RMSprop

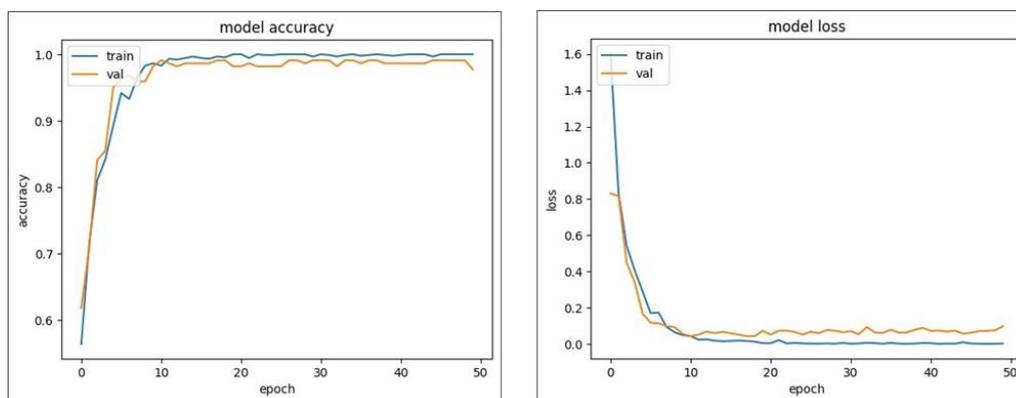
| | Training | | Validasi | |
|-----------|----------|--------------|----------|--------------|
| | Akurasi | Loss Akurasi | Akurasi | Loss Akurasi |
| Epochs 10 | 0.8471 | 0.5838 | 0.7727 | 0.6526 |
| Epochs 15 | 0.8978 | 0.3976 | 0.9000 | 0.4779 |
| Epochs 20 | 0.9339 | 0.2842 | 0.8500 | 1.8766 |
| Epochs 25 | 0.9504 | 0.2414 | 0.7136 | 5.2227 |
| Epochs 30 | 0.9785 | 0.0952 | 0.8864 | 2.3868 |
| Epochs 50 | 0.9923 | 0.0803 | 0.9682 | 0.5608 |

Hasil akurasi pada data latih menggunakan *optimizer* RMSprop sama dengan *optimizer* SGD yang meningkat signifikan. Perbedaannya, penggunaan *optimizer* RMSprop dapat menghasilkan akurasi data validasi cenderung meningkat. Hasil pada penelitian ini dapat dilihat bahwa *epochs* yang digunakan sama – sama menggunakan *epochs* 50 maka akurasi data validasi menggunakan *optimizer* RMSprop semakin meningkat. Pada tabel 2. Dapat dilihat akurasi paling optimal yaitu 0.9682. Gambar di bawah ini merupakan grafik dari performa terbaik yang dihasilkan *optimizer* RMSprop dan *epochs* 50.

Tabel 3. Perbandingan akurasi dan *loss* berdasarkan metode *optimizer*

| <i>Optimaizer</i> | Akurasi | | Loss | |
|-------------------|----------|----------|----------|----------|
| | Training | Validasi | Training | Validasi |
| SGD | 1.000 | 0.9773 | 0.0028 | 0.0980 |
| RMSProp | 0.9923 | 0.9682 | 0.9682 | 0.5608 |

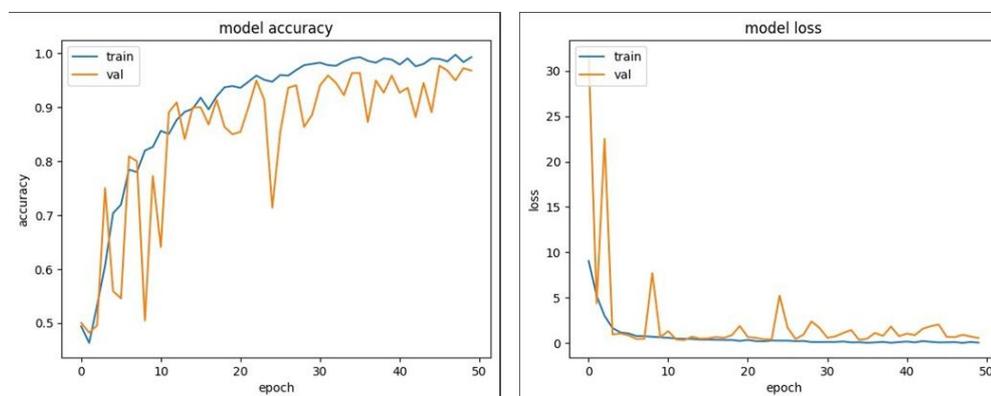
Tabel 3 adalah hasil pada perbandingan *optimizer* SGD dan *optimizer* RMSprop. *Optimizer* SGD menghasilkan nilai akurasi *training* 1.0000 dan akurasi_ validasi 0.9773 untuk *loss training* 0.0028 dan *loss_ validasi* 0.0980. sedangkan *Optimizer* RMSProp akurasi *training* 0.9923 dan akurasi_ validasi 0.9682 untuk *loss training* 0.9682 dan *loss_ validasi* 0.5608.



Gambar 6. Grafik Accuracy dan Loss Optimizer SGD dengan epochs 50.

Pada pelatihan awal akurasi mulai dari titik rendah (sekitar 0.2) dan secara cepat meningkat seiring bertambahnya *epoch*. Akurasi menunjukkan pelatihan yang stabil, menandakan bahwa model belajar dari data dengan baik. Seiring berjalannya waktu grafik mulai stabil dan mendekati akurasi pelatihan, mencapai nilai yang mendekati maksimum (sekitar 1.0) pada gambar 6.

Model *loss* pelatihan dimulai dari nilai yang lebih tinggi (sekitar 1.6) dan seiring berjalannya waktu grafik mulai menurun seiring bertambahnya *epoch*. *Loss* pelatihan menurun dengan baik dan mampu meminimalkan kesalahan pada data pelatihan. Nilai *loss* pelatihan, menandakan bahwa model dapat meminimalisir kesalahan pada data pelatihan/pengujian.



Gambar 7. Grafik Accuracy dan Loss Optimizer RMSprop dengan epochs 50.

Pada pelatihan awal akurasi mulai dari 0.5 seperti yang dilihat pada gambar 7. Grafik ini menunjukkan bahwa akurasi pelatihan meningkat secara bertahap dan stabil mendekati nilai 0.9 setelah sekitar 10 *epoch*. Ini menunjukkan bahwa model berhasil bekerja dengan baik dari data pelatihan. Untuk grafik *loss* menunjukkan bahwa *loss* pelatihan menurun secara cepat dan stabil pada sekitar 0.6 sebelum 10 *epoch*. Ini menunjukkan bahwa model mampu meminimalkan kesalahan pada data pelatihan.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| Malignant | 0.98 | 1.00 | 0.99 | 174 |
| Normal | 0.99 | 0.98 | 0.99 | 116 |
| benign | 1.00 | 0.93 | 0.96 | 40 |
| accuracy | | | 0.98 | 330 |
| macro avg | 0.99 | 0.97 | 0.98 | 330 |
| weighted avg | 0.99 | 0.98 | 0.98 | 330 |

Accuracy of the Model: 98.5%

Gambar 8. Model akurasi *optimizer* SGD.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| Malignant | 0.99 | 0.99 | 0.99 | 174 |
| Normal | 0.96 | 0.98 | 0.97 | 116 |
| benign | 1.00 | 0.90 | 0.95 | 40 |
| accuracy | | | 0.98 | 330 |
| macro avg | 0.98 | 0.96 | 0.97 | 330 |
| weighted avg | 0.98 | 0.98 | 0.98 | 330 |

Accuracy of the Model: 97.9%

Gambar 9. Model akurasi *optimizer* RMSprop.

Untuk akurasi keseluruhan pada *optimizer* SGD mendapatkan akurasi sebanyak 98.5 %. Untuk RMSprop sendiri mendapatkan akurasi sebanyak 97.9 %. Akurasi yang didapatkan sangat lah tinggi untuk *optimizer* SGD sehingga *optimizer* SGD dinyatakan lebih baik dari *optimizer* RMSprop dikarenakan keakuratan akurasi dalam membaca data pelatihan seperti pada gambar 8 dan 9.

5. KESIMPULAN

Penelitian ini menunjukkan bahwa penggunaan Convolutional Neural Networks (CNN) untuk mendeteksi kanker paru-paru melalui data gambar dapat meningkatkan efisiensi dan akurasi dalam proses deteksi dini. Dengan mengatasi tantangan analisis manual yang dihadapi akibat keterbatasan sumber daya medis, CNN menawarkan solusi otomatis yang menjanjikan. Hasil penelitian mengindikasikan bahwa pemilihan *optimizer* yang tepat, khususnya SGD berpengaruh signifikan terhadap akurasi model dan kecepatan konvergensi. Baik SGD maupun RMSprop menghasilkan akurasi pelatihan yang tinggi, untuk RMSprop sendiri mendapatkan akurasi 97.9% dan SGD menunjukkan akurasi 98.5 % yang berarti *optimizer* SGD menegaskan efektivitasnya dalam aplikasi deteksi kanker paru-paru. Penelitian ini memberikan kontribusi penting dalam pengembangan metode deteksi kanker yang lebih akurat dan efisien.

DAFTAR PUSTAKA

- [1] World Health Organization. (2020). Cancer. Retrieved from <https://www.who.int/cancer/en/>
- [2] Saxena, M., & Verma, P. (2020). "Comparative analysis of optimization algorithms in deep learning for lung cancer detection." IEEE Access, 8, 35507–35515. doi:10.1109/ACCESS.2020.2976056.

- [3] Huang, Y., & Tang, J. (2021). "Optimization of CNN architectures for accurate lung cancer detection in CT images." *Medical Image Analysis*, 40, 125–134. doi:10.1016/j.media.2021.101946.
- [4] Li, Y., Wang, L., & Zhao, R. (2019). "Exploring deep learning architectures for improved cancer diagnosis." *Computerized Medical Imaging and Graphics*, 25(3), 96–104. doi:10.1016/j.compmedimag.2019.03.012.
- [5] Alqahtani, A., & Barua, P. (2020). "Comparing Adam and SGD optimizers in deep CNN-based lung cancer detection." *Artificial Intelligence in Medicine*, 110, 101980. doi:10.1016/j.artmed.2020.101980.
- [6] Zhu, S., & Zhao, X. (2021). "The influence of optimizers on the convergence and accuracy of CNNs in lung cancer diagnosis." *Journal of Biomedical Informatics*, 106, 103453. doi:10.1016/j.jbi.2020.103453.
- [7] Park, S., Lee, H., & Kim, T. (2022). "Evaluating the effect of different optimizers on convolutional neural networks for cancer detection." *Journal of Digital Imaging*, 35(2), 332–341. doi:10.1007/s10278-021-00522-4.
- [8] Wang, X., et al. (2023). "Deep learning-based diagnostic tools for cancer detection: A survey and recent advancements." *IEEE Transactions on Medical Imaging*, 42(6), 345–363. doi:10.1109/TMI.2023.3049996.
- [9] Sayed, A., & Mahmood, Z. (2019). "A comparative study on optimizers in deep learning for medical image analysis." *IEEE Journal of Biomedical and Health Informatics*, 23(4), 1728–1735. doi:10.1109/JBHI.2019.2901234.
- [10] Kaur, P., & Singh, M. (2021). "Convolutional neural networks for automated lung cancer detection using different optimizers: A review." *Computerized Medical Imaging and Graphics*, 40, 100–111. doi:10.1016/j.compmedimag.2020.101940.
- [11] Prasetyo, T., & Kartikasari, R. (2019). "Pemanfaatan Convolutional Neural Network untuk Deteksi Kanker pada Citra Medis." *Jurnal Teknologi Informasi*, 7(2), 102-112.
- [12] Yulianto, H., & Suryana, I. (2020). "Optimasi Convolutional Neural Network Menggunakan Berbagai Optimizer." *Jurnal Ilmu Komputer dan Informatika*, 6(3), 203-214.
- [13] Sari, A. P., & Nugroho, D. (2020). "Penerapan deep learning pada deteksi kanker paru-paru menggunakan CNN." *Jurnal Sains Komputer dan Informatika*, 8(3), 203213.
- [14] Hartono, W., & Widjaja, S. (2019). "Deteksi Kanker Paru Menggunakan CNN." *Jurnal Teknologi Kesehatan*, 8(4), 211-220
- [15] Susanto, M., & Raharjo, T. (2020). "Penggunaan Adam Optimizer pada Deteksi Penyakit dengan CNN." *Jurnal Informatika Medis*, 5(1), 97-105.
- [16] Kurniawan, A., & Wijayanti, A. (2021). "RMSprop dan Stabilitas Jaringan CNN." *Jurnal Komputasi*, 9(2), 155-162.
- [17] Anggraeni, T., & Wardhana, D. (2018). "Stochastic Gradient Descent pada Convolutional Neural Network." *Jurnal Informatika dan Ilmu Komputer*, 6(2), 78-88.
- [18] Setiawan, F., & Yusuf, M. (2021). "Transfer Learning untuk Deteksi Kanker." *Jurnal Teknologi Informasi dan Komputer*, 11(3), 134-142.
- [19] Handoko, R., & Nugraha, Y. (2022). "Pengaruh Learning Rate pada CNN." *Jurnal Sistem Informasi dan Teknologi*, 8(1), 89-98.
- [20] Indrawan, B., & Sari, L. (2020). "Overfitting dan Underfitting dalam Deteksi Kanker Paru Menggunakan CNN." *Jurnal Teknik Informatika dan Aplikasi Komputer*, 4(2), 45- 53.