

SISTEM DETEKSI OTOMATIS CORONAVIRUS DISEASE (COVID-19) MENGUNAKAN GAMBAR CHEST X- RAY DENGAN JETSON NANO

Rian Fahrizal¹, Romi Wiryadinata¹, Alief Maulana¹

¹Jurusan Teknik Elektro, Fakultas Teknik, Universitas Sultan
Ageng Tirtayasa, Cilegon, Banten.

Informasi Artikel

Naskah Diterima: 4 Desember 2020

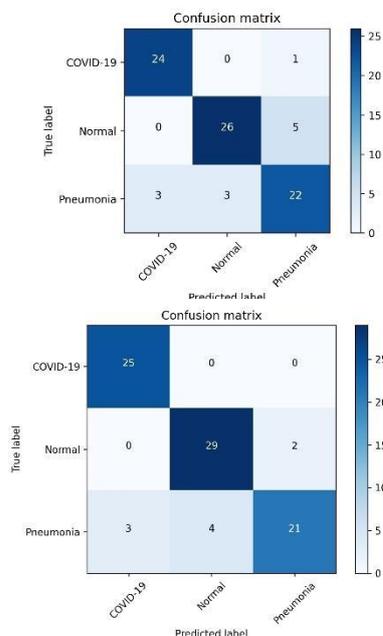
Direvisi: 21 Desember 2020

Disetujui: 21 Desember 2020

***Korespondensi Penulis:**

rian.fahrzal@untirta.ac.id

Graphical abstract



Abstract

Chest-X ray (CXR) radiography can be used as a first-line triage process for non-COVID-19 patients with pneumonia. However, the similarity between features of CXR images of COVID-19 and pneumonia caused by other infections make the differential diagnosis by radiologists challenging. We hypothesized that machine learning-based classifiers can reliably distinguish the CXR images of COVID-19 patients from other forms of pneumonia. We used a dimensionality reduction method to generate a set of optimal features of CXR images to build an efficient machine learning classifier with Nvidia Jetson Nano that can distinguish COVID-19 cases from non-COVID-19 cases with high accuracy and sensitivity. By using global features of the whole CXR images, we were able to successfully implement our classifier using a relatively small dataset of CXR images. We propose that our COVID-Classifier can be used in conjunction with other tests for optimal allocation of hospital resources by rapid triage of non-COVID-19 cases.

Keywords: Chest-X-Ray, Covid-19, CXR Images, COVID-19 Classifier, NVidia Jetson Nano

Abstrak

Radiografi rontgen dada (CXR) dapat digunakan sebagai proses triase lini pertama untuk pasien pneumonia non-COVID-19. Namun, kesamaan antara fitur gambar CXR COVID-19 dan pneumonia yang disebabkan oleh infeksi lain membuat diagnosis banding oleh ahli radiologi menjadi tantangan. Kami berhipotesis bahwa pengklasifikasi berbasis pembelajaran mesin dapat secara andal membedakan gambar CXR pasien COVID-19 dari bentuk pneumonia lainnya. Kami menggunakan perangkat Nvidia Jetson Nano dengan metode pengurangan dimensi untuk menghasilkan sekumpulan fitur optimal gambar CXR guna membuat pengklasifikasi pembelajaran mesin yang efisien yang dapat membedakan kasus COVID-19 dari kasus non-COVID-19 dengan akurasi dan sensitivitas tinggi. Dengan menggunakan fitur global dari seluruh gambar CXR, kami berhasil mengimplementasikan pengklasifikasi kami menggunakan kumpulan data gambar CXR yang relatif kecil. Kami mengusulkan agar Pengklasifikasi COVID kami dapat digunakan bersama dengan tes lain untuk alokasi optimal sumber daya rumah sakit dengan triase cepat kasus non-COVID-19.

Kata kunci: Radiografi rontgen dada, gambar CXR, COVID-19, Nvidia Jetson Nano.

© 2020 Penerbit Jurusan Teknik Elektro UNTIRTA Press. All rights reserved

1. PENDAHULUAN

Radiografi Chest-X Ray (CXR) adalah alat untuk pemeriksaan cepat di daerah pedesaan dan perkotaan. Alat ini telah dipasang di banyak PUSKESMAS (Pusat Kesehatan Masyarakat). CXR telah digunakan untuk mendeteksi penyakit Tuberculosis (TBC). [1]. Gambar CXR adalah analisis cepat untuk menunjukkan kondisi paru-paru dan secara cepat tersedia untuk dianalisis oleh ahli radiologi. CXR yang dipasang di daerah pedesaan dan kota di kabupaten dan beberapa fasilitas kesehatan swasta menjadikannya salah satu modalitas pencitraan pertama yang dapat digunakan dalam pandemi COVID-19. CXR cepat digunakan oleh ahli radiologi di banyak daerah dari kota hingga pedesaan di Indonesia

untuk melakukan triase pada pasien pneumonia non-COVID-19 untuk mengalokasikan alat dan sumber daya rumah sakit secara efisien [2]. Namun, banyak penyakit yang memiliki ciri-ciri umum antara gambaran medis COVID-19 dan pneumonia lain yang disebabkan oleh infeksi virus atau bakteri seperti flu biasa (influenza A) [2] atau tuberkulosis. Kesamaan ini membuat gambar CXR memiliki fitur gambar yang sedikit berbeda, dan hal ini membuat diagnosis kasus COVID-19 oleh ahli radiologi menjadi tantangan [2,3]. Mesin otomatis yang andal dengan Nvidia Jetson Nano untuk klasifikasi gambar CXR COVID-19 dan non-COVID-19 dapat mempercepat proses triase kasus non COVID-19 dan memaksimalkan alokasi sumber daya rumah sakit untuk kasus COVID-19.

Metode berbasis pembelajaran mesin (ML) telah menunjukkan keberhasilan yang belum pernah terjadi sebelumnya dalam analisis citra medis yang andal [4-8]. Pendekatan berbasis ML dapat diskalakan, dapat diotomatiskan, dan mudah diterapkan dalam pengaturan klinis [9, 10]. Aplikasi umum dari analisis gambar berbasis ML adalah klasifikasi gambar dengan fitur yang sangat mirip. Pendekatan ini bergantung pada segmentasi wilayah citra yang diminati, identifikasi fitur citra efektif yang dihitung dari area tersegmentasi dalam domain spasial atau frekuensi, dan pengembangan metode klasifikasi berbasis pembelajaran mesin yang optimal untuk secara akurat menetapkan sampel gambar ke dalam kelas target [11]. Di sini, kami berhipotesis bahwa gambar CXR pasien COVID-19 dapat dibedakan secara andal dari bentuk pneumonia lainnya menggunakan pengklasifikasi berbasis ML. Kami menggunakan pendekatan pengurangan dimensi untuk menghasilkan model dengan serangkaian fitur sintetis yang dioptimalkan yang dapat membedakan gambar COVID-19 dengan akurasi 94% dari kasus non-COVID-19. Fitur berbeda dari model kami adalah identifikasi dan fusi fitur gambar global yang dihitung dari seluruh gambar CXR tanpa segmentasi lesi, yang memungkinkan kami menghasilkan penanda pencitraan kuantitatif baru untuk memprediksi kemungkinan kasus pengujian menjadi COVID-19. Pendekatan berbasis fitur citra sinar-X global baru ini tidak hanya menghindari segmentasi lesi tetapi juga mengurangi kebutuhan set data pelatihan yang besar seperti halnya pendekatan pembelajaran dalam konvensional. Studi kami memberikan bukti konsep yang kuat bahwa klasifikasi berbasis ML sederhana dengan menggunakan perangkat Nvidia Jetson Nano dapat diterapkan secara efisien sebagai tambahan untuk tes lain untuk memfasilitasi diagnosis banding gambar CXR pasien COVID-19. Secara lebih luas, kami berpendapat bahwa pendekatan kami dapat dengan mudah diterapkan di setiap wabah virus di masa mendatang untuk klasifikasi cepat gambar CXR.

2. METODE PENELITIAN

2.1. Set data dan Kode (halaman Github)

Kode dan kumpulan data Python kami tersedia untuk diunduh di laman GitHub kami <https://github.com/abzargar/COVID-Classifier.git>.

Resource ini sepenuhnya open-source, menyediakan pengguna dengan kode Python yang digunakan dalam menyiapkan set data gambar, ekstraksi fitur, evaluasi fitur, melatih model ML, dan evaluasi model ML yang dilatih. Kami menggunakan kumpulan data, yang dikumpulkan dari dua sumber daya [28, 29]. Dataset kami yang dimodifikasi mencakup 420 gambar sinar-X 2-D, dalam tampilan dada Posteroanterior (PA), diklasifikasikan oleh tes yang valid ke tiga kategori yang telah ditentukan sebelumnya yaitu Normal (140 gambar), pneumonia (140 gambar), dan COVID-19 (140 gambar). Kami mengatur semua ukuran gambar menjadi 512×512 piksel.

2.2. Ekstraksi Fitur

Kami menggunakan skema untuk menghitung total 252 fitur di domain spasial dan frekuensi. Kami mengkategorikannya menjadi lima kelompok, termasuk Texture [30], Gray-Level Co-Occurrence Matrix (GLCM) [31], Gray Level Difference Method (GLDM) [8], Fast Fourier Transform (FFT) [32], dan Wavelet transformasi [33]. Kami menerapkan metode GLCM dan GLDM dalam empat arah yang berbeda, dan transformasi Wavelet dalam delapan sub-band. Seperti yang ditunjukkan, untuk setiap grup atau setiap sub-bagian, kami menghitung 14 fitur dengan menerapkan ukuran statistik yang sama. 14 fitur yang kami ukur terdiri dari Mean, Std, Skewness, Kurtosis, Energy, Entropy, Max, Min, Mean Deviation, Median, Range, RMS, Uniformity, MeanGradient, dan StdGradient. Skema ekstraksi fitur menghasilkan total 252 fitur untuk setiap citra X-ray (14 fitur dari Texture, 14 fitur dari FFT, 56 fitur dari GLCM, 56 fitur dari GLDM, dan 112 fitur dari Wavelet).

2.3. Evaluasi kekuatan klasifikasi fitur yang diekstraksi

Perbandingan nilai AUC di antara fitur tunggal yang berbeda (misalnya, Mean, Std_FFT, dan Min_Wavelet) untuk tiga label kelas positif. Semua fitur diurutkan menggunakan nilai AUC sebagai indikator daya diskriminasi fitur. Seperti yang terlihat di ketiga grafik, lebih dari 100 fitur mencatat nilai AUC lebih tinggi dari 0,6 sedangkan fitur Max_FFT, MeanDeviation_GLDM, dan Kurtosis_Wavelet adalah tiga pemain teratas yang terkait dengan label kelas positif COVID-19, Normal, dan Pneumonia dengan nilai AUC 0,87, 0,91, dan 0,88, masing-masing.

Kinerja lima kelompok fitur (misalnya, Tekstur, FFT, dan Wavelet) dengan membandingkan nilai AUC rata-rata mereka. Seperti yang terlihat, tidak ada perbedaan yang signifikan di antara keduanya, terutama jika label positifnya adalah pneumonia. Mengingat COVID merupakan kelas sasaran, maka kelompok FFT mencatat kinerja terbaik, sedangkan kelompok terbaik untuk kelas Normal adalah GLDM.

2.4. Buat model hyperparameter dan run-time

Untuk proses pelatihan jaringan saraf multi-lapisan yang dirancang, kami memilih pengoptimal Adam dan Adamax untuk mengoptimalkan bobot model dan meminimalkan fungsi kerugian lintas-entropi kategoris. Hyperparameter algoritme pembelajaran ditetapkan sebagai berikut: BatchSize = 2, MaxEpochs = 100, LearningRate = 0,001, DropoutValue = 0,2, TrainRatio = 0,6, ValRatio = 0,2, dan TestRatio = 0,2. Kami juga menggunakan teknik Penghentian Awal untuk menghentikan pelatihan saat skor validasi berhenti meningkat, yang bertujuan untuk menghindari overfitting.

3. HASIL DAN PEMBAHASAN

3.1. Pembuatan fitur sintetis

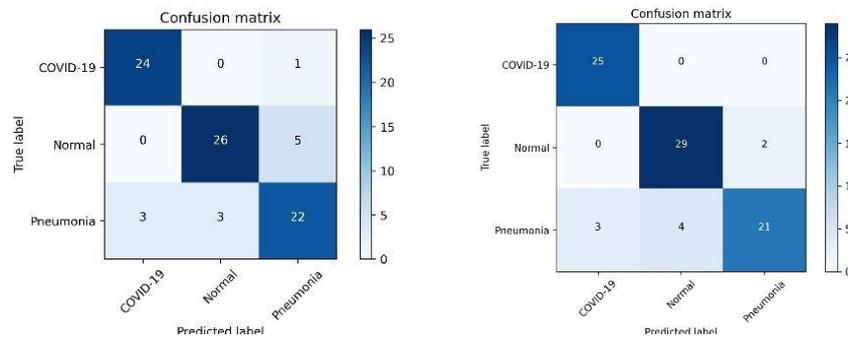
Identifikasi fitur optimal gambar CXR dapat mengurangi ruang fitur model ML dengan membuat fitur sintetis berkorelasi utama dan menghapus fitur yang kurang penting. Fitur sintetis ini bekerja dengan lebih andal dalam tugas klasifikasi sambil mengurangi ukuran model ML. Yang penting, pengklasifikasi ML yang lebih kuat dapat dibuat dengan meningkatkan rasio antara kasus pelatihan per kelas dan fitur gambar. Kami awalnya mengekstraksi 252 fitur dari keseluruhan gambar CXR tanpa melibatkan segmentasi lesi untuk akhirnya menghasilkan kumpulan fitur dari 420 gambar CXR. Kami berhipotesis bahwa kami dapat menggunakan skema analisis fitur untuk mengurangi ukuran ruang fitur ke sejumlah fitur yang optimal. Kami menghitung koefisien korelasi Pearson yang menghasilkan matriks untuk setiap kombinasi fitur berpasangan. Analisis histogram dari kumpulan fitur awal menunjukkan bahwa lebih dari 73% fitur memiliki koefisien korelasi kurang dari 0,4, menunjukkan bahwa kumpulan fitur yang dibuat dalam penelitian kami telah memberikan pandangan yang komprehensif tentang kasus, yang berisi relatif kecil. redundansi. Kami menggunakan metode Kernel-Principal Component Analysis (PCA) untuk mengurangi dimensi ruang fitur menjadi jumlah optimal fitur sintetis yang terdiri dari fitur berkorelasi. Dengan menggunakan PCA, kami mengonversi fitur pool 252 asli menjadi 64 fitur sintetis baru yang menghasilkan ruang fitur ~ 4x lebih kecil. Vektor dari 64 fitur terpilih ini digunakan untuk tujuan klasifikasi.

3.2. Kinerja Klasifikasi

Untuk mendesain pengklasifikasi kami, kami mengelompokkan gambar CXR kami ke dalam tiga kelas target, masing-masing berisi 140 gambar; normal, COVID-19, pneumonia non-COVID-19. Kami menggunakan jaringan saraf multi-layer dengan dua lapisan tersembunyi dan satu pengklasifikasi keluaran untuk mengklasifikasikan gambar CXR menjadi tiga kelompok.

Selama pelatihan model kami, set pelatihan dan validasi mencapai ~ 0,22 skor kerugian dan akurasi 94% setelah 33 periode. Grafik kerugian menunjukkan kesesuaian yang baik antara kurva validasi dan pelatihan, yang mengonfirmasi bahwa model kami tidak mengalami overfitting atau underfitting. Kami ingin mencatat bahwa model kami memiliki ~ 10.000 parameter yang jauh lebih kecil daripada model klasifikasi gambar biasa seperti AlexNET dengan 60 juta parameter [12], VGG-16 dengan 138 juta [13], GoogleNet-V1 dengan 5 juta [14], dan ResNet-50 dengan 25 juta parameter [15]. Selanjutnya, kami menghasilkan kurva karakteristik operasi penerima (ROC) dan area komputasi di bawah ROC (AUC) untuk menilai lebih lanjut kinerja model kami. Perbandingan gambar CXR kasus COVID-19 dengan non-COVID-19 menunjukkan bahwa model kami memiliki sensitivitas 100% dan presisi 96% saat dievaluasi pada set pengujian 84 gambar CXR. Selain itu, pengklasifikasi fitur sintetis

kami mengungguli pengklasifikasi fitur tunggal apa pun yang diukur dengan AUC. Patut dicatat bahwa fitur sintesis tunggal sebagai pengklasifikasi biaya komputasi cepat dan rendah utama dapat akurat hingga ~ 90%. Adapun hasil dari klasifikasi kami dapat ditunjukkan dengan menggunakan confusion matriks pada optimasi Adam dan Adamax pada Gambar 1.



Gambar 1. Confusion Matriks dengan Optimasi Adam dan Adamax

Dalam studi ini, kami menunjukkan bahwa pengklasifikasi pembelajaran mesin yang efisien dapat secara akurat membedakan gambar CXR COVID19 dari kasus normal dan juga pneumonia yang disebabkan oleh virus lain. Meskipun modalitas pencitraan yang berbeda telah diterapkan untuk skrining paru [16-18], X-ray tetap menjadi alat tercepat dan banyak digunakan untuk skrining penyakit paru berbasis populasi. Namun, sejumlah besar lesi paru yang mencurigakan dapat menyebabkan kesalahan klasifikasi kasus. Dengan demikian, pengembangan pendekatan baru untuk memfasilitasi klasifikasi berbagai jenis kondisi paru-paru sangat penting untuk meningkatkan efektivitas skrining dan analisis paru. Dalam studi ini, kami mengembangkan skema pembelajaran mesin baru yang memanfaatkan fitur citra global untuk memprediksi kemungkinan kasus pengujian menjadi COVID-19 tanpa segmentasi lesi. Pekerjaan kami memiliki sejumlah pengamatan baru sebagai berikut:

Pertama, alih-alih menghitung fitur citra dari area tersegmentasi, kami mengekstrak fitur citra global dari seluruh area dada, yang menghindari kesulitan dan kesalahan dalam segmentasi lesi dan menemukan ukuran optimal ROI untuk memasukkan lesi dengan berbagai ukuran dan bentuk. Hasil kami menunjukkan bahwa informasi yang bermakna secara klinis tidak hanya terfokus pada lesi tetapi juga menyebar ke seluruh area dada dari citra sinar-X.

Kedua, tidak seperti banyak model pembelajaran mesin yang dikembangkan sebelumnya yang berfokus pada komputasi fitur berbasis tekstur dalam domain spasial, kami menghitung fitur gambar di domain spasial (Tekstur, GLDM, GLCM) dan domain frekuensi (FFT dan Wavelet). Dengan menilai performa prediksi semua fitur tunggal, tiga fitur prediktor teratas adalah Max_FFT, MeanDeviation_GLDM, dan Kurtosis_Wavelet. Mengingat sifat fitur unggulan pada kategori COVID-19 yang sebagian besar terekam dalam domain frekuensi, maka kemungkinan besar perubahan varians pada domain frekuensi tersebut merupakan ciri khas citra CXR kasus COVID-19. Selain itu, jika kami menghitung rata-rata performa fitur di masing-masing dari lima grup yang berbeda, fitur FFT memiliki daya prediksi yang lebih baik daripada grup lain yang terkait dengan COVID-19. Ini menunjukkan pentingnya memperoleh fitur domain frekuensi tersebut dan menyiratkan bahwa fitur tersebut relevan dengan deteksi infeksi COVID-19 pada gambar CXR.

Ketiga, karena mengidentifikasi fitur gambar yang optimal dan paling efektif adalah salah satu tugas terpenting dan menantang dalam mengembangkan pengklasifikasi berbasis pembelajaran mesin, kami menyelidiki pengaruh penerapan metode pengurangan dimensi untuk memilih fitur yang lebih optimal dan lebih berkorelasi. Menariknya, hasil menunjukkan bahwa metode pengurangan dimensi kami tidak hanya mengurangi dimensi ruang fitur tetapi juga mampu mengatur ulang vektor fitur baru yang lebih kecil dengan informasi yang lebih berkorelasi dan jumlah redundansi yang lebih rendah. Selain itu, berdasarkan teori pembelajaran mesin, meningkatkan rasio jumlah kasus per kelas dengan jumlah fitur akan meningkatkan ketahanan pengklasifikasi pembelajaran mesin dan mengurangi risiko overfitting. Oleh karena itu, dengan menggunakan metode pemilihan fitur yang optimal ini, kami dapat menggunakan kumpulan data yang relatif kecil sebanyak 420 kasus untuk model pengklasifikasi akhir, yang menghindari persyaratan kumpulan data yang besar saat mengembangkan skema berbasis pembelajaran yang dalam dengan akurasi yang sama atau bahkan lebih rendah [19].

Dari Gambar 1 yang telah ditunjukkan sebelumnya dapat ditentukan kinerja dari kecerdasan buatan pada Nvidia Jetson Nano dapat ditunjukkan pada tabel 1.

Kinerja	Adam			Adamax		
	Covid-19	Normal	Pneumonia	Covid-19	Normal	Pneumonia
Accuracy	0.9473684	0.9	0.85714285	0.96153846	0.92592592	0.89285714
Precision	0.96	0.83870967	0.78571428	1	0.93548387	0.75
Sensitifitas	0.8888888	0.89655172	0.78571428	0.89285714	0.87878787	0.91304347
Specifity	0.9795918	0.90196078	0.89285714	1	0.95833333	0.88524590
F1-Score	0.9230769	0.86666666	0.78571428	0.94339622	0.90625	0.82352941

Dari Tabel 1. menunjukkan bahwa nilai Adamax memiliki nilai yang lebih baik jika dibandingkan dengan optimalisasi Adam. Dapat dilihat bahwa nilai perbandingan Accuracy pada Covid-19 untuk Adamax memiliki nilai 94,73% sedangkan untuk Adamax sebesar 96,15%. Kemudian nilai Precision pada Adamax untuk kategori Covid-19 sebesar 96% sedangkan untuk Adamax sebesar 100%. Hal ini menunjukkan bahwa optimalisasi Adamax berhasil mendeteksi COvid-19 dengan baik dan akurat. Sedangkan kinerja secara keseluruhan untuk optimalisasi Adam dan adamax adalah sebagai berikut dengan nilai rata-rata untuk akurasi adalah sebesar 90,15% untuk Adam dan sebesar 92,677% untuk Adamax. Nilai Precession dari Adamax memiliki rata-rta 86,147% sedangkan untuk Adamax adalah 89.516%. Kemudian Nilai sensitifitas dan specifity rata-rata dari Adamax ialah 85,705% dan 92,48% sedangkan untuk Adamax ialah 89,49% dan 94,786%. Untuk nilai yang terpenting dari kinerja kecerdasan buatan pada Jetson Nano ini ialah nilai F-1 Score dimana nilai untuk Adam memiliki nilai rata-rata 85,849% sedangkan untuk Adamax bernilai 89,106%. Hal ini menunjukkan bahwa Nvidia Jetson Nano telah bisa digunakan untuk membantu mendiagnosa penyakit Covid-19 dengan menggunakan gambar hasil rontgen paru.

Terlepas dari hasil yang menggembirakan, kami menyadari bahwa penelitian ini memiliki beberapa keterbatasan. Pertama, set data CXR kami memiliki ukuran yang relatif kecil. Dataset yang lebih besar yang terdiri dari kasus-kasus dari institusi berbeda akan berguna untuk lebih memverifikasi keandalan dan ketahanan model yang kami usulkan. Kedua, dalam pekerjaan kami selanjutnya, kami akan menyelidiki pemilihan fitur yang berbeda dan metode pengurangan fitur seperti DNE [20], Relief [21], LPP [5], Fast-ICA [22], penghapusan fitur rekursif [23], peringkat variabel teknik [24], atau menggabungkannya dengan pendekatan pengurangan fitur kami. Ketiga, penelitian ini menggunakan pengklasifikasi berbasis jaringan saraf tiruan yang dapat menyelesaikan masalah kompleks dan beradaptasi dengan baik pada data berdimensi tinggi. Namun, mungkin ada kebutuhan untuk mengeksplorasi pengklasifikasi efektif lainnya seperti SVM [25], GLM [26], Random Forest [27].

4. KESIMPULAN

4.1 Kesimpulan

Hasil dari perhitungan kinerja dari system ini, yaitu:

- a) Sistem deteksi memiliki kinerja yang baik yakni memiliki nilai rata-rata F1-Score sebesar 92% dengan nilai specifity sebesar 85,7% dengan Presisi 86% dan accuracy sebesar 90% untuk metode optimalisasi Adam.

- b) Untuk metode optimalisasi Adamax dihasilkan nilai rata-rata untuk Accuracy sebesar 92,6%, nilai presisi 89,5%, nilai sensitifitas 89,5% dan dengan F1-score 89,1%.
- c) Untuk kedua metode optimalisasi berikut ini nilai optimalisasi Adamax lebih baik jika dibandingkan dengan optimaslisasi Adam.

4.2 Saran

Dalam penelitian ini masih banyak sekali kekurangan dan ketidaksempurnaan. Untuk itu, perlu dilakukan pengembangan agar ke depannya menjadi sempurna ataupun lebih baik lagi sehingga memiliki beberapa saran, diantaranya:

- a) Perlu dilakukan studi lebih lanjut mengenai menggunakan metode optimalisasi lainnya.
- b) Perlu dilakukan studi lebih lanjut mengenai metode ekstraksi ciri lain sehingga didapatkan hasil yang lebih optimal
- c) Perlu dilakukan penelitian lagi dengan menggunakan alat yang memiliki kinerja yang lebih baik lagi

REFERENSI

- [1] Organization, W.H., chest radiography in tuberculosis detection. 2016.
- [2] Dai, W.-c., et al., CT Imaging and Differential Diagnosis of COVID-19. Canadian Association of Radiologists Journal, 2020. 71(2): p. 195-200.
- [3] Wong, H.Y.F., et al., Frequency and Distribution of Chest Radiographic Findings in COVID-19 Positive Patients. Radiology, 2020: p. 201160.
- [4] Du, Y., et al., Classification of Tumor Epithelium and Stroma by Exploiting Image Features Learned by Deep Convolutional Neural Networks. Annals of Biomedical Engineering, 2018. 46(12): p. 19881999.
- [5] Heidari, M., et al., Prediction of breast cancer risk using a machine learning approach embedded with a locality preserving projection algorithm. Physics in Medicine & Biology, 2018. 63(3): p. 035020.
- [6] Heidari, M., et al., Development and Assessment of a New Global Mammographic Image Feature Analysis Scheme to Predict Likelihood of Malignant Cases. IEEE Transactions on Medical Imaging, 2020. 39(4): p. 1235-1244.
- [7] Opbroek, A.v., et al., Transfer Learning Improves Supervised Image Segmentation Across Imaging Protocols. IEEE Transactions on Medical Imaging, 2015. 34(5): p. 1018-1030.
- [8] Zargari, A., et al., Prediction of chemotherapy response in ovarian cancer patients using a new clustered quantitative image marker. Physics in Medicine & Biology, 2018. 63(15): p. 155020.
- [9] Ahmed, Z., et al., Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. Database: the journal of biological databases and curation, 2020. 2020: p. baaa010.
- [10] Shah, P., et al., Artificial intelligence and machine learning in clinical development: a translational perspective. NPJ digital medicine, 2019. 2: p. 69-69.
- [11] Sun, L., et al., High-Order Feature Learning for Multi-Atlas Based Label Fusion: Application to Brain Segmentation With MRI. IEEE Transactions on Image Processing, 2020. 29: p. 2702-2713.
- [12] Krizhevsky, A., I. Sutskever, and G.E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks. 2012: p. 1097-1105.
- [13] Simonyan, K. and A. Zisserman, Very Deep Convolutional Networks for Large-Scale Image Recognition. 2014.
- [14] Szegedy, C., et al., Going deeper with convolutions. 2014.
- [15] He, K., et al., Deep residual learning for image recognition. 2015.
- [16] Dimastromatteo, J., E.J. Charles, and V.E. Laubach, Molecular imaging of pulmonary diseases. Respiratory Research, 2018. 19(1): p. 17.
- [17] Kesim, E., Z. Dokur, and T. Olmez. X-Ray Chest Image Classification by A Small-Sized Convolutional Neural Network. in 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT). 2019.
- [18] Srivastava, S.D., M.J. Eagleton, and L.J. Greenfield, Diagnosis of pulmonary embolism with various imaging modalities. Seminars in Vascular Surgery, 2004. 17(2): p. 173-180.

- [19] Wang, L. and A. Wong, COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images. 2020.
- [20] Zhang, W., et al., Discriminant neighborhood embedding for classification. *Pattern Recognition*, 2006. 39(11): p. 2240-2243.
- [21] Urbanowicz, R.J., et al., Relief-based feature selection: Introduction and review. *Journal of Biomedical Informatics*, 2018. 85: p. 189-203.
- [22] Moallem, P., A. Zargari, and A. Kiyoumars, An approach for data mining of power quality indices based on fast-ICA algorithm. *International Journal of Power and Energy Systems*, 2014. 34(3): p. 91-98.
- [23] Chen, X. and J.C. Jeong. Enhanced recursive feature elimination. in *Sixth International Conference on Machine Learning and Applications (ICMLA 2007)*. 2007.
- [24] Haq, A.U., et al., Combining Multiple Feature-Ranking Techniques and Clustering of Variables for Feature Selection. *IEEE Access*, 2019. 7: p. 151482-151492.
- [25] Guo, Y., X. Jia, and D. Paull, Effective Sequential Classifier Training for SVM-Based Multitemporal Remote Sensing Image Classification. *IEEE Transactions on Image Processing*, 2018. 27(6): p. 30363048.
- [27] Zhao, L., Y. Chen, and D.W. Schaffner, Comparison of Logistic Regression and Linear Regression in Modeling Percentage Data. *Applied and Environmental Microbiology*, 2001. 67(5): p. 2129.
- [28] Naghibi, S.A., K. Ahmadi, and A. Daneshi, Application of Support Vector Machine, Random Forest, and Genetic Algorithm Optimized Random Forest Models in Groundwater Potential Mapping. *Water Resources Management*, 2017. 31(9): p. 2761-2775.
- [29] Kermany, D.Z., Kang; Goldbaum, Michael, Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification. 2018. Mendeley Data.
- [30] Cohen, J.P., P. Morrison, and L. Dao, COVID-19 Image Data Collection. 2020.
- [31] Danala, G., et al., Applying Quantitative CT Image Feature Analysis to Predict Response of Ovarian Cancer Patients to Chemotherapy. *Academic Radiology*, 2017. 24(10): p. 1233-1239.
- [32] Rajkovic, N., et al., Novel application of the gray-level co-occurrence matrix analysis in the parvalbumin stained hippocampal gyrus dentatus in distinct rat models of Parkinson's disease. *Computers in Biology and Medicine*, 2019. 115: p. 103482.
- [33] Moallem, P., A. Zargari, and A. Kiyoumars, Improvement in Computation of ΔV_{10} Flicker Severity Index Using Intelligent Methods. *Journal of Power Electronics*, 2011. 11(2): p. 228-236.
- [34] Kehtarnavaz, N., *Digital signal processing system design*. Elsevier Inc. 2008.