

KLASIFIKASI PNEUMONIA DAN CONGESTIVE HEART FAILURE PADA CITRA X-RAY DADA MENGGUNAKAN GAMMA CORRECTION DENGAN COATNET-SVM

Rafy Aulia Akbar ¹⁾, Ricky Eka Putra ¹⁾, Wiyli Yustanti ¹⁾

1) Universitas Negeri Surabaya

E-mail: 24051905007@mhs.unesa.ac.id, rickyeka@unesa.ac.id, wilyliyustanti@unesa.ac.id

Abstrak

Sistem pelayanan kesehatan menghadapi tekanan akibat volume citra medis yang terus meningkat sementara jumlah tenaga ahli terbatas, sehingga klasifikasi otomatis citra Chest X-ray (CXR) menggunakan kecerdasan buatan menjadi solusi mengingat peran CXR sebagai pencitraan utama dalam skrining awal. Penelitian ini bertujuan untuk mengembangkan pendekatan terintegrasi untuk klasifikasi pneumonia dan Congestive Heart Failure (CHF) melalui tiga tahap utama: *preprocessing* citra menggunakan *gamma correction* untuk peningkatan kontras, ekstraksi fitur dengan model *pretrained CoAtNet* yang menggabungkan arsitektur CNN dan Transformer, serta klasifikasi menggunakan *Support Vector Machine (SVM)* dengan optimasi *hyperparameter* melalui *k-fold cross-validation*. Hasil pengujian menunjukkan metode yang diusulkan mencapai performa dengan akurasi 0,841, presisi 0,842, recall 0,831, dan F1-score 0,832, melampaui semua pendekatan sebelumnya termasuk yang bergantung pada data *eye-gaze* tambahan. Kesimpulannya, kombinasi *gamma correction*, ekstraksi fitur *CoAtNet*, dan SVM yang dioptimalkan terbukti efektif meningkatkan akurasi klasifikasi pneumonia dan CHF tanpa memerlukan data eksternal yang sulit diperoleh, sehingga berpotensi diimplementasikan dalam praktik klinis untuk mendukung diagnosis cepat dan akurat.

Kata kunci: *Pneumonia, Congestive Heart Failure (CHF), Chest X-ray, Gamma Correction, CoAtNet.*

Pendahuluan

Identifikasi penyakit pneumonia dan CHF sangat penting karena berdampak tinggi terhadap sistem perawatan kesehatan dan unit gawat darurat [1]. Diagnosis penyakit dengan memanfaatkan teknologi pencitraan medis kini menjadi metode utama bagi dokter dan tenaga kesehatan. Citra radiologi, seperti X-ray dan CT scan, berperan penting dalam mengidentifikasi berbagai kondisi, seperti pneumonia dan CHF [2]. Pneumonia adalah kondisi peradangan paru-paru sedangkan CHF adalah kondisi medis di mana jantung tidak dapat memompa cukup darah untuk memenuhi kebutuhan tubuh [3]. Sistem pelayanan kesehatan saat ini menghadapi tekanan besar akibat meningkatnya volume citra medis yang harus dianalisis oleh tenaga ahli yang jumlahnya terbatas [4]. Untuk mengatasi tantangan ini, klasifikasi otomatis citra *Chest X-ray (CXR)* menggunakan kecerdasan buatan menjadi solusi strategis karena CXR merupakan pencitraan pertama dan paling umum digunakan dalam skrining awal [5].

Klasifikasi citra *Chest X-ray (CXR)* masih menghadapi sejumlah tantangan utama yang menghambat kinerja dan penerapan model secara luas. Pertama, sebagian besar penelitian belum menerapkan *preprocessing* citra secara sistematis untuk meningkatkan kualitas *input*, padahal kualitas CXR sangat memengaruhi akurasi model [6], [7]. Kedua, banyak pendekatan bergantung pada data tambahan seperti *eye-gaze* dari radiolog, yang sulit dikumpulkan dalam praktik klinis [4], [8], [9], [10]. Ketiga, optimasi *hyperparameter* sering diabaikan, seperti pada pendekatan ensemble berbasis transfer learning yang belum memanfaatkan *hyperparameter tuning*, sehingga potensi performa model belum tercapai secara optimal [2]. Oleh karena itu, dibutuhkan *preprocessing* yang baik untuk meningkatkan kualitas data, penggunaan *pretrained* model canggih yang telah dilatih pada dataset besar untuk ekstraksi fitur.

Untuk mengatasi tantangan tersebut, penelitian ini bertujuan untuk mengembangkan pendekatan terintegrasi yang mencakup *preprocessing*, ekstraksi fitur menggunakan model *hybrid*, dan optimasi *hyperparameter*. Citra CXR terlebih dahulu ditingkatkan kualitasnya menggunakan *gamma correction* untuk memperbaiki kontras. Fitur kemudian diekstraksi menggunakan model *pretrained CoAtNet*, yang dipilih karena kemampuannya menggabungkan kekuatan CNN dan Transformer, sehingga cocok untuk klasifikasi multi-kondisi seperti pneumonia dan CHF. Fitur

tersebut digunakan sebagai *input* klasifikasi SVM, dengan *hyperparameter* yang dioptimalkan melalui k-fold cross-validation. Singkatnya, kontribusi utama penelitian ini dapat dirangkum sebagai berikut:

1. Penerapan gamma correction sebagai tahap *preprocessing* untuk meningkatkan kualitas dan kontras citra CXR.
2. Pemanfaatan ekstraksi fitur berbasis model *pretrained* CoAtNet untuk menghasilkan representasi fitur yang lebih komprehensif.
3. Optimasi klasifikasi menggunakan SVM melalui *hyperparameter tuning* dengan k-fold cross-validation untuk memperoleh konfigurasi model terbaik.

Studi Pustaka

Penelitian dalam bidang ini telah berkembang pesat dalam beberapa tahun terakhir, terutama dengan kemajuan *deep learning*. [4] mengusulkan dua metode yaitu Gaze-WS yang menggunakan pola pandangan mata untuk menghasilkan *weak* label tanpa diagnosis asli dan Gaze-MTL yang menerapkan pembelajaran *multi-task* dengan menggabungkan data *gaze* dan label penyakit sebenarnya, namun keduanya terkendala oleh sifat data *gaze* yang sulit dikumpulkan. Selain itu, [8] mengembangkan Gaze-Guided Class Activation Mapping (GG-CAM) yang menggunakan *heat map visual attention* dari *eye-gaze* ahli untuk mengarahkan *attention* jaringan CNN, bertujuan meningkatkan interpretabilitas dan akurasi lokal, tetapi berdampak pada waktu pelatihan yang lebih lama dan ketergantungan pada arsitektur CNN tertentu.


Selanjutnya, [9] mengusulkan model dua tahap berbasis *variational inference* yang secara probabilistik menggabungkan dataset besar dengan label global dan subset kecil yang dilengkapi anotasi tingkat objek, seperti *eye-gaze*, untuk memperkaya representasi spasial dan meningkatkan akurasi klasifikasi, meskipun keterbatasannya terletak pada rendahnya generalisasi antar dataset akibat. Di sisi lain, [11] mengembangkan pendekatan ensemble berbasis *transfer learning* dengan menggabungkan dua arsitektur CNN, yaitu InceptionResNetV2 dan MobileNetV2, melalui *Ensemble Average Voting* untuk memanfaatkan keunggulan komplementer keduanya dalam menangkap fitur spasial dan kontekstual; namun pendekatan ini belum menerapkan *hyperparameter tuning*, sehingga potensi performa optimal model belum sepenuhnya tercapai.

Terakhir, [10] mengusulkan GazeGNN, sebuah *Graph Neural Network* yang dipandu oleh data *eye-gaze*. Dalam pendekatan ini, citra dibagi menjadi *patch*, masing-masing dijadikan *node* dalam graf yang menggabungkan tiga jenis informasi: lokasi *patch*, intensitas citra lokal, dan *human attention* dari data *gaze*. Namun, metode ini tetap bergantung pada ketersediaan data *eye-gaze* dari radiolog, yang seringkali tidak tersedia dalam praktik klinis.

Secara umum, sebagian besar metode sebelumnya bergantung pada data tambahan yang sulit diperoleh, seperti *eye-gaze* dari radiolog, serta kurangnya optimasi *hyperparameter*. Oleh karena itu, penelitian ini mengusulkan pendekatan yang lebih praktis dan efektif tanpa menggunakan *gaze data*.

Metodologi Penelitian

Gambar 1 mengilustrasikan alur kerja sistem yang diusulkan dalam penelitian ini untuk klasifikasi pneumonia dan CHF pada citra CXR. Proses dimulai dari citra CXR sebagai input, yang kemudian melalui tahap *preprocessing* menggunakan gamma correction untuk meningkatkan kontras dan kualitas visual citra. Selanjutnya, fitur-fitur representatif diekstraksi menggunakan model *pretrained* CoAtNet. Vektor fitur yang dihasilkan digunakan sebagai input bagi SVM dengan *hyperparameter tuning* dan k-fold cross-validation. Tahap akhir menghasilkan prediksi kelas, yaitu pneumonia, CHF, atau normal. Pendekatan terintegrasi ini dirancang untuk mengatasi tantangan utama dalam klasifikasi CXR, termasuk kualitas citra, ekstraksi fitur yang komprehensif, serta optimasi model.




Gambar 1. Alur metodologi klasifikasi CXR

Gamma Correction

Gamma correction adalah teknik pengolahan citra untuk memperbaiki kontras citra dengan menyesuaikan intensitas piksel. Secara umum, metode power-law banyak digunakan karena

$$I_{out} = I_{in}^{\gamma} \quad (1)$$

Diagram alur pada Gambar 2 menjelaskan proses gamma correction untuk meningkatkan kualitas citra chest X-ray mengikuti [12]. Proses ini dimulai dengan memasukkan citra sebagai input, lalu menghitung rata-rata kecerahan pikselnya. Jika kecerahan kurang dari 0,3 (citra terlalu gelap), nilai gamma 0,7 digunakan untuk mencerahkan citra. Jika cukup terang, nilai gamma 1,5 diterapkan untuk menyesuaikan kontras. Hasil akhir dari proses ini adalah citra rontgen dada yang telah dikoreksi dengan gamma.



Gambar 2. Implementasi gamma correction

CoAtNet



Gambar 3. Pretrained CoAtNet sebagai ekstraktor fitur untuk citra CXR.

CoAtNet merupakan arsitektur hybrid yang menggabungkan lapisan konvolusi dan mekanisme self-attention untuk meningkatkan kualitas ekstraksi fitur dalam berbagai skenario data [13]. Arsitektur ini dikembangkan untuk mengatasi keterbatasan CNN dan model transformer, terutama dalam menangani data berukuran besar. Gambar 3 menampilkan arsitektur CoAtNet yang dimanfaatkan sebagai ekstraktor fitur dalam penelitian ini. Model ini menerima citra CXR berukuran 224×224 piksel sebagai input dan memprosesnya melalui stem stage yang terdiri atas konvolusi 3×3 dengan stride 2 diikuti konvolusi 3×3. Setelah tahap awal, citra melewati blok MBConv pada tahap S1 (56×56) dan S2 (28×28) yang berfungsi menangkap pola lokal melalui kombinasi pointwise convolution, depthwise convolution dengan ekspansi empat kali, serta pointwise projection. Tahap berikutnya, yaitu S3 (14×14) dan S4 (7×7), memanfaatkan relative attention yang dikombinasikan dengan feed-forward network ber-ekspansi empat kali untuk merepresentasikan relasi global antarfitur. Setelah melewati global average pooling, dihasilkan representasi vektor berdimensi 1024 yang digunakan sebagai fitur visual. Dalam penelitian ini, CoAtNet yang digunakan merupakan model yang telah dilatih menggunakan NIH ChestX-ray14 Dataset [14], sehingga mampu menghasilkan representasi fitur yang relevan untuk citra CXR.

SVM

SVM adalah metode pembelajaran mesin yang digunakan untuk tugas klasifikasi dalam pemodelan prediktif [15]. Algoritma ini awalnya dibuat untuk mengatasi masalah klasifikasi dengan dua kelas dengan cara mencari hyperplane yang memisahkan kedua kelas secara maksimal. Hyperplane ini adalah garis atau bidang yang memisahkan kelas-kelas tersebut dengan jarak terluas dari data terdekat. SVM sangat efektif dalam menangani data berdimensi tinggi, yang merupakan hal penting dalam bidang seperti bioinformatika dan klasifikasi citra [16]. Selain itu, SVM juga menunjukkan akurasi klasifikasi yang tinggi dan efisiensi, yang dibuktikan oleh waktu pelatihan dan prediksi yang cepat [16], [17].

Dataset

Penelitian ini menggunakan dataset Eye Gaze Dataset for Chest X-Ray (EGD-CXR), sebuah dataset publik yang dikembangkan oleh [1] yang terdiri dari 1.083 gambar X-ray dada frontal dengan label klinis yang telah divalidasi. Dataset ini mencakup tiga kelas yang seimbang: normal, Pneumonia, dan CHF. Kami menggunakan dataset EGD-CXR yang telah dibagi menjadi data latih dan uji oleh [10] dengan distribusi seperti yang ditunjukkan pada Tabel 1, sehingga dapat direproduksi.

Tabel 1. Distribusi Kelas

Kelas	Jumlah Data Latih	Jumlah Data Uji
CHF	331	32
Normal	316	44
Pneumonia	329	31

Detail Implementasi

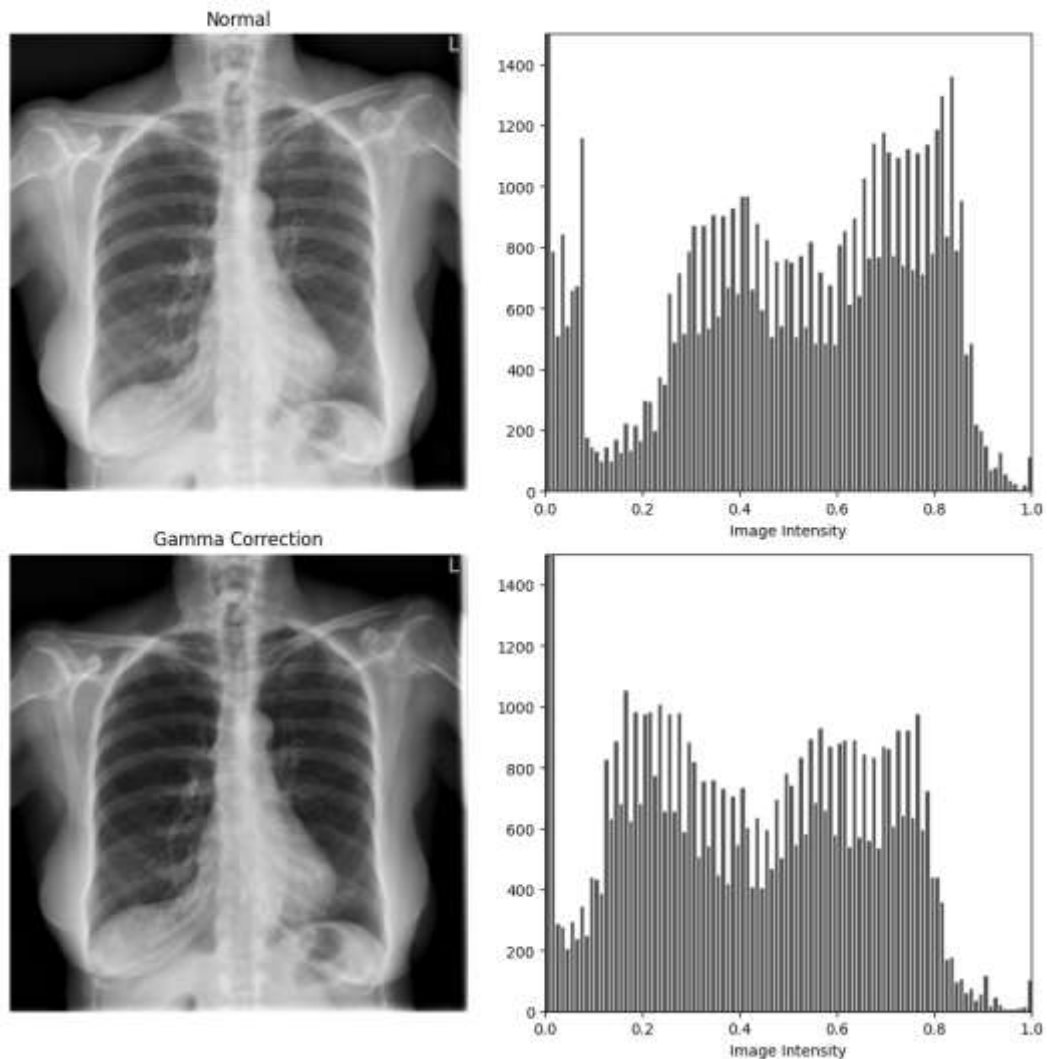
Proses pelatihan model dilakukan menggunakan bahasa pemrograman Python dengan Torch dan sklearn. Hyperparameter tuning dilakukan menggunakan metode Grid Search dengan GridSearchCV dari sklearn. Evaluasi menggunakan Stratified K-Fold Cross Validation dengan 5 fold. Seluruh proses ini diterapkan pada SVM dengan detail kombinasi parameter yang dapat dilihat pada Tabel 2. Dalam eksperimen ini, terdapat total 720 kombinasi parameter yang diuji. Proses evaluasi menggunakan StratifiedKFold dengan 5 *split*, dimana random state diatur pada 42 sehingga menghasilkan 3600 proses *fit*.

Tabel 2. Kombinasi Parameter pada SVM

Parameter	Nilai
scaler	StandardScaler(), MinMaxScaler(), None
classifier	SVC()
classifier__C	0.1, 0.5, 1.0, 1.5, 2.0, 3.0
classifier__kernel	'rbf', 'poly'
classifier__gamma	'scale', 'auto'
classifier__degree	2, 3, 4, 5, 10
classifier__tol	1e-3, 1e-4
classifier__random_state	42
classifier__probability	True

Hasil dan Pembahasan

Eksperimen dilakukan untuk mengevaluasi dampak gamma correction terhadap kualitas citra dan performa klasifikasi, serta membandingkan hasil dengan penelitian sebelumnya. Hasil analisis pada Gambar 4 menunjukkan perbedaan antara citra normal dan citra yang telah melalui gamma correction. Pada citra normal, histogram menunjukkan distribusi yang cenderung terkonsentrasi pada rentang intensitas sekitar 0,275 hingga 0,8. Sebaliknya, setelah penerapan gamma correction, histogram menunjukkan distribusi yang lebih merata di rentang 0,175 hingga 0,8 dengan peningkatan frekuensi pada area intensitas rendah dan tinggi, yang mencerminkan peningkatan kontras secara keseluruhan. Perubahan ini secara visual terlihat pada citra hasil gamma correction yang menampilkan struktur paru-paru dengan lebih jelas, sehingga diharapkan dapat meningkatkan kemampuan ekstraksi fitur oleh CoAtNet dan pada akhirnya meningkatkan performa klasifikasi.



Gambar 4. Hasil perbandingan antara citra normal dengan gamma correction.

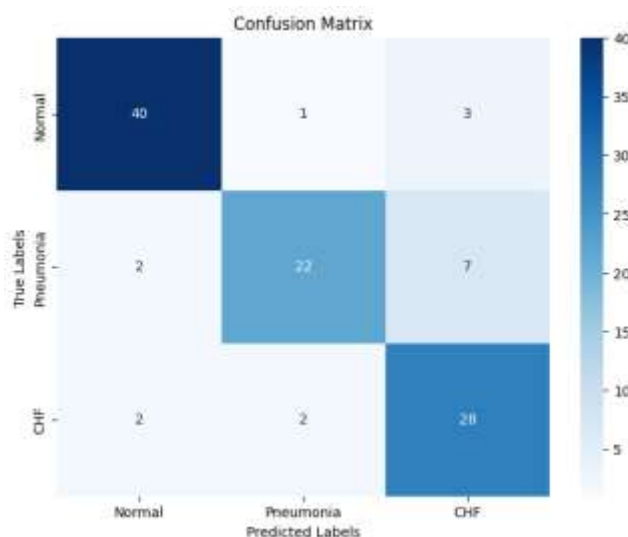
Hasil pengujian performa model menunjukkan bahwa penerapan gamma correction sebagai tahap preprocessing memberikan dampak signifikan terhadap kemampuan klasifikasi, seperti yang ditunjukkan dalam Tabel 3. Model dengan gamma correction mencapai akurasi sebesar 0,8411, precision 0,8420, recall 0,8313, dan F1 score 0,8316, yang secara konsisten lebih tinggi dibandingkan model tanpa gamma correction yang hanya mencapai akurasi 0,8131, precision 0,8077, recall 0,8057,

dan F1 score 0,8038. Peningkatan ini mengindikasikan bahwa perbaikan kontras dan kualitas visual citra melalui gamma correction secara efektif membantu model dalam menangkap fitur-fitur penting yang relevan untuk membedakan antara kondisi normal, pneumonia, dan CHF.

Tabel 3. Hasil Pengujian Performa Model Tanpa dan dengan Gamma Correction

Pengujian	Akurasi	Presisi	Recall	F1-Score
Tanpa Gamma Correction	0,8131	0,8077	0,8057	0,8038
Dengan Gamma Correction	0,8411	0,8420	0,8313	0,8316

Parameter terbaik yang diperoleh melalui proses optimasi adalah penggunaan StandardScaler dengan kernel RBF, $C=3.0$, $\gamma='scale'$, dan $\text{degree}=2$, seperti yang ditunjukkan dalam hasil tuning. Confusion matrix pada Gambar 5 menggambarkan performa klasifikasi detail dari model dengan gamma correction, di mana kelas normal berhasil diklasifikasikan dengan benar sebanyak 40 dari 44 sampel, pneumonia 22 dari 31 sampel, dan CHF 28 dari 32 sampel. Meskipun terdapat beberapa kesalahan klasifikasi terutama pada kelas pneumonia yang sering tertukar dengan CHF (7 kasus), secara keseluruhan model menunjukkan kemampuan yang baik antar kelas, yang sejalan dengan peningkatan metrik evaluasi setelah penerapan gamma correction.



Gambar 5. Confusion matrix

Tabel 4. Perbandingan dengan Penelitian Sebelumnya

#	Model	Akurasi	Presisi	Recall	F1-Score
[4]	ResNet-50 + Gaze-MTL	0,785	0,786	0,781	0,779
[8]	EfficientNetv2(s) + GG-CAM	0,776	0,770	0,772	0,770
[9]	DenseNet121 + Grad-CAM	-	-	-	0,270
	DenseNet121	0,710	0,696	0,689	0,689
	ResNet18	0,720	0,706	0,706	0,705
[10]	ResNet50	0,701	0,685	0,685	0,684
	ResNet101	0,710	0,703	0,705	0,703
	Swin-T	0,776	0,762	0,760	0,755

#	Model	Akurasi	Presisi	Recall	F1-Score
	Swin-S	0,748	0,733	0,735	0,733
	Swin-B	0,766	0,771	0,754	0,748
	GazeGNN	0,832	0,839	0,821	0,823
Ours	Gamma Correction + CoAtNet + SVM	0,841	0,842	0,831	0,832

Berdasarkan hasil yang disajikan dalam Tabel 4, metode yang diusulkan (Gamma Correction + CoAtNet + SVM) secara konsisten mengungguli semua pendekatan sebelumnya, termasuk yang bergantung pada data eye-gaze. Metode kami mencapai akurasi tertinggi sebesar 0,841 dan F1-score 0,832, melampaui model GazeGNN yang sebelumnya menjadi model terbaik dengan akurasi 0,832 dan F1-score 0,823. Peningkatan performa ini signifikan mengingat GazeGNN dan model lainnya memanfaatkan data eye-gaze tambahan yang sulit diperoleh dalam praktik klinis, sementara pendekatan kami hanya mengandalkan preprocessing citra, ekstraksi fitur menggunakan pretrained CoAtNet, dan optimasi model tanpa memerlukan data eksternal. Selain itu, metode kami juga mengungguli semua varian ResNet, DenseNet, dan Swin Transformer yang diuji dalam [10], yang menunjukkan efektivitas kombinasi gamma correction, ekstraksi fitur CoAtNet, dan klasifikasi SVM dengan *hyperparameter* optimal dalam meningkatkan kemampuan model untuk klasifikasi pneumonia dan CHF.

Kesimpulan

Penelitian ini berhasil mengembangkan pendekatan terintegrasi untuk klasifikasi pneumonia dan Congestive Heart Failure (CHF) pada citra Chest X-ray dengan menggabungkan gamma correction, ekstraksi fitur CoAtNet, dan klasifikasi SVM yang dioptimasi. Hasil pengujian menunjukkan performa superior dengan akurasi 0,841, presisi 0,842, recall 0,831, dan F1-score 0,832, melampaui semua metode sebelumnya termasuk yang bergantung pada data eye-gaze. Kontribusi utama terletak pada penerapan gamma correction untuk peningkatan kontras citra, pemanfaatan CoAtNet sebagai ekstraktor fitur hybrid CNN-Transformer, serta optimasi SVM melalui hyperparameter tuning.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Pertama, dataset yang digunakan (EGD-CXR) masih tergolong kecil dengan total 1.083 citra, yang berpotensi membatasi generalisasi model pada data yang lebih beragam. Kedua, belum dilakukan augmentasi data untuk memperkaya variasi data latih, sehingga kurang robust dalam menghadapi variasi kondisi citra.

Untuk pengembangan lebih lanjut, disarankan agar penelitian selanjutnya menggunakan dataset yang lebih besar dan beragam untuk meningkatkan generalisasi model. Selain itu, perlu dilakukan eksplorasi teknik preprocessing alternatif seperti CLAHE atau kombinasi CLAHE dengan gamma correction untuk peningkatan kualitas citra yang lebih optimal. Terakhir, eksplorasi pendekatan penggabungan fitur dari beberapa model arsitektur berbeda, seperti CoAtNet dengan MaxViT, untuk menangkap representasi fitur yang lebih kaya dan meningkatkan akurasi klasifikasi.

Daftar Pustaka

- [1] A. Karargyris *et al.*, "Creation and validation of a chest X-ray dataset with eye-tracking and report dictation for AI development," *Sci Data*, vol. 8, no. 1, 2021, doi: 10.1038/s41597-021-00863-5.
- [2] M. Widiarto, P. N. Andono, C. Supriyanto, M. A. Soeleman, and A. Wijaya, "Ensemble CNN Models for Accurate Pneumonia Classification in Chest X-Ray Images," in *Proceedings of the International Conference on Computer Engineering, Network and Intelligent Multimedia*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/CENIM64038.2024.10882716.
- [3] M. J. Hall, S. Levant, and C. J. DeFrances, "Hospitalization for congestive heart failure: United States, 2000-2010.," *NCHS Data Brief*, no. 108, 2012.

- [4] K. Saab *et al.*, “Observational Supervision for Medical Image Classification Using Gaze Data,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2021. doi: 10.1007/978-3-030-87196-3_56.
- [5] A. C. Mehta, A. P. Chua, F. Gleeson, and M. Meziane, “The debate on CXR utilization and interpretation is only just beginning: A Pro/Con Debate,” 2010. doi: 10.1111/j.1440-1843.2010.01842.x.
- [6] S. Goyal and R. Singh, “Detection and classification of lung diseases for pneumonia and Covid-19 using machine and deep learning techniques,” *J Ambient Intell Humaniz Comput*, vol. 14, no. 4, 2023, doi: 10.1007/s12652-021-03464-7.
- [7] M. Nahiduzzaman *et al.*, “A novel method for multivariant pneumonia classification based on hybrid CNN-PCA based feature extraction using extreme learning machine with CXR images,” *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3123782.
- [8] H. Zhu, S. Salcudean, and R. Rohling, “Gaze-Guided Class Activation Mapping: Leverage Human Visual Attention for Network Attention in Chest X-rays Classification,” in *Proceedings of the 15th International Symposium on Visual Information Communication and Interaction*, in VINCI '22. New York, NY, USA: Association for Computing Machinery, 2022. doi: 10.1145/3554944.3554952.
- [9] T. Van Sonsbeek, X. Zhen, D. Mahapatra, and M. Worring, “Probabilistic Integration of Object Level Annotations in Chest X-ray Classification,” in *Proceedings - 2023 IEEE Winter Conference on Applications of Computer Vision, WACV 2023*, 2023. doi: 10.1109/WACV56688.2023.00362.
- [10] B. Wang *et al.*, “GazeGNN: A Gaze-Guided Graph Neural Network for Chest X-ray Classification,” in *2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2024, pp. 2183–2192. doi: 10.1109/WACV57701.2024.00219.
- [11] M. Widiarto, P. N. Andono, C. Supriyanto, M. A. Soeleman, and A. Wijaya, “Ensemble CNN Models for Accurate Pneumonia Classification in Chest X-Ray Images,” in *Proceedings of the International Conference on Computer Engineering, Network and Intelligent Multimedia, CENIM 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/CENIM64038.2024.10882716.
- [12] H. Tsaniya, C. Fatichah, and N. Suciati, “Automatic Radiology Report Generator Using Transformer With Contrast-Based Image Enhancement,” *IEEE Access*, vol. 12, 2024, doi: 10.1109/ACCESS.2024.3364373.
- [13] Z. Dai, H. Liu, Q. V. Le, and M. Tan, “CoAtNet: Marrying Convolution and Attention for All Data Sizes,” in *Advances in Neural Information Processing Systems*, 2021.
- [14] S. M. N. Ashraf, M. A. Mamun, H. M. Abdullah, and M. G. R. Alam, “SynthEnsemble: A Fusion of CNN, Vision Transformer, and Hybrid Models for Multi-Label Chest X-Ray Classification,” in *2023 26th International Conference on Computer and Information Technology, ICCIT 2023*, 2023. doi: 10.1109/ICCIT60459.2023.10441433.
- [15] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Mach Learn*, vol. 20, no. 3, 1995, doi: 10.1023/A:1022627411411.
- [16] J. Li and S. Chao, “A novel twin-support vector machine for binary classification to imbalanced data,” *Data Technologies and Applications*, vol. 57, no. 3, 2023, doi: 10.1108/DTA-08-2022-0302.
- [17] X. Guo, H. Song, Y. Zeng, H. Chen, W. Hu, and G. Liu, “An intelligent water supply pipeline leakage detection method based on SV-WTBSVM,” *Meas Sci Technol*, vol. 35, no. 4, 2024, doi: 10.1088/1361-6501/ad21d7.