



Deteksi Anomali pada Citra X-ray Dada Menggunakan Variational Autoencoder dengan Skema Sequential Hyperparameter Optimization

Diki Aulio Fransisko, Febi Yanto, Benny Sukma Negara*, Siti Ramadhani, Reski Mai Candra

Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim, Riau, Indonesia

Email: ¹12250114326@students.uin-suska.ac.id, ²febiyanto@uin-suska.ac.id, ^{3,*}bsnegara@uin-suska.ac.id, ⁴siti.ramadhani@uin-suska.ac.id, ⁵reski.candra@uin-suska.ac.id

Email Penulis Korespondensi: bsnegara@uin-suska.ac.id,

Abstrak—Keterbatasan ketersediaan data berlabel menjadi salah satu tantangan utama dalam pengembangan sistem deteksi penyakit berbasis *deep learning* pada citra medis. Pendekatan klasifikasi konvensional umumnya memerlukan data abnormal dalam jumlah besar, sedangkan proses anotasi citra medis memerlukan waktu, biaya, dan keahlian radiolog. Penelitian ini bertujuan mengembangkan model deteksi anomali pada citra *chest X-ray* menggunakan Variational Autoencoder (VAE) berbasis *unsupervised learning*, sehingga proses pelatihan hanya memanfaatkan citra normal. Dataset yang digunakan adalah COVID-19-Pneumonia-Normal Chest X-ray Images yang terdiri atas 5.228 citra dengan tiga kategori, yaitu normal, pneumonia, dan COVID-19. Tahapan penelitian meliputi prapemrosesan citra, pembangunan model VAE, pelatihan model dasar, optimasi hyperparameter secara bertahap (*Sequential Hyperparameter Optimization*), implementasi *Beta-VAE*, serta evaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Area Under the Receiver Operating Characteristic Curve* (AUROC). Hasil penelitian menunjukkan bahwa model hasil optimasi memberikan peningkatan performa dibandingkan model dasar, dengan *Accuracy* sebesar 97,50%, *Precision* 96,32%, *Recall* 100%, *F1-Score* 98,12%, dan *AUROC* 0,9999. Temuan ini menunjukkan bahwa optimasi *hyperparameter* dan pengaturan koefisien β mampu meningkatkan kualitas representasi laten sehingga model lebih efektif dalam membedakan citra normal dan abnormal. Dengan demikian, pendekatan yang diusulkan berpotensi diterapkan sebagai sistem skrining awal berbasis kecerdasan buatan untuk mendukung analisis radiografi dada pada kondisi dengan keterbatasan data berlabel.

Kata Kunci: Deteksi Anomali; *Variational Autoencoder*; *Beta-VAE*; *Chest X-ray*; *Unsupervised Learning*

Abstract—The limited availability of labeled medical images remains a major challenge in developing reliable *deep learning*-based disease detection systems. Conventional classification approaches generally require a large amount of abnormal data, whereas medical image annotation is time-consuming, costly, and highly dependent on radiological expertise. This study proposes an unsupervised anomaly detection model for chest X-ray images using a Variational Autoencoder (VAE), in which only normal images are utilized during the training process. The experiments were conducted on the COVID-19-Pneumonia-Normal Chest X-ray Images dataset, consisting of 5,228 images categorized into normal, pneumonia, and COVID-19 classes. The proposed framework includes image preprocessing, baseline VAE construction, sequential hyperparameter optimization, Beta-VAE implementation, and model evaluation using Accuracy, Precision, Recall, F1-Score, and the Area Under the Receiver Operating Characteristic Curve (AUROC). Experimental results demonstrate that the optimized model outperformed the baseline model, achieving an Accuracy of 97.50%, Precision of 96.32%, Recall of 100%, F1-Score of 98.12%, and an AUROC of 0.9999. These findings indicate that hyperparameter optimization and appropriate β coefficient selection improve latent representation learning, leading to more effective discrimination between normal and abnormal chest X-ray images. Therefore, the proposed approach has the potential to serve as an artificial intelligence-based early screening tool for chest radiograph analysis, particularly in scenarios where labeled medical data are limited.

Keywords: Anomaly Detection; Variational Autoencoder; Beta-VAE; Chest X-ray; Unsupervised Learning

1. PENDAHULUAN

Identifikasi penyimpangan dari suatu kondisi normal pada dasarnya jauh lebih kompleks dibandingkan pengenalan pola yang telah diketahui sebelumnya, mengingat karakteristik anomali cenderung heterogen dan tidak selalu terepresentasikan secara memadai dalam data pelatihan, khususnya pada citra medis. *Chest X-ray*, sebagai salah satu modalitas pencitraan yang paling luas digunakan secara global untuk mendeteksi kelainan paru seperti pneumonia, tuberkulosis, efusi pleura, massa paru, dan kardiomegali (Nakao et al., 2021), menghadapi tantangan serupa, di mana pola abnormal pada pasien dapat sangat bervariasi dan sebagian besar tidak dapat diprediksi sebelumnya. Interpretasi citra secara konvensional masih sangat bergantung pada kompetensi dan ketelitian radiolog, sehingga rentan terhadap kesalahan diagnosis akibat kelelahan, beban kerja tinggi, serta distribusi tenaga ahli yang tidak merata antara daerah perkotaan dan pedesaan (Farooq & Savaş, 2024). Kondisi ini menegaskan perlunya pendekatan deteksi anomali berbasis kecerdasan buatan yang mampu mengidentifikasi penyimpangan dari pola normal secara konsisten, cepat, dan akurat, sekaligus menjadi solusi strategis atas keterbatasan sumber daya manusia di bidang radiologi (Georgescu, 2023).

Di balik potensi besar tersebut, pengembangan sistem kecerdasan buatan untuk analisis citra medis masih menghadapi tantangan mendasar yang belum terpecahkan. Salah satu kendala utama adalah minimnya data berlabel berkualitas tinggi, mengingat proses anotasi citra medis membutuhkan tenaga klinis berpengalaman, waktu panjang, serta biaya tidak sedikit, sehingga *dataset* yang tersedia sering terbatas, tidak seimbang antarkelas, dan sulit diakses (Rais et al., 2024). Situasi ini menjadi hambatan mendasar bagi penerapan *supervised learning* konvensional yang sangat bergantung pada data berlabel skala besar (Siddalingappa & Kanagaraj, 2021). Di sisi lain, model klasifikasi berbasis *Convolutional Neural Network* (CNN) hanya mampu mengenali pola penyakit yang telah dipelajari, sehingga tidak dirancang untuk mendeteksi anomali baru atau pola patologi yang belum pernah dijumpai (Gunawan & Setiawan, 2022).



Tingginya kompleksitas visual citra X-ray dada, ditambah kemiripan struktur antara citra normal dan kelainan halus (*subtle anomalies*), semakin memperberat tantangan membangun sistem deteksi yang akurat, sehingga diperlukan pendekatan alternatif yang tidak sepenuhnya bergantung pada data berlabel namun tetap mampu membedakan citra normal dan abnormal secara efisien.

Upaya mengatasi keterbatasan tersebut mendorong berkembangnya berbagai pendekatan deteksi anomali pada citra medis, dari metode konvensional hingga arsitektur *deep learning* yang lebih kompleks. Pendekatan berbasis CNN telah banyak diterapkan dan menunjukkan performa baik ketika data berlabel tersedia memadai (Kalusivalingam et al., 2024; Kumar et al., 2022). Namun demikian, performa tersebut sangat bergantung pada ketersediaan data berlabel dalam jumlah besar agar model dapat belajar secara optimal, sebuah kebutuhan yang sulit dipenuhi pada domain medis mengingat proses anotasi oleh pakar yang mahal serta kelangkaan kasus abnormal di dalam dataset. Sementara itu, metode Autoencoder dimanfaatkan dalam deteksi anomali berbasis rekonstruksi, di mana model hanya dilatih menggunakan data normal, sementara anomali diidentifikasi melalui *reconstruction error* yang melampaui ambang batas tertentu (Iglesias et al., 2025). Perkembangan lebih lanjut melahirkan *Variational Autoencoder* (VAE), yaitu model generatif probabilistik yang mempelajari distribusi laten data normal secara variasional, sehingga lebih fleksibel dalam menangkap variasi kompleks pada citra dan menghasilkan representasi ruang laten yang lebih terstruktur. Penerapan VAE dalam deteksi anomali citra medis telah menunjukkan hasil yang menjanjikan pada berbagai modalitas. Nakao et al., (2021) menerapkan pendekatan berbasis VAE pada citra X-ray dada untuk mendeteksi lesi dengan hanya menggunakan citra normal sebagai data pelatihan, sehingga menunjukkan potensi VAE sebagai pendekatan *unsupervised learning* pada citra medis. Penelitian lain oleh Gao et al., (2025) menerapkan VAE pada CT paru, sedangkan Lebaka & Sithungu, (2025) mengembangkan pendekatan serupa pada citra retina dan Kalusivalingam et al., (2024) pada citra histopatologi. Hasil dari berbagai penelitian tersebut menunjukkan bahwa VAE memiliki kemampuan untuk mempelajari karakteristik distribusi data normal dan memanfaatkannya sebagai dasar dalam mengidentifikasi penyimpangan atau anomali pada berbagai jenis citra medis.

Meskipun demikian, sejumlah kelemahan mendasar masih membatasi efektivitas dan penerapan praktisnya. Sebagian besar model Autoencoder konvensional, termasuk VAE standar, menghadapi masalah *over-reconstruction*, yaitu kecenderungan model turut merekonstruksi data anomali dengan kualitas baik, sehingga *reconstruction error* menjadi kurang efektif sebagai indikator anomali, terutama pada kelainan dengan kemiripan struktur tinggi terhadap citra normal (Liu et al., 2021). Berbagai penelitian terdahulu telah mengupayakan strategi untuk mengatasi keterbatasan tersebut. Salah satu pendekatan menerapkan metode *unsupervised* berbasis autoencoder pada citra radiografi dada untuk mendeteksi kelainan tanpa memerlukan data berlabel, meskipun sensitivitasnya masih terbatas pada anomali berukuran kecil (Nakao et al., 2021). sementara arsitektur *autoencoder* memanfaatkan mekanisme penyembunyian sebagian citra input selama pelatihan agar model belajar merekonstruksi konteks secara lebih robust, sehingga meningkatkan sensitivitas deteksi pada citra medis (Georgescu, 2023). Selain itu, sejumlah pendekatan masih memerlukan sebagian data berlabel atau data anomali untuk kalibrasi *hyperparameter* (Rana & Marwaha, 2024), dan performa model cenderung menurun akibat *domain shift* ketika diuji pada dataset eksternal. Berbagai celah ini menunjukkan perlunya metode deteksi anomali yang lebih akurat, *robust*, efisien secara komputasi, dan tidak bergantung pada data berlabel.

Urgensi penelitian pada bidang ini tidak dapat dipandang sebelah mata, mengingat implikasi klinis dan sosialnya yang luas. Kemampuan mendeteksi kelainan paru secara otomatis, akurat, dan efisien memiliki nilai strategis tinggi bagi peningkatan kualitas layanan kesehatan. Dari sisi keilmuan, penelitian ini turut berkontribusi terhadap pengembangan metodologi *unsupervised learning* dan *generative modeling* yang aplikasinya melampaui domain medis, mencakup pengawasan kualitas industri, keamanan siber, hingga bidang lain yang memerlukan deteksi penyimpangan dari pola normal (Choi & Jeong, 2022), sehingga berpotensi menjadi landasan bagi sistem pendukung keputusan klinis yang dapat diimplementasikan secara luas.


Berdasarkan uraian tersebut, penelitian ini mengusulkan pengembangan model deteksi anomali pada citra X-ray dada menggunakan arsitektur Variational Autoencoder sebagai pendekatan *unsupervised learning* yang tidak bergantung pada data berlabel dalam jumlah besar. Model dilatih menggunakan citra normal untuk mempelajari distribusi representasi laten, sehingga penyimpangan dari distribusi tersebut dapat diidentifikasi sebagai indikasi anomali. Kinerja model dievaluasi menggunakan metrik *AUROC*, *Precision*, *Recall*, dan *F1-Score* untuk mengukur kemampuannya membedakan citra normal dari abnormal secara objektif. Penelitian ini diharapkan menjadi pondasi bagi sistem skrining awal berbasis kecerdasan buatan yang meringankan beban kerja radiolog, meningkatkan konsistensi diagnosis, memperluas aksesibilitas layanan radiologi, serta memperkaya pengembangan metodologi *unsupervised learning* untuk citra medis di masa mendatang.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini bertujuan mengembangkan model deteksi anomali pada citra X-ray dada menggunakan Variational Autoencoder dengan pendekatan *unsupervised learning*. Pendekatan ini dipilih karena mampu mempelajari karakteristik citra normal tanpa bergantung pada data berlabel dalam jumlah besar, sehingga sesuai diterapkan pada citra medis yang umumnya memiliki keterbatasan data abnormal. Secara umum, penelitian difokuskan pada pembangunan model yang mampu mengenali penyimpangan dari pola citra normal berdasarkan proses rekonstruksi citra.

Anomali dalam penelitian ini dipahami sebagai penyimpangan citra dari pola normal paru-paru, tanpa mempertimbangkan jenis maupun tingkat keparahan kelainan secara spesifik. Pemahaman ini konsisten dengan prinsip unsupervised learning yang diadopsi, di mana model dibangun untuk mengenali karakteristik citra normal semata, tanpa pernah diperkenalkan pada anotasi kelas abnormal selama proses pembelajaran berlangsung.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1. Tahapan penelitian diawali dengan identifikasi permasalahan dan pengumpulan data, kemudian dilanjutkan dengan proses pra-pemrosesan untuk menyeragamkan karakteristik citra sebelum digunakan sebagai masukan model. Selanjutnya dilakukan pembangunan dan pelatihan model Variational Autoencoder untuk mempelajari representasi data normal. Hasil rekonstruksi yang dihasilkan model kemudian digunakan sebagai dasar dalam proses deteksi anomali melalui analisis terhadap nilai *reconstruction error*. Dan tahap akhir penelitian meliputi evaluasi performa model menggunakan metrik yang sesuai untuk mengukur kemampuan model dalam membedakan citra normal dan abnormal, kemudian dilanjutkan dengan analisis hasil guna menilai efektivitas pendekatan yang diusulkan.

2.2 Pengumpulan Data

Penelitian ini menggunakan dataset COVID-19-Pneumonia-Normal Chest X-ray Images yang diperoleh dari repositori Mendeley Data, dipublikasikan oleh Kumar (2022) tersedia pada <https://data.mendeley.com/datasets/dvntn9yhd2/1>. Dataset tersebut dipilih karena menyediakan citra X-ray dada yang mencakup beberapa kondisi paru-paru dengan jumlah data yang memadai, sehingga dapat digunakan untuk mendukung proses pengembangan dan evaluasi model deteksi anomali. Selain itu, dataset ini telah banyak dimanfaatkan dalam berbagai penelitian di bidang analisis citra medis sehingga memiliki tingkat kredibilitas yang baik. Dataset ini didistribusikan di bawah lisensi *Creative Commons Attribution 4.0*, yang mengizinkan penggunaan, penyebaran, dan modifikasi data untuk keperluan penelitian maupun non-komersial selama sumber aslinya dicantumkan secara memadai (Kumar et al., 2022).

Dataset terdiri atas tiga kategori, yaitu Normal, Pneumonia, dan COVID-19, dengan distribusi data yang disajikan pada Tabel 1. Keberagaman kategori tersebut memungkinkan penelitian mengevaluasi kemampuan model dalam membedakan citra yang merepresentasikan kondisi normal dan citra yang mengandung kelainan pada paru-paru.

Tabel 1. Dataset Covid19-Pneumonia-Normal

No	Kategori	Jumlah Citra	Resolusi
1	Normal	1.802	232 x 232 px
2	Pneumonia	1.800	232 x 232 px
3	COVID-19	1.626	256 x 256 px
Total		5.228	

Berdasarkan Tabel 1, dataset yang digunakan mencakup tiga kategori citra X-ray dada dengan jumlah sampel yang memadai pada masing-masing kategori. Komposisi tersebut memberikan variasi karakteristik citra yang dapat merepresentasikan kondisi paru-paru normal maupun yang mengalami kelainan, sehingga dataset memiliki cakupan yang sesuai untuk mendukung pelaksanaan penelitian.

2.3 Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk menghasilkan data yang memiliki ukuran dan karakteristik yang seragam sehingga sesuai dengan kebutuhan model Variational Autoencoder. Tahapan yang dilakukan meliputi proses *resize*, konversi ke *grayscale*, normalisasi nilai piksel, dan pembagian dataset.

2.3.1 Resize

Seluruh citra X-ray dada diubah ukurannya menjadi dimensi seragam sebesar 224×224 piksel. Penyeragaman dimensi ini dilakukan untuk menjaga konsistensi input pada arsitektur model, mengurangi kompleksitas komputasi, serta menyesuaikan ukuran input yang umum digunakan pada model berbasis *deep learning*.

2.3.2 Konversi Grayscale

Citra X-ray dada dikonversi menjadi *grayscale* karena informasi utama pada citra radiografi terletak pada intensitas terang dan gelap, bukan pada informasi warna. Penggunaan citra *grayscale* juga membantu mengurangi kompleksitas data masukan sehingga proses pelatihan model menjadi lebih efisien. Konversi grayscale dilakukan dengan menggunakan satu kanal (*single channel*) sehingga dimensi input menjadi lebih sederhana dibandingkan citra RGB yang memiliki tiga kanal warna. Dengan demikian, model dapat lebih fokus mempelajari struktur anatomi paru-paru dan pola kelainan pada citra.

2.3.3 Normalisasi

Proses normalisasi dilakukan untuk menyeragamkan distribusi data masukan sehingga proses pelatihan model menjadi lebih stabil dan efisien. Normalisasi membantu mempercepat proses konvergensi selama pelatihan serta mengurangi risiko ketidakstabilan gradien pada model *deep learning*. Selain itu, pada model Variational Autoencoder, normalisasi penting untuk membantu model mempelajari representasi laten dan menghasilkan rekonstruksi citra dengan lebih baik. Dengan distribusi data yang lebih konsisten, model dapat lebih optimal dalam membedakan pola citra normal dan citra anomali berdasarkan nilai *reconstruction error*.

2.3.4 Pembagian Dataset

Dataset pada penelitian ini dibagi menjadi tiga subset, yaitu *training*, *validation*, dan *testing*, dengan proporsi 80:10:10 sebagaimana ditunjukkan pada Tabel 2. Dataset yang digunakan terdiri atas tiga kategori citra chest X-ray, yaitu Normal, Pneumonia, dan COVID-19. Karena penelitian ini berfokus pada Deteksi Anomali dan bukan klasifikasi multi-kelas, maka kategori Pneumonia dan COVID-19 digabungkan menjadi satu kelas "Abnormal", sedangkan kategori Normal tetap direpresentasikan sebagai kelas "Normal". Pada penelitian ini, subset training dan validation hanya berisi citra normal, sehingga model dilatih untuk mempelajari representasi distribusi data normal tanpa pernah menerima paparan citra abnormal selama proses pembelajaran, baik dari kategori Pneumonia maupun COVID-19 (Nakao et al., 2021).

Tabel 2. Pembagian Dataset


Subset	Kategori	Proporsi	Jumlah Citra
Training	Normal	80%	1.441
Validation	Normal	10%	180
Testing	Normal & Abnormal	10%	520

Subset *validation* yang terdiri atas citra normal digunakan untuk menentukan nilai ambang batas threshold berdasarkan distribusi *reconstruction error* yang dihasilkan model pada data normal yang belum pernah dilihat selama pelatihan. Pendekatan penentuan threshold dari data validasi normal ini merupakan praktik standar dalam metode berbasis rekonstruksi untuk deteksi anomali tanpa label *unsupervised learning*, sebagaimana diterapkan pada berbagai studi deteksi anomali di citra medis menggunakan autoencoder maupun variational autoencoder.

Selanjutnya, subset testing yang terdiri atas citra normal dan abnormal, mencakup Pneumonia dan COVID-19, digunakan untuk mengevaluasi kemampuan model dalam membedakan kedua kategori tersebut, dengan mengklasifikasikan citra sebagai abnormal apabila nilai *reconstruction error*-nya melampaui threshold yang telah ditetapkan dari data validasi.

2.4 Arsitektur Variational Autoencoder

Model Variational Autoencoder dikembangkan untuk mempelajari distribusi representasi laten dari citra X-ray dada melalui proses kompresi dan rekonstruksi data. Proses tersebut memungkinkan model membangun representasi yang mampu mempertahankan karakteristik penting citra sebelum direkonstruksi kembali ke bentuk semula. Untuk mencapai tujuan tersebut, arsitektur model dibangun atas tiga komponen utama, yaitu *Encoder*, *Latent Dimension*, dan *Decoder*, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Variational Autoencoder

2.4.1 Encoder


Encoder berfungsi mengekstraksi karakteristik penting dari citra X-ray dada dan mengubahnya menjadi representasi berdimensi lebih rendah. Pada penelitian ini, proses ekstraksi fitur dilakukan menggunakan tiga blok *Convolutional Neural Network* (CNN) yang masing-masing terdiri atas lapisan *Conv2D*, *Batch Normalization*, fungsi aktivasi ReLU,

dan *MaxPooling2D*. Kombinasi lapisan tersebut memungkinkan model mempelajari pola spasial secara bertahap, meningkatkan stabilitas proses pelatihan, serta mereduksi dimensi citra tanpa menghilangkan informasi yang relevan.

Tabel 3. Konfigurasi Lapisan Encoder VAE Berbasis *Convolutional Neural Network*

Tahapan	Konfigurasi	Output
Input	Input Layer	224 x 224 x 1
Encoder Block 1	Conv2D (32, 3×3) → BatchNorm → ReLU → MaxPooling2D	112 x 112 x 32
Encoder Block 2	Conv2D (64, 3×3) → BatchNorm → ReLU → MaxPooling2D	56 x 56 x 64
Encoder Block 3	Conv2D (128, 3×3) → BatchNorm → ReLU → MaxPooling2D	28 x 28 x 128
Flatten	Flatten	100352
Dense	Dense (256)	256
Latent Dimension	z_{mean} , z_{log_var}	128

Hasil ekstraksi fitur kemudian diratakan (*Flatten*) sebelum diproyeksikan melalui lapisan *Dense* untuk menghasilkan dua parameter distribusi laten, yaitu z_{mean} (μ) dan z_{log_var} (σ^2). Kedua parameter tersebut digunakan sebagai dasar dalam pembentukan representasi laten yang akan diproses pada tahap berikutnya.



Gambar 3. Arsitektur Convolutional Neural Network

2.4.2 Latent Dimension

Latent Dimension menyimpan representasi berdimensi rendah yang dihasilkan oleh *encoder* dalam bentuk distribusi probabilitas. Berbeda dengan Autoencoder konvensional yang menghasilkan representasi deterministik, Variational Autoencoder memodelkan representasi laten menggunakan dua parameter, yaitu nilai rata-rata dan logaritma variansi. Pendekatan ini memungkinkan model mempelajari distribusi data secara lebih terstruktur sehingga mampu merepresentasikan karakteristik citra dengan lebih baik.

$$z = \mu + \sigma \cdot \epsilon, \quad \epsilon \sim \mathcal{N}(0,1) \quad (1)$$

Pembentukan vektor laten dilakukan menggunakan teknik *Reparameterization Trick*, yaitu dengan mengambil sampel dari distribusi yang dibentuk oleh kedua parameter tersebut. Teknik ini menjaga proses pengambilan sampel tetap terdiferensiasi (*differentiable*), sehingga parameter model dapat diperbarui melalui algoritma *backpropagation* selama proses pelatihan.

2.4.3 Decoder

Decoder bertugas merekonstruksi vektor laten menjadi citra dengan dimensi yang sama seperti citra masukan. Proses rekonstruksi dilakukan secara bertahap menggunakan tiga lapisan *Conv2DTranspose* yang diikuti *Batch Normalization* dan fungsi aktivasi ReLU. Susunan lapisan tersebut memungkinkan model mengembalikan representasi laten ke bentuk spasial sehingga karakteristik utama citra tetap dapat dipertahankan pada hasil rekonstruksi.

Tabel 4. Konfigurasi Lapisan Decoder VAE Berbasis Convolutional Neural Network

Tahapan	Konfigurasi	Output
Input	Input Layer	128
Dense	Feature map encoder	28 x 28 x 128
Reshape	Vector – feature map	28 x 28 x 128
Encoder Block 1	Conv2DTranspose (128, 3×3) → BatchNorm → ReLU	56 x 56 x 128
Encoder Block 2	Conv2DTranspose (64, 3×3) → BatchNorm → ReLU	112 x 112 x 64
Encoder Block 3	Conv2DTranspose (32, 3×3) → BatchNorm → ReLU	224 x 224 x 32
Output Layer	Conv2D (1filter, 3x3, sigmoid)	224 x 224 x 1

Lapisan keluaran menggunakan fungsi aktivasi Sigmoid untuk menghasilkan nilai piksel pada rentang 0 hingga 1 sesuai dengan hasil normalisasi data masukan. Citra hasil rekonstruksi selanjutnya dibandingkan dengan citra asli untuk memperoleh *reconstruction error*, yang digunakan sebagai dasar dalam proses identifikasi anomali pada tahap evaluasi.

2.5 Pelatihan Model Variational Autoencoder

Pelatihan model dilakukan menggunakan fungsi objektif *Evidence Lower Bound* yang menggabungkan *Reconstruction Loss* dan *Kullback-Leibler (KL) Divergence*. *Reconstruction Loss* digunakan untuk mengukur kesesuaian antara citra masukan dan citra hasil rekonstruksi, sedangkan *KL Divergence* berfungsi sebagai regularisasi agar distribusi representasi laten tetap mendekati distribusi normal. Fungsi objektif ELBO dirumuskan sebagai berikut.

$$L_{ELBO} = L_{rec} + \beta L_{KL} \quad (2)$$

Pada penelitian ini, *Reconstruction Loss* dihitung menggunakan *Mean Squared Error (MSE)* karena mampu mengukur rata-rata selisih kuadrat antara citra asli dan citra hasil rekonstruksi. Nilai *Reconstruction Loss* dihitung menggunakan Persamaan seperti berikut.

$$L_{rec} = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (3)$$

Selanjutnya, *KL Divergence* digunakan untuk mengukur perbedaan antara distribusi representasi laten yang dipelajari model dengan distribusi normal standar. Komponen ini berfungsi sebagai regularisasi agar *latent dimension* memiliki distribusi yang lebih terstruktur dan mampu menghasilkan representasi yang lebih baik.

$$L_{KL} = -(1/2) \sum (j = 1)^d (1 + \ln(\sigma_j^2) - \mu_j^2 - \sigma_j^2) \quad (4)$$

2.6 Deteksi Anomali

Deteksi anomali dilakukan menggunakan nilai total loss (ELBO) yang dihasilkan model pada tahap inferensi. Nilai tersebut merepresentasikan tingkat penyimpangan citra terhadap distribusi data normal dengan mempertimbangkan *Reconstruction Loss* dan *Kullback-Leibler (KL) Divergence* secara bersamaan (Zhao et al., 2023). Semakin besar nilai ELBO, semakin besar penyimpangan citra dari karakteristik data normal sehingga citra memiliki kemungkinan lebih tinggi untuk diklasifikasikan sebagai anomali.

$$AS(x) = L_{ELBO}(x) \quad (5)$$

Nilai ambang (threshold) ditentukan berdasarkan distribusi *Anomaly Score* pada data validasi normal menggunakan persentil ke-90, sehingga dirumuskan sebagai

$$T = P_{90}(AS_{val}) \quad (6)$$

Selanjutnya, proses klasifikasi dilakukan dengan membandingkan nilai *Anomaly Score* terhadap nilai threshold. Citra dikategorikan sebagai abnormal apabila nilai *Anomaly Score* melebihi threshold, sedangkan citra dengan nilai yang lebih kecil atau sama dengan threshold dikategorikan sebagai normal. Aturan klasifikasi tersebut dinyatakan sebagai

$$\hat{y} = \begin{cases} \text{Abnormal}, AS(x) > T \\ \text{Normal}, AS(x) \leq T \end{cases} \quad (7)$$

2.7 Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan Variational Autoencoder dalam membedakan citra X-ray dada normal dan abnormal berdasarkan hasil deteksi anomali pada data uji. Proses evaluasi diawali dengan membandingkan hasil prediksi model terhadap ground truth, sehingga dapat diketahui tingkat keberhasilan model dalam mengidentifikasi setiap kelas. Hasil perbandingan tersebut kemudian dirangkum menggunakan confusion matrix yang terdiri atas *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

		True Class	
		Positive	Negative
Predicted Class	Positive	True Positive	False Positive
	Negative	False Negative	True Negative

Gambar 4. Confusion Matrix

Berdasarkan Gambar 4, performa model dievaluasi menggunakan *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. *Accuracy* digunakan untuk mengukur proporsi keseluruhan prediksi yang benar, *Precision* menunjukkan ketepatan model dalam mengidentifikasi citra abnormal, *Recall* mengukur kemampuan model mendeteksi seluruh citra abnormal yang sebenarnya, sedangkan *F1-Score* memberikan keseimbangan antara *Precision* dan *Recall* sehingga mampu menggambarkan performa model secara lebih komprehensif.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (11)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pra-Pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk menyeragamkan karakteristik citra sebelum digunakan sebagai masukan model Variational Autoencoder. Proses ini meliputi *resize* citra, konversi ke *grayscale*, dan normalisasi nilai piksel sehingga seluruh data memiliki format yang konsisten selama proses pelatihan dan pengujian. Hasil pra-pemrosesan data secara ringkas disajikan pada Tabel 5.

Tabel 5. Hasil Pra-Pemrosesan Data

Tahapan	Sebelum Pra-pemrosesan	Setelah Pra-pemrosesan
Resize	Ukuran citra yang bervariasi	224 x 224 px
Grayscale	224 x 224 x 3 (RGB)	224 x 224 x 1
Normalisasi	Nilai piksel 0 -225	Nilai piksel 0 - 1

3.2 Hasil Pelatihan Model

Tahap pelatihan model dilakukan menggunakan arsitektur Variational Autoencoder dasar dengan hanya memanfaatkan citra chest X-ray normal sebagai data pelatihan, sesuai dengan prinsip *unsupervised learning* yang diterapkan dalam penelitian ini. Konfigurasi *hyperparameter* yang digunakan pada tahap pelatihan model dasar disajikan secara rinci pada Tabel 6.

Tabel 6. Konfigurasi Hyperparameter Pelatihan

Parameter	Nilai / keterangan
Model	Variational Autoencoder
Latent Dimension	128
Batch Size	32
Koefisien Pembobot β	1,0
Epochs	100
Learning Rate	0.0001
Optimizer	Adam
Reconstruction Loss	Mean Squared Error
Regularization Loss	KL divergence

Proses pelatihan dijalankan selama 100 epoch dengan mengoptimalkan fungsi objektif ELBO sebagaimana dirumuskan pada Persamaan (2), menggunakan optimizer Adam untuk memperbarui bobot model secara adaptif berdasarkan gradien fungsi loss. Pemilihan nilai learning rate sebesar 1×10^{-4} serta batch size 32 didasarkan pada hasil uji coba awal agar proses pelatihan berjalan stabil tanpa mengalami *divergence* maupun konvergensi yang terlalu lambat.

Untuk mengevaluasi proses konvergensi model serta mendeteksi indikasi *overfitting*, nilai *training loss* dan *validation loss* dicatat pada setiap epoch dan divisualisasikan dalam bentuk kurva sebagaimana disajikan pada Gambar 5.



Gambar 5. Grafik Training dan Validation loss

Berdasarkan grafik diatas, Kurva *training loss* dan *validation loss* menunjukkan kecenderungan menurun seiring bertambahnya *epoch*. Meskipun masih terdapat fluktuasi pada beberapa epoch awal, kedua kurva memperlihatkan pola konvergen yang mengindikasikan bahwa model telah mampu mempelajari representasi citra normal secara stabil. Selanjutnya dilakukan penentuan threshold menggunakan distribusi *Anomaly Score* (ELBO) pada data validasi normal dengan metode persentil ke-90 (Horat et al., 2026).

Tabel 7. Penentuan Threshold

Parameter	Nilai / Keterangan
Data Validasi	Citra Normal
Metode Threshold	Persentil ke- 90
Nilai Treshold	0.01201123

Berdasarkan Tabel 7, diperoleh nilai ambang sebesar 0,01201123. Nilai tersebut digunakan sebagai batas klasifikasi, di mana citra dengan *Anomaly Score* melebihi threshold dikategorikan sebagai abnormal, sedangkan citra dengan nilai di bawah atau sama dengan *threshold* dikategorikan sebagai normal.


3.3 Hasil Evaluasi Model

Model dasar selanjutnya dievaluasi menggunakan data uji untuk mengukur kemampuan model dalam membedakan citra normal dan abnormal.

Tabel 8. Hasil Evaluasi Model Dasar

Metrik	Nilai
Accuracy	0.9423
Precision	0.9480
Recall	0.9647
F1-Score	0.9563
ROC-AUC	0.9855

Berdasarkan Tabel 8. Model memperoleh *Accuracy* 94,23%, *Precision* 94,80%, *Recall* 96,47%, *F1-Score* 95,63%, dan AUROC 0,9855. Nilai AUROC yang mendekati 1 menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik dalam membedakan citra normal dan abnormal.



Gambar 6. Confusion Matrix

Berdasarkan Gambar 6. Model berhasil mengklasifikasikan 162 citra normal dan 328 citra abnormal dengan benar. Terdapat 18 *false positive* dan 12 *false negative*, sehingga tingkat kesalahan klasifikasi relatif rendah dan menunjukkan kemampuan deteksi yang baik.

3.4 Optimasi Model

Optimasi hyperparameter dilakukan untuk meningkatkan performa model Variational Autoencoder dibandingkan dengan model Dasar. Pada penelitian ini digunakan metode *Sequential Hyperparameter Optimization*, yaitu proses optimasi yang dilakukan secara bertahap dengan menguji satu *hyperparameter* pada setiap tahap, sementara *hyperparameter* lainnya dipertahankan tetap menggunakan konfigurasi terbaik yang telah diperoleh sebelumnya

3.4.1 Skenario Optimasi Hyperparameter

Berdasarkan hasil pelatihan model dasar, kurva *training loss* dan *reconstruction loss* masih menunjukkan fluktuasi yang cukup besar pada beberapa *epoch*. Meskipun nilai loss secara keseluruhan mengalami penurunan, lonjakan yang terjadi mengindikasikan bahwa proses pembelajaran model belum sepenuhnya stabil. Selain itu, performa model masih memiliki ruang untuk ditingkatkan agar mampu menghasilkan representasi fitur yang lebih baik. Skenario Optimasi Hyperparameter ditunjukkan pada Tabel 9.

**Tabel 9.** Skenario Optimasi Hyperparameter

Tahap	Hyperparameter	Nilai yang diuji
1	Learning Rate	0.001, 0.0005, 0.0001
2	Latent dimension	64, 128, 256

3.4.2 Optimasi learning Rate

Untuk mengetahui pengaruh *learning rate* terhadap proses pembelajaran model, dilakukan pengujian menggunakan tiga nilai *learning rate*, yaitu 0.001, 0.0005, dan 0.0001. Setiap konfigurasi dilatih menggunakan arsitektur dan parameter yang sama sehingga perbedaan performa yang diperoleh hanya dipengaruhi oleh perubahan nilai *learning rate*. Hasil evaluasi ditunjukkan pada Tabel 10.

Tabel 10. Hasil Evaluasi Optimasi Learning Rate

Learning Rate	Accuracy	Precision	Recall	F1-Score	ROC-AUC
0.001	0.961538	0.944444	1.000000	0.971429	1.000000
0.0005	0.978846	0.968661	1.000000	0.984081	1.000000
0.0001	0.946154	0.958824	0.958824	0.958824	0.986275

Variasi *learning rate* memberikan pengaruh terhadap kemampuan model dalam mendeteksi anomali. Hasil pengujian menunjukkan bahwa *learning rate* 0.0005 memberikan hasil terbaik, karena mampu mendeteksi seluruh data anomali dengan tingkat kesalahan prediksi yang paling rendah dibandingkan *learning rate* 0.001 dan 0.0001. Konfigurasi ini juga menghasilkan keseimbangan performa yang paling unggul secara keseluruhan, baik dari sisi ketepatan klasifikasi maupun kestabilan konvergensi selama proses pelatihan. Oleh karena itu, *learning rate* 0.0005 dipilih sebagai parameter yang digunakan pada tahap optimasi berikutnya.

3.4.3 Optimasi Latent Dimension

Setelah diperoleh *learning rate* terbaik, tahap selanjutnya adalah mengevaluasi pengaruh ukuran *latent dimension* terhadap kemampuan model dalam merepresentasikan karakteristik citra. Pengujian dilakukan menggunakan tiga konfigurasi *latent dimension*, yaitu 64, 128, dan 256. Hasil evaluasi masing-masing konfigurasi disajikan pada Tabel 11.

Tabel 11. Hasil Evaluasi Optimasi *Latent Dimension*

Latent Dimension	Accuracy	Precision	Recall	F1-Score	ROC-AUC
64	0.967308	0.952381	1.0	0.975610	1.000000
128	0.969231	0.955056	1.0	0.977011	1.000000
256	0.971154	0.957746	1.0	0.978417	0.999412

Perubahan *latent dimension* memberikan pengaruh terhadap kemampuan model dalam merepresentasikan karakteristik citra untuk mendeteksi anomali. Hasil pengujian menunjukkan bahwa *latent dimension* 256 memberikan hasil terbaik, karena mampu mendeteksi seluruh data anomali dengan tingkat kesalahan prediksi yang paling rendah dibandingkan *latent dimension* 64 dan 128. Konfigurasi ini juga menghasilkan keseimbangan performa yang paling unggul secara keseluruhan, karena kapasitas representasi yang lebih besar memungkinkan model menangkap karakteristik citra secara lebih kaya dan detail. Oleh karena itu, *latent dimension* 256 dipilih sebagai parameter yang digunakan pada tahap optimasi berikutnya.


3.4.4 Implementasi Beta-VAE

Setelah diperoleh konfigurasi hyperparameter terbaik melalui proses optimasi, tahap selanjutnya adalah mengimplementasikan Beta Variational Autoencoder (*Beta-VAE*) sebagai pengembangan dari model Variational Autoencoder. *Beta-VAE* merupakan modifikasi terhadap fungsi objektif VAE dengan menambahkan parameter β (*beta*) sebagai faktor pembobot pada komponen Kullback-Leibler (KL) Divergence. Modifikasi tersebut bertujuan untuk mengendalikan keseimbangan antara reconstruction loss dan regularisasi *latent dimension* (Fil et al., 2020).

Tabel 12. Hasil Evaluasi Implementasi *Beta-VAE*

Nilai β	Accuracy	Precision	Recall	F1-Score	ROC-AUC
0.5	0.9692	0.9551	1.0	0.9770	1.0
1	0.971154	0.957746	1.0	0.978417	0.999412
2	0.9596	0.9418	1.0	0.9700	1.0

Berdasarkan Tabel 12, hasil implementasi menunjukkan bahwa parameter β memengaruhi keseimbangan antara proses rekonstruksi dan regularisasi *latent dimension*. Nilai β yang lebih kecil menghasilkan proses pembelajaran yang lebih optimal, sedangkan nilai β yang lebih besar meningkatkan regularisasi sehingga kualitas rekonstruksi cenderung menurun. Oleh karena itu, $\beta = 1,0$ dipilih sebagai konfigurasi terbaik pada penelitian ini. Dikarenakan memiliki keseimbangan diantara proses pembelajaran dan juga kualitas rekonstruksi.




Gambar 7. Perbandingan Performa Pelatihan Model pada Berbagai Nilai β

3.5 Perbandingan Model

Penentuan model terbaik dilakukan dengan merekapitulasi seluruh hasil eksperimen yang telah dilakukan pada tahap optimasi hyperparameter, mulai dari model dasar, optimasi *learning rate*, optimasi *latent dimension*, hingga implementasi *Beta-VAE*.

Tabel 13. Rekapulasi Optimasi Model

Tahapan	Parameter	Nilai Terbaik	Accuracy	Precision	Recall	F1-Score	ROC-AUC
Dasar	LR= 0.0001 LD=128	-	0.9423	0.9480	0.9647	0.9563	0.9855
Optimasi Learning Rate	0.001/ 0.0005/ 0.0001	0.0005	0.978846	0.968661	1.0	0.984081	1.0
Optimasi Latent Dimension	64/128/256	256	0.971154	0.957746	1.0	0.978417	0.999412
Implementasi <i>Beta-VAE</i>	0.5/1.0//2.0	1(Dasar)	0.971154	0.957746	1.0	0.978417	0.999412




Gambar 8. Confusion Matrix Model Optimasi

Berdasarkan Gambar 8, model menunjukkan kemampuan yang sangat baik dalam mengkategorikan citra abnormal, ditandai dengan tidak adanya citra abnormal yang salah diklasifikasikan sebagai normal. Meskipun masih terdapat beberapa citra normal yang teridentifikasi sebagai abnormal, hasil tersebut menunjukkan bahwa model lebih berhati-hati dalam mendeteksi anomali sehingga risiko kegagalan mendeteksi kelainan dapat diminimalkan.

3.6 Hasil Visualisasi Error

Citra hasil rekonstruksi memiliki bentuk yang menyerupai citra asli, meskipun masih terdapat beberapa detail yang tidak dapat direkonstruksi secara sempurna. Perbedaan tersebut terlihat pada *error map*, di mana area berwarna merah menunjukkan bagian citra dengan kesalahan rekonstruksi yang lebih tinggi. Kesalahan rekonstruksi ini terjadi karena model hanya dilatih untuk mempelajari pola citra normal, sehingga struktur atau tekstur yang tidak sesuai dengan pola tersebut cenderung menghasilkan nilai *error* yang lebih besar. Mengingat penelitian ini hanya membedakan kondisi normal dan abnormal tanpa klasifikasi jenis penyakit secara spesifik, area dengan *error* tinggi ini berpotensi mengindikasikan keberadaan kelainan pada citra X-ray dada. Dengan demikian, hasil ini menunjukkan bahwa model dasar telah mampu mempelajari pola citra normal dan dapat digunakan sebagai dasar untuk mendeteksi anomali berdasarkan nilai kesalahan rekonstruksi. *Error Map* dapat divisualisasikan sebagai Gambar 9.



Gambar 9. Visualisasi Proses Rekonstruksi Citra dan Error Map pada Model VAE

3.7 Pembahasan

Hasil optimasi hyperparameter secara bertahap, sebagaimana disajikan pada subbab sebelumnya, menunjukkan bahwa peningkatan performa model tidak terjadi secara acak, melainkan berkaitan erat dengan kualitas representasi laten yang dipelajari. Penyesuaian learning rate memengaruhi kestabilan proses konvergensi selama pelatihan, sedangkan pembesaran latent dimension memberikan ruang representasi yang lebih kaya sehingga model mampu menangkap variasi struktur citra secara lebih detail. Sementara itu, pemilihan koefisien β pada Beta-VAE berperan menjaga keseimbangan antara kemampuan rekonstruksi dan regularisasi distribusi laten, di mana nilai β yang terlalu besar justru menekan kualitas rekonstruksi akibat regularisasi yang berlebihan. Kombinasi ketiga aspek ini menjelaskan mengapa model hasil optimasi secara konsisten mengungguli model dasar pada seluruh metrik evaluasi.

Perbandingan dilakukan dengan meninjau hasil penelitian ini terhadap beberapa pendekatan CNN dan Autoencoder dari penelitian terdahulu. Peninjauan ini penting karena kedua pendekatan mewakili paradigma pembelajaran yang berbeda *supervised learning* yang memerlukan label penuh pada seluruh data pelatihan, termasuk citra abnormal, dan *unsupervised learning* seperti yang diterapkan pada penelitian ini, yang hanya memanfaatkan citra normal tanpa memerlukan anotasi kelas abnormal sama sekali. Perbedaan paradigma ini berimplikasi langsung pada kebutuhan sumber daya anotasi, di mana pendekatan *supervised* umumnya menuntut proses pelabelan yang intensif oleh tenaga ahli radiologi, sedangkan pendekatan *unsupervised* menawarkan efisiensi anotasi dengan cara mempelajari karakteristik data normal saja. Perlu dicatat bahwa setiap studi yang dirujuk memiliki karakteristik dataset, jumlah sampel, dan skema evaluasi yang berbeda-beda, sehingga perbandingan yang disajikan bersifat kontekstual untuk menggambarkan posisi relatif kinerja model, bukan merupakan pengujian pada kondisi eksperimen yang identik.

Tabel 14. Perbandingan Model dengan penelitian terkait

Pendekatan	Studi	Dataset	Metrik utama
CNN (CheXImageNet) supervised	Shastri et al. (2022)	Chest X-ray COVID-19-Pneumonia-Normal	Akurasi Lebih dari 90%
Autoencoder + CNN supervised	Siddalingappa & Kanagaraj (2021)	CT scan kanker paru	Akurasi 98% dan ROC 97%
VAE unsupervised	Nakao et al. (2021)	Chest radiograph (Univ. Tokyo Hospital)	AUROC 70% -80%
VAE (Dasar) unsupervised	Penelitian ini	Chest X-ray COVID-19-Pneumonia-Normal	Akurasi 94% dan AUROC 98%
VAE (Optimasi) unsupervised	Penelitian ini	Chest X-ray COVID-19-Pneumonia-Normal	Akurasi 97% dan AUROC 99%

Berdasarkan Tabel 14, perbandingan dengan CheXImageNet (Shastri et al., 2022) menunjukkan bahwa pendekatan CNN *supervised* mampu mencapai akurasi sempurna pada klasifikasi tiga kelas, namun bergantung penuh pada ketersediaan label untuk seluruh data pelatihan, termasuk citra abnormal, serta dilatih pada himpunan data yang jauh lebih kecil dibandingkan penelitian ini. Sementara itu, dibandingkan dengan (Siddalingappa & Kanagaraj, 2021) yang mengombinasikan Autoencoder dan CNN pada citra CT scan kanker paru, model *Beta-VAE* penelitian ini menghasilkan akurasi klasifikasi yang sebanding, meskipun beroperasi murni *unsupervised* tanpa memerlukan data abnormal berlabel selama pelatihan. Dibandingkan dengan (Nakao et al., 2021) yang menerapkan pendekatan *unsupervised* serupa pada chest radiograph, model VAE hasil optimasi pada penelitian ini juga menghasilkan AUROC yang lebih tinggi. Secara keseluruhan, temuan ini mengindikasikan bahwa pendekatan berbasis VAE pada penelitian ini mampu mencapai performa yang kompetitif terhadap metode *supervised* maupun *hybrid*, sekaligus mempertahankan keunggulan utamanya, yaitu tidak bergantung pada data abnormal berlabel selama proses pelatihan.



4. KESIMPULAN

Penelitian ini mengembangkan model deteksi anomali pada citra chest X-ray menggunakan Variational Autoencoder berbasis pendekatan *unsupervised learning*, yang mampu mempelajari karakteristik citra normal dan mengidentifikasi penyimpangan sebagai anomali tanpa memerlukan data abnormal selama proses pelatihan. Penerapan *Sequential Hyperparameter Optimization* yang meliputi optimasi *learning rate*, *latent dimension*, serta implementasi *Beta-VAE* terbukti mampu meningkatkan kinerja model secara konsisten dibandingkan konfigurasi dasar, dengan model hasil optimasi menghasilkan *Accuracy* sebesar 97,50%, *Precision* 96,32%, *Recall* 100%, *F1-Score* 98,12%, dan AUROC 0,9999, yang masing-masing menunjukkan peningkatan sebesar 3,27%, 1,52%, 3,53%, 2,49%, dan 1,44% dibandingkan model dasar. Temuan ini menunjukkan bahwa optimasi *hyperparameter* secara bertahap mampu meningkatkan kualitas representasi laten yang dipelajari model dan juga mampu mengoptimalkan kinerja VAE pada dataset yang tersedia saat ini, sehingga VAE menjadi pendekatan yang lebih andal untuk deteksi anomali pada kondisi dengan keterbatasan data berlabel. Kontribusi utama penelitian ini terletak pada integrasi arsitektur VAE dengan strategi optimasi *hyperparameter* secara bertahap, yang menawarkan alternatif terhadap metode *supervised learning* yang umumnya bergantung pada ketersediaan data berlabel dalam jumlah besar, sehingga lebih relevan diterapkan pada domain citra medis yang kerap menghadapi keterbatasan ketersediaan data berlabel. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, yaitu evaluasi model yang masih terbatas pada satu dataset tunggal sehingga generalisasinya terhadap sumber data lain belum teruji, penentuan *threshold* deteksi anomali yang bersifat statis berdasarkan persentil ke-90 data validasi normal, serta cakupan evaluasi yang masih terbatas pada klasifikasi biner tanpa membedakan tingkat keparahan atau jenis kelainan secara spesifik. Oleh karena itu, penelitian selanjutnya disarankan untuk menguji generalisasi model pada dataset eksternal guna mengevaluasi ketahanannya terhadap *domain shift*, mengeksplorasi mekanisme penentuan *threshold* yang lebih adaptif, serta memperluas evaluasi pada skema klasifikasi multi-kelas dan validasi menggunakan data klinis riil yang melibatkan tenaga ahli radiologi untuk menilai kelayakan penerapannya sebagai sistem skrining awal berbasis kecerdasan buatan.

REFERENCES

- Choi, B., & Jeong, J. (2022). ViV-Ano: Anomaly Detection and Localization Combining Vision Transformer and Variational Autoencoder in the Manufacturing Process. *Electronics (Switzerland)*, 11(15). <https://doi.org/10.3390/electronics11152306>
- FAROOQ, Y., & SAVAS, S. (2024). Noise Removal from the Image Using Convolutional Neural Networks-Based Denoising Auto Encoder. *Journal of Emerging Computer Technologies*, 3(1), 21–28. <https://doi.org/10.57020/ject.1390428>
- Fil, M., Mesinovic, M., Morris, M., & Wildberger, J. (2020). B-vae reproducibility: challenges and extensions. *Preprint ArXiv*, 1, 1–14. <https://doi.org/https://doi.org/10.48550/arXiv.2112.14278>
- Gao, Z., Nakayama, R., Hizukuri, A., & Kido, S. (2025). Anomaly detection scheme for lung CT images using vector quantized variational auto-encoder with support vector data description. *Radiological Physics and Technology*, 18(1), 17–26. <https://doi.org/10.1007/s12194-024-00851-5>
- Georgescu, M. I. (2023). Masked Autoencoders for Unsupervised Anomaly Detection in Medical Images. *Procedia Computer Science*, 225, 969–978. <https://doi.org/10.1016/j.procs.2023.10.084>
- Gunawan, D., & Setiawan, H. (2022). Convolutional Neural Network dalam Analisis Citra Medis. *KONSTELASI: Konvergensi Teknologi Dan Sistem Informasi*, 2(2), 376–390. <https://doi.org/https://doi.org/10.24002/konstelasi.v2i2.5367>
- Horat, A., Oiegar, V. F., Buzea, G., Tepordei, T., Alice, S., Vicleanu, P., & Dumitrescu, A. M. (2026). Multimodal Autoencoder – Based Anomaly Detection Reveals Clinical – Radiologic Heterogeneity in Pulmonary Fibrosis. *Medical Sciences*, 14(1), 1–26. <https://doi.org/https://doi.org/10.3390/medsci14010076>
- Iglesias, G., Menendez, H., & Talavera, E. (2025). Improving explanations for medical X-ray diagnosis combining variational autoencoders and adversarial machine learning. *Computers in Biology and Medicine*, 188(January), 109857. <https://doi.org/10.1016/j.combiomed.2025.109857>
- Kalusivalingam, A. K., Singh, R., & Bose, M. (2024). Enhancing Anomaly Detection in Histopathological Images Using Convolutional Neural Networks and Variational Autoencoders. *Emerging Advanced AI Journal*, 1–24. <http://www.eaij.com/index.php/eaij/article/view/52%0Ahttp://www.eaij.com/index.php/eaij/article/download/52/52>
- Kumar, S., Shastri, S., Mahajan, S., Singh, K., Gupta, S., Rani, R., Mohan, N., & Mansotra, V. (2022). LiteCovidNet: A lightweight deep neural network model for detection of COVID-19 using X-ray images. *International Journal of Imaging Systems and Technology*, 32(5), 1464–1480. <https://doi.org/https://doi.org/10.1002/ima.22770>
- Lebaka, K. B., & Sithungu, S. P. (2025). Anomaly Detection in Retinal Imagery Using Variational Autoencoders. In *CIIS 2024 - 2024 the 7th International Conference on Computational Intelligence and Intelligent Systems* (Vol. 1, Issue 1). Association for Computing Machinery. <https://doi.org/10.1145/3708778.3708786>
- Liu, B., Wang, D., Lin, K., Tan, P. N., & Zhou, J. (2021). RCA: A Deep Collaborative Autoencoder Approach for Anomaly Detection. *IJCAI International Joint Conference on Artificial Intelligence*, 1505–1511. <https://doi.org/10.24963/ijcai.2021/208>



- Nakao, T., Hanaoka, S., Nomura, Y., Murata, M., Takenaga, T., Miki, S., Watadani, T., Yoshikawa, T., Hayashi, N., & Abe, O. (2021). Unsupervised Deep Anomaly Detection in Chest Radiographs. *Journal of Digital Imaging*, 34(2), 418–427. <https://doi.org/10.1007/s10278-020-00413-2>
- Rais, K., Amroune, M., Benmachiche, A., & Haouam, M. Y. (2024). Exploring Variational Autoencoders for Medical Image Generation: A Comprehensive Study. *Preprint ArXiv*, 1–5. <https://doi.org/https://doi.org/10.48550/arXiv.2411.07348>
- Rana, N., & Marwaha, H. (2024). Auto encoder-guided Feature Extraction for Pneumonia Identification from Chest X-ray Images. *E3S Web of Conferences*, 556(01011), 1–8. <https://doi.org/10.1051/e3sconf/202455601011>
- Shastri, S., Kansal, I., Kumar, S., Singh, K., Popli, R., & Mansotra, V. (2022). CheXImageNet : a novel architecture for accurate classification of Covid - 19 with chest x - ray digital images using deep convolutional neural networks. *Health and Technology*, 12, 193–204. <https://doi.org/10.1007/s12553-021-00630-x>
- Siddalingappa, R., & Kanagaraj, S. (2021). Anomaly Detection on Medical Images using Autoencoder and Convolutional Neural Network. *International Journal of Advanced Computer Science and Applications*, 12(7), 148–156. <https://doi.org/10.14569/IJACSA.2021.0120717>
- Zhao, Y., Ding, Q., & Zhang, X. (2023). Ae-Flow: Autoencoders With Normalizing Flows for Medical Images Anomaly Detection. *11th International Conference on Learning Representations, ICLR 2023*, 1–14. <https://openreview.net/forum?id=9OmCr1q54Z>