



Squeeze-and-Excitation Attention on DenseNet169 for Multi-Class Classification of Chest X-Ray Images

Penerapan Squeeze-and-Excitation Attention pada DenseNet169 untuk Klasifikasi Multi-Kelas Citra X-Ray Dada

Lyra Zulyanda Daulay¹, Benny Sukma Negara^{2*}, Yelfi Vitriani³,
Iwan Iskandar⁴, Fitra Kurnia⁵

^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Sains dan Teknologi,
Universitas Islam Negeri Sultan Syarif Kasim Riau, Indonesia

E-Mail: ¹12250120375@students.uin-suska.ac.id, ²bsnegara@uin-suska.ac.id,
³yelfi.vitriani@uin-suska.ac.id, ⁴iwan.iskandar@uin-suska.ac.id, ⁵fitra.k@uin-suska.ac.id

Received Mar 07th 2026; Revised Mar 26th 2026; Accepted Apr 20th 2026; Available Online Apr 30th 2026

Corresponding Author: Benny Sukma Negara

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Chest X-ray (CXR) images are widely used to detect various lung diseases, including COVID-19 and pneumonia. Although deep learning models based on Convolutional Neural Networks (CNNs) have been widely applied to medical image classification, conventional CNNs still have limitations in highlighting important features in complex images and in distinguishing between similar visual patterns across disease classes. These limitations may cause the model to struggle in extracting the most relevant features for accurate classification. Therefore, this study proposes incorporating the Squeeze-and-Excitation (SE) attention mechanism into the DenseNet169 model to improve its ability to focus on important features in chest X-ray images. The main contribution of this study is to analyze the impact of attention mechanisms on improving feature extraction quality in multi-class CXR classification tasks. The dataset consists of 3,000 images across three classes: Normal, COVID-19, and Pneumonia, with 80% for training and 20% for validation. The model is trained using the Adam optimizer with appropriate parameter settings. Evaluation is conducted using a confusion matrix with accuracy, precision, recall, and F1-score. The experimental results show that the baseline DenseNet169 achieves 95.8% accuracy, while the DenseNet169 with SE achieves 96.5% accuracy, indicating significantly improved classification performance overall.

Keyword: Attention Mechanism, Chest X-Ray Image, Densenet169, Multi-Class Classification, Squeeze-and-Excitation

Abstrak

Citra X-ray dada (CXR) ialah satu dari metode pencitraan medis yang banyak diterapkan guna mendeteksi banyak penyakit paru diantaranya COVID-19 serta pneumonia. Meskipun model deep learning yang basisnya Convolutional Neural Network (CNN) sudah banyak diterapkan untuk klasifikasi citra medis, model CNN konvensional masih memiliki keterbatasan dalam menyoroti fitur penting pada citra yang memiliki kompleksitas tinggi serta kemiripan pola antar kelas penyakit. Kondisi tersebut dapat menyebabkan model kesulitan dalam mengekstraksi fitur yang paling relevan untuk proses klasifikasi. Oleh sebab itu, penelitian mengusulkan penerapan *attention mechanism* berupa modul *Squeeze-and-Excitation* (SE) pada arsitektur DenseNet169 guna meningkatkan kemampuan model dalam menekankan fitur penting dari CXR. Kontribusi utama penelitian ini adalah menganalisis pengaruh mekanisme attention terhadap peningkatan kualitas ekstraksi fitur pada klasifikasi multi-kelas citra CXR. Dataset diterapkan pada penelitian ini terdiri dari 3.000 citra yang diklasifikasikan kedalam tiga kelas yakni Normal, COVID-19, serta Pneumonia dengan pembagian data sebesar 80% untuk pelatihan dan 20% untuk validasi. Pelatihan model menggunakan optimizer Adam. Evaluasi model menggunakan confusion matrix dengan accuracy, precision, recall, dan F1 score. Temuan eksperimen mengindikasikan bahwasanya model DenseNet169 *baseline* memperoleh akurasi senilai 95,8%, sedangkan model DenseNet169 dengan modul SE mencapai akurasi 96,5%. Temuan ini menegaskan bahwa SE meningkatkan representasi fitur sehingga performa klasifikasi lebih optimal.

Kata Kunci: *Attention Mechanism, Citra X-Ray Dada, Densenet169, Klasifikasi Multi-Kelas, Squeeze-and-Excitation*

1. PENDAHULUAN

Dada ialah bagian tubuh yang menyimpan berbagai organ penting, salah satunya ialah paru paru. Penyakit paru-paru yakni satu dari penyakit yang menjadi penyebab kematian di seluruh dunia Penyakit yang berdampak pada fungsi pernapasan manusia yakni *Coronavirus Disease 2019* (Covid-19) serta Pneumonia. Covid-19 ialah penyakit menular yang disebabkan oleh virus SARS-CoV-2, dimana pertama kali teridentifikasi pada akhir 2019 di Wuhan, China. Gejala umum termasuk demam tinggi di atas 38°C, batuk, sakit tenggorokan, hidung tersumbat, sakit kepala, serta kesulitan bernapas. Penularan virus berikut terutama melalui percikan droplet saat penderita batuk, bersin, ataupun berbicara, serta kontak dengan permukaan yang terkontaminasi dan kemudian menyentuh area mulut, hidung, ataupun mata. Pneumonia ialah infeksi yang membuat peradangan dikantong udara di paru-paru yang dapat berisi cairan ataupun nanah hingga mengganggu pertukaran oksigen. Pneumonia disebabkan oleh beberapa mikroorganisme, diantaranya patogen bakteri, virus, dan jamur [1].

Radiografi dada ataupun *Chest X-ray* (CXR) ialah sebuah metode pencitraan medis yang umum diterapkan guna mengidentifikasi berbagai penyakit pada sistem pernapasan sebab biayanya relatif rendah, proses pemeriksaannya cepat, serta mampu memberi gambaran struktur paru-paru secara menyeluruh [2]. Namun, proses interpretasi citra CXR masih sangat tergantung atas keahlian radiolog hingga berpotensi membuat subjektivitas, terutama pada kasus klasifikasi multi-kelas yang memiliki pola visual yang mirip[3]. Kondisi berikut dapat meningkatkan risiko kesalahan diagnosis serta memperlambat proses pengambilan keputusan klinis. Seiring dengan perkembangan teknologi kecerdasan buatan, khususnya *deep learning*, berbagai penelitian mulai memanfaatkan *Convolutional Neural Network* (CNN) guna melaksanakan klasifikasi otomatis atas citra CXR sebab kemampuannya dalam mengekstraksi fitur citra secara hierarkis dan menghasilkan performa klasifikasi yang tinggi [4]. Meskipun demikian, model CNN konvensional sering kali belum optimal dalam menyoroti fitur yang paling relevan pada area paru-paru. Oleh sebab itu, penerapan *attention mechanism* menjadi pendekatan yang efektif guna meningkatkan kemampuan model dalam memfokuskan perhatian pada fitur yang paling informatif. Salah satu *attention mechanism* yang banyak diterapkan ialah *Squeeze-and-Excitation* (SE) block, yang bekerja dengan memodelkan hubungan antar kanal fitur (*channel-wise feature recalibration*) hingga jaringan dapat menekankan fitur penting dan menekan fitur yang kurang relevan, hingga berpotensi meningkatkan performa klasifikasi citra CXR multi-kelas secara lebih akurat dan robas.

Penerapan *deep learning* dengan pengolahan citra medis memiliki potensi besar dalam meningkatkan akurasi diagnosis, mempercepat waktu interpretasi, serta menggali informasi dari dataset citra berskala besar. CNN dan berbagai teknik *deep learning* lainnya sudah terbukti sangat efektif dalam tugas segmentasi citra, deteksi objek, dan klasifikasi [5]. Pemilihan DenseNet169 sebagai *backbone* didukung berlandaskan penelitian Breve *et al.* yang melakukan komparasi performa CNN untuk klasifikasi CXR yang mengindikasikan bahwasanya yang terbaik ialah DenseNet169 dengan akurasi 98,15% dan F1-score 98,12% [6] Beberapa penelitian terdahulu mengindikasikan bahwasanya integrasi *attention mechanism* pada model *deep learning*, khususnya CNN, mampu meningkatkan performa klasifikasi citra CXR. Penelitian oleh Oltu *et al.* mengindikasikan bahwasanya penerapan *attention mechanism* pada model *deep learning* untuk klasifikasi penyakit paru, di antaranya COVID-19 dan pneumonia, mampu mencapai akurasi 97,4%. [7]. Penelitian oleh Potharaju *et al.* juga melaporkan bahwasanya penggunaan CNN dengan modul SE dapat meningkatkan performa deteksi penyakit pada citra X-ray dengan akurasi hingga 96,17% [8]. Secara umum, berbagai penelitian tersebut mengindikasikan bahwasanya penerapan *attention mechanism* pada CNN untuk klasifikasi citra X-ray dada menghasilkan performa yang tinggi dengan rata-rata akurasi sekitar 96%, hingga robust dalam meningkatkan kemampuan model dalam mengekstraksi fitur penting dari citra medis.

Beberapa penelitian terbaru menunjukkan efektivitas penggunaan *deep learning*, khususnya DenseNet dan *attention mechanism*, dalam klasifikasi citra CXR. Penelitian terdahulu yang dilakukan oleh Torbicki *et al.* mengungkapkan bahwa model CNN mampu mencapai akurasi tinggi dalam deteksi penyakit paru berbasis CXR, namun masih terbatas dalam menangkap fitur kompleks[9]. Penelitian Wei *et al.* juga membuktikan bahwa penggunaan arsitektur CNN dengan *attention* menghasilkan representasi fitur yang lebih baik [10]. Selain itu, penelitian Finck *et al.* menyoroti bahwa klasifikasi multi-kelas pada citra CXR masih menjadi tantangan akibat kemiripan pola visual antar kelas dan menunjukkan bahwa *attention mechanism* berperan penting dalam meningkatkan diskriminasi fitur pada citra medis [11]. Meskipun demikian, sebagian besar penelitian tersebut masih berfokus pada peningkatan akurasi tanpa memberikan analisis mendalam terkait pengaruh *attention* terhadap proses ekstraksi fitur, sehingga penelitian ini dilakukan untuk mengisi celah tersebut dengan mengintegrasikan SE pada DenseNet169 serta menganalisis pengaruhnya secara komprehensif.

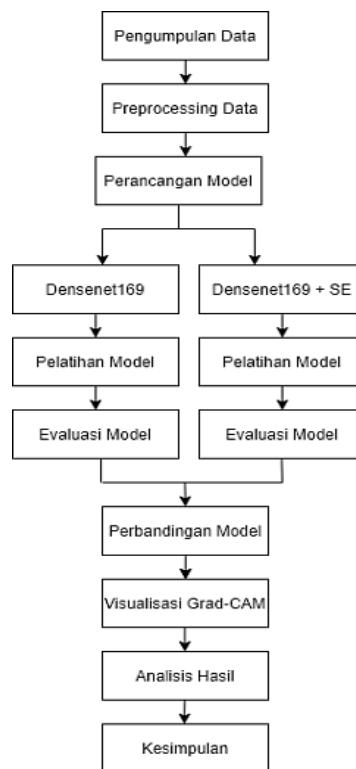
Penelitian berikut menjadi penting sebab klasifikasi multi-kelas citra CXR memiliki peran yang penting dalam membantu diagnosis secara cepat pada berbagai kondisi paru, terutama di fasilitas kesehatan dengan keterbatasan tenaga radiolog. Dengan memanfaatkan arsitektur DenseNet169 yang memiliki kemampuan representasi fitur yang mendalam dan model SE yang mampu menekankan kanal fitur informatif, sistem

diagnosis otomatis berpotensi memberikan temuan yang lebih dapat diandalkan dalam konteks klinis. Pengembangan model yang lebih optimal menjadi hal yang krusial dalam penelitian ini.

Berlandaskan berbagai permasalahan tersebut, penelitian berikut bermaksud untuk menerapkan modul SE pada arsitektur DenseNet169 dalam tugas klasifikasi multi-kelas citra X-ray dada. Penelitian berikut berfokus untuk menganalisis pengaruh mekanisme *channel attention* yang dihasilkan oleh SE terhadap peningkatan performa model DenseNet169, khususnya dalam hal *accuracy*, *precision*, *recall*, dan *F1-score* pada proses klasifikasi penyakit paru-paru. Selain itu, penelitian berikut juga melaksanakan perbandingan performa diantara model DenseNet169 baseline dan DenseNet169 yang diintegrasikan dengan modul SE guna mengetahui efektivitas penerapan mekanisme *channel attention* pada ekstraksi fitur citra medis. Dengan demikian, temuan penelitian berikut diharapkan dapat memberi kontribusi didalam perkembangan sistem diagnosis berbasis kecerdasan buatan yang lebih akurat serta dapat membantu proses analisis CXR di bidang medis.

2. BAHAN DAN METODE


Penelitian berikut menerapkan dataset citra X-ray paru-paru yang terdiri dari tiga kelas, yakni Covid-19, Normal, dan Pneumonia. Dataset tersebut diklasifikasikan dengan menerapkan arsitektur DenseNet169 yang dikombinasikan dengan metode SE *Attention* guna meningkatkan kemampuan model dalam mengekstraksi fitur. Proses penelitian berikut dilaksanakan melalui beberapa tahapan, diantaranya pengumpulan data, *preprocessing* data, perancangan model, pelatihan model, evaluasi model, perbandingan model, visualisasi Grad-CAM serta analisis hasil. Alur tahapan penelitian tersebut dapat dicermati pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Dataset yang diterapkan didalam riset berikut bersumber dari dataset publik yang sebelumnya dimanfaatkan dalam penelitian terkait klasifikasi penyakit paru-paru yang menerapkan pendekatan *deep learning* pada citra CXR. Penelitian yang dilakukan Kumar et al. dan Shastri et al. mengembangkan sistem klasifikasi otomatis guna mengidentifikasi beberapa kondisi paru-paru berlandaskan pola visual yang muncul pada CXR, khususnya guna membedakan antara paru-paru normal, pneumonia, dan COVID-19. Dalam penelitian tersebut, citra CXR dianalisis menerapkan beberapa metode *deep learning*, guna mengekstraksi fitur-fitur penting dari struktur paru-paru, melalui proses ekstraksi fitur tersebut, model dapat mempelajari karakteristik visual yang membedakan tiap kategori penyakit hingga mampu melaksanakan proses klasifikasi citra secara otomatis [12], [13]. Dataset yang diterapkan didalam penelitian ini terdiri dari tiga kategori, yakni Normal, Covid-19, dan Pneumonia. Tiap kategori memiliki 1.000 citra, sehingga jumlah keseluruhan dataset mencapai 3.000 citra. Contoh citra dari masing-masing kategori dataset tersebut ditampilkan pada Gambar 2.



Gambar 2. Citra X-ray Paru-paru Normal, Covid-19 dan Pneumonia

2.2. Preprocessing Data

Penelitian oleh Rahman *et al.* menunjukkan bahwa preprocessing seperti normalisasi dan augmentasi data berperan penting dalam meningkatkan performa model. Proses *preprocessing* diawali dengan mengubah ukuran citra (*resize*) ke 224×224 piksel agar selaras pada ukuran input standar DenseNet169 [14], selanjutnya dilaksanakan normalisasi piksel, yakni mengubah nilai piksel citra kedalam rentang 0–1 dengan tujuan menstabilkan distribusi data selama proses pelatihan model. Sesudah itu, diterapkan augmentasi data guna meningkatkan variasi dataset serta membantu mengurangi risiko *overfitting*[15] Tahap terakhir ialah pembagian dataset, di mana data terbagi ke dua bagian, ialah 80% sebagai data latih serta 20% sebagai data validasi. Pemilihan rasio berikut didasarkan pada penelitian sebelumnya yang mengindikasikan bahwasanya perbandingan 80:20 mampu menghasilkan performa yang lebih optimal dan stabil dalam tugas klasifikasi citra [16].

2.3. Perancangan Model


Pada tahap berikut, dilaksanakan perancangan arsitektur model klasifikasi CXR yang menerapkan pendekatan *transfer learning* dengan *backbone* DenseNet169. Riset berikut menerapkan dua model untuk dilaksanakan perbandingan performa yakni:

1. DenseNet169 (*Baseline Model*)
2. DenseNet169 dengan *SE Attention* (*Proposed Model*)

Pendekatan berikut diterapkan guna menganalisis pengaruh mekanisme attention atas peningkatan performa klasifikasi.

2.3.1 DenseNet169 (*Baseline Model*)

Berdasarkan penelitian yang dilakukan Zhou *et al.* DenseNet169 ialah varian dari arsitektur DenseNet (*Densely Connected Convolutional Networks*) yang terdiri dari 169 lapisan dengan konsep *dense connectivity*, di mana tiap layer terhubung langsung dengan seluruh layer sebelumnya [17]. Struktur berikut dirancang agar mengatasi permasalahan *vanishing gradient*, meningkatkan aliran informasi dan gradien, serta mendorong penggunaan parameter yang lebih efisien. Arsitektur DenseNet169 terdiri dari empat *dense block* yang dipisahkan oleh *transition layer*. Tiap *dense block* mengombinasikan beberapa komponen utama yakni *batch normalization*, fungsi aktivasi ReLU, serta operasi konvolusi 1×1 dan 3×3 . Konvolusi 1×1 berfungsi sebagai *bottleneck layer* guna melaksanakan reduksi dimensi hingga mengurangi jumlah parameter, sedangkan konvolusi 3×3 tersebut diterapkan guna melaksanakan ekstraksi fitur spasial pada citra. Didalam penelitian berikut, DenseNet169 diterapkan dengan bobot pralatih *ImageNet* melalui pendekatan *transfer learning* dan diambil tanpa lapisan klasifikasi akhir (*include_top=False*) hingga berperan sebagai *feature extractor* utama dalam proses ekstraksi fitur dari CXR [18].



Gambar 3. Arsitektur Densenet169

2.3.2 DenseNet169 dengan *SE Attention* (*Proposed Model*)

Model menerapkan arsitektur DenseNet169 sebagai ekstraktor fitur dasar, kemudian dilengkapi dengan blok *SE Attention* guna meningkatkan kualitas representasi fitur pada kanal. Pendekatan berikut bermaksud guna menghasilkan model yang lebih adaptif dalam menyoroti pola-pola penting pada citra medis, diantaranya konsolidasi dan *ground-glass opacity*, hingga performa klasifikasi multi-kelas dapat meningkat. Diintegrasikan *attention mechanism* berbasis kanal melalui modul *SE block* untuk meningkatkan kemampuan model dalam

memfokuskan perhatian pada fitur yang relevan. Mekanisme berikut terinspirasi oleh cara kerja otak manusia yang mampu memilih informasi yang paling relevan diantara banyak informasi yang diterima. Dalam konteks *machine learning*, *attention mechanism* membantu model menempatkan sumber daya pemrosesan secara efisien dengan memberi bobot yang berbeda pada elemen input yang berbeda, hingga membuat model lebih efektif dalam memahami konteks dan relasi dalam data yang kompleks. *SE block* secara khusus memodelkan ketergantungan antar-kanal hingga jaringan dapat memperkuat kanal yang penting dan menekan kanal yang kurang relevan [19].

Squeeze-and-Excitation (SE) block merupakan mekanisme attention yang bertujuan untuk meningkatkan kualitas representasi fitur dengan memodelkan hubungan antar channel. Prosesnya terdiri dari tiga tahap utama, yaitu *squeeze*, *excitation*, dan *scale*.

1. *Squeeze*, informasi spasial diringkas menggunakan *global average pooling* untuk menghasilkan representasi global pada setiap channel, $U_c(i, j)$ merupakan nilai piksel pada channel ke- c , serta H dan W menunjukkan dimensi spasial feature map. Hasilnya adalah vektor Z yang mempresentasikan informasi penting dari setiap channel.


$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (1)$$

2. *Excitation*, untuk mempelajari tingkat kepentingan tiap channel menggunakan dua layer fully connected. s yaitu vektor bobot dari proses *excitation*. W_1 dan W_2 merupakan bobot layer, δ adalah fungsi ReLU, dan σ adalah fungsi sigmoid yang menghasilkan bobot dalam rentang 0 hingga 1.

$$s = \theta(W_2 \delta(W_1 z)) \quad (2)$$

3. *Recalibration*, yakni proses feature map awal dikalikan dengan bobot yang dihasilkan untuk setiap channel, s_c merupakan bobot channel dan \hat{U}_c adalah feature map hasil kalibrasi [20].

$$\hat{U}_c = s_c \cdot U_c \quad (3)$$



Gambar 4. SE Block

Secara keseluruhan (Gambar 4), proses pada SE block dimulai dengan merangkum informasi global setiap channel, dilanjutkan dengan pembelajaran bobot kepentingan channel, dan diakhiri dengan penyesuaian feature map. Untuk memperjelas alur tersebut, tahapan SE block direpresentasikan dalam bentuk algoritma berikut.


Input : Feature map $X \in \mathbb{R}^{H \times W \times C}$

Output: Recalibrated feature map $\hat{X} \in \mathbb{R}^{H \times W \times C}$

1. Squeeze: Global Information Embedding
2. for each channel $c = 1$ to C do
3. $Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j)$
4. end for
5. Excitation: Adaptive Recalibration
6. $s = \theta(W_2 \delta(W_1 z))$
7. Scale: Feature Reweighting
8. for each channel $c = 1$ to C do
9. $\hat{U}_c = s_c \cdot U_c$
10. end for
11. return \hat{U}

Algoritma tersebut menunjukkan bahwa SE block bekerja dengan menyesuaikan bobot pada setiap channel secara adaptif, sehingga model dapat lebih fokus pada fitur yang relevan. Feature map hasil recalibration kemudian diteruskan ke tahap klasifikasi pada arsitektur model.

Penambahan lapisan klasifikasi dengan cara menambahkan beberapa layer di atas *backbone*, yakni *Global Average Pooling* agar mengubah *feature map* menjadi vektor, agar bisa masuk ke *Dense*, [21], *Dropout* agar mengurangi *overfitting*, sangat penting untuk dataset, *Dense Softmax* (3 neuron untuk 3 kelas) agar menentukan kelas normal/ Covid/ Pneumonia [22]. Arsitektur lengkap dari model DenseNet169 yang diintegrasikan dengan SE block ditunjukkan pada Gambar 5.



Gambar 5. Arsitektur DenseNet169 + SE

Setelah arsitektur model terbentuk, proses selanjutnya adalah pelatihan model yang dilaksanakan dengan optimalisasi *hyperparameter*, yakni dengan menerapkan learning rate, batch size, jumlah epoch, dan skema penyesuaian learning rate yang ditentukan melalui percobaan awal untuk memperoleh hasil yang robust.

2.4. Pelatihan Model


Proses pelatihan model dilaksanakan menerapkan dataset pelatihan dengan konfigurasi *hyperparameter* tertentu. Kedua model yakni DenseNet169 *baseline* dan DenseNet169 dengan SE dilatih menerapkan *hyperparameter* yang sama agar perbandingan performa model dapat dilaksanakan secara adil. Proses pelatihan dilaksanakan hingga model mencapai kondisi konvergen ataupun hingga mencapai jumlah epoch maksimum yang ditentukan. Konfigurasi yang dilaksanakan dapat dicermati pada Tabel 1.

Tabel 1. Parameter Pelatihan Model

Parameter	Nilai
Optimizer	Adam
Learning Rate	0.001
Batch Size	16
Epoch	30

2.5. Evaluasi Model

Berdasarkan penelitian yang dilakukan oleh Sathyanarayan dan kawan-kawan, evaluasi model dilaksanakan guna menilai kinerja klasifikasi dari kedua model yang diterapkan didalam riset berikut. Proses evaluasi dilaksanakan dengan menerapkan *confusion matrix*, yang termasuk ke empat komponen utama, yakni *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), serta *False Negative* (FN), secara umum dapat dilihat pada Gambar 6. Keempat komponen tersebut menjadi landasan didalam perhitungan berbagai metrik evaluasi, diantaranya *accuracy*, *precision*, *recall*, dan *F1-score*, sehingga memungkinkan dilaksanakan analisis yang lebih komprehensif atas kemampuan model dalam mengklasifikasikan CXR secara akurat [23].



Gambar 6. Confusion Matrix

True Positive (TP) ialah jumlah sampel dari kelas positif yang berhasil diprediksi dengan benar oleh sistem. *True Negative* (TN) ialah jumlah sampel dari kelas negatif yang berhasil diklasifikasikan dengan tepat sebagai negatif. *False Negative* (FN) mengindikasi jumlah sampel yang seharusnya termasuk dalam kelas positif, tetapi diprediksi sebagai kelas negatif oleh sistem. Sementara itu, *False Positive* (FP) ialah jumlah sampel yang sebenarnya termasuk kelas negatif, namun oleh sistem diprediksi sebagai kelas positif [24]. Berlandaskan nilai-nilai tersebut, berbagai metrik evaluasi diantaranya *accuracy*, *precision*, *recall*, serta *F1-score*, dapat dihitung guna mengukur performa model secara lebih menyeluruh.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

$$\text{F1-Score} = 2 \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (7)$$

2.6. Perbandingan Model

Sesudah proses evaluasi selesai, dilaksanakan perbandingan performa diantara DenseNet169 *baseline* dan DenseNet169 dengan SE *Attention*. Perbandingan berikut bermaksud guna mengetahui apakah penambahan modul SE mampu meningkatkan kemampuan model dalam melaksanakan klasifikasi CXR. Perbandingan dilaksanakan berlandaskan nilai *accuracy*, *precision*, *recall* serta *F1-score*.

2.7. Visualisasi Grad-CAM

Grad-CAM digunakan untuk memvisualisasikan area citra yang paling berpengaruh terhadap keputusan klasifikasi model. Metode ini memanfaatkan gradien dari kelas target pada *feature map* di lapisan konvolusi terakhir untuk menghasilkan peta aktivasi berupa *heatmap*. *Heatmap* tersebut kemudian ditumpangkan pada citra asli sehingga dapat menunjukkan bagian citra yang menjadi fokus perhatian model dalam proses prediksi. Teknik ini membantu meningkatkan interpretabilitas model *deep learning*, khususnya pada analisis citra medis.

2.8. Analisis Hasil

Tahap terakhir didalam riset berikut ialah melaksanakan analisis atas temuan eksperimen yang didapat. Analisis dilaksanakan guna mengevaluasi performa model serta mengidentifikasi pengaruh penerapan SE *Attention* atas peningkatan kualitas ekstraksi fitur pada arsitektur DenseNet169 dalam tugas klasifikasi multi-kelas CXR. Temuan analisis berikut kemudian diterapkan sebagai dasar dalam menarik kesimpulan dari penelitian yang dilaksanakan.

3. HASIL DAN ANALISIS

3.1. Hasil Perancangan Model

Pada penelitian berikut dilaksanakan perancangan dua arsitektur model, yakni DenseNet169 *baseline* dan DenseNet169 yang diintegrasikan dengan modul SE. Dalam proses perancangan model *deep learning*, jumlah parameter menjadi salah satu aspek penting yang perlu dianalisis. Parameter pada model merupakan bobot yang dipelajari selama proses pelatihan untuk mengenali pola pada data. Secara umum, parameter terbagi menjadi dua jenis, yaitu parameter trainable dan non-trainable. Trainable parameter adalah parameter yang diperbarui selama proses pelatihan model, sedangkan non-trainable parameter merupakan parameter yang tidak mengalami perubahan. Tabel berikut mengindikasikan perbandingan jumlah parameter dari kedua model yang diterapkan didalam riset berikut.


Tabel 2. Hasil Perancangan Model

Model	Total Parameter	Trainable Parameter	Non-Trainable Parameter
DenseNet169	12,647,875	4,995	12,642,880
DenseNet169+SE	12,995,755	352,875	12,642,880

Berdasarkan Tabel 2, dapat dicermati bahwasanya penambahan modul SE menyebabkan peningkatan jumlah parameter pada model. Model DenseNet169 dengan SE memiliki total *trainable* parameter sejumlah 4,995, sedangkan model DenseNet169 *baseline* memiliki 352,875 *trainable* parameter. Peningkatan jumlah parameter berikut disebabkan oleh keberadaan lapisan tambahan pada modul SE yang berfungsi guna mempelajari bobot penting dari tiap kanal fitur. Hal tersebut mengindikasikan bahwasanya model dengan modul SE memiliki kapasitas pembelajaran yang lebih tinggi dalam menyesuaikan bobot selama proses pelatihan. Namun demikian, peningkatan jumlah parameter *trainable* tersebut juga berimplikasi pada kebutuhan komputasi yang lebih tinggi, robas dalam hal penggunaan memori maupun waktu pelatihan, sebab model harus memperbarui lebih banyak parameter selama proses pembelajaran.

3.2. Hasil Pelatihan Model


Model didalam riset berikut dilatih dengan *batch size* senilai 16 dengan jumlah maksimum 30 *epoch* serta memanfaatkan *optimizer Adam*. Dalam proses pelatihan berlangsung, kinerja model dipantau dengan menerapkan metrik *accuracy* serta *loss* baik pada data *training* maupun *validation*.



Gambar 7. Grafik loss dan accuracy model DenseNet Baseline

Berdasarkan grafik pada Gambar 7, ditampilkan kurva *accuracy* dan *loss* dari model DenseNet169 *baseline* selama proses pelatihan. Dari grafik tersebut dapat diamati bahwasanya nilai *training accuracy* meningkat secara bertahap pada tiap *epoch*, yang mengindikasikan bahwasanya model makin mampu mempelajari representasi fitur dari CXR. Pada saat yang sama, nilai *training loss* mengalami penurunan yang cukup signifikan pada beberapa *epoch* awal, kemudian menurun secara lebih stabil hingga akhir proses pelatihan.

Pada kurva *validation accuracy*, terlihat tren peningkatan yang relatif mengikuti pola *training accuracy*, meskipun terdapat sedikit fluktuasi pada beberapa *epoch*. Kondisi berikut umum terjadi pada pelatihan model *deep learning*, sebab data validasi diterapkan guna menguji kemampuan generalisasi model atas data yang tidak diterapkan secara langsung dalam proses pelatihan. Selain itu, *validation loss* juga mengindikasikan kecenderungan menurun secara stabil, yang mengindikasikan bahwasanya model tidak mengalami *overfitting* yang signifikan selama proses pelatihan berlangsung.



Gambar 8. Grafik loss dan accuracy model DenseNet+SE

Sementara itu pada Gambar 8, mengindikasikan grafik pelatihan guna model DenseNet169 + SE yang sudah diintegrasikan dengan modul SE *Block*. Berlandaskan grafik tersebut, terlihat bahwasanya nilai *accuracy* pada model berikut meningkat lebih cepat dibandingkan model *baseline*, terutama pada beberapa *epoch* awal pelatihan. Perihal berikut mengindikasikan bahwasanya mekanisme *channel attention* yang terdapat pada modul SE mampu membantu model dalam menekankan fitur-fitur yang lebih penting dari citra input.

Selain itu, nilai *validation accuracy* pada model DenseNet169 + SE juga cenderung lebih tinggi dan lebih stabil dibandingkan model *baseline*. Sementara itu, kurva *loss* pada model berikut mengindikasikan penurunan yang lebih cepat dan mencapai nilai yang lebih rendah pada akhir proses pelatihan. Kondisi tersebut mengindikasikan bahwasanya model mampu meminimalkan kesalahan prediksi dengan lebih efektif.

3.3. Hasil Evaluasi Model

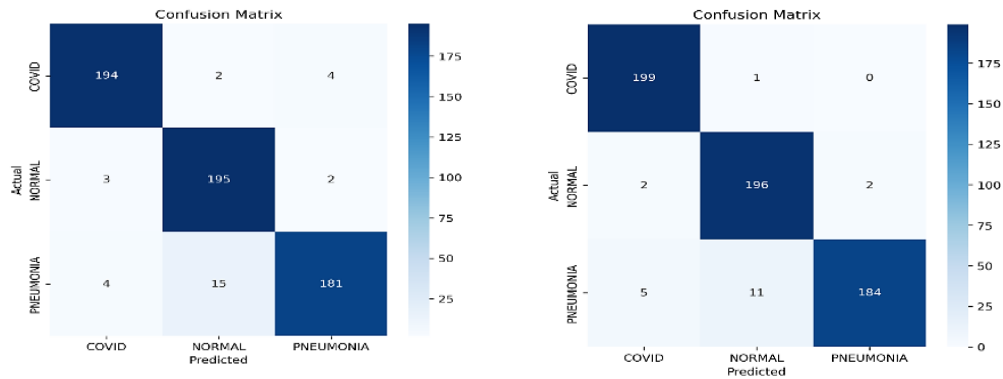
Evaluasi model dilaksanakan dengan menerapkan beberapa metrik penilaian, yakni *precision*, *recall*, *F1-score*, dan *accuracy*. Temuan dari proses evaluasi tersebut disajikan pada tabel 3.

Tabel 3. Hasil Evaluasi Model

Model	Precision	Recall	F1-Score	Accuracy
DenseNet169	0.951	0.95	0.95	0.95
DenseNet169+SE	0.966	0.965	0.965	0.965

Berdasarkan Tabel 3, model DenseNet169 + SE terlihat mengalami peningkatan. Peningkatan nilai pada seluruh metrik tersebut mengindikasikan bahwasanya penambahan SE *Block* mampu meningkatkan kemampuan model dalam mengekstraksi fitur yang lebih relevan hingga menghasilkan prediksi yang lebih akurat. Dalam bidang klasifikasi citra medis, *recall* yang juga dikenal sebagai *sensitivity* ialah metrik yang

sangat penting. *Sensitivity* ialah sebuah hal yang menggambarkan kemampuan model dalam mengidentifikasi seluruh kasus positif yang benar-benar terdapat pada data. Nilai *sensitivity* yang tinggi mengindikasikan bahwasanya model mampu mengurangi kesalahan *false negative*, yakni kondisi ketika citra yang sebenarnya mengindikasikan keberadaan penyakit justru diprediksi sebagai kondisi normal. Kesalahan semacam berikut dapat berdampak serius dalam praktik medis sebab berpotensi menyebabkan keterlambatan diagnosis dan penanganan pasien.



Gambar 9. Visualisasi Confusion Matrix DenseNet169 Baseline dan DenseNet+SE

Berdasarkan Gambar 9, visualisasi *confusion matrix* mengindikasikan performa klasifikasi dari model DenseNet169 *baseline* dan DenseNet169 dengan SE pada tiga kelas, yakni COVID, Normal, dan Pneumonia. Secara umum, kedua model mampu mengklasifikasikan sebagian besar data dengan benar, yang terlihat dari nilai diagonal yang tinggi pada matriks. Namun, model DenseNet169 + SE mengindikasikan peningkatan performa dibandingkan dengan model *baseline*, terutama pada kelas COVID dan Pneumonia, dengan jumlah prediksi yang benar lebih tinggi serta kesalahan klasifikasi yang lebih sedikit.

3.4 Perbandingan Model

Perbandingan performa antara model *baseline* dan model dengan modul SE ditunjukkan pada tabel 4.


Tabel 4. Hasil Perbandingan Model

Model	Accuracy	Val Accuracy	Loss	Val Loss
DenseNet169	0,9496	0,9583	0,1393	0,1520
DenseNet169+SE	0.9712	0.965	0.09	0.1354


Berdasarkan Tabel 4 tersebut, peningkatan nilai *accuracy* dan *validation accuracy* mengindikasikan bahwasanya model dengan modul SE mampu melaksanakan klasifikasi citra dengan tingkat ketepatan yang lebih tinggi dibandingkan dengan model *baseline*. Selain itu, nilai *loss* dan *validation loss* yang lebih rendah pada model DenseNet169 + SE mengindikasikan bahwasanya kesalahan prediksi model selama proses pelatihan menjadi lebih rendah dan kemampuan generalisasi model atas data yang tidak dilatih menjadi lebih baik.

3.5 Hasil Visualisasi Grad-CAM

Hasil visualisasi Grad-CAM diantara model *baseline* dan model dengan modul SE ditunjukkan pada Gambar 10 dan Gambar 11.



Gambar 10. Visualisasi Grad-CAM DenseNet169 Baseline



Gambar 11. Visualisasi Grad-CAM DenseNet169 Baseline+SE

Visualisasi Grad-CAM menghasilkan *heatmap* yang menunjukkan tingkat perhatian model terhadap area tertentu pada citra. Perbedaan warna pada *heatmap* memiliki makna yang merepresentasikan tingkat kontribusi masing-masing area terhadap keputusan klasifikasi. Warna merah menunjukkan area dengan tingkat aktivasi tertinggi, yang berarti bagian tersebut paling berpengaruh dalam proses prediksi model. Warna kuning hingga oranye menunjukkan tingkat kontribusi menengah, sedangkan warna hijau hingga biru merepresentasikan area dengan kontribusi rendah atau tidak signifikan terhadap hasil klasifikasi. Berdasarkan hasil visualisasi, model DenseNet169 *baseline* dan DenseNet169 dengan penambahan modul SE sama-sama mampu menyoroti area paru-paru pada citra X-ray. Model dengan penambahan SE cenderung menghasilkan peta aktivasi yang lebih terfokus pada area yang relevan dibandingkan dengan model *baseline*.

Berlandaskan temuan eksperimen, penerapan modul SE pada DenseNet169 terbukti meningkatkan performa klasifikasi citra X-ray dada melalui mekanisme *channel attention* yang mampu menekankan fitur relevan dan mengurangi fitur kurang penting. Hasil ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa *attention mechanism* dapat meningkatkan fokus model dan akurasi klasifikasi, seperti penelitian terdahulu. Pada penelitian ini, model DenseNet169 + SE menghasilkan akurasi 96,5%, lebih tinggi dibandingkan dengan model *baseline* sebesar 95,8%, yang menunjukkan kontribusi positif SE dalam meningkatkan kemampuan ekstraksi fitur. Namun, peningkatan tersebut relatif kecil, kemungkinan disebabkan oleh keterbatasan dataset dan kemiripan pola antarkelas, sehingga penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan mengeksplorasi metode *attention* lain untuk hasil yang lebih optimal.

4. KESIMPULAN

Berlandaskan temuan riset yang sudah dilaksanakan, dapat diambil sebuah simpulan bahwasanya penerapan modul SE pada arsitektur DenseNet169 mampu meningkatkan performa model dalam melaksanakan klasifikasi multi-kelas CXR. Model DenseNet169 *baseline* menghasilkan nilai akurasi senilai 95,8%, sedangkan model DenseNet169 + SE mengindikasikan peningkatan performa dengan nilai akurasi senilai 96,5%. Selain itu, nilai *precision*, *recall*, serta *F1-score* pada model DenseNet169 + SE juga lebih tinggi dibandingkan dengan model *baseline*. Peningkatan performa berikut mengindikasikan bahwasanya mekanisme *channel attention* pada modul SE mampu membantu model dalam menekankan fitur-fitur penting pada CXR sehingga proses ekstraksi fitur menjadi lebih efektif. Dengan demikian, integrasi modul SE pada arsitektur DenseNet169 terbukti dapat meningkatkan kemampuan model dalam mengklasifikasikan penyakit paru pada CXR. Penelitian selanjutnya dianjurkan untuk melibatkan tenaga medis dalam validasi hasil *Explainable Artificial Intelligence* (XAI), seperti Grad-CAM, guna memastikan bahwa area yang diinterpretasikan oleh model sesuai dengan kondisi klinis sehingga hasilnya lebih dapat dipercaya dalam penerapan nyata.

REFERENSI

- [1] N. Rezaei, Ed., *Pneumonia*, vol. 13. in *Infectious Diseases*, vol. 13. IntechOpen, 2022. doi: 10.5772/intechopen.73895.
- [2] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?," *IEEE Access*, vol. 8, pp. 132665–132676, 2020, doi: 10.1109/ACCESS.2020.3010287.
- [3] T. Rahman *et al.*, "Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images," *Comput. Biol. Med.*, vol. 132, May 2021, doi: 10.1016/j.combiomed.2021.104319.
- [4] P. Afshar *et al.*, "COVID-CT-MD, COVID-19 computed tomography scan dataset applicable in machine learning and deep learning," *Sci. Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1038/s41597-021-00900-3.
- [5] M.Kranthi, S.Sailaja, and E.V.N.Jyothi, "Deep Learning Approaches for Medical Image Processing in the Big Data Era," *International Journal of Scientific Methods in Computational Science and Engineering*, vol. 01, no. 01, pp. 24–31, Jun. 2024, doi: 10.58599/ijsmcse.2024.1108.

- [6] F. Breve, "COVID-19 Detection on Chest X-Ray Images: A comparison of CNN architectures and ensembles," May 2022, [Online]. Available: <http://arxiv.org/abs/2111.09972>
- [7] B. Oltu, S. Güney, S. E. Yuksel, and B. Dengiz, "Automated classification of chest X-rays: a deep learning approach with attention mechanisms," *BMC Med. Imaging*, vol. 25, no. 1, Dec. 2025, doi: 10.1186/s12880-025-01604-5.
- [8] S. Potharaju, S. N. Tambe, K. Dasari, N. Srikanth, R. Venkatarao, and S. Tambe, "Enhanced X-ray image classification for pneumonia detection using deep learning based CBAM and SE mechanisms," *Intell. Based. Med.*, vol. 12, Jan. 2025, doi: 10.1016/j.ibmed.2025.100299.
- [9] A. Torbicki, "Pulmonary hypertension: Diagnosis and management," Jun. 01, 2021, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/diagnostics11061066.
- [10] Y. J. Wei *et al.*, "Effects of Diesel Hydrocarbon Components on Cetane Number and Engine Combustion and Emission Characteristics," *Applied Sciences (Switzerland)*, vol. 12, no. 7, Apr. 2022, doi: 10.3390/app12073549.
- [11] T. Finck *et al.*, "Faster and Better: How Anomaly Detection Can Accelerate and Improve Reporting of Head Computed Tomography," *Diagnostics*, vol. 12, no. 2, Feb. 2022, doi: 10.3390/diagnostics12020452.
- [12] S. Kumar *et al.*, "LiteCovidNet: A lightweight deep neural network model for detection of COVID-19 using X-ray images," *Int. J. Imaging Syst. Technol.*, vol. 32, no. 5, pp. 1464–1480, Sep. 2022, doi: 10.1002/ima.22770.
- [13] S. Shastri, I. Kansal, S. Kumar, K. Singh, R. Popli, and V. Mansotra, "CheXImageNet: a novel architecture for accurate classification of Covid-19 with chest x-ray digital images using deep convolutional neural networks," *Health Technol. (Berl.)*, vol. 12, no. 1, pp. 193–204, Jan. 2022, doi: 10.1007/s12553-021-00630-x.
- [14] G. S. P. Ramadhan, M. Maimunah, and S. Nugroho, "Optimasi Data Preprocessing dan Hyperparameter Tuning pada Klasifikasi Penyakit Daun Apel menggunakan DenseNet169," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1352–1362, Dec. 2024, doi: 10.47065/bits.v6i3.6134.
- [15] D. Husen, F. Ilmu Komputer, U. Kuningan Kuningan, and J. Barat, "Husen-Evaluasi Teknik Augmentasi Data Untuk Klasifikasi Tumor Otak Menggunakan CNN Pada Citra MRI Evaluasi Teknik Augmentasi Data Untuk Klasifikasi Tumor Otak Menggunakan CNN Pada Citra MRI (Performance Evaluation OF CNN Models With Various Data Augmentasi Techniques ON MRI Images For Brain Tumor Classification)."
- [16] H. Bichri, A. Chergui, and M. Hain, "Investigating the Impact of Train / Test Split Ratio on the Performance of Pre-Trained Models with Custom Datasets," 2024. [Online]. Available: www.ijacsa.thesai.org
- [17] T. Zhou, X. Ye, H. Lu, X. Zheng, S. Qiu, and Y. Liu, "Dense Convolutional Network and Its Application in Medical Image Analysis," 2022, *Hindawi Limited*. doi: 10.1155/2022/2384830.
- [18] P. P. Dalvi, D. R. Edla, and B. R. Purushothama, "Diagnosis of Coronavirus Disease From Chest X-Ray Images Using DenseNet-169 Architecture," May 01, 2023, *Springer*. doi: 10.1007/s42979-022-01627-7.
- [19] A. Hernández and J. M. Amigó, "Attention mechanisms and their applications to complex systems," *Entropy*, vol. 23, no. 3, pp. 1–18, Mar. 2021, doi: 10.3390/e23030283.
- [20] K. A. Huang, H. K. Choudhary, A. Santiago, and N. S. Prakash, "Squeeze-and-Excitation Enhanced Convolutional Neural Networks for Multi-class Pneumonia Classification on Chest Radiographs," *Cureus*, Dec. 2025, doi: 10.7759/cureus.99649.
- [21] C. Halkiopoulou, E. Gkintoni, A. Aroutzidis, and H. Antonopoulou, "Advances in Neuroimaging and Deep Learning for Emotion Detection: A Systematic Review of Cognitive Neuroscience and Algorithmic Innovations," Feb. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/diagnostics15040456.
- [22] K. A. Huang and N. Prakash, "Evaluating the Impact of Attention Mechanisms on a Fine-Tuned Neural Network for Magnetic Resonance Imaging Tumor Classification: A Comparative Analysis," *Cureus*, Mar. 2025, doi: 10.7759/cureus.80872.
- [23] S. Sathyanarayanan, "Confusion Matrix-Based Performance Evaluation Metrics," *African Journal of Biomedical Research*, pp. 4023–4031, Nov. 2024, doi: 10.53555/ajbr.v27i4s.4345.
- [24] B. Kocak *et al.*, "Evaluation metrics in medical imaging AI: fundamentals, pitfalls, misapplications, and recommendations," *European Journal of Radiology Artificial Intelligence*, vol. 3, p. 100030, Sep. 2025, doi: 10.1016/j.ejrai.2025.100030.