

Penggunaan Dual Attention Network pada DenseNet-169 untuk Klasifikasi Multi-kelas Citra X-Ray Dada

Azizah Tasykira Paramitha El Razi¹, Benny Sukma Negara², Muhammad Irsyad³, Suwanto Sanjaya⁴, Siti Ramadhani⁵

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

¹12250121159@students.uin-suska.ac.id, ²bsnegara@uin-suska.ac.id*, ³irsyadtech@uin-suska.ac.id, ⁴suwantosanjaya@uin-suska.ac.id, ⁵siti.ramadhani@uin-suska.ac.id

Abstract

Multi-class classification of chest X-ray images is an important approach to automatically distinguish COVID-19, normal, and pneumonia cases. However, visual similarities among these classes may make it difficult for a model to extract relevant features. This study integrates a Dual Attention Network (DANet) into DenseNet-169 to enhance feature representation through the combination of Grouped Channel Attention Module and Strip Spatial Attention Module. The dataset consists of 5,228 chest X-ray images divided into training and testing sets using an 80:20 ratio. DenseNet-169 baseline and DenseNet-169 with DANet were evaluated using accuracy, precision, recall, F1-score, sensitivity, specificity, ROC-AUC, confusion matrix, and Grad-CAM. The experimental results show that DenseNet-169 with DANet achieved 98.47% accuracy, 98.55% precision, 98.50% recall, 98.50% F1-score, 98.50% sensitivity, and 99.22% specificity. The ROC-AUC values for COVID-19, normal, and pneumonia classes were 0.9994, 0.9989, and 0.9980, respectively. These results indicate that DenseNet-169 with DANet has good classification and discrimination performance across the three classes. Grad-CAM visualization also shows that DANet helps the model produce more focused attention.

Keywords: DenseNet-169, Dual Attention Network, Chest X-ray, Multi-class Classification, Deep Learning

Abstrak

Klasifikasi multi-kelas citra X-ray dada menjadi salah satu pendekatan yang dapat membantu membedakan kondisi COVID-19, normal, dan pneumonia secara otomatis. Namun, kemiripan karakteristik visual antar kelas dapat menyebabkan model kesulitan dalam mengekstraksi fitur yang relevan. Penelitian ini mengintegrasikan *Dual Attention Network* (DANet) pada DenseNet-169 untuk meningkatkan representasi fitur melalui kombinasi *Grouped Channel Attention Module* dan *Strip Spatial Attention Module*. Dataset yang digunakan terdiri atas 5.228 citra X-ray dada yang dibagi menjadi data latih dan data uji dengan rasio 80:20. Model DenseNet-169 *baseline* dan DenseNet-169 dengan DANet dievaluasi menggunakan akurasi, presisi, *recall*, F1-score, sensitivitas, spesifisitas, ROC-AUC, *confusion matrix*, dan Grad-CAM. Hasil pengujian menunjukkan bahwa DenseNet-169 dengan DANet memperoleh akurasi 98,47%, presisi 98,55%, *recall* 98,50%, F1-score 98,50%, sensitivitas 98,50%, dan spesifisitas 99,22%. Nilai ROC-AUC yang diperoleh pada kelas COVID-19, normal, dan pneumonia masing-masing sebesar 0,9994, 0,9989, dan 0,9980. Hasil tersebut menunjukkan bahwa DenseNet-169 dengan DANet memiliki kemampuan klasifikasi dan diskriminasi yang baik pada ketiga kelas. Visualisasi Grad-CAM menunjukkan bahwa DANet membantu model menghasilkan perhatian yang lebih terarah.

Kata kunci: DenseNet-169, *Dual Attention Network*, Citra X-Ray Dada, Klasifikasi Multi-Kelas, *Deep Learning*

1. Pendahuluan

Penyakit paru merupakan masalah kesehatan yang membutuhkan diagnosis secara cepat dan akurat. Citra X-ray dada sering digunakan sebagai modalitas pencitraan utama untuk mendeteksi berbagai kelainan pada paru. Seiring berkembangnya penerapan kecerdasan buatan di bidang medis, klasifikasi multi-kelas pada citra X-ray dada menjadi semakin penting untuk membantu membedakan berbagai kondisi paru dalam satu sistem otomatis. Namun, kemiripan karakteristik visual antara paru normal, infiltrat pneumonia, dan bayangan kaca buram (*ground-glass opacity*) pada COVID-19 menyebabkan proses identifikasi menjadi lebih menantang [1,2]. Kondisi tersebut berpotensi meningkatkan beban interpretasi citra oleh tenaga medis, sehingga pengembangan

sistem klasifikasi otomatis yang akurat menjadi salah satu pendekatan yang dapat mendukung analisis citra X-ray dada.

Arsitektur *deep learning* terbukti memiliki kapabilitas komputasi yang baik untuk membangun sistem *screening* otomatis yang efektif guna memecahkan masalah pengenalan pola medis tersebut [3]. Varian *Dense Convolutional Network* (DenseNet), khususnya DenseNet-169, dilaporkan mampu mencatatkan nilai presisi klasifikasi yang unggul karena kemampuannya memaksimalkan penggunaan ulang fitur (*feature reuse*) dan mengatasi masalah kehilangan gradien pada pelatihan jaringan yang dalam [4]. Meskipun memiliki fondasi yang kuat, model *Convolutional Neural Network* (CNN) standar masih berpotensi mempelajari informasi yang kurang relevan karena karakteristik

penyakit pada citra X-ray dada umumnya hanya muncul pada area tertentu, sedangkan sebagian besar citra didominasi oleh area non-lesi. Alam et al. [5] menyatakan bahwa area terinfeksi pada citra X-ray dada umumnya hanya menempati sebagian kecil dari keseluruhan citra, sementara metode CNN yang ada masih memiliki keterbatasan dalam memfokuskan perhatian pada informasi kritis yang dibutuhkan untuk klasifikasi multi-kelas. Hal ini menunjukkan bahwa arsitektur CNN yang dalam saja belum cukup untuk memastikan model berfokus pada fitur yang merepresentasikan karakteristik penyakit. Oleh karena itu, diperlukan mekanisme tambahan yang mampu mengarahkan perhatian model pada area citra yang lebih relevan.

Integrasi mekanisme atensi (*attention mechanism*) diperlukan untuk mengatasi keterbatasan model dasar dalam mengekstraksi fitur yang relevan. Mekanisme ini bekerja dengan memberikan bobot yang lebih besar pada fitur-fitur penting dan mengurangi pengaruh informasi yang kurang relevan sehingga representasi fitur yang dihasilkan menjadi lebih efektif [6,7]. Penerapan mekanisme atensi ganda (*dual attention mechanism*) menjadi salah satu pendekatan yang digunakan dalam analisis citra medis dengan menggabungkan atensi kanal dan atensi spasial untuk meningkatkan representasi fitur serta menyoroti area yang relevan pada citra [8,9].


Penelitian sebelumnya dari Chen et al. [10] mengembangkan *Dual Attention Network* (CXRDANet) yang mengintegrasikan *Channel Attention Module* (CAM) dan *Spatial Attention Module* (SAM) pada DenseNet-121 untuk identifikasi *cardiomegaly* pada citra X-ray dada. Model tersebut mencapai akurasi 90,50% dan AUC 0,9588 serta menunjukkan kemampuan yang baik dalam menyoroti area lesi yang relevan. Penerapan mekanisme atensi pada arsitektur DenseNet juga telah dilakukan oleh Daulay et al. [11] melalui integrasi *Squeeze-and-Excitation* (SE) *Attention* pada DenseNet-169 untuk klasifikasi multi-kelas citra X-ray dada dengan kelas Normal, COVID-19, dan Pneumonia. Penelitian tersebut menunjukkan peningkatan akurasi dari 95,8% pada DenseNet-169 *baseline* menjadi 96,5% setelah ditambahkan SE *Attention*, sehingga membuktikan bahwa mekanisme atensi dapat membantu model menekankan fitur penting pada citra X-ray dada. Penelitian lain juga telah menerapkan mekanisme atensi pada berbagai tugas analisis citra X-ray dada, seperti klasifikasi pneumoconiosis berbasis Xception [5], serta deteksi dan klasifikasi multi-label penyakit toraks [8,12]. Meskipun menunjukkan hasil yang baik, sebagian penelitian tersebut masih berfokus pada klasifikasi biner, penggunaan mekanisme atensi tertentu, deteksi lesi, atau menggunakan arsitektur yang lebih kompleks melalui kombinasi beberapa *backbone*. Selain itu, implementasi DANet pada arsitektur

DenseNet-169 untuk klasifikasi multi-kelas citra X-ray dada yang terdiri atas kelas COVID-19, normal, dan pneumonia masih jarang ditemukan. Oleh karena itu, penelitian ini mengintegrasikan DANet pada DenseNet-169 dan mengevaluasi pengaruhnya terhadap performa klasifikasi citra COVID-19, pneumonia, dan normal.

Berdasarkan *research gap* tersebut, penelitian ini mengintegrasikan arsitektur *Dual Attention Network* (DANet) ke dalam DenseNet-169 untuk klasifikasi multi-kelas citra X-ray dada yang terdiri atas kelas COVID-19, normal, dan pneumonia. Integrasi DANet dilakukan dengan mengadaptasi *Grouped Channel Attention Module* (*Grouped CAM*) dan *Strip Spatial Attention Module* (*Strip SAM*) sebagaimana diusulkan oleh Chen et al. [10]. Mekanisme tersebut digunakan untuk membantu model menekankan informasi kanal dan spasial yang relevan pada citra X-ray dada. Berbeda dengan penelitian sebelumnya yang menerapkan mekanisme tersebut pada DenseNet-121 untuk klasifikasi biner *cardiomegaly*, penelitian ini mengimplementasikan arsitektur tersebut pada *backbone* DenseNet-169 untuk klasifikasi multi-kelas citra COVID-19, pneumonia, dan normal. Kontribusi mekanisme atensi dievaluasi melalui perbandingan dengan DenseNet-169 tanpa DANet sebagai model *baseline* menggunakan metrik akurasi, presisi, *recall*, F1-score, sensitivitas, spesifisitas, ROC-AUC, *confusion matrix*, serta visualisasi Grad-CAM untuk menganalisis interpretabilitas model.

2. Metode Penelitian

Rancangan penelitian digunakan untuk menggambarkan alur klasifikasi multi-kelas citra X-ray dada menggunakan DenseNet-169 *Baseline* dan DenseNet-169 yang diintegrasikan dengan DANet. Langkah penelitian meliputi pengumpulan dataset, pra-pemrosesan citra, pembagian data, pelatihan model, dan evaluasi performa model. Rancangan penelitian ditampilkan pada Gambar 1.




Gambar 1. Rancangan Penelitian

Berdasarkan Gambar 1, penelitian diawali dari pengumpulan dataset citra X-ray dada, kemudian dilanjutkan dengan pembagian data, pra-pemrosesan, augmentasi data, pelatihan dua skenario model, evaluasi performa model, dan kesimpulan dari hasil penelitian.

2.1. Dataset dan Pembagian Data

Dataset yang digunakan dalam penelitian ini adalah dataset bernama *Covid19-Pneumonia-Normal Chest X-Ray Images Dataset* yang diperoleh dari repositori publik Mendeley Data [13]. Dataset ini terdiri atas citra X-ray dada yang dikelompokkan ke dalam tiga kelas, yaitu COVID-19, normal, dan pneumonia. Jumlah keseluruhan data yang digunakan adalah 5.228 citra, dengan distribusi data yang terdiri atas 1.626 citra kelas normal, 1.626 citra kelas COVID-19, dan 1.976 citra kelas pneumonia. Contoh citra dari masing-masing kelas ditampilkan pada Gambar 2 untuk menunjukkan perbedaan karakteristik visual pada setiap kategori.



Gambar 2. Sampel Citra X-Ray Dada pada Kelas (a) Normal, (b) COVID-19, dan (c) Pneumonia

Proses pembagian data dilakukan dengan mengikuti rasio proporsional 80:20 [14], yaitu 80% digunakan sebagai data latih (*train*), dan 20% digunakan sebagai data uji (*test*). Pembagian ini bertujuan agar model dapat dilatih menggunakan sebagian besar data, sementara data uji digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra yang belum pernah dilihat selama proses pelatihan. Berdasarkan pembagian tersebut, diperoleh 4.182 citra data latih dan 1.046 citra data uji. Rincian jumlah data pada masing-masing kelas setelah proses pembagian ditampilkan pada Tabel 1.

Tabel 1. Uraian Dataset

Nama Kelas	Data Latih	Data Uji
Normal	1441	361
COVID-19	1301	325
Pneumonia	1440	360
Total	4182	1046

2.2. Pra-pemrosesan dan Data Augmentasi

Seluruh citra terlebih dahulu melalui tahap pra-pemrosesan sebelum digunakan dalam proses pelatihan model. Citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran masukan DenseNet-169 [15]. Selanjutnya, nilai intensitas piksel dinormalisasi ke rentang 0–1 dengan membagi setiap nilai piksel terhadap 255 [16]. Proses ini diikuti dengan normalisasi berbasis nilai rata-rata (*mean*) dan standar deviasi dari dataset ImageNet guna memastikan konsistensi fitur dengan bobot *pre-trained* yang digunakan dalam model [10]. Proses ini bertujuan untuk meningkatkan stabilitas pelatihan serta mempercepat proses konvergensi model.

Tahapan selanjutnya adalah penerapan augmentasi data pada data latih. Augmentasi data dilakukan untuk menambah variasi citra selama proses pelatihan. Teknik augmentasi seperti rotasi, zoom, dan pergeseran dimensi panjang dan lebar guna menghasilkan variasi visual yang lebih beragam tanpa menghilangkan makna patologis medis pada citra [17]. Pemilihan parameter augmentasi dilakukan dengan intensitas rendah karena augmentasi geometris pada citra X-ray dada perlu diterapkan secara hati-hati. Perubahan geometris yang terlalu besar dapat menghasilkan citra yang kurang realistis secara klinis dan berpotensi menambah *noise* pada proses pelatihan model [18]. Parameter augmentasi ditampilkan pada Tabel 2.

Tabel 2. Parameter Augmentasi Citra

Teknik Augmentasi	Nilai
Rotation Range	5
Zoom Range	0.03
Width Shift Range	0.03
Height Shift Range	0.05

2.3. Perancangan Arsitektur Model

Penelitian ini menggunakan arsitektur DenseNet-169 sebagai *backbone* ekstraksi fitur dengan pendekatan *transfer learning*. DenseNet-169 dipilih karena memiliki mekanisme *dense connectivity* yang memaksimalkan penggunaan ulang fitur antarlapisan dan membantu menjaga aliran gradien pada jaringan yang dalam [19]. Secara matematis, keluaran layer ke-(*l*) dapat dirumuskan pada Persamaan (1).


$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (1)$$

Pada Persamaan (1), x_l merupakan keluaran layer ke-*l*, H_l merupakan fungsi transformasi komposit seperti *Batch Normalization*, ReLU, dan *Convolution*, sedangkan $[x_0, x_1, \dots, x_{l-1}]$ merupakan penggabungan *feature map* dari seluruh layer sebelumnya.

Dalam implementasinya, DenseNet-169 dibangun menggunakan pendekatan *transfer learning* dengan bobot awal *pretrained* ImageNet. Bobot *pretrained* digunakan agar model memiliki representasi fitur awal sebelum disesuaikan dengan karakteristik citra X-ray dada. Pada tahap *fine-tuning*, sebagian lapisan akhir *backbone* dilatih kembali, sedangkan lapisan *Batch Normalization* tidak diperbarui. Hal ini dilakukan untuk menjaga kestabilan nilai normalisasi internal yang telah dipelajari dari bobot *pretrained*, terutama ketika model dilatih pada dataset target dengan jumlah data yang lebih terbatas [20].

Berdasarkan mekanisme tersebut, penelitian ini menggunakan DenseNet-169 sebagai arsitektur *baseline*. Pada model *baseline*, citra X-ray dada yang telah melalui tahap pra-pemrosesan digunakan sebagai masukan ke *backbone* DenseNet-169. *Feature map* yang dihasilkan dari *backbone* kemudian direduksi

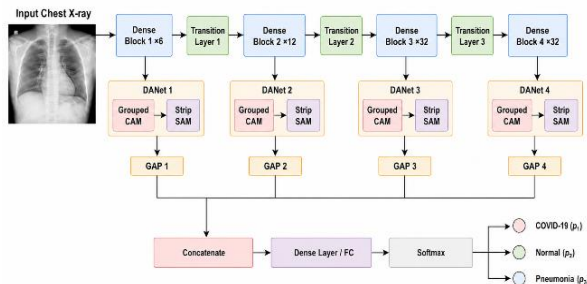
menggunakan *Global Average Pooling* (GAP), dilanjutkan dengan lapisan *fully connected* (FC), dan lapisan softmax untuk menghasilkan probabilitas tiga kelas, yaitu COVID-19, normal, dan pneumonia. Arsitektur DenseNet-169 *baseline* ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur DenseNet-169 baseline untuk klasifikasi citra X-ray dada

Berdasarkan Gambar 3, model DenseNet-169 *baseline* digunakan sebagai model pembandingan tanpa penambahan mekanisme atensi. Pada model ini, proses klasifikasi hanya memanfaatkan *feature map* akhir dari *backbone* DenseNet-169 yang direduksi menggunakan *Global Average Pooling* sebelum diteruskan ke lapisan *fully connected* dan *softmax*. Dengan demikian, *baseline* digunakan sebagai acuan untuk menilai pengaruh penambahan DANet terhadap performa klasifikasi.

Selanjutnya, arsitektur *baseline* dimodifikasi dengan menambahkan *Dual Attention Network* (DANet) yang mengadaptasi konsep dari Chen et al. [10] pada keluaran setiap *dense block* utama. Berbeda dengan *baseline* yang hanya menggunakan *feature map* akhir dari *backbone*, model DenseNet-169 dengan DANet memanfaatkan *feature map* dari setiap *dense block* yang telah diperkuat melalui mekanisme atensi. Modul DANet terdiri atas *Grouped Channel Attention Module* (*Grouped CAM*) dan *Strip Spatial Attention Module* (*Strip SAM*). Arsitektur DenseNet-169 dengan penerapan DANet ditunjukkan pada Gambar 4.



Gambar 4. Arsitektur Model DenseNet-169 dengan penerapan DANet pada setiap dense block utama

Berdasarkan Gambar 4, modul DANet diterapkan pada keluaran *dense block* pertama, kedua, ketiga, dan keempat. Setiap *feature map* hasil *dense block* terlebih dahulu diproyeksikan menggunakan *convolution layer* untuk menyeragamkan jumlah kanal, kemudian diproses secara berurutan melalui *Grouped Channel Attention Module* (*Grouped CAM*) dan *Strip Spatial Attention Module* (*Strip SAM*). Setelah melalui modul

DANet, *feature map* dari masing-masing *dense block* direduksi menggunakan *Global Average Pooling* (GAP). Hasil *pooling* dari setiap blok kemudian digabungkan melalui operasi *concatenation* dan diteruskan ke *fully connected layer* untuk menghasilkan probabilitas tiga kelas, yaitu COVID-19, normal, dan pneumonia. Untuk memperjelas tahapan pemrosesan pada arsitektur yang diusulkan, alur kerja model disajikan pada Algoritma 1.

Algoritma 1. DenseNet-169 dengan DANet

```

Input: Citra X-ray dada I
Output: Probabilitas kelas y
Initialization:
Load DenseNet-169 pretrained ImageNet
Define Grouped CAM, Strip SAM
Define GAP, Concatenate, FC, and Softmax
Get I
I ← Resize(I, 224 × 224)
I ← PreprocessInput(I)

F1 ← output DenseBlock1
F2 ← output DenseBlock2
F3 ← output DenseBlock3
F4 ← output DenseBlock4

for each Fi in {F1, F2, F3, F4} do
  Fi ← Conv2D(Fi)
  Fi ← BatchNormalization(Fi)

  Fi ← GroupedCAM(Fi)
  Fi ← Conv2D(Fi)

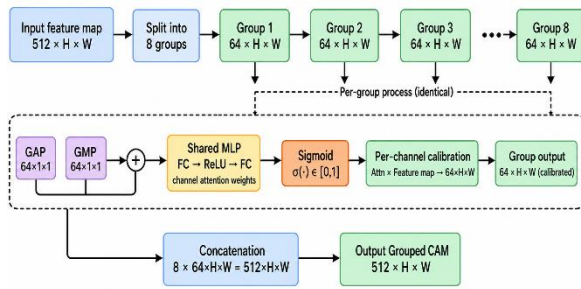
  Fi ← StripSAM(Fi)
  Fi ← Conv2D(Fi)
  Fi ← BatchNormalization(Fi)
  Fi ← ReLU(Fi)

  Pi ← GAP(Fi)
end for

F ← Concatenate(P1, P2, P3, P4)
F ← Dense(F)
F ← Dropout(F)
y ← Softmax(F)

Return y
  
```

Berdasarkan Algoritma 1, proses utama model terdiri atas tiga tahap, yaitu ekstraksi fitur menggunakan DenseNet-169, penerapan atensi menggunakan DANet pada keluaran setiap *dense block*, dan penggabungan fitur sebelum klasifikasi. Algoritma tersebut menunjukkan bahwa fitur dari setiap blok tidak langsung diklasifikasikan secara terpisah, tetapi terlebih dahulu diperkuat melalui *Grouped CAM* dan *Strip SAM*, kemudian direduksi menggunakan *Global Average Pooling*, digabungkan melalui *concatenation*, dan diteruskan ke lapisan klasifikasi akhir. Proses pemberian atensi pada modul DANet dilakukan melalui dua komponen utama, yaitu *Grouped Channel Attention Module* dan *Strip Spatial Attention Module*. Komponen pertama, yaitu *Grouped Channel Attention Module*, digunakan untuk memberikan penekanan pada kanal fitur yang memiliki kontribusi penting terhadap proses klasifikasi. Struktur *Grouped Channel Attention Module* ditunjukkan pada Gambar 5.




Gambar 5. Struktur *Grouped Channel Attention Module*

Berdasarkan Gambar 5, *feature map* masukan pada *Grouped Channel Attention Module* memiliki ukuran $512 \times H \times W$. *Feature map* tersebut terlebih dahulu dibagi menjadi 8 grup kanal, sehingga setiap grup memiliki ukuran $64 \times H \times W$. Pada masing-masing grup, informasi kanal diekstraksi menggunakan *Global Average Pooling* (GAP) dan *Global Max Pooling* (GMP). Kedua hasil *pooling* tersebut kemudian diproses melalui *shared multilayer perceptron* (MLP) yang terdiri atas lapisan *fully connected* untuk menghasilkan bobot atensi kanal. Bobot atensi yang diperoleh selanjutnya diaktifkan menggunakan fungsi *sigmoid* dan digunakan untuk kalibrasi *feature map* pada setiap grup melalui operasi perkalian elemen. Setelah seluruh grup dikalibrasi, hasil dari masing-masing grup digabungkan kembali melalui operasi *concatenation* pada dimensi kanal sehingga menghasilkan keluaran *Grouped CAM* berukuran $512 \times H \times W$. Keluaran tersebut kemudian diteruskan ke lapisan konvolusi 3×3 pada tahap berikutnya dalam modul DANet. Proses *channel attention* secara umum dirumuskan pada Persamaan (2).

$$F'_g = F_g \otimes M_c \quad (2)$$

Pada Persamaan (2), F_g merupakan *feature map* masukan grup ke- g , M_c merupakan bobot atensi kanal, \otimes menyatakan perkalian *element-wise*, dan F'_g merupakan *feature map* keluaran setelah proses pembobotan kanal. Seluruh *feature map* hasil pembobotan kanal dari setiap grup kemudian digabungkan kembali untuk membentuk *feature map* hasil *Grouped CAM* (F_{CAM}).

Selanjutnya, *feature map* hasil *Grouped CAM* diproses menggunakan *Strip Spatial Attention Module* (*Strip SAM*) untuk memberikan penekanan pada informasi spasial yang relevan. Berbeda dengan *channel attention* yang berfokus pada hubungan antar kanal fitur, *Strip SAM* berfokus pada pembentukan peta atensi spasial dengan memanfaatkan informasi arah horizontal dan vertikal pada *feature map*. Struktur *Strip SAM* ditunjukkan pada Gambar 6.



Gambar 6. Struktur *Strip Spatial Attention Module*

Berdasarkan Gambar 6, *feature map* hasil *Grouped CAM* diproses melalui dua jalur, yaitu jalur horizontal dan jalur vertikal. Pada jalur horizontal, dilakukan proses *average pooling* sepanjang dimensi lebar untuk memperoleh representasi spasial berukuran $512 \times H \times 1$. Sementara itu, pada jalur vertikal dilakukan proses *average pooling* sepanjang dimensi tinggi untuk memperoleh representasi berukuran $512 \times 1 \times W$. Kedua representasi tersebut kemudian diproses menggunakan konvolusi 1×1 lalu diperluas kembali ke ukuran semula $512 \times H \times W$. Hasil dari kedua jalur tersebut kemudian digabungkan melalui operasi *add/fuse* dan diproses menggunakan konvolusi 1×1 dengan fungsi aktivasi *sigmoid* untuk menghasilkan *spatial attention map*. Peta atensi spasial tersebut digunakan untuk memberikan bobot pada *feature map* masukan melalui operasi perkalian *element-wise*, sehingga diperoleh *feature map* hasil *Grouped CAM* melalui operasi perkalian *element-wise*, sehingga diperoleh *feature map* keluaran DANet yang telah diperkuat secara spasial. Proses *spatial attention* dirumuskan pada Persamaan 3.

$$F_{DANET} = F_{CAM} \otimes M_s \quad (3)$$

Pada Persamaan (3), M_s merupakan *spatial attention map*, sedangkan F_{DANET} merupakan *feature map* akhir setelah melalui modul DANet. Perkalian antara F_{CAM} dan M_s membuat model lebih fokus pada area spasial yang relevan terhadap proses klasifikasi.

Feature map dari setiap *dense block* yang telah melalui DANet kemudian direduksi menggunakan *Global Average Pooling*. Hasil *pooling* dari keempat *dense block* digabungkan melalui operasi *concatenation* untuk membentuk representasi fitur akhir yang mengandung informasi dari seluruh *dense block*. Representasi fitur tersebut selanjutnya diteruskan ke *dense layer*, *dropout*, dan lapisan *output softmax* untuk menghasilkan probabilitas tiga kelas, yaitu COVID-19, normal, dan pneumonia.

2.4. Evaluasi Model

Proses evaluasi dilakukan menggunakan beberapa metrik, yaitu akurasi, presisi, recall, F1-score, *confusion matrix*, *specificity*, *sensitivity*, ROC-AUC, serta visualisasi Grad-CAM. *Confusion matrix* digunakan untuk merepresentasikan jumlah prediksi benar dan salah yang dihasilkan oleh model pada setiap kelas [21]. Struktur *confusion matrix* dapat dilihat pada Tabel 3.

Tabel 3. Confusion Matrix

	Prediksi Negatif	Prediksi Positif
Aktual Negatif	True Negative (TN)	False Positive (FP)
Aktual Positif	False Negative (FN)	True Positive (TP)

Evaluasi dengan *confusion matrix* menghasilkan beberapa metrik pengukuran, yaitu akurasi, presisi, F1-score, *recall*/sensitivitas, dan spesifisitas. Selain itu, ROC-AUC digunakan untuk mengukur kemampuan diskriminasi model, sedangkan Grad-CAM digunakan untuk menginterpretasikan area citra yang menjadi fokus model dalam proses klasifikasi.

Akurasi merupakan metrik yang menampilkan perbandingan antara jumlah prediksi benar dengan total keseluruhan data yang diuji. Nilai akurasi dihitung menggunakan Persamaan (4) [21].

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

Presisi merupakan rasio antara jumlah prediksi positif yang benar dengan seluruh data yang diprediksi sebagai positif. Nilai presisi dihitung menggunakan Persamaan (5) [22].

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

Recall atau sensitivitas merupakan metrik yang menunjukkan jumlah data positif yang berhasil dikenali dengan benar dari seluruh data aktual positif. Nilai *recall* atau sensitivitas dihitung menggunakan Persamaan (6) [22,23].

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

F1-Score merupakan rata-rata harmonik antara presisi dan *recall*. Metrik ini digunakan untuk menilai keseimbangan antara ketepatan prediksi positif dan kemampuan model dalam mengenali data positif. Nilai F1-score dihitung menggunakan Persamaan (7) [22].

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (7)$$

Spesifisitas merupakan metrik yang menunjukkan kemampuan model dalam mengenali data negatif secara benar. Metrik ini digunakan untuk melihat kemampuan model dalam menghindari kesalahan saat mengklasifikasikan kelas lain sebagai kelas tertentu. Nilai spesifisitas dihitung menggunakan Persamaan (8) [22].

$$Specificity = \frac{TN}{TN+FP} \quad (8)$$

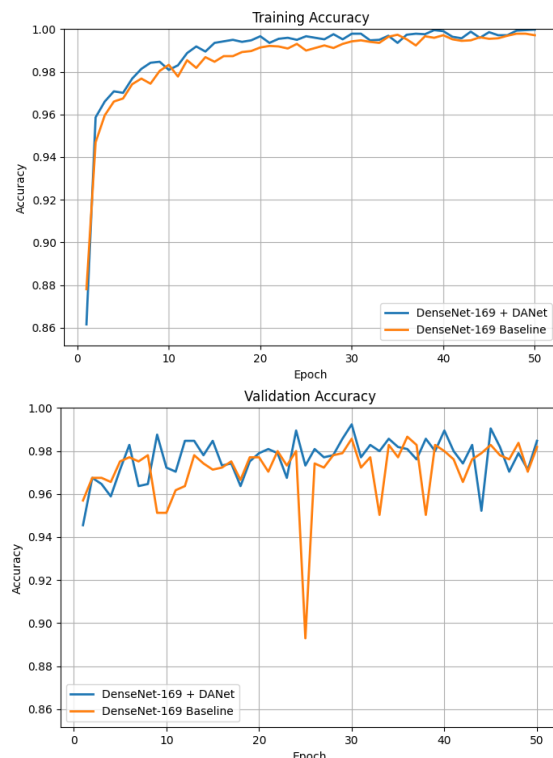
Selain metrik berbasis *confusion matrix*, penelitian ini juga menggunakan *Receiver Operating Characteristic-Area Under Curve* (ROC-AUC) untuk mengevaluasi kemampuan model dalam membedakan setiap kelas. Nilai AUC berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan kemampuan diskriminasi model yang semakin baik [24].

Penelitian ini menggunakan *Gradient-weighted Class Activation Mapping* (Grad-CAM) untuk menampilkan area citra yang berkontribusi terhadap prediksi model. Metode ini menghasilkan peta panas (*heatmap*) yang memvisualisasikan area citra yang memberikan kontribusi terbesar terhadap prediksi model [25]. Visualisasi ini digunakan sebagai analisis pendukung untuk melihat area fokus model, bukan sebagai dasar penentuan diagnosis penyakit.

3. Hasil dan Pembahasan

3.1. Hasil Pelatihan Model

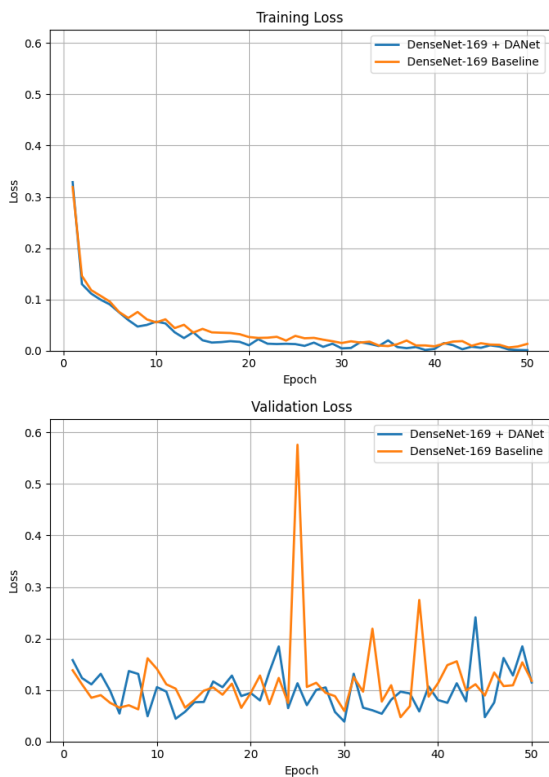
Pada penelitian ini, pelatihan dilakukan pada dua skenario model, yaitu DenseNet-169 *Baseline* dan DenseNet-169 diintegrasikan dengan DANet. Kedua model dilatih selama 50 *epoch* dengan fungsi *loss categorical cross-entropy* dan *optimizer Adam* menggunakan *learning rate* 0,0001. Proses pelatihan bertujuan agar model mampu mempelajari pola citra X-ray dada pada tiga kelas, yaitu COVID-19, normal, dan pneumonia, sekaligus meminimalkan nilai *loss* sebagai ukuran kesalahan prediksi. Hasil pelatihan model DenseNet-169 *Baseline* dan DenseNet-169 dengan DANet ditampilkan melalui grafik *training* dan *validation accuracy* pada Gambar 4.



Gambar 7. Grafik Training dan Validation Accuracy DenseNet-169 Baseline dan DenseNet-169 dengan DANet

Berdasarkan Gambar 7, *training accuracy* kedua model meningkat secara cepat pada beberapa *epoch* awal dan kemudian stabil mendekati nilai 1,00. Hal ini

menunjukkan bahwa DenseNet-169 *baseline* dan DenseNet-169 dengan DANet mampu mempelajari pola data latih dengan baik. Pada *validation accuracy*, kedua model juga memperoleh nilai yang tinggi meskipun terdapat fluktuasi pada beberapa *epoch*. Model DenseNet-169 dengan DANet menunjukkan performa validasi yang relatif stabil dan kompetitif terhadap model *baseline*. Secara umum, hasil ini menunjukkan bahwa kedua model memiliki kemampuan generalisasi yang baik pada data validasi. Selanjutnya, Hasil pelatihan model DenseNet-169 *Baseline* dan DenseNet-169 dengan DANet ditampilkan melalui grafik *training* dan *validation loss* pada Gambar 8.



Gambar 8. Grafik *Training* dan *Validation Loss* DenseNet-169 *Baseline* dan DenseNet-169 dengan DANet

Berdasarkan Gambar 8, *training loss* kedua model mengalami penurunan tajam pada beberapa *epoch* awal dan kemudian cenderung stabil pada nilai rendah hingga akhir pelatihan. Hal ini menunjukkan bahwa DenseNet-169 *baseline* maupun DenseNet-169 dengan DANet mampu mempelajari pola data latih dengan baik. Pada *validation loss*, kedua model menunjukkan nilai yang relatif rendah meskipun terdapat fluktuasi pada beberapa *epoch*. Model *baseline* sempat mengalami lonjakan *loss* yang cukup tinggi, namun kembali menurun pada *epoch* berikutnya. Secara umum, hasil ini menunjukkan bahwa kedua model memiliki proses pelatihan yang baik dan mampu

mempertahankan performa validasi hingga akhir pelatihan.

3.2. Hasil Klasifikasi Model

Setelah pelatihan selesai, kedua model dievaluasi menggunakan 1.046 citra data *testing*. Evaluasi dilakukan menggunakan akurasi, presisi, *recall*, F1-score, sensitivitas, dan spesifisitas. Hasil evaluasi kedua model ditampilkan pada Tabel 4.

Tabel 4. Perbandingan Performa Model

Metrics	DenseNet-169 Baseline	DenseNet-169 + DANet
Accuracy	98,18%	98,47%
Precision	98,25%	98,55%
Recall	98,22%	98,50%
F1-score	98,21%	98,50%
Sensitivity	98,22%	98,50%
Specificity	99,09%	99,22%

Berdasarkan Tabel 4, model DenseNet-169 dengan DANet menunjukkan peningkatan performa dibandingkan DenseNet-169 *baseline* pada seluruh metrik evaluasi. Nilai akurasi meningkat dari 98,18% menjadi 98,47%. Metrik presisi juga meningkat dari 98,25% menjadi 98,55%, sedangkan *recall* dan sensitivitas meningkat dari 98,22% menjadi 98,50%. Selain itu, F1-score mengalami peningkatan dari 98,21% menjadi 98,50%, dan spesifisitas meningkat dari 99,09% menjadi 99,22%. Hasil ini menunjukkan bahwa integrasi DANet mampu meningkatkan kemampuan model dalam melakukan klasifikasi citra X-ray dada secara lebih konsisten dibandingkan model *baseline*.


Peningkatan akurasi yang diperoleh relatif kecil, yaitu sebesar 0,29%. Namun, hasil tersebut tetap menunjukkan adanya kontribusi positif dari integrasi DANet terhadap performa model. Peningkatan yang tidak terlalu besar dapat dipahami karena DenseNet-169 *baseline* telah memiliki performa awal yang sangat tinggi, yaitu 98,18%, sehingga ruang peningkatan performa menjadi lebih terbatas. Oleh karena itu, kontribusi DANet tidak hanya dilihat dari peningkatan akurasi secara keseluruhan, tetapi juga dari peningkatan metrik lain seperti presisi, *recall*, F1-score, sensitivitas, dan spesifisitas yang seluruhnya mengalami kenaikan.

Jika dibandingkan dengan penelitian terdahulu yang relevan, hasil penelitian ini menunjukkan performa yang kompetitif. Chen et al. [10] menerapkan DenseNet-121 dengan kombinasi *Channel Attention Module* dan *Spatial Attention Module* untuk identifikasi *cardiomegaly* pada citra X-ray dada dan memperoleh akurasi 90,50%, sensitivitas 94,45%, spesifisitas 86,10%, dan F1-score 90,59%. Daulay et al. [11] menerapkan *SE Attention* pada DenseNet-169 untuk klasifikasi multi-kelas Normal, COVID-19, dan

Pneumonia, dengan memperoleh akurasi 96,5%, presisi 96,60%, recall 96,50%, dan F1-score 96,50%, lebih tinggi dibandingkan DenseNet-169 *baseline* yang memperoleh akurasi 95,8%. Sementara itu, penelitian ini memperoleh akurasi 98,47%, presisi 98,55%, *recall*/sensitivitas 98,50%, F1-score 98,50%, dan spesifisitas 99,22%.

Perbandingan dengan penelitian terdahulu digunakan untuk menunjukkan posisi dan relevansi hasil penelitian yang diusulkan, mengingat setiap penelitian memiliki karakteristik dataset, jumlah kelas, dan skenario eksperimen yang berbeda. Hasil tersebut menunjukkan bahwa DenseNet-169 dengan DANet memiliki performa yang baik dalam klasifikasi multi-kelas citra X-ray dada. Selain itu, berbeda dari penelitian Chen et al. dan Daulay et al., penelitian ini mengintegrasikan DANet pada DenseNet-169 dengan kombinasi atensi kanal dan spasial untuk klasifikasi tiga kelas, yaitu COVID-19, normal, dan pneumonia.

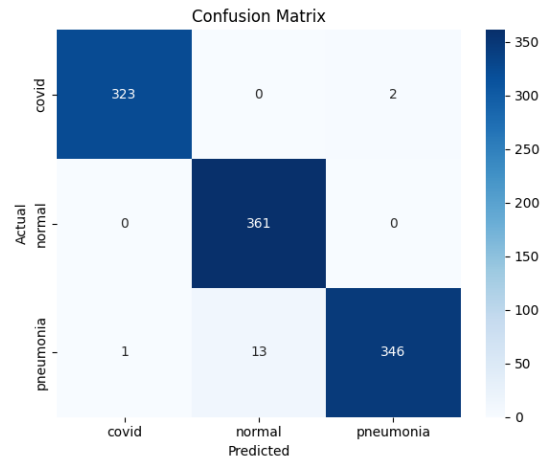
Evaluasi berikutnya menggunakan *confusion matrix* untuk melihat sebaran prediksi yang benar dan salah pada setiap kelas. *Confusion matrix* model DenseNet-169 *Baseline* ditampilkan pada Gambar 9.



Gambar 9. Gambar Confusion Matrix DenseNet-169 Baseline

Berdasarkan Gambar 9, model DenseNet-169 *baseline* mampu mengklasifikasikan sebagian besar citra dengan benar, ditunjukkan oleh nilai dominan pada diagonal utama *confusion matrix*. Model berhasil mengklasifikasikan 323 citra COVID-19, 360 citra normal, dan 344 citra pneumonia dengan benar. Kesalahan klasifikasi masih terjadi pada beberapa sampel, yaitu 1 citra COVID-19 diprediksi sebagai normal, 1 citra COVID-19 diprediksi sebagai pneumonia, 1 citra normal diprediksi sebagai COVID-19, serta 16 citra pneumonia salah diklasifikasikan sebagai COVID-19 dan normal. Kesalahan terbesar terjadi pada kelas pneumonia yang diprediksi sebagai normal sebanyak 13 citra. Hasil ini menunjukkan bahwa model *baseline* memiliki kemampuan klasifikasi yang baik, meskipun masih terdapat

kesulitan dalam membedakan sebagian citra pneumonia dengan kelas normal. Selanjutnya *Confusion matrix* model DenseNet-169 dan DANet ditampilkan pada Gambar 10.




Gambar 10. Gambar Confusion Matrix DenseNet-169 dengan DANet

Berdasarkan Gambar 10, model DenseNet-169 dengan DANet mampu mengklasifikasikan sebagian besar citra dengan benar, yang ditunjukkan oleh nilai dominan pada diagonal utama *confusion matrix*. Model berhasil mengklasifikasikan 323 citra COVID-19, 361 citra normal, dan 346 citra pneumonia dengan benar. Kesalahan klasifikasi masih terjadi pada beberapa sampel, yaitu 2 citra COVID-19 diprediksi sebagai pneumonia, 1 citra pneumonia diprediksi sebagai COVID-19, dan 13 citra pneumonia diprediksi sebagai normal. Pada kelas normal, seluruh citra berhasil diklasifikasikan dengan benar tanpa kesalahan prediksi.

Jika dibandingkan dengan model DenseNet-169 *baseline*, model *baseline* menghasilkan 1.027 prediksi benar dari 1.046 data uji, sedangkan model DenseNet-169 dengan DANet menghasilkan 1.030 prediksi benar. Dengan demikian, jumlah kesalahan klasifikasi berkurang dari 19 citra menjadi 16 citra. Peningkatan ini terlihat terutama pada kelas normal dan pneumonia, di mana seluruh citra normal berhasil diklasifikasikan dengan benar pada model dengan DANet, serta jumlah prediksi benar pada kelas pneumonia meningkat dari 344 menjadi 346 citra. Hal ini menunjukkan bahwa integrasi DANet dapat membantu model memperbaiki sebagian kesalahan klasifikasi, terutama pada kelas yang memiliki kemiripan visual dengan kelas lain.

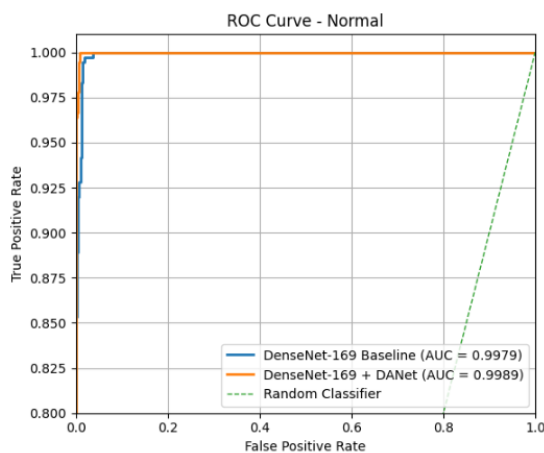
3.3. Evaluasi ROC-AUC

Kurva ROC-AUC kelas COVID-19 model DenseNet-169 *Baseline* dan DenseNet-169 dengan DANet ditampilkan pada Gambar 11.



Gambar 11. Gambar Kurva ROC-AUC Kelas COVID-19 DenseNet-169 Baseline dan DenseNet-169 dengan DANet

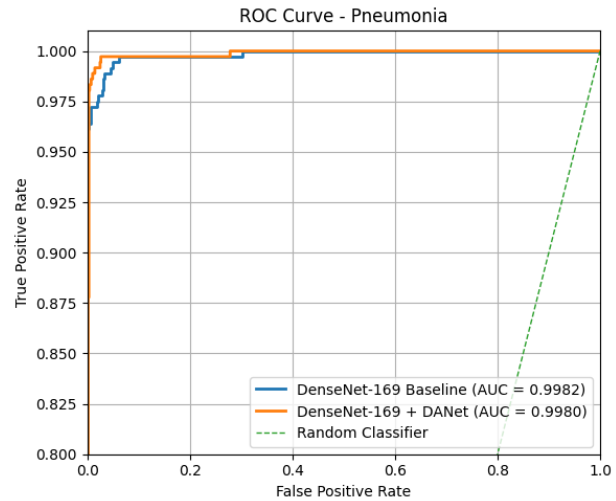
Berdasarkan Gambar 11, kurva ROC pada kelas COVID-19 menunjukkan bahwa kedua model memiliki kemampuan diskriminasi yang sangat baik. Hal ini terlihat dari kurva ROC yang berada dekat dengan sudut kiri atas grafik dan nilai AUC yang mendekati 1,00. Model DenseNet-169 *baseline* memperoleh nilai AUC sebesar 0,9999, sedangkan DenseNet-169 dengan DANet memperoleh nilai AUC sebesar 0,9994. Hasil ini menunjukkan bahwa kedua model mampu membedakan citra COVID-19 dari kelas lainnya dengan sangat baik, meskipun nilai AUC model *baseline* sedikit lebih tinggi pada kelas ini. Selanjutnya kurva ROC-AUC kelas normal model DenseNet-169 *baseline* dan DenseNet-169 dengan DANet ditampilkan pada Gambar 12.



Gambar 12. Gambar Kurva ROC-AUC Kelas Normal DenseNet-169 Baseline dan DenseNet-169 dengan DANet

Berdasarkan Gambar 12, kurva ROC pada kelas normal menunjukkan bahwa kedua model memiliki kemampuan diskriminasi yang sangat baik, ditunjukkan oleh kurva yang berada dekat dengan sudut kiri atas grafik. Model DenseNet-169 *baseline* memperoleh nilai AUC sebesar 0,9979, sedangkan

DenseNet-169 dengan DANet memperoleh nilai AUC sebesar 0,9989. Nilai AUC yang lebih tinggi pada model DenseNet-169 dengan DANet menunjukkan bahwa penambahan DANet mampu meningkatkan kemampuan model dalam membedakan kelas normal dari kelas lainnya. Selanjutnya kurva ROC-AUC kelas pneumonia model DenseNet-169 *baseline* dan DenseNet-169 dengan DANet ditampilkan pada Gambar 13.



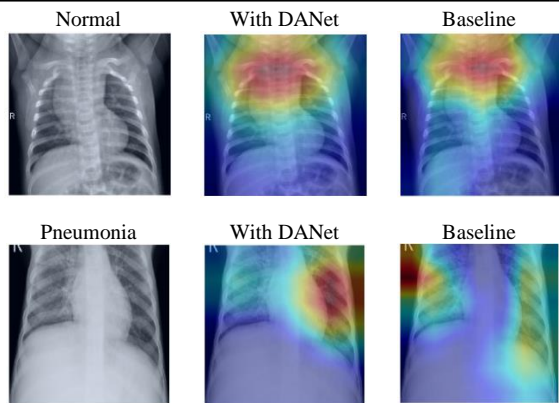
Gambar 13. Gambar Kurva ROC-AUC Kelas Pneumonia DenseNet-169 Baseline dan DenseNet-169 dengan DANet

Berdasarkan Gambar 13, kurva ROC pada kelas pneumonia menunjukkan bahwa kedua model memiliki kemampuan diskriminasi yang sangat baik, ditandai dengan kurva yang berada dekat dengan sudut kiri atas grafik. Model DenseNet-169 *baseline* memperoleh nilai AUC sebesar 0,9982, sedangkan DenseNet-169 dengan DANet memperoleh nilai AUC sebesar 0,9980. Meskipun nilai AUC model *baseline* sedikit lebih tinggi, perbedaan keduanya sangat kecil sehingga kedua model tetap menunjukkan performa yang hampir setara dalam membedakan kelas pneumonia dari kelas lainnya.

3.4. Visualisasi Grad-CAM

Hasil visualisasi Grad-CAM dari model DenseNet-169 *baseline* dan DenseNet-169 dengan DANet ditampilkan pada Gambar 14.





Gambar 14. Gambar Hasil Visualisasi Grad-CAM DenseNet-169 Baseline dan DenseNet-169 dengan DANet

Berdasarkan Gambar 14, visualisasi Grad-CAM menunjukkan bahwa model DenseNet-169 dengan DANet dan DenseNet-169 *baseline* sama-sama memberikan perhatian pada area paru-paru yang relevan terhadap proses klasifikasi. Pada kelas COVID-19 dan normal, pola aktivasi kedua model terlihat relatif mirip, meskipun model dengan DANet menunjukkan area perhatian yang sedikit lebih terkonsentrasi. Perbedaan yang lebih jelas terlihat pada kelas pneumonia, di mana aktivasi model *baseline* tampak lebih menyebar, sedangkan model DenseNet-169 dengan DANet menunjukkan perhatian yang lebih terarah pada area tertentu. Hasil ini menunjukkan bahwa mekanisme DANet dapat membantu mengarahkan fokus model pada area visual yang lebih relevan, meskipun peningkatannya tidak terlihat sama besar pada seluruh kelas.

Hasil penelitian ini menunjukkan bahwa penerapan DANet pada DenseNet-169 mampu memberikan peningkatan performa pada klasifikasi multi-kelas citra X-ray dada yang terdiri atas kelas COVID-19, normal, dan pneumonia. Peningkatan terlihat pada seluruh metrik evaluasi, meskipun selisih performa terhadap model *baseline* tidak terlalu besar. Penelitian ini menunjukkan bahwa mekanisme atensi dapat membantu memperkuat representasi fitur pada DenseNet-169, khususnya melalui kombinasi atensi kanal dan atensi spasial. Selain itu, visualisasi Grad-CAM menunjukkan bahwa kedua model sama-sama menyoroti area paru-paru yang relevan, dengan model DenseNet-169 dengan DANet memperlihatkan area perhatian yang lebih terarah terutama pada kelas pneumonia.

4. Kesimpulan

Penelitian ini mengintegrasikan *Dual Attention Network* (DANet) pada arsitektur DenseNet-169 untuk klasifikasi multi-kelas citra X-ray dada yang terdiri atas kelas COVID-19, normal, dan pneumonia. Hasil pengujian menunjukkan bahwa DenseNet-169 dengan DANet memberikan peningkatan performa

dibandingkan DenseNet-169 *baseline* pada seluruh metrik evaluasi. Model DenseNet-169 dengan DANet memperoleh akurasi sebesar 98,47%, presisi 98,55%, *recall* 98,50%, F1-score 98,50%, sensitivitas 98,50%, dan spesifisitas 99,22%. Nilai ROC-AUC pada setiap kelas juga mendekati 1,00, sehingga menunjukkan kemampuan diskriminasi model yang sangat baik. Visualisasi Grad-CAM menunjukkan bahwa kedua model sama-sama menyoroti area paru-paru yang relevan, dengan model DenseNet-169 dengan DANet memperlihatkan area perhatian yang lebih terarah terutama pada kelas pneumonia. Dengan demikian, integrasi DANet dapat membantu meningkatkan representasi fitur melalui kombinasi atensi kanal dan spasial, meskipun peningkatan performa terhadap model *baseline* tidak terlalu besar. Penelitian selanjutnya dapat difokuskan pada peningkatan nilai ROC-AUC, khususnya pada kelas COVID-19 dan pneumonia yang masih sedikit lebih rendah dibandingkan *baseline*, serta optimasi arsitektur dan parameter pelatihan agar model lebih baik dalam membedakan citra pneumonia dan normal.

Daftar Rujukan

- [1] D. M. Ibrahim, N. M. Elshennawy, and A. M. Sarhan, "Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases," *Computers in Biology and Medicine*, vol. 132, Art. no. 104348, Jan. 2021, <https://doi.org/10.1016/j.compbio.2021.104348>
- [2] G. M. M. Alshmrani, Q. Ni, R. Jiang, H. Pervaiz, and N. M. Elshennawy, "A deep learning architecture for multi-class lung diseases classification using chest X-ray (CXR) images," *Alexandria Engineering Journal*, vol. 64, pp. 923–935, Feb. 2023, <https://doi.org/10.1016/j.aej.2022.10.053>
- [3] S. Kim, B. Rim, S. Choi, A. Lee, S. Min, and M. Hong, "Deep Learning in Multi-Class Lung Diseases' Classification on Chest X-ray Images," *Diagnostics*, vol. 12, no. 4, Art. no. 915, Apr. 2022, <https://doi.org/10.3390/diagnostics12040915>
- [4] S. Katreddi, A. Midatani, A. P. Roy, U. Velpuri, and S. Kasani, "Pediatric pneumonia X-ray image classification: predictive model development with DenseNet-169 transfer learning," *Journal of Medical Artificial Intelligence*, vol. 8, Art. no. 37, Apr. 2025, <https://doi.org/10.21037/jmai-24-356>
- [5] Md. S. Alam, D. Wang, and A. Sowmya, "DLA Net: dual lesion attention network for classification of pneumoconiosis using chest X ray images," *Scientific Reports*, vol. 14, Art. no. 11616, May 2024 doi: <https://doi.org/10.1038/s41598-024-61024-3>
- [6] D. Li, "Attention-enhanced architecture for improved pneumonia detection in chest X-ray images," *BMC Medical Imaging*, vol. 24, no. 1, Art. no. 6, Jan. 2024, <https://doi.org/10.1186/s12880-023-01177-1>
- [7] X. Li et al., "Deep Learning Attention Mechanism in Medical Image Analysis: Basics and Beyonds," *International Journal of Network Dynamics and Intelligence*, vol. 2, no. 1, pp. 93–116, Mar. 2023 <https://doi.org/10.53941/ijndi0201006>
- [8] Q. Xu and W. Duan, "DualAttNet: Synergistic fusion of image-level and fine-grained disease attention for multi-label lesion detection in chest X-rays," *Computers in Biology and Medicine*, vol. 168, Art. no. 107742, Jan. 2024, <https://doi.org/10.1016/j.compbio.2023.107742>

- [9] J. Zhang, X. Chen, B. Yang, Q. Guan, Q. Chen, J. Chen, Q. Wu, Y. Xie, and Y. Xia, "Advances in attention mechanisms for medical image segmentation," *Computer Science Review*, vol. 56, Art. no. 100721, May 2025, <https://doi.org/10.1016/j.cosrev.2024.100721>
- [10] L. Chen, T. Mao, and Q. Zhang, "Identifying cardiomegaly in chest x-rays using dual attention network," *Applied Intelligence*, vol. 52, no. 10, pp. 11058–11067, Jul. 2022, <https://doi.org/10.1007/s10489-021-02935-w>
- [11] L. Z. Daulay, B. S. Negara, Y. Vitriani, I. Iskandar, and F. Kurnia, "Penerapan Squeeze-and-Excitation Attention pada DenseNet169 untuk Klasifikasi Multi-Kelas Citra X-Ray Dada: Squeeze-and-Excitation Attention on DenseNet169 for Multi-Class Classification of Chest X-Ray Images," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 6, no. 2, pp. 986–996, Apr. 2026, doi: 10.57152/malcom.v6i2.2665.
- [12] L. A. Gonçalves, G. B. Junior, M. L. L. Bessa, C. E. F. Matos, and A. G. S. Fernandes, "DualAttentionNet: A Convolutional Neural Network for Thoracic Disease Classification in Chest X-Rays," *Procedia Computer Science*, vol. 256, pp. 797–804, 2025, <https://doi.org/10.1016/j.procs.2025.02.181>
- [13] S. Kumar, "Covid19-Pneumonia-Normal Chest X-Ray Images," *Mendeley Data*, V1, 2022, doi: 10.17632/dvntn9yhd2.1. Accessed: Apr. 08, 2026. [Online]. Available: <https://data.mendeley.com/datasets/dvntn9yhd/1>
- [14] 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," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 2, pp. 331–339, 2024, <https://doi.org/10.14569/IJACSA.2024.0150235>
- [15] M. R. S. Sahri and Y. Azhar, "Klasifikasi pengemudi yang terdistraksi menggunakan DenseNet 169," *Jurnal Repositor*, vol. 7, no. 3, pp. 361–370, Aug. 2025, doi: 10.22219/repositor.v7i3.38353.
- [16] B. Oltu, S. Güney, S. E. Yuksel, and B. Dengiz, "Automated classification of chest X-rays: a deep learning approach with attention mechanisms," *BMC Medical Imaging*, vol. 25, no. 1, Art. no. 71, Mar. 2025, <https://doi.org/10.1186/s12880-025-01604-5>
- [17] T. Zebin and S. Rezvy, "COVID-19 detection and disease progression visualization: Deep learning on chest X-rays for classification and coarse localization," *Applied Intelligence*, vol. 51, no. 2, pp. 1010–1021, Feb. 2021, <https://doi.org/10.1007/s10489-020-01867-1>
- [18] M. Elgendi et al., "The Effectiveness of Image Augmentation in Deep Learning Networks for Detecting COVID-19: A Geometric Transformation Perspective," *Frontiers in Medicine*, vol. 8, Art. no. 629134, Mar. 2021, <https://doi.org/10.3389/fmed.2021.629134>
- [19] M. Bunde and G. M. Danciu, "Pneumonia Image Classification Using DenseNet Architecture," *Information (Switzerland)*, vol. 15, no. 10, 2024, <https://doi.org/10.3390/info15100611>
- [20] F. Kanavati and M. Tsuneki, "Partial transfusion: on the expressive influence of trainable batch norm parameters for transfer learning," in *Proceedings of the Fourth Conference on Medical Imaging with Deep Learning, ser. Proceedings of Machine Learning Research*, vol. 143, pp. 338–353, Jul. 2021. [Online]. Available: <https://proceedings.mlr.press/v143/kanavati21a.html>
- [21] S. Patel, "Classification of COVID-19 from chest X-ray images using a deep convolutional neural network," *Turkish Journal of Computer and Mathematics Education*, vol. 12, no. 9, pp. 2643–2651, Apr. 2021. [Online]. Available: <https://turcomat.org/index.php/turkbilmata/article/view/3983>
- [22] Ž. Vujović, "Classification Model Evaluation Metrics," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 6, pp. 599–606, 2021, <https://doi.org/10.14569/IJACSA.2021.0120670>
- [23] F. J. M. Shamrat, S. Azam, A. Karim, K. Ahmed, F. M. Bui, and F. De Boer, "High-precision multiclass classification of lung disease through customized MobileNetV2 from chest X-ray images," *Computers in Biology and Medicine*, vol. 155, Art. no. 106646, Mar. 2023, <https://doi.org/10.1016/j.compbiomed.2023.106646>
- [24] O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Scientific Reports*, vol. 14, no. 1, Art. no. 6086, Mar. 2024, <https://doi.org/10.1038/s41598-024-56706-x>
- [25] K. Raghavan, S. B, and K. v, "Attention guided grad-CAM : an improved explainable artificial intelligence model for infrared breast cancer detection," *Multimedia Tools Application.*, vol. 83, no. 19, pp. 57551–57578, Jun. 2024, <https://doi.org/10.1007/s11042-023-17776-7>