

Analisis Pendekatan *Preprocessing* terhadap Deteksi Stenosis pada Citra X-Ray Coronary Angiography dengan Faster R-CNN

Melya Vebryanti*¹, Kartika Maulida Hindrayani², Alfian Rizaldy Pratama³

¹²³Universitas Pembangunan Nasional Veteran Jawa Timur

¹²³Surabaya-Indonesia

Email: ¹22083010063@student.upnjatim.ac.id,

²kartika.maulida.ds@upnjatim.ac.id, ³alfan.fasilkom@upnjatim.ac.id

Abstract

Coronary Artery Disease (CAD) is a cardiovascular disease caused by the buildup of plaque composed of cholesterol and cellular waste products on the walls of the arteries, resulting in stenosis or narrowing of the coronary arteries that obstructs blood flow. One of the gold standard examination methods for detecting stenosis is X-ray coronary angiography. This study aims to analyze the effect of preprocessing stages on the performance of the Faster R-CNN model in detecting stenosis in X-ray coronary angiography images. Two training scenarios were conducted, namely a model without preprocessing and a model with preprocessing stages that included black border removal, denoising, and contrast enhancement using CLAHE. The dataset was divided with a ratio of 80:20 for training and testing data, and the model was trained for 10 epochs using the ResNet-50 FPN backbone. The evaluation results show that the model with preprocessing performs better than the model without preprocessing, with a precision value of 0.8050, recall of 0.9718, F1-Score of 0.8805, and Mean IoU of 0.7596.

Keywords: Deep Learning, Stenosis Detection, Preprocessing Data, Faster R-CNN, X-Ray Coronary Angiography

Abstraksi

Coronary Artery Disease (CAD) merupakan salah satu penyakit kardiovaskular yang terjadi akibat penumpukan plak yang tersusun atas kolesterol dan sisa metabolisme sel pada dinding arteri, sehingga menimbulkan stenosis atau penyempitan arteri koroner yang menghambat aliran darah. Salah satu metode pemeriksaan yang dianggap gold standard untuk melihat adanya stenosis yaitu X-ray coronary angiography. Penelitian ini bertujuan untuk menganalisis pengaruh tahapan preprocessing terhadap performa model Faster R-CNN dalam mendeteksi stenosis pada citra X-ray coronary angiography. Dua skenario pelatihan dilakukan, yaitu model tanpa preprocessing dan model dengan tahapan preprocessing yang meliputi penghapusan black border, denoising, serta peningkatan kontras menggunakan CLAHE. Dataset dibagi dengan rasio 80:20 untuk data pelatihan dan pengujian, dan model dilatih selama 10 epoch menggunakan backbone ResNet-50 FPN. Hasil evaluasi menunjukkan bahwa model dengan preprocessing memberikan performa yang lebih baik dibandingkan model tanpa preprocessing dengan nilai precision 0,8050, recall 0,9718, F1-Score 0,8805, dan Mean IoU 0,7596.

Kata Kunci: Deep Learning, Stenosis Detection, Preprocessing Data, Faster R-CNN, X-Ray Coronary Angiography

1. PENDAHULUAN

Coronary Artery Disease (CAD), atau biasa disebut dengan penyakit arteri koroner, adalah salah satu bentuk dari penyakit kardiovaskuler yang menjadi penyebab utama kematian di dunia [1]. Menurut data *World Health Organization* (WHO), pada tahun 2022, sekitar 19,8 juta orang di dunia meninggal dunia akibat penyakit kardiovaskuler, yaitu sekitar 32% dari total kematian global [2]. CAD terjadi akibat penumpukan plak yang sebagian besar tersusun atas kolesterol dan sisa metabolisme sel pada dinding arteri. Penumpukan ini menyebabkan stenosis, yaitu penyempitan abnormal pada arteri koroner yang menghambat aliran darah [3], [4].

Salah satu metode pemeriksaan yang dianggap *gold standard* untuk melihat adanya stenosis yaitu *X-ray coronary angiography*, teknik pencitraan medis *invasif* yang menggunakan media kontras [4], [5], [6]. Stenosis pada arteri koroner umumnya dievaluasi melalui penilaian visual citra untuk menilai tingkat keparahannya [7]. Namun, interpretasi ini masih bergantung pada keahlian klinisi dan rentan terhadap subjektivitas [8], [9], [10], [11]. Selain itu, kualitas citra juga menjadi faktor penting yang memengaruhi keakuratan penilaian stenosis [12].

Di sisi lain, dalam beberapa dekade terakhir, perkembangan teknologi *deep learning* memberikan peluang besar dalam bidang pengolahan citra medis [13]. Salah satu algoritma yang banyak digunakan untuk deteksi objek adalah *Faster Region-based Convolutional Neural Network* (Faster R-CNN) yang diperkenalkan pada tahun 2015 [14]. Algoritma ini menggabungkan Fast R-CNN dengan *Region Proposal Network* (RPN) dalam arsitekturnya [15]. Mekanisme RPN ini yang meningkatkan kemampuan model untuk mendeteksi objek berukuran kecil dengan akurasi tinggi [16]. Hal inilah yang menjadi dasar pemilihan metode karena karakteristik stenosis yang memiliki ukuran relatif kecil dan batas yang tidak selalu tegas pada citra.

Selanjutnya, keberhasilan model *deep learning* dalam pengolahan citra sangat bergantung pada kualitas data *input* [16]. Tahapan *preprocessing* pada pengolahan citra merupakan teknik yang bertujuan meningkatkan kualitas citra melalui penyesuaian kecerahan, kontras, dan penghilangan *noise*, serta mencakup pemotongan dan penghilangan bagian yang tidak relevan sebelum analisis dilakukan [17]. Dalam pengolahan citra, tahap *preprocessing* dianggap sangat penting karena model sering kali lebih mampu mengenali objek target dan dapat mengatasi permasalahan pencahayaan yang tidak merata. Namun, dalam konteks citra medis, seluruh bagian citra sering kali mengandung informasi penting.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan menganalisis pengaruh tahap *preprocessing* terhadap performa deteksi stenosis pada citra *X-ray coronary angiography* menggunakan Faster R-CNN dengan *backbone* ResNet-50 dan *Feature Pyramid Network* (FPN), yang dipilih karena kemampuannya mengekstraksi fitur secara mendalam dan mendukung deteksi multiskala [18], [19]. Penelitian membandingkan dua skenario, yaitu data tanpa dilakukan pendekatan *preprocessing*, yang hanya dilakukan *resize*, konversi *grayscale* ke RGB, dan normalisasi, serta data

dengan *preprocessing* lebih lengkap yang mencakup *resize*, pemotongan *black border*, *denoising*, *Contrast Limited Adaptive Histogram Equalization (CLAHE)*, konversi *grayscale* ke RGB, dan normalisasi. Melalui perbandingan ini, penelitian bertujuan memberikan pemahaman mengenai sejauh mana pendekatan tahapan *preprocessing* berkontribusi terhadap peningkatan kualitas pengolahan citra medis, khususnya dalam deteksi stenosis pada citra angiografi.

2. TINJAUAN PUSTAKA

Dalam pengolahan citra medis, model Faster R-CNN telah diaplikasikan untuk mendeteksi lesi atau abnormalitas dari citra seperti CT, X-ray, maupun MRI dengan hasil yang baik [20]. Penggunaan algoritma ini juga semakin berkembang dalam bidang kardiovaskuler, khususnya untuk mendeteksi stenosis arteri koroner pada citra *X-ray coronary angiography*.

Penelitian [21] membandingkan tiga model *deep learning* untuk deteksi stenosis arteri koroner pada citra X-ray angiografi, yaitu SSD MobileNet V1, Faster R-CNN ResNet-50 V1, dan Faster R-CNN NASNet. Dari 8.325 citra angiografi milik 100 pasien, Faster R-CNN ResNet-50 V1 menunjukkan kinerja paling seimbang dengan akurasi tinggi yaitu *mean Average Precision (mAP)* sebesar 0,92 dan waktu inferensi cepat (98 ms per citra), sedangkan SSD MobileNet lebih cepat tetapi kurang akurat.

Penelitian lanjutan [22] mengembangkan sistem deteksi stenosis arteri koroner secara *real-time* menggunakan delapan model *deep learning*, termasuk SSD, R-FCN, dan Faster R-CNN. Dari hasil uji pada 8.325 citra angiografi, model Faster R-CNN Inception ResNet V2 menunjukkan akurasi tertinggi dengan mAP 0,95 dan F1-score 0,96, meskipun memiliki kecepatan inferensi yang lebih lambat.

Sementara itu, penelitian [23] membandingkan tiga model *deep learning*, yaitu Faster R-CNN ResNet-101, RetinaNet ResNet-50 FPN, dan EfficientDet D3 untuk mendeteksi stenosis pada citra *X-ray* angiografi dari 438 pasien. Hasilnya menunjukkan EfficientDet D3 memiliki performa terbaik secara keseluruhan, yaitu mAP dan *F1-score* sebesar 0,67 dan 0,64, sedangkan Faster R-CNN menempati posisi kedua dengan nilai mAP sebesar 0,57. Namun, model ini menunjukkan nilai presisi tertinggi yaitu 0,58, yang berarti model ini menghasilkan prediksi stenosis yang lebih akurat dengan sedikit *false positives*.


Selain untuk deteksi stenosis, model Faster R-CNN juga telah digunakan dalam domain medis lainnya. Penelitian [24] menggunakan Faster R-CNN dengan ResNet-50 FPN untuk mendeteksi glaukoma pada citra fundus melalui tiga skenario *preprocessing*. Hasil menunjukkan bahwa citra asli tanpa modifikasi memberikan akurasi tertinggi (0,8900), mengungguli citra dengan *resize* dan *histogram equalization* (0,8753) dan citra asli dengan *histogram equalization* (0,8800), sehingga menegaskan bahwa *preprocessing* tidak selalu meningkatkan performa dan harus disesuaikan dengan karakteristik data.

Di sisi lain, penelitian [25] secara eksplisit menyoroti pengaruh *preprocessing* terhadap deteksi stenosis dengan mengusulkan metode berbasis *Hessian Frangi*

Vesselness (HFV) dan *image fusion* untuk memperjelas struktur vaskular. Lima arsitektur *deep learning* diuji, dan hasilnya menunjukkan bahwa *preprocessing* ini meningkatkan performa deteksi secara signifikan, dengan R-FCN–InceptionResNetv2 menjadi model terbaik melalui peningkatan akurasi hingga 112–116%.

Dari berbagai penelitian tersebut, dapat disimpulkan bahwa Faster R-CNN menunjukkan performa kompetitif dalam mendeteksi kelainan pada citra medis. Namun kajian mengenai pengaruh *preprocessing*, terutama pada deteksi stenosis, masih sangat terbatas. Penelitian sebelumnya umumnya hanya membandingkan arsitektur model, sementara hasil studi terkait pengaruh pendekatan *preprocessing* menunjukkan temuan yang tidak konsisten, ada yang menyatakan tidak berpengaruh, sementara lainnya melaporkan peningkatan signifikan. Perbedaan ini menegaskan perlunya analisis komparatif yang sistematis antara data dengan dan tanpa *preprocessing*, baik dari sisi metrik performa maupun visualisasi hasil deteksi stenosis pada citra X-ray angiografi menggunakan Faster R-CNN.

3. METODE PENELITIAN



Gambar 1. Diagram Alir Penelitian


3.1. Dataset

Penelitian ini menggunakan dataset publik yang berjudul “*Angiographic dataset for stenosis detection*” yang tersedia di repositori Mendeley Data. Dataset ini terdiri dari 8.325 citra angiografi koroner dari 100 pasien yang menjalani pemeriksaan di *Research Institute for Complex Problems of Cardiovascular Diseases*, Kemerovo, Rusia [22]. Setiap citra memiliki anotasi *bounding box* yang menandai lokasi stenosis pada arteri koroner. Citra pada dataset ini memiliki format *grayscale* dengan resolusi bervariasi antara 512×512 hingga 1000×1000 piksel.

Selain itu, untuk menguji kemampuan generalisasi model yang telah dilatih, digunakan dataset ARCADE sebagai data uji terpisah [26]. Dataset ini berisi citra angiografi koroner dari sumber yang berbeda, sehingga membantu mengevaluasi sejauh mana model mampu mendeteksi stenosis pada data yang memiliki karakteristik visual dan pencahayaan yang tidak identik dengan dataset pelatihan.

3.2. Residual Network-50 (ResNet-50)


Residual Network (ResNet) merupakan arsitektur *deep learning* yang dirancang untuk mengatasi permasalahan *vanishing gradient* pada jaringan saraf dalam (*deep neural networks*) [27]. Arsitektur ini terdiri atas 50 lapisan. ResNet-50 memperkenalkan konsep *residual connection*, yaitu jalur *bypass* yang memungkinkan informasi dari lapisan awal diteruskan langsung ke lapisan yang lebih tinggi tanpa mengalami transformasi berlebih, sehingga mempercepat konvergensi dan meningkatkan akurasi pelatihan. Lapisan-lapisan utama yang membentuk ResNet-50 meliputi *convolutional layer*, fungsi aktivasi *Rectified Linear Unit* (ReLU), *batch normalization*, *pooling layer*, serta *residual connection* yang bekerja untuk mengekstraksi dan mempertahankan fitur penting dari citra *input* [28]. Arsitektur ResNet-50 dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur ResNet-50 [29]

3.3. Feature Pyramid Network (FPN)

FPN merupakan algoritma deteksi *multi-scale* yang dirancang untuk menggabungkan fitur tingkat tinggi dan rendah secara efisien. Algoritma ini didasarkan pada hierarki piramida yang melekat pada CNN, di mana jalur *top-down* dibangun menggunakan *skip connection* untuk menghasilkan peta fitur pada berbagai skala dengan biaya komputasi yang kecil. Setiap tingkat pada piramida fitur mengandung informasi semantik tingkat tinggi yang kemudian digunakan untuk mendeteksi objek pada setiap level piramida [30]. Struktur FPN dapat dilihat pada Gambar 3.



Gambar 3. Struktur FPN [30]

Pada Faster R-CNN, Integrasi FPN dilakukan untuk meningkatkan kemampuan deteksi objek pada berbagai skala. Pada versi awal, *Region Proposal Network* (RPN) hanya bekerja pada satu peta fitur dari lapisan tertinggi (C5), sehingga sulit mengenali objek kecil. Melalui FPN, RPN kini memanfaatkan peta fitur *multi-scale* (P2–P5) yang dibentuk dengan jalur *top-down* dan *lateral connections* [31].

3.4. Faster R-CNN

Faster R-CNN merupakan arsitektur *deep learning* pengembangan dari metode sebelumnya yaitu R-CNN dan Fast R-CNN. Model ini bekerja melalui dua tahap utama, yaitu *Region Proposal Network* (RPN) dan jaringan deteksi Fast R-CNN. RPN bertanggung jawab untuk menghasilkan proposal wilayah dengan menggeser jendela kecil melintasi peta fitur konvolusional. Proses ini menghasilkan proposal *bounding box* bersama skor objek, yang menunjukkan kemungkinan adanya objek di wilayah tersebut. RPN menggunakan kumpulan kotak acuan dengan rasio aspek dan skala yang berbeda untuk menghasilkan proposal ini. Skor untuk setiap proposal wilayah dihitung menggunakan fungsi *sigmoid* pada Persamaan 1.

$$\text{score}(x) = \text{sigmoid}(w_r^T x + b_r) \quad (1)$$

Dimana x adalah *input feature map*, w_r dan b_r adalah parameter RPN, dan skor keluaran mewakili kemungkinan adanya objek di wilayah yang diusulkan.

Selanjutnya, setelah RPN menghasilkan proposal wilayah, jaringan deteksi Fast R-CNN melakukan klasifikasi objek dan *bounding box regression*. Proposal wilayah tersebut dilewatkan melalui lapisan *pooling Region of Interest* (RoI), yang mengekstrak *fixed-size feature maps* dari setiap wilayah yang diusulkan. Fitur-fitur ini kemudian dilewatkan melalui *fully connected layers* untuk klasifikasi dan penyempurnaan *bounding box*.

Bounding box regression bertujuan untuk menyesuaikan *bounding box* yang diprediksi agar lebih sesuai dengan data sebenarnya. Fungsi *loss* yang digunakan untuk *bounding box regression* adalah *Smooth L1 loss* pada Persamaan 2.


$$L_{reg} = \sum_{i=1}^N \text{Smooth L1}(\hat{t}_i, t_i) \quad (2)$$

Dimana $\hat{t}_i$ adalah transformasi *bounding box* yang diprediksi dan t_i adalah transformasi data sebenarnya.

Faster R-CNN menggunakan CNN *backbone* untuk mengekstraksi *hierrarchical feature maps* yang kemudian diteruskan ke RPN dan jaringan deteksi. Model ini dilatih secara end-to-end dengan fungsi *loss* gabungan yang mengombinasikan *classification loss* dan *bounding box regression loss*, serta dioptimalkan menggunakan *Stochastic Gradient Descent* (SGD) agar konvergensi pelatihan tetap stabil [32].

4. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan lingkungan *Google Colab* dan *framework* PyTorch untuk membangun serta melatih model Faster R-CNN. Pada data yang menggunakan pendekatan *preprocessing*, tahapan yang diterapkan meliputi pemotongan *black border*, *denoising*, peningkatan kontras dengan CLAHE, *resize* ke 600×600 piksel, konversi *grayscale* ke RGB, dan normalisasi piksel ke rentang $[0,1]$. Sementara itu, data tanpa *preprocessing* hanya melalui proses dasar berupa *resize*, konversi ke RGB, dan normalisasi. Seluruh proses juga disertai dengan pembaruan data anotasi agar posisi *bounding box* tetap sesuai setelah citra mengalami perubahan ukuran dan pemotongan. Perbandingan visualisasi citra asli, citra tanpa dilakukan *preprocessing*, dan citra setelah dilakukan *preprocessing* dapat dilihat pada Gambar 4.



Gambar 4. Perbandingan Citra; (1) Citra Asli; (2) Citra Tanpa Tahapan *Preprocessing*; dan (3) Citra Dengan Tahapan *Preprocessing*

Pada Gambar 4. citra dengan tahapan *preprocessing* telah melalui proses peningkatan kualitas visual, sehingga struktur pembuluh darah dan area stenosis tampak lebih jelas dan kontras.

Model dikonfigurasi dengan dua kelas, yaitu *background* dan *stenosis*. Proses pelatihan dilakukan menggunakan *optimizer Stochastic Gradient Descent* (SGD) dengan nilai *learning rate* sebesar 0,005, momentum 0,9, dan *weight decay* 0,0005. Pelatihan dijalankan dengan 10 *epoch*, rasio pembagian data 80% untuk pelatihan dan 20% untuk pengujian. Setiap *epoch* mencatat nilai *loss* total dan komponen-komponen *loss* lainnya seperti *classification loss*, *box regression loss*, *objectness loss*, dan RPN *box regression loss* untuk memantau performa model secara bertahap. Setelah proses pelatihan selesai, model disimpan dalam format berkas *.pth* sebagai hasil akhir pelatihan.

Performa kedua model diukur menggunakan metrik evaluasi *Precision*, *Recall*, *F1-Score*, dan *Mean Intersection over Union* (IoU).


Tabel 1. Hasil Evaluasi Model


Matriks Evaluasi	Model tanpa <i>Preprocessing</i>	Model dengan <i>Preprocessing</i>
<i>Precision</i>	0,8050	0,8533
<i>Recall</i>	0,9718	0,9646
<i>F1-Score</i>	0,8805	0,9056
<i>Mean IoU</i>	0,7596	0,7616

Berdasarkan hasil pada Tabel 1. diketahui bahwa model dengan *preprocessing* menunjukkan peningkatan kinerja pada sebagian besar metrik evaluasi. Nilai *Precision* meningkat dari 0,8050 menjadi 0,8533, menunjukkan bahwa model yang melalui tahap *preprocessing* mampu mengurangi kesalahan dalam mendeteksi area stenosis yang salah (*false positive*). Meskipun nilai *Recall* sedikit menurun dari 0,9718 menjadi 0,9646, penurunan tersebut tidak signifikan dan masih menunjukkan bahwa model tetap mampu mendeteksi sebagian besar area stenosis yang benar (*true positive*).

Peningkatan yang konsisten juga terlihat pada F1-Score, yang naik dari 0,8805 menjadi 0,9056. Hal ini menunjukkan keseimbangan yang lebih baik antara *precision* dan *recall* setelah diterapkan *preprocessing*. Selain itu, nilai *Mean IoU* juga meningkat dari 0,7596 menjadi 0,7616, menandakan bahwa hasil segmentasi atau prediksi area deteksi stenosis lebih akurat dan sesuai dengan *ground truth*.

Selanjutnya, pengujian kinerja juga dilakukan menggunakan dataset berbeda untuk menilai kemampuan generalisasi model dalam mendeteksi stenosis pada citra angiografi yang tidak termasuk dalam data pelatihan. Pada tahap ini, hasil prediksi dari dua model, tanpa dan dengan pendekatan tahapan *preprocessing*, dibandingkan dengan *ground truth* untuk melihat perbedaan kualitas deteksi yang dihasilkan.





Gambar 5. Perbandingan Hasil Test Model pada Dataset ARCADE; (1) *Ground Truth*; (2) Prediksi Model tanpa *Preprocessing*; (3) Prediksi Model dengan *Preprocessing*

Gambar 5. menampilkan hasil uji coba model pada dataset ARCADE untuk menilai kemampuan generalisasi terhadap data di luar pelatihan. Kolom (1) menunjukkan *ground truth* lokasi stenosis, kolom (2) menampilkan prediksi model tanpa *preprocessing*, dan kolom (3) menampilkan prediksi model dengan *preprocessing*.

Secara visual, model yang dilatih dengan tahapan *preprocessing* menunjukkan hasil deteksi yang sedikit lebih mendekati *ground truth*. Kotak prediksi yang dihasilkan lebih presisi dan tidak menampilkan prediksi ganda yang berlebihan seperti pada model tanpa *preprocessing*. Hal ini menunjukkan bahwa tahapan *preprocessing* berperan penting dalam meningkatkan kualitas representasi citra, sehingga model dapat mengenali pola stenosis dengan lebih baik meskipun pada dataset yang berbeda dari data latih.

Di sisi lain, meskipun secara umum kedua model mampu mendeteksi area stenosis dengan cukup baik, masih terdapat beberapa kasus di mana deteksi belum sepenuhnya akurat, misalnya pada citra yang memiliki dua area stenosis, model hanya berhasil mendeteksi satu di antaranya. Hal ini menunjukkan bahwa model masih memiliki keterbatasan dalam mengenali stenosis dengan ukuran kecil atau kontras rendah.

5. KESIMPULAN

Berdasarkan tujuan penelitian yang berfokus pada analisis pengaruh *preprocessing* terhadap performa model Faster R-CNN dalam mendeteksi stenosis, hasil pengujian menunjukkan bahwa tahapan *preprocessing* memberikan peningkatan kinerja yang konsisten. Model tanpa *preprocessing* memperoleh hasil evaluasi *precision* sebesar 0,8050, *recall* 0,9718, *F1-score* 0,8805, dan *Mean IoU* 0,7596, sedangkan model dengan *preprocessing* menghasilkan evaluasi yaitu *precision* 0,8533, *recall* 0,9646, *F1-score* 0,9056, dan *Mean IoU* 0,7616. Peningkatan nilai *precision*, *F1-score*, dan *Mean IoU* mengindikasikan bahwa proses seperti *denoising* dan CLAHE mampu memperjelas struktur vaskular sehingga model lebih akurat dalam mengidentifikasi lokasi stenosis. Namun, hasil uji silang pada dataset berbeda memperlihatkan bahwa kedua model masih mengalami kesalahan deteksi, terutama pada citra dengan lebih dari satu area stenosis, sehingga penelitian lanjutan diperlukan, baik melalui pengayaan dataset maupun

optimasi arsitektur, untuk meningkatkan kemampuan generalisasi dan sensitivitas model dalam kondisi klinis yang lebih kompleks.

DAFTAR PUSTAKA

- [1] E. Alskaf, U. Dutta, C. M. Scannell, and A. Chiribiri, "Deep learning applications in coronary anatomy imaging: a systematic review and meta-analysis," *J Med Artif Intell*, vol. 5, pp. 22–36, Dec. 2022, doi: 10.21037/jmai-22-36.
- [2] "Cardiovascular diseases (CVDs)," World Health Organization. Accessed: Nov. 08, 2025. [Online]. Available: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [3] R. D. Shahjehan, S. Sharma, and B. S. Bhutta, "Coronary Artery Disease," in *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Accessed: Nov. 08, 2025. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK564304/>
- [4] E. Ovalle-Magallanes, J. G. Avina-Cervantes, I. Cruz-Aceves, and J. Ruiz-Pinales, "Transfer learning for stenosis detection in X-ray Coronary Angiography," *Mathematics*, vol. 8, no. 1510, pp. 1–20, Sep. 2020, doi: 10.3390/math8091510.
- [5] B. Huang *et al.*, "A Deep Learning Model for Coronary Artery Segmentation and Quantitative Stenosis Detection in Angiographic Images," *ArXiv*, Mar. 2025, [Online]. Available: <http://arxiv.org/abs/2406.00492>
- [6] T. Chen *et al.*, "Computational Methods for Analysing X-ray-guided Coronary Angiography: From Key Frame Selection to Vessel Segmentation, Stenosis Detection and Classification," *Journal of Asian Pacific Society of Cardiology*, vol. 4, Jul. 2025, doi: 10.15420/japsc.2024.46.
- [7] R. Avram *et al.*, "CathAI: fully automated coronary angiography interpretation and stenosis estimation," *NPJ Digit Med*, vol. 6, no. 1, Dec. 2023, doi: 10.1038/s41746-023-00880-1.
- [8] H. Ling, Z.-Y. Guo, L.-L. Tan, R.-C. Guan, J.-B. Chen, and C.-L. Song, "Machine learning in diagnosis of coronary artery disease," *Chin Med J (Engl)*, vol. 134, no. 4, pp. 401–403, 2021, doi: 10.1097/CM9.0000000000001202.
- [9] M. Popov, T. Aimyshev, E. Ismailov, A. Bulegenov, and S. Fazli, "A Review of Modern Approaches for Coronary Angiography Imaging Analysis," *ArXiv*, Sep. 2022, [Online]. Available: <http://arxiv.org/abs/2209.13997>
- [10] S. Shivaie, H. Tohidi, P. Loganathan, M. Kar, H. Hashemy, and M. A. Shafiee, "Interobserver Variability of Coronary Stenosis Characterized by Coronary Angiography: A Single-Center (Toronto General Hospital) Retrospective Chart Review by Staff Cardiologists," *Vasc Health Risk Manag*, vol. 20, pp. 359–368, Aug. 2024, doi: 10.2147/VHRM.S431612.
- [11] X. Xu *et al.*, "Sex differences in assessing stenosis severity between physician visual assessment and quantitative coronary angiography," *Int J Cardiol*, vol. 348, pp. 9–14, Dec. 2021, doi: 10.1016/j.ijcard.2021.11.089.
- [12] C. Cong, Y. Kato, H. D. De Vasconcellos, M. R. Ostovaneh, J. A. C. Lima, and B. Ambale-Venkatesh, "Deep learning-based end-to-end automated stenosis classification and localization on catheter coronary angiography," *Front Cardiovasc Med*, vol. 10, Feb. 2023, doi: 10.3389/fcvm.2023.944135.
- [13] J. Egger *et al.*, "Medical deep learning—A systematic meta-review," *Comput Methods Programs Biomed*, vol. 221, no. 106874, pp. 1–22, 2022, doi: 10.1016/j.cmpb.2022.106874.

- [14] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," Jan. 2016, [Online]. Available: <http://arxiv.org/abs/1506.01497>
- [15] J. Justam, A. Malik, E. Erlita, D. Mangellak, and Y. Yuyun, "Perbandingan Kinerja YOLO vs Faster R-CNN untuk Deteksi & Estimasi Berat Ikan," *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, vol. 7, no. 2, pp. 363–376, Oct. 2024, doi: 10.57093/jisti.v7i2.273.
- [16] X. Yuan, A. Chakravarty, L. Gu, Z. Wei, E. Lichtenberg, and T. Chen, "An Empirical Study of Methods for Small Object Detection from Satellite Imagery," *ArXiv*, Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2502.03674>
- [17] S. R. Sulistiyanti, F. A. Setyawan, and M. Komarudin, *Pengolahan Citra Dasar dan Contoh Penerapannya*. Universitas Lampung, 2016. [Online]. Available: <https://www.researchgate.net/publication/337928062>
- [18] A. Rachmad, F. A. Mufarroha, E. M. S. Rochman, M. A. Syakur, F. Solihin, and Y. P. Asmara, "The Impact of Convolutional Layer Selection in ResNet-50v2 Architecture on Corn Leaf Disease Classification," *International Information and Engineering Technology Association*, vol. 30, no. 6, pp. 1509–1515, Jun. 2025, doi: 10.18280/isi.300609.
- [19] H.-J. Park, J.-W. Kang, and B.-G. Kim, "ssFPN: Scale Sequence (S2) Feature-Based Feature Pyramid Network for Object Detection," *Sensors*, vol. 23, no. 9, Apr. 2023, doi: 10.3390/s23094432.
- [20] S. Ma, Y. Huang, X. Che, and R. Gu, "Faster RCNN-based detection of cervical spinal cord injury and disc degeneration," *J Appl Clin Med Phys*, vol. 21, no. 9, pp. 235–243, Jul. 2020, doi: 10.1002/acm2.13001.
- [21] V. Danilov, O. Gerget, K. Klyshnikov, E. Ovcharenko, and A. Frangi, "Comparative Study of Deep Learning Models for Automatic Coronary Stenosis Detection in X-ray Angiography," *Proceedings of the 30th International Conference on Computer Graphics and Machine Vision (GraphiCon 2020)*, vol. 2744, no. 75, 2020.
- [22] V. V. Danilov *et al.*, "Real-time coronary artery stenosis detection based on modern neural networks," *Sci Rep*, vol. 11, no. 7582, pp. 1–13, 2021, doi: 10.1038/s41598-021-87174-2.
- [23] P. V. Stralen, D. L. Rodrigues, M. N. Menezes, F. J. Pinto, and A. L. Oliveira, "Stenosis Detection in X-ray Coronary Angiography with Deep Neural Networks Leveraged by Attention Mechanisms," in *2022 9th International Conference on Bioinformatics Research and Applications (ICBRA 2022)*, Association for Computing Machinery, Sep. 2022, pp. 123–128. doi: 10.1145/3569192.3569212.
- [24] N. G. de Sá, D. O. Dantas, and G. J. F. da Silva, "Glaucoma Detection Using Transfer Learning with the Faster R-CNN Model and a ResNet-50-FPN Backbone," in *International Conference on Enterprise Information Systems, ICEIS - Proceedings*, Science and Technology Publications, Lda, 2024, pp. 837–844. doi: 10.5220/0012706500003690.
- [25] Y. Li, T. Yoshimura, Y. Horima, and H. Sugimori, "A Preprocessing Method for Coronary Artery Stenosis Detection Based on Deep Learning," *Algorithms*, vol. 17, no. 3, p. 119, Mar. 2024, doi: 10.3390/a17030119.
- [26] M. Popov *et al.*, "Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images," *Sci Data*, vol. 11, no. 20, pp. 1–9, Jan. 2024, doi: 10.1038/s41597-023-02871-z.

- [27] Asriani, N. T. Lapatta, D. W. Nugraha, Amriana, and Wirdayanti, "Implementation of ResNet-50-Based Convolutional Neural Network For Mobile Skin Cancer Classification," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 4, pp. 1569–1577, 2025, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [28] S. R. Reeja, T. Thotakura, and I. Yaseen, "Scrutinization of mammogram images using deep learning," in *Computational Intelligence and Modelling Techniques for Disease Detection in Mammogram Images*, Cambridge, MA, USA: Elsevier (Academic Press), 2024, ch. Chapter 9, pp. 177–202. doi: 10.1016/B978-0-443-13999-4.00009-2.
- [29] S. Mukherjee, "The Annotated ResNet-50," Towards Data Science. Accessed: Nov. 09, 2025. [Online]. Available: <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758/>
- [30] S. Xu and Z. Shao, "Faster RCNN based on Feature Fusion and its Application in Steel Surface Defect Detection," *Scientific Journal of Technology*, vol. 4, no. 10, pp. 19–27, 2022.
- [31] S. Tanwar, "FPN(feature pyramid networks)," Medium. Accessed: Nov. 09, 2025. [Online]. Available: <https://medium.com/analytics-vidhya/fpn-feature-pyramid-networks-77d8be41817c>
- [32] Y. Patki and T. Gawade, "Object Detection Using Faster R-CNN," *ResearchGate*, Dec. 2024, [Online]. Available: <https://www.researchgate.net/publication/387275821>