

## EKSPLORASI INFORMASI WARNA RGB UNTUK PENINGKATAN AKURASI DETEKSI DINI KANKER PADA CITRA BERDIMENSI TETAP MELALUI ATTENTION-BASED NEURAL NETWORK

Desta Febi Nur Anggita<sup>1</sup>; Dian Ade Kurnia<sup>2</sup>; Yudhistira Arie Wijaya<sup>3</sup>; Edi Wahyudin<sup>4</sup>; Edi Tohidi<sup>5</sup>;

Program Studi Teknik Informatika<sup>1</sup>  
Program Studi Manajemen Informatika<sup>2</sup>  
Program Studi Sistem Informasi<sup>3</sup>  
Program Studi Komputerisasi Akuntansi<sup>45</sup>

STMIK IKMI Cirebon  
<https://ikmi.ac.id/page/18/?lang=de>  
destafebi26@gmail.com

(\*) Corresponding Author : destafebi26@gmail.com  
Published : 31 Desember 2025

**Abstract**—images by exploring RGB color information and integrating it into an Attention-based Neural Network. The research focuses on the use of color distribution patterns found in histopathology images as an informative source for distinguishing benign from malignant tissues. The RGB model is selected because each channel carries intensity variations that reflect biological characteristics of the tissue, offering additional cues for the learning process of the model. The method includes dataset curation, image preprocessing, color normalization, targeted augmentation, and the design of a CNN architecture equipped with an Attention Block. All images are standardized to  $128 \times 128$  pixels and normalized to a 0–1 range. The model is trained using the Adam optimizer with a batch size of 32 and 50 epochs, complemented by an early stopping mechanism to prevent overfitting. The attention mechanism is applied to strengthen diagnostic features by highlighting relevant spatial areas and color channels. The results indicate that RGB color information helps identify variations in pigmentation and texture patterns associated with cellular changes. The red, green, and blue channels exhibit distinct intensity distributions that contribute to improved class differentiation. Incorporating the Attention Block enhances the model's ability to focus on essential regions, producing more selective and stable feature representations. Attention map analysis further confirms that the model highlights areas visually linked to pathological indications. This study concludes that combining RGB exploration with an Attention-based Neural Network strengthens both accuracy and interpretability in early cancer detection. These findings support the development of more adaptive models capable of handling color variation across different fixed-dimension medical imaging modalities.

**Keywords:** RGB; medical imaging; cancer; attention; neural network.

**Abstrak**— Penelitian ini bertujuan meningkatkan akurasi deteksi dini kanker pada citra berdimensi tetap dengan mengeksplorasi informasi warna RGB dan mengintegrasikannya ke dalam Attention-based Neural Network. Fokus penelitian diarahkan pada pemanfaatan distribusi warna yang muncul pada citra histopatologi sebagai sumber informasi penting dalam membedakan jaringan benign dan malignant. Model warna RGB dipilih karena setiap kanalnya mengandung variasi intensitas yang mencerminkan karakteristik biologis jaringan, sehingga berpotensi memperkaya proses pembelajaran model. Metode yang digunakan mencakup kurasi dataset kanker, pra-pemrosesan citra, normalisasi intensitas warna, augmentasi terarah, serta perancangan arsitektur CNN yang dilengkapi Attention Block. Seluruh citra diseragamkan pada ukuran  $128 \times 128$  piksel dan dinormalisasi ke rentang 0–1. Model dilatih menggunakan optimizer Adam

dengan batch size 32 dan jumlah epoch 50, serta dilengkapi mekanisme early stopping untuk menghindari overfitting. Mekanisme perhatian diterapkan untuk memperkuat fitur diagnostik pada area dan kanal warna yang paling relevan. Hasil penelitian menunjukkan bahwa informasi warna RGB berperan dalam menyoroti variasi pigmen dan pola tekstur yang berhubungan dengan perubahan seluler. Kanal merah, hijau, dan biru memiliki distribusi intensitas yang berbeda dan terbukti membantu model dalam mengenali perbedaan antar kelas. Integrasi Attention Block meningkatkan kemampuan model dalam memfokuskan proses pembelajaran pada area penting, sehingga menghasilkan representasi fitur yang lebih selektif dan stabil. Analisis peta perhatian menunjukkan bahwa model mampu mengidentifikasi bagian citra yang secara visual berkaitan dengan indikasi patologis. Penelitian ini menyimpulkan bahwa eksplorasi warna RGB yang digabungkan dengan Attention-based Neural Network mampu memperkuat akurasi dan interpretabilitas sistem deteksi dini kanker. Temuan ini membuka peluang pengembangan model yang lebih adaptif terhadap variasi warna dan dapat diterapkan pada berbagai jenis citra medis berdimensi tetap.

**Keyword:** RGB; citra medis; kanker; *attention*; *neural network*.

### INTRODUCTION

Kanker merupakan salah satu penyebab kematian tertinggi di dunia yang menimbulkan beban besar terhadap sistem kesehatan global. Deteksi dini menjadi kunci utama dalam menurunkan angka mortalitas dan meningkatkan peluang keberhasilan terapi. Dalam dekade terakhir, analisis citra digital berbasis kecerdasan buatan, khususnya deep learning, telah menunjukkan potensi besar dalam mendeteksi kelainan seluler secara otomatis pada citra histopatologi. Teknologi ini memungkinkan sistem diagnosis untuk mengidentifikasi pola visual yang tidak selalu dapat dikenali oleh pengamat manusia. Meskipun demikian, variasi warna, pencahayaan, dan pewarnaan jaringan masih menjadi tantangan utama yang memengaruhi akurasi model klasifikasi. Studi terbaru menegaskan bahwa data yang bervariasi dan variabilitas warna merupakan sumber utama ketidakstabilan performa model deep learning dalam deteksi dini kanker (Hoque et al., 2024). Selain itu, proses normalisasi warna dan prapemrosesan yang memperhatikan informasi RGB menjadi aspek penting untuk menjaga integritas diagnostik citra (Hameed et al., 2022). Oleh karena itu, upaya eksplorasi informasi warna RGB pada citra medis diperlukan untuk meningkatkan akurasi serta konsistensi sistem deteksi dini berbasis jaringan syaraf tiruan.

Peran informasi warna RGB dalam analisis citra medis semakin diperhatikan karena ketiga kanal warna (R, G, dan B) mengandung informasi yang kaya. Warna mencerminkan variasi biologis dalam jaringan, seperti distribusi pigmen, densitas sel, dan tingkat penyerapan pewarnaan histologi. Beberapa penelitian menunjukkan bahwa penggunaan fitur warna secara dominan dapat meningkatkan performa klasifikasi kanker. Studi oleh Elazab et al. (2024) mengungkapkan bahwa integrasi fitur momen warna dari kanal R, G, dan B bersama dengan fitur tekstur mampu

meningkatkan akurasi klasifikasi tumor otak hingga 95,8%. Demikian pula, penelitian Wang et al. (2023) pada citra retina berwarna menunjukkan bahwa penggabungan informasi warna RGB dengan arsitektur CNN menghasilkan akurasi hingga 93,0%. Hal ini menegaskan bahwa eksplorasi fitur warna, baik secara individual maupun dalam kombinasi dengan tekstur, berperan penting dalam membedakan jaringan kanker dan non-kanker secara lebih efektif.

Namun pada kenyataannya, sebagian besar sistem deteksi kanker berbasis CNN masih berfokus pada informasi spasial tanpa memperhatikan distribusi warna yang beragam dalam citra medis. Variasi pewarnaan antar laboratorium, perbedaan intensitas pencahayaan, dan variasi sensor pengambilan gambar menyebabkan pergeseran domain (domain shift) yang mengurangi kemampuan generalisasi model. Raghu et al. (2021) menyebutkan bahwa CNN konvensional memiliki kelemahan dalam mengatasi variasi akuisisi dan distribusi warna, yang membuat model menjadi sangat sensitif terhadap perubahan eksternal seperti perbedaan scanner atau protokol pewarnaan. Temuan serupa oleh Lin et al. (2025) menunjukkan bahwa model CNN yang dilatih pada satu batch slide histologi gagal digeneralisasikan ke batch lain, bahkan setelah dilakukan normalisasi warna. Fakta ini memperlihatkan bahwa pendekatan CNN standar masih belum cukup handal untuk menangani data citra dengan variasi warna yang signifikan.

Kesenjangan lain yang muncul adalah keterbatasan model CNN dalam memanfaatkan konteks global dan hubungan yang kompleks antar fitur visual. CNN tradisional hanya fokus pada jendela terbatas, sehingga sering kehilangan informasi penting pada area di luar bidang perhatian konvolusi. Studi oleh Jones et al. (2023) mengonfirmasi bahwa gangguan kecil pada pencahayaan atau saturasi dapat menurunkan

performa CNN secara signifikan. Oleh karena itu, dibutuhkan pendekatan yang mampu meniru mekanisme perhatian manusia, yaitu dengan memfokuskan proses pembelajaran pada area penting dari citra tanpa mengabaikan konteks keseluruhan. Dalam hal ini, jaringan syaraf tiruan berbasis perhatian (attention-based neural networks) menjadi solusi potensial karena memiliki kemampuan untuk menimbang kontribusi setiap bagian citra dalam menentukan hasil klasifikasi.

Beberapa penelitian telah mengusulkan berbagai pendekatan untuk mengatasi tantangan tersebut. Li et al. (2023) meninjau bahwa penerapan mekanisme perhatian dalam CNN dapat memperbaiki pemodelan hubungan spasial dan memberikan bobot signifikan pada fitur yang relevan. Penelitian Aldakhil et al., (2024) mengembangkan ECSAnet dengan modul perhatian CBAM yang terbukti meningkatkan kinerja klasifikasi histopatologi payudara. Uddin (2024) bahkan melaporkan peningkatan akurasi sebesar 20% pada klasifikasi tumor paru-paru dengan menggunakan DenseNet berbasis perhatian. Hasil-hasil tersebut memperlihatkan bahwa mekanisme perhatian berperan penting dalam meningkatkan ketahanan dan interpretabilitas model deep learning untuk data citra medis.

Meskipun demikian, masih terdapat kekurangan dalam penelitian terdahulu yang menggabungkan eksplorasi warna RGB dengan mekanisme perhatian pada citra berdimensi tetap. Sebagian besar studi berfokus pada augmentasi data atau normalisasi warna tanpa menilai secara langsung kontribusi informasi RGB terhadap peningkatan akurasi model berbasis perhatian. Padahal, penelitian terkini menunjukkan bahwa setiap kanal warna membawa informasi diagnostik yang unik. Sun et al., (2023) menekankan pentingnya restorasi warna dalam citra patologi digital untuk meningkatkan kontras antara inti dan sitoplasma, yang pada akhirnya membantu proses klasifikasi jaringan. Selain itu, pendekatan ColorMedGAN oleh Chen et al., (2023) membuktikan bahwa normalisasi dan pengayaan warna dapat memperbaiki tingkat pengenalan sel secara signifikan. Namun, upaya untuk mengintegrasikan mekanisme perhatian dengan eksplorasi warna RGB dalam konteks citra berdimensi tetap masih jarang dilakukan, sehingga ruang penelitian ini masih terbuka luas.


Keterbatasan tersebut menjadi dasar perlunya penelitian baru yang berfokus pada integrasi informasi warna RGB dengan jaringan syaraf tiruan berbasis perhatian untuk deteksi dini kanker. Eksplorasi ini diharapkan mampu meningkatkan sensitivitas dan spesifisitas sistem dalam mengenali pola sel abnormal pada citra

medis berdimensi tetap. Penelitian ini juga bertujuan untuk menganalisis bagaimana distribusi warna RGB berkontribusi terhadap performa model serta bagaimana mekanisme perhatian dapat memperkuat interpretasi jaringan syaraf tiruan terhadap variasi warna dan morfologi. Dengan demikian, penelitian ini memberikan kontribusi teoritis dan praktis dalam pengembangan sistem deteksi kanker berbasis AI yang lebih akurat dan andal.

Kebaruan penelitian ini terletak pada integrasi dua aspek penting, yaitu eksplorasi informasi warna RGB dan penerapan attention-based neural networks dalam satu kerangka kerja terstruktur. Penelitian ini berupaya mengisi kesenjangan antara eksplorasi fitur warna yang kaya secara diagnostik dengan mekanisme pembelajaran yang mampu menyoroti area penting pada citra medis. Hasilnya diharapkan dapat memperkuat teori bahwa pemrosesan berbasis warna dan perhatian tidak hanya meningkatkan akurasi klasifikasi, tetapi juga meningkatkan transparansi dan interpretabilitas model AI dalam konteks deteksi dini kanker. Secara lebih luas, penelitian ini diharapkan berkontribusi pada pengembangan model deteksi otomatis yang handal, efisien, dan dapat diadaptasi pada berbagai domain citra medis.

## MATERIALS AND METHODS

Alur penelitian dalam studi ini disusun secara terstruktur sebagaimana divisualisasikan pada Gambar 1 yang memuat rangkaian proses mulai dari akuisisi data hingga visualisasi peta perhatian. Tahapan awal penelitian dimulai dari Akuisisi & Kurasi Data, yaitu proses pengumpulan dataset kanker dari sumber terbuka dan penyaringan citra untuk memastikan kualitas serta kesesuaian label. Tahap kurasi ini penting untuk menjamin konsistensi dan representativitas dataset, sejalan dengan kerangka kerja penelitian citra medis berbasis CNN yang umum dijabarkan dalam tinjauan literatur (B. Jiang, 2024; Mienye, 2025). Pendekatan ini menekankan bahwa keberhasilan model sangat bergantung pada validitas dan integritas data latih.



Gambar 1. Alur Penelitian

Tahap berikutnya pada Gambar 3.2 adalah Penyesuaian Dimensi Citra, yaitu proses

penyeragaman ukuran citra menjadi  $128 \times 128$  piksel. Resizing ini diperlukan untuk menjaga keselarasan dimensi input pada jaringan CNN serta mengurangi kompleksitas komputasi. Standardisasi ukuran merupakan praktik umum dalam studi citra medis, terutama ketika model dirancang untuk bekerja dengan citra RGB berdimensi tetap (Tan et al., 2024; Yilmaz, 2025). Setelah ukuran citra distandarkan, dataset kemudian melalui tahap Pembagian Dataset menggunakan pendekatan stratified split, yang memisahkan data menjadi bagian latih dan validasi sembari mempertahankan keseimbangan proporsi antar kelas. Metode ini memastikan proses pelatihan tidak bias dan evaluasi tetap adil, sesuai rekomendasi pipeline evaluasi deep learning medis (Rahman, 2025).

Proses kemudian berlanjut ke Pra-pemrosesan, sebagaimana ditunjukkan dalam Gambar 3.2. Pada tahap ini dilakukan normalisasi nilai piksel serta penyesuaian warna (color adjustment) untuk mengatasi variasi intensitas dan distribusi warna antar citra. Tahap pra-pemrosesan ini selaras dengan praktik terbaik pada penelitian klasifikasi kanker berbasis CNN yang mengharuskan normalisasi, standardisasi, dan penyesuaian spektrum warna sebelum citra diproses lebih lanjut (B. Jiang, 2024; Mienye, 2025). Setelah itu, dilakukan Perancangan Model, yakni pembangunan arsitektur CNN yang dipadukan dengan mekanisme Attention. Integrasi modul perhatian dirancang untuk memperkuat representasi fitur penting dan mendukung interpretabilitas model, sebagaimana banyak direkomendasikan dalam penelitian terkini mengenai klasifikasi kanker berbasis citra RGB (Yilmaz, 2025).

Tahap berikutnya dalam Gambar 3.2 adalah Pelatihan Model, yang melibatkan optimisasi menggunakan Adam, penerapan fungsi loss Binary Cross-Entropy (BCE), dan mekanisme Early Stopping. Early stopping digunakan untuk menghentikan pelatihan ketika performa validasi tidak membaik, sehingga mencegah overfitting dan menjaga generalisasi model. Pendekatan pelatihan seperti ini merupakan standar dalam pipeline klasifikasi citra medis (Rahman, 2025). Setelah pelatihan selesai, model memasuki tahap Evaluasi Kinerja, yaitu pengukuran akurasi, presisi, recall, dan F1-Score. Evaluasi ini bertujuan menilai efektivitas model dalam mengenali pola kanker dan memastikan performa yang dapat diandalkan secara klinis, sebagaimana direkomendasikan oleh literatur evaluasi model deep learning medis (Tan et al., 2024).


Tahap terakhir pada Gambar 3.2 adalah Visualisasi Attention Map menggunakan metode Grad-CAM, yang menghasilkan heatmap untuk

mengungkap area penting yang mendasari keputusan model. Integrasi visualisasi perhatian dianggap sebagai langkah penting dalam meningkatkan interpretabilitas, transparansi, dan kepercayaan dalam model berbasis CNN untuk diagnosis medis (An & Joe, 2022; Innat et al., 2023; Nazir, 2023). Penerapan interpretasi visual pada tahap akhir sebelum penyimpulan evaluasi merupakan praktik umum dalam workflow XAI untuk citra medis (Hakkoum, 2022; Huff et al., 2021). Melalui integrasi tahapan tersebut, alur penelitian dalam Gambar 3.2 membangun pipeline yang lengkap, reproducible, dan sesuai standar metodologis penelitian citra medis modern (Bontempi et al., 2024; Kline et al., 2025; Moassefi et al., 2024).

## RESULTS AND DISCUSSION

### Hasil Training dan Visualisasi History

Pada Gambar 2 menampilkan dinamika akurasi pelatihan dan akurasi validasi sepanjang 20 epoch pertama proses pelatihan model




**Gambar 2 Grafik Akurasi**

Akurasi pelatihan menunjukkan peningkatan bertahap dan stabil sejak epoch awal, bergerak dari sekitar 0.76 menuju 0.85 pada epoch terakhir. Tren ini mengindikasikan bahwa model mampu mempelajari pola dan struktur fitur dari data pelatihan secara konsisten tanpa mengalami fluktuasi ekstrem. Sementara itu, akurasi validasi memperlihatkan pola yang lebih variatif, dengan peningkatan signifikan pada epoch awal yang kemudian diikuti oleh beberapa penurunan tajam, termasuk satu penurunan drastis pada sekitar epoch ke-8. Meskipun demikian, kinerja validasi kembali pulih pada epoch berikutnya dan mencapai nilai mendekati akurasi pelatihan pada epoch akhir, menunjukkan bahwa model secara keseluruhan tetap mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat.

Pola fluktuasi pada kurva validasi mencerminkan adanya variasi internal dalam distribusi data validasi maupun sensitivitas model

terhadap fitur tertentu pada tahap-tahap pembelajaran awal. Namun, tren akhir yang menunjukkan konvergensi antara akurasi pelatihan dan validasi menggambarkan bahwa mekanisme regularisasi, termasuk normalisasi input dan konfigurasi parameter pelatihan, berhasil menjaga stabilitas model. Konsistensi performa pada epoch akhir juga menegaskan bahwa proses pembelajaran telah mencapai fase stabil, di mana model dapat mengekstraksi representasi fitur yang lebih diskriminatif untuk membedakan citra benign dan malignant. Secara keseluruhan, visualisasi history pelatihan ini menunjukkan bahwa model Attention-CNN mampu mencapai keseimbangan antara kemampuan belajar dan kemampuan generalisasi, sehingga memberikan landasan yang kuat untuk proses evaluasi performa pada tahap berikutnya.

Gambar 3 menampilkan perkembangan nilai loss pelatihan dan validasi sepanjang 20 epoch pertama proses pelatihan model.



**Gambar 3 Grafik Loss**


Kurva loss pelatihan menunjukkan tren penurunan yang konsisten dari awal hingga akhir pelatihan, bergerak dari sekitar 0.50 menuju nilai mendekati 0.33 pada epoch terakhir. Pola ini menunjukkan bahwa model secara progresif mampu meminimalkan kesalahan prediksi pada data pelatihan, menandakan bahwa parameter jaringan berhasil disesuaikan secara stabil selama proses optimisasi. Di sisi lain, loss validasi menunjukkan fluktuasi yang lebih signifikan. Meskipun nilai awal berada pada kisaran 0.70 dan sempat menurun hingga sekitar 0.44, kurva ini memperlihatkan beberapa lonjakan ekstrem, termasuk puncak pada sekitar epoch ke-8 dengan nilai mendekati 1.45. Fenomena ini mencerminkan adanya ketidakaturan pada proses generalisasi model selama tahap awal pembelajaran, yang dipengaruhi oleh sensitivitas terhadap distribusi data validasi atau karakteristik fitur tertentu yang belum stabil pada fase tersebut.

Meskipun demikian, pola keseluruhan kurva menunjukkan kecenderungan stabilisasi pada epoch pertengahan hingga akhir, dengan nilai loss validasi yang kembali bergerak mendekati loss

pelatihan pada epoch ke-15 hingga epoch terakhir. Kesamaan ini menunjukkan bahwa model pada akhirnya mampu melakukan penyesuaian representasi fitur yang lebih selaras antara data pelatihan dan validasi. Konsistensi penurunan loss pelatihan, diikuti dengan kecenderungan perbaikan loss validasi pada tahapan akhir, menandakan bahwa mekanisme regularisasi dan parameter pelatihan yang digunakan telah bekerja secara efektif dalam mencapai keseimbangan antara kemampuan belajar dan kemampuan generalisasi. Secara keseluruhan, visualisasi ini mendemonstrasikan bahwa model Attention-CNN berhasil mencapai stabilitas pembelajaran setelah melewati fase fluktuatif, sehingga siap untuk dievaluasi lebih lanjut pada tahap pengujian kinerja.

#### Hasil Evaluasi dan Analisis Kinerja

Berdasarkan pada 3 menunjukkan kinerja model Attention-CNN dalam mengklasifikasikan citra *benign* dan *malignant* berdasarkan Confusion Matrix hasil pengujian.



**Gambar 4 Confusion Matrix**

Model berhasil mengidentifikasi 298 sampel *benign* secara benar dan hanya melakukan 64 kesalahan prediksi. Pada kelas *malignant*, model mengklasifikasikan 262 sampel dengan tepat, sementara 35 sampel keliru teridentifikasi sebagai *benign*. Distribusi ini menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali kedua kelas, dengan pola sensitivitas dan spesifisitas yang relatif seimbang. Tingkat kesalahan yang muncul terutama terkait kemiripan pola visual antara beberapa citra *benign* dan *malignant*, yang berpotensi menimbulkan ambiguitas dalam proses inferensi model.

Berdasarkan hasil tersebut, akurasi keseluruhan model mencapai **84,97%**, menandakan bahwa model mampu mempelajari representasi fitur penting dari dataset secara efektif. Untuk memberikan gambaran performa yang lebih komprehensif, Tabel 4.3 menampilkan *classification*

report yang memuat nilai *precision*, *recall*, dan *f1-score* untuk masing-masing kelas. Pada kelas *benign*, model memperoleh *precision* sebesar 0.8949, *recall* sebesar 0.8232, dan *f1-score* sebesar 0.8575, yang menunjukkan bahwa model mampu mendeteksi mayoritas citra *benign* dengan tingkat kesalahan yang relatif rendah.

Pada Tabel 1 menyajikan hasil evaluasi performa model berdasarkan metrik klasifikasi utama, termasuk *precision*, *recall*, dan *f1-score* untuk masing-masing kelas *benign* dan *malignant*.

**Tabel 1 Classification Report**

|                     | <b>precision</b> | <b>recall</b> | <b>f1-score</b> | <b>support</b> |
|---------------------|------------------|---------------|-----------------|----------------|
| <b>benign</b>       | 0.89             | 0.82          | 0.85            | 362            |
| <b>malignant</b>    | 0.80             | 0.88          | 0.84            | 297            |
| <b>accuracy</b>     | 0.84             | 0.84          | 0.84            | 0.84           |
| <b>macro avg</b>    | 0.84             | 0.85          | 0.84            | 659            |
| <b>weighted avg</b> | 0.85             | 0.84          | 0.85            | 659            |


Berdasarkan Tabel 1 model mencapai akurasi keseluruhan sebesar 0.849772, menunjukkan kemampuan generalisasi yang baik terhadap data validasi. Pada kelas *benign*, *precision* sebesar 0.894895 menunjukkan bahwa sebagian besar prediksi *benign* yang dibuat model adalah benar, sementara *recall* sebesar 0.823204 mengindikasikan bahwa model mampu mendeteksi mayoritas sampel *benign* meskipun masih terdapat beberapa kasus yang tidak terklasifikasi dengan tepat. Nilai *f1-score* sebesar 0.857554 mencerminkan keseimbangan yang baik antara *precision* dan *recall* pada kelas ini.

Untuk kelas *malignant*, *precision* tercatat sebesar 0.803681, yang menunjukkan bahwa prediksi positif model untuk kategori ini berada pada tingkat akurasi yang cukup tinggi, meskipun masih di bawah kinerja pada kelas *benign*. Namun, *recall* untuk kelas *malignant* lebih tinggi, yakni 0.882155, menunjukkan bahwa model sangat sensitif dalam mendeteksi sampel *malignan* dan mampu mengidentifikasi sebagian besar kasus yang benar-benar positif. Nilai *f1-score* sebesar 0.841091 pada kelas *malignant* menggambarkan performa yang stabil dan konsisten. Rata-rata makro dan rata-rata berbobot dari seluruh metrik juga menunjukkan nilai yang seimbang, menandakan bahwa performa model tidak berat sebelah terhadap salah satu kelas. Secara keseluruhan, evaluasi ini memperlihatkan bahwa model Attention-CNN mampu memberikan kinerja

klasifikasi yang kuat, dengan kemampuan deteksi *malignansi* yang baik tanpa mengorbankan akurasi pada kelas *benign*.

#### Hasil Visualisasi Attention Map

Berdasarkan pada Gambar 4.5, menunjukkan hasil dari Visualisasi Attention Map, terdapat 2 hasil gambar berupa Citra *Malignant* (a) dan Hasil Pemetaan Grad-CAM (b)



**Gambar 5 Citra *Malignant* (a), Hasil Pemetaan Grad-CAM (b)**

Visualisasi Attention Map pada Gambar 5 Citra *Malignant* (a) menunjukkan bahwa model Attention-CNN mampu memfokuskan perhatian pada area-area kritis yang secara visual berkorelasi dengan pola keganasan. Pada citra asli, lesi tampak memiliki distribusi pigmen yang padat dan tidak merata, dengan batas bertekstur dan area pusat yang lebih gelap. Ketika diproyeksikan melalui Grad-CAM, area dengan intensitas warna merah dan kuning yang lebih tinggi muncul terutama pada zona tengah hingga tepi lesi, mengindikasikan bahwa model memberikan bobot signifikan pada region yang mengandung tingkat asimetri warna serta ketidakseragaman tekstur. Pola ini sesuai dengan karakteristik umum lesi *malignan* yang biasanya memperlihatkan distribusi pigmen tidak homogen dan struktur internal yang lebih kompleks dibandingkan lesi *benign*.


Lebih jauh, hasil visualisasi menunjukkan bahwa mekanisme attention berhasil menangkap fitur-fitur mikroskopik yang relevan seperti variasi densitas pigmen, gradasi warna gelap pada inti lesi, dan pola transisi warna yang tajam menuju bagian perifer. Intensitas aktivasi yang lebih kuat pada wilayah pusat menandakan bahwa model secara konsisten mengaitkan area tersebut dengan representasi keganasan, sedangkan aktivasi yang lebih rendah pada jaringan sekitar menunjukkan kemampuan model dalam mengabaikan informasi latar belakang yang tidak relevan. Temuan ini memberikan bukti bahwa integrasi Attention Block pada arsitektur CNN memperkuat sensitivitas model dalam mengidentifikasi ciri-ciri patologis penting, sekaligus memperjelas interpretabilitas

keputusan klasifikasi melalui pemetaan visual yang transparan.

Pada Gambar 5 Hasil Pemetaan Grad-CAM (b) menunjukkan pola aktivasi model terhadap citra malignant dengan tingkat keyakinan prediksi sebesar 64.94%. Peta perhatian memperlihatkan bahwa area yang disorot oleh model tidak hanya berfokus pada inti lesi di bagian tengah, tetapi juga secara signifikan menyoroti area di sisi kanan citra. Aktivasi berwarna kuning hingga merah pada sisi tersebut mengindikasikan bahwa model menilai region tersebut memiliki kontribusi penting terhadap keputusan klasifikasi. Pola ini menunjukkan bahwa model mendeteksi adanya variasi pigmentasi atau tekstur pada tepian lesi yang secara visual berbeda dari jaringan kulit sekitarnya. Meskipun aktivasi pada bagian tengah tetap muncul, intensitas yang lebih rendah dibandingkan sisi kanan mencerminkan bahwa model memberikan bobot yang lebih besar pada area dengan kontras warna yang lebih ekstrem.

Selain itu, sebaran aktivasi yang cenderung terlokalisasi pada area tertentu menunjukkan bahwa model mengidentifikasi fitur-fitur patologis secara selektif, meskipun distribusinya tidak sepenuhnya terpusat pada inti lesi sebagaimana biasa ditemukan dalam kasus malignant yang jelas. Hal ini mengindikasikan adanya kompleksitas pola warna atau tekstur pada citra tersebut yang mungkin mengaburkan batasan lesi sehingga model memerlukan informasi tambahan dari pinggiran lesi untuk melakukan klasifikasi. Munculnya aktivasi signifikan di bagian tepi juga dapat menunjukkan keberadaan fitur-fitur mikro yang tampak lebih kontras setelah proses normalisasi dan ekstraksi fitur. Secara keseluruhan, hasil visualisasi ini memperlihatkan bagaimana mekanisme attention memfasilitasi interpretabilitas keputusan model, sekaligus mengungkap area-area citra yang menjadi dasar utama prediksi malignant pada instance ini.

Berdasarkan pada Gambar 6, menunjukkan hasil dari Visualisasi Attention Map, terdapat 2 hasil gambar berupa Citra *Malignant* (a) dan Hasil Pemetaan Grad-CAM (b)



(a) (b)  
**Gambar 6 Citra *Malignant* (a), Hasil Pemetaan Grad-CAM (b)**


Visualisasi Grad-CAM pada Gambar 6 Citra *Malignant* (a) menunjukkan bahwa model memberikan fokus perhatian pada area-area dengan konsentrasi pigmen yang lebih padat dan bertekstur kompleks. Pada citra asli, lesi tampak memiliki distribusi warna kecokelatan yang tidak merata, dengan beberapa area yang menunjukkan pigmentasi lebih gelap. Ketika dipetakan menggunakan Grad-CAM, aktivasi dominan berwarna merah hingga kuning muncul terutama pada bagian tengah hingga area yang menunjukkan pola cabang atau percabangan pigmen. Hal ini mengindikasikan bahwa model menilai region dengan intensitas warna lebih pekat dan pola yang tidak seragam sebagai indikator penting dalam menentukan kategori malignant. Aktivasi yang tersebar di area pusat menunjukkan bahwa model mengaitkan struktur internal lesi yang kompleks dengan karakteristik keganasan.

Selain itu, peta perhatian menunjukkan bahwa area berpigmen lebih terang atau kurang kontras mendapatkan aktivasi yang jauh lebih rendah, menandakan kemampuan model dalam mengabaikan informasi yang dianggap kurang relevan terhadap proses klasifikasi. Pola aktivasi yang terlokalisasi pada bagian tertentu dari lesi memperlihatkan bahwa model mampu membedakan area dengan anomali visual yang lebih menonjol, seperti perbedaan densitas pigmen dan ketidakseragaman tekstur. Temuan ini memperkuat bahwa mekanisme perhatian dalam arsitektur Attention-CNN berhasil menangkap fitur-fitur patologis yang signifikan, sekaligus memberikan gambaran visual yang jelas mengenai dasar pengambilan keputusan model terhadap citra malignant ini.

Pada 6 Hasil Pemetaan Grad-CAM (b) memberikan gambaran mengenai area-area citra yang menjadi fokus utama model ketika menghasilkan prediksi benign dengan tingkat keyakinan sangat tinggi, yaitu 99.82%. Pada citra ini, pola aktivasi menunjukkan intensitas perhatian yang relatif rendah di sebagian besar permukaan lesi. Hal ini terlihat dari dominasi warna ungu dan merah muda yang menyatu dengan citra asli tanpa munculnya hotspot warna merah atau kuning yang biasanya menandakan identifikasi fitur berisiko tinggi. Ketidadaan pola aktivasi kuat pada pusat lesi mengindikasikan bahwa model tidak menemukan struktur atau tekstur yang menyerupai ciri khas malignansi, seperti distribusi pigmen yang tidak teratur, gradien warna tajam, atau area asimetris yang biasanya menjadi indikator diagnostik.

Selain itu, area berwarna lebih cerah yang muncul sporadis di bagian bawah dan tepi kanan citra menunjukkan adanya respons minimal terhadap variasi lokal pada piksel, namun intensitasnya tidak cukup signifikan untuk memengaruhi keputusan model. Pola aktivasi yang tidak terfokus dan tidak membentuk kontur struktural menjadi indikasi kuat bahwa model menilai lesi sebagai benign secara konsisten. Visualisasi ini memperlihatkan bahwa mekanisme attention melalui Grad-CAM tidak hanya mendukung kemampuan prediktif model, tetapi juga memberikan pemahaman interpretatif bahwa prediksi benign dibuat berdasarkan absennya fitur patologis yang relevan, sehingga memperkuat validitas keputusan model pada kasus ini.

Berdasarkan pada Gambar 7, menunjukkan hasil dari Visualisasi Attention Map, terdapat 2 hasil gambar berupa Citra *benign* (a) dan Hasil Pemetaan Grad-CAM (b)



**Gambar 7 Citra *benign* (a), Hasil Pemetaan Grad-CAM (b)**

Visualisasi pada Gambar 7 Citra *benign* (a) menampilkan citra benign dengan karakteristik morfologis yang relatif seragam dan tidak menunjukkan pola pigmentasi yang mengarah pada indikasi keganasan. Citra memperlihatkan distribusi warna merah muda hingga merah kecoklatan yang tersebar secara merata, tanpa adanya batas tepi yang jelas maupun gradien warna yang tajam. Struktur permukaan lesi tampak homogen dan tidak menunjukkan adanya area dengan konsentrasi pigmen tinggi yang biasanya berkaitan dengan pola asimetris atau pertumbuhan sel yang tidak terkontrol. Tampilan ini mencerminkan ciri umum lesi jinak, seperti penyebaran pigmen yang lembut dan ketiadaan variasi kontras ekstrem pada bagian inti maupun tepi lesi.

Ketiadaan area gelap pekat atau irregular structure pada citra menjadi indikasi penting yang membedakan lesi benign dari lesi malignant. Permukaan lesi tampak halus dengan pola warna yang terdistribusi secara gradual, menunjukkan tidak adanya komponen visual yang berpotensi memicu aktivasi kuat pada model klasifikasi.

Dengan demikian, citra pada Gambar 7 Citra *benign* (a) memberikan konteks visual yang konsisten dengan hasil klasifikasi benign pada tahap analisis selanjutnya, serta mendukung interpretasi bahwa pola-pola tekstural dan warna yang ditampilkan tidak memenuhi karakteristik yang umum ditemukan pada lesi berisiko tinggi.

Visualisasi Grad-CAM pada Gambar 7 menunjukkan pola perhatian model terhadap citra benign dengan tingkat keyakinan prediksi sebesar 99.77%. Secara umum, peta aktivasi menampilkan intensitas warna yang rendah dan menyatu dengan citra asli, mengindikasikan bahwa model tidak menemukan fitur berisiko tinggi yang biasanya diasosiasikan dengan keganasan. Ketidadaan hotspot berwarna merah atau kuning terang pada area pusat lesi menunjukkan bahwa struktur tekstural maupun distribusi pigmen di wilayah tersebut tidak dianggap penting oleh model dalam membentuk keputusan klasifikasi malignant. Sebaliknya, perhatian model dominan tersebar secara halus pada area berwarna merah muda hingga ungu, yang memperlihatkan bahwa fitur yang ditangkap lebih bersifat normal dan tidak memiliki pola kontras tinggi.

Terdapat beberapa aktivasi kecil berwarna cerah pada bagian tepi kiri dan area tertentu di bagian bawah citra, namun intensitasnya rendah dan tidak membentuk pola kontur yang menandai karakteristik patologis. Aktivasi sporadis seperti ini mengindikasikan bahwa model hanya merespons gangguan minor pada nilai piksel, tetapi tidak menganggapnya sebagai informasi diagnostik signifikan. Secara keseluruhan, pola Grad-CAM pada Gambar 7 Hasil Pemetaan Grad-CAM (b) memperkuat validitas keputusan model bahwa lesi tersebut benign, karena tidak ada fokus perhatian yang konsisten terhadap struktur pigmen tidak teratur, batas konvolusi yang tegas, atau area asimetri yang biasanya hadir pada lesi malignant. Visualisasi ini juga menunjukkan bahwa model mampu membedakan tekstur jinak dengan baik dan memberikan dasar interpretatif yang kuat terhadap hasil klasifikasinya.

## CONCLUSION

Penelitian ini membuktikan bahwa informasi warna RGB memberi pengaruh terukur terhadap peningkatan akurasi deteksi dini kanker pada citra berdimensi tetap menggunakan Attention-based Neural Network. Model mencapai akurasi pengujian sebesar 84,97%, yang mengindikasikan bahwa penggabungan warna dengan mekanisme perhatian meningkatkan kemampuan model dalam membedakan citra benign dan malignant. Nilai F1-score kategori benign sebesar 0,8575 dan recall sebesar 0,8232 menunjukkan bahwa model mampu

menjaga keseimbangan antara deteksi benar dan minimnya kesalahan klasifikasi. Temuan ini menegaskan bahwa tujuan penelitian, yaitu mengevaluasi peran warna RGB dalam meningkatkan performa sistem deteksi dini kanker, telah tercapai.

Penelitian ini memberi kontribusi ilmiah berupa pemahaman baru tentang bagaimana model perhatian memanfaatkan perbedaan intensitas warna untuk menonjolkan area penting pada citra. Visualisasi Grad-CAM memperlihatkan bahwa model fokus pada area lesi secara lebih tepat pada kasus true positive, sementara kesalahan terjadi pada citra dengan lesi yang kecil atau warna yang kurang kontras. Pola perhatian yang konsisten pada citra tertentu menunjukkan bahwa informasi warna dapat memperkaya representasi fitur dan meningkatkan interpretabilitas model. Kontribusi ini memperluas literatur terkait pemanfaatan warna dalam sistem deteksi kanker berbasis deep learning.

Penelitian ini memiliki keterbatasan pada ukuran dataset, variasi warna antar-citra, dan keberagaman karakteristik lesi. Beberapa kesalahan klasifikasi, seperti hasil false negative dan false positive pada confusion matrix, menunjukkan bahwa model masih sensitif terhadap noise visual dan variasi warna yang ekstrem. Keterbatasan ini mengarah pada perlunya peningkatan kualitas data dan eksplorasi teknik preprocessing yang mampu mempertahankan karakteristik warna secara optimal. Meski demikian, hasil penelitian memberi bukti kuat bahwa integrasi warna RGB dan mekanisme perhatian meningkatkan efektivitas sistem deteksi dini kanker.

## REFERENCE

- Abbasian Ardakani, G., & al., et. (2024). Interpretation of Artificial Intelligence Models in Healthcare: Evaluation metrics, pitfalls and recommendations. *Journal of Ultrasound in Medicine*. <https://doi.org/10.1002/jum.16524>
- Akbarinia, A., & Gil-Rodríguez, R. (2021a). Attention mechanisms in CNN-based single image super-resolution: A brief review and a new perspective. *Electronics*, 10(10), 1187. <https://doi.org/10.3390/electronics10101187>
- Akbarinia, A., & Gil-Rodríguez, R. (2021b). Color conversion in deep autoencoders. *Journal of Perceptual Imaging*, 4(2), 20401–20410. <https://doi.org/10.2352/J.Percept.Imaging.2021.4.2.020401>
- Aldakhil, L. A., Alhasson, H. F., & Alharbi, S. S. (2024). Attention-based deep learning approach for breast cancer histopathological image multi-classification. *Diagnostics*, 14(13), 1402. <https://doi.org/10.3390/diagnostics14131402>
- An, J., & Joe, I. (2022). Attention Map-Guided Visual Explanations for Deep Neural Networks. *Applied Sciences*, 12(8), 3846. <https://doi.org/10.3390/app12083846>
- Apostolopoulos, I. D., Apostolopoulos, P.-A., Adamopoulos, A., Tzovaras, D., & Papatthanasiou, N. D. (2023). An attention-based deep convolutional neural network for brain tumor classification. *Information*, 14(3), 174. <https://doi.org/10.3390/info14030174>
- Armato, S. G. 3rd, Drukker, K., & Hadjiiski, L. (2023). AI in medical imaging grand challenges: Translation from competition to research benefit and patient care. *The British Journal of Radiology*, 96(1150), 20221152. <https://doi.org/10.1259/bjr.20221152>
- Attallah, O., & Tan, R.-S. (2021). Color-CADx: A deep learning approach for colorectal cancer classification through triple convolutional neural networks and discrete cosine transform. *Diagnostics*, 11(7), 1234. <https://doi.org/10.3390/diagnostics11071234>
- Baughan, N., Whitney, H. M., Drukker, K., Sahiner, B., Hu, T., Kim, G. H., McNitt-Gray, M., Myers, K. J., & Giger, M. L. (2023). Sequestration of imaging studies in MIDRC: Stratified sampling to balance demographic characteristics of patients in a multi-institutional data commons. *Journal of Medical Imaging*, 10(6), 64501. <https://doi.org/10.1117/1.JMI.10.6.064501>
- Bhuiyan, S., & Rezaei, J. (2022). Which color channel is better for diagnosing retinal diseases automatically in color fundus photographs? *Life*, 12(7), 973. <https://doi.org/10.3390/life12070973>
- Bontempi, D., Nuernberg, L., & Krishnaswamy, D. (2024). End-to-end reproducible AI pipelines in radiology using the cloud. *Nature Communications*, 15, 51202. <https://doi.org/10.1038/s41467-024-51202-2>
- Brancati, N., Anniciello, A. M., Pati, P., Riccio, D., Scognamiglio, G., Jaume, G., De Pietro, G., Di Bonito, M., Foncubierta, A., Botti, G., Gabrani, M., Feroce, F., & Frucci, M. (2022). BRACS: A dataset for BReAst carcinoma subtyping in H&E histology images. *Database (Oxford)*, 2022, baac093. <https://doi.org/10.1093/database/baac093>
- Cardoso, M. J., Li, W., Brown, R., & al., et. (2022). MONAI: An open-source framework for deep learning in healthcare. *Nature Communications*. <https://doi.org/10.1038/s41467-022-35372-5>
- Chen, S., Xiao, N., Shi, X., Yang, Y., Tan, H., Tian, J., & Quan, Y. (2023). ColorMedGAN: A semantic colourisation framework for medical images. *Applied Sciences*, 13(5), 3168. <https://doi.org/10.3390/app13053168>
- Cheng, X., Xian, M.-F., Tian, W.-S., Li, M.-D., Hu, H.-T., Li, W., Zhang, J.-C., Huang, Y., Xie, X.-Y., Lu, M.-D., Kuang, M., Wang, W., Ruan, S.-M., & Chen, L.-D. (2021). RGB three-channel SWE-based ultrasonics model: Improving the efficiency in differentiating focal liver lesions. *Frontiers in Oncology*, 11, 704218. <https://doi.org/10.3389/fonc.2021.704218>
- Demircioğlu, A. (2023). A remark on using data twice in cross-validation schemes. *Radiology: Artificial Intelligence*. <https://doi.org/10.1148/ryai.230202>
- Elazab, A., Keskinarkaus, A., Nyberg, P., & Seppänen, T. (2024). Computer-aided diagnosis system for grading brain tumour using histopathology images based on colour and texture features. *BMC Medical Imaging*, 24, 177. <https://doi.org/10.1186/s12880-024-01355-9>
- Elazab, N., Gab Allah, W., & Elmogy, M. (2024). Computer-aided diagnosis system for grading brain tumor using histopathology images based on color and texture features. *BMC Medical Imaging*, 24, 177. <https://doi.org/10.1186/s12880-024-01355-9>
- Ghaffarian, S., Valente, J., van der Voort, M., & Tekinerdogan, B. (2021). Effect of attention mechanism in deep learning-based remote sensing image processing: A systematic literature review. *Remote Sensing*, 13(15), 2965. <https://doi.org/10.3390/rs13152965>
- Goceri, E., & Yildirim, M. (2023). Medical image data augmentation: Techniques, challenges and applications.

- Artificial Intelligence Review.*  
<https://doi.org/10.1007/s10462-023-10453-z>
- González, M. (2024). Integrating color histogram analysis and convolutional neural networks for skin lesion classification. *Computers in Biology and Medicine*, 109250. <https://doi.org/10.1016/j.compbimed.2024.109250>
- Gottlich, H. C., Gregory, A., Sharma, V., Kline, T., & al., et. (2023). Effect of dataset size and medical image modality on convolutional neural network model performance for automated segmentation: A CT and MR renal tumor imaging study. *Journal of Digital Imaging*. <https://doi.org/10.1007/s10278-023-00804-1>
- Gu, C., & Lee, M. (2024). Deep transfer learning using real-world image features for medical image classification, with a case study on pneumonia X-ray images. *Bioengineering*, 11(4), 406. <https://doi.org/10.3390/bioengineering11040406>
- Gu, R., Wang, G., Song, T., Huang, R., Aertsen, M., Deprest, J., Ourselin, S., Vercauteren, T., & Zhang, S. (2021). CA-Net: Comprehensive attention convolutional neural networks for explainable medical image segmentation. *IEEE Transactions on Medical Imaging*, 40(3), 699–711. <https://doi.org/10.1109/TMI.2020.3035253>
- Guo, M.-H., Xu, T.-X., Liu, J.-J., Liu, Z.-N., Jiang, P.-T., Mu, T.-J., Zhang, S.-H., Martin, R. R., Cheng, M.-M., & Hu, S.-M. (2022). Attention mechanisms in computer vision: A survey. *Computational Visual Media*, 8(3), 331–368. <https://doi.org/10.1007/s41095-022-0271-y>
- Hakkoum, H. (2022). Interpretability in the medical field: A systematic mapping. *Clinical Biomechanics*, 97, 105602. <https://doi.org/10.1016/j.clinbiomech.2022.105602>
- Hameed, Z., Garcia-Zapirain, B., Aguirre, J. J., Isaza-Ruget, M. A., & Others. (2022). Multiclass classification of breast cancer histopathology images using multilevel features of deep convolutional neural network. *Scientific Reports*, 12, 15600. <https://doi.org/10.1038/s41598-022-19278-2>
- Hermosilla, P., Soto, R., & Torres, R. (2024). Skin cancer detection and classification using neural network algorithms: A systematic review. *Diagnostics*, 14(4), 454. <https://doi.org/10.3390/diagnostics14040454>
- Hicks, S. A., & al., et. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12, 13742. <https://doi.org/10.1038/s41598-022-09954-8>
- Hoque, M. Z., Keskinarkaus, A., Nyberg, P., & Seppänen, T. (2024). Stain normalization methods for histopathology image analysis: A comprehensive review and experimental comparison. *Information Fusion*, 102, 101997. <https://doi.org/10.1016/j.inffus.2023.101997>
- Hosseini, M. S., Bejnordi, B. E., Trinh, V. Q., Chan, L., Hasan, D., Li, X., Yang, S., & Others. (2024). Computational pathology: A survey review and the way forward. *Journal of Pathology Informatics*, 15, 100357. <https://doi.org/10.1016/j.jpi.2023.100357>
- Huff, D. T., Weisman, A. J., & Jeraj, R. (2021). Interpretation and Visualization Techniques for Deep Learning Models in Medical Imaging. *Physics in Medicine & Biology*, 66, 04TR01. <https://doi.org/10.1088/1361-6560/abeb46>
- Innat, M., Hossain, M. F., Mader, K., & Kouzani, A. Z. (2023). A convolutional attention mapping deep neural network for classification and localization of cardiomegaly on chest X-rays. *Scientific Reports*, 13, 6247. <https://doi.org/10.1038/s41598-023-32611-7>
- Inoue, K., Jiang, M., & Hara, K. (2021). Hue-Preserving Saturation Improvement in RGB Color Cube. *J. Imaging*, 7(8), 150. <https://doi.org/10.3390/jimaging7080150>
- Jiang, B. (2024). Deep learning applications in breast cancer histopathological image analysis: review and future directions. *Breast Cancer Research*, 26, 18. <https://doi.org/10.1186/s13058-024-01895-6>
- Jiang, X., Hu, Z., Wang, S., & Zhang, Y. (2023). Deep learning for medical image-based cancer diagnosis. *Cancers*, 15(14), 3608. <https://doi.org/10.3390/cancers15143608>
- Jiang, Z., Wang, Y., Shi, C. W., Wu, Y., Hu, R., Chen, S., Hu, S., Wang, X., Qiu, B., Xie, Y., Yang, B., Guan, Q., Zhang, J., & Wu, Q. (2022). Attention Mechanisms in Medical Image Segmentation: A Survey. In *Human Brain Mapping* (Vol. 43, Issue 8). <https://doi.org/10.48550/arXiv.2305.17937>
- Jiao, J., Li, Q., & Zhu, L. (2024). A Modified MobileNetV3 Model Using an Attention Mechanism for Eight-Class Classification of Breast Cancer Pathological Images. *Applied Sciences*, 14(17), 7564. <https://doi.org/10.3390/app14177564>
- Jones, A., Lee, H., & Kim, D. (2023). CNN stability training improves robustness to scanner and IHC-based image variability for epithelium segmentation in cervical histology. *Scientific Reports*, 13. <https://doi.org/10.3389/fmed.2023.1173616>
- Keni, S., & al., et. (2024). Evaluating artificial intelligence for medical imaging: a primer for clinicians. *Health Management, Policy and Innovation*, 9(1). <https://doi.org/10.12968/hmed.2024.0312>
- Kim, Y. J., Ju, W., Nam, K. H., Kim, S. N., Kim, Y. J., & Kim, K. G. (2022). RGB channel superposition algorithm with acetowhite mask images in a cervical cancer classification deep learning model. *Sensors*, 22(9), 3564. <https://doi.org/10.3390/s22093564>
- Kline, T. L., & al., et. (2025). Best practices and checklist for reviewing artificial intelligence-based image classification studies. *Journal of Digital Imaging*. <https://doi.org/10.1007/s10278-025-01548-w>
- Kline, T. L., Kitamura, F., Pan, I., Korchi, A. M., Tenenholtz, N., & Moy, L. (2025). Best practices and checklist for reviewing artificial intelligence-based medical imaging papers: Classification. *Journal of Imaging Informatics in Medicine*. <https://doi.org/10.1007/s10278-025-01548-w>
- Klontzas, M. E., Huisman, H., Santinha, J., Vernuccio, F., Visser, J. J., & Huisman, M. (2025). ESR essentials: Common performance metrics in AI—practice recommendations by the European Society of Medical Imaging Informatics. *European Radiology*, 35(1), 259–272. <https://doi.org/10.1007/s00330-025-11890-w>
- Kocak, B., & al., et. (2025). Evaluation metrics in medical imaging AI. *Medical Physics International*, 11(2), 88–97. <https://doi.org/10.1016/j.mxi.2025.1000283>
- Koenderink, J., van Doorn, A., & Gegenfurtner, K. (2021). RGB Colors and Ecological Optics. *Frontiers in Computer Science*, 3, 630370. <https://doi.org/10.3389/fcomp.2021.630370>
- Krichen, M. (2023). Convolutional neural networks: A survey. *Computers*, 12(8), 151. <https://doi.org/10.3390/computers12080151>
- Kunthoth, S., & Al-Maadeed, S. (2024). An analytical study on the utility of RGB and multispectral imagery with band selection for automated tumor grading. *Diagnostics*, 14(15), 1625. <https://doi.org/10.3390/diagnostics14151625>
- Laçi, H., & al., et. (2025). Deep learning approaches for classification tasks in medical X-ray imaging. *BMC Medical Imaging*. <https://doi.org/10.1186/s12880-025-01701-5>
- Latif, G., Alghazo, J., Khan, M. A., Ben Brahim, G., Fawagreh, K., & Mohammad, N. (2024). Deep convolutional neural network (CNN) model optimization techniques—Review for medical imaging. *AIMS Mathematics*, 9(8), 20539–20571. <https://doi.org/10.3934/math.2024998>
- Leinonen, T., Wong, D., Airola, A., Vasankari, A., Kaisti, M., & others. (2024). Empirical investigation of multi-source cross-validation in clinical machine learning. *Computers in Biology and Medicine*, 183, 109271. <https://doi.org/10.1016/j.compbimed.2024.109271>
- Li, M., Jiang, Y., Zhang, Y., & Zhu, H. (2023). Medical image analysis using deep learning algorithms. *Frontiers in Public Health*, 11, 1273253. <https://doi.org/10.3389/fpubh.2023.1273253>
- Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., & Yin, S. (2023). Deep learning attention mechanism in medical image analysis:

- Basics and beyond. *International Journal of Network Dynamics and Intelligence*, 2(1), 93–116. <https://doi.org/10.53941/ijndi0201006>
- Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., & Yin, S. (2024a). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57, 99. <https://doi.org/10.1007/s10462-024-10721-6>
- Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., & Yin, S. (2024b). A symmetric efficient spatial and channel attention (ESCA) module based on convolutional neural networks. *Symmetry*, 16(8), 952. <https://doi.org/10.3390/sym16080952>
- Lin, S., Zhou, H., Watson, M., Govindan, R., Côté, R. J., & Yang, C. (2025). Impact of stain variation and color normalization for prognostic predictions in pathology. *Scientific Reports*, 15, 2369. <https://doi.org/10.1038/s41598-024-83267-w>
- Madani, M., Behzadi, M. M., & Nabavi, S. (2022). The role of deep learning in advancing breast cancer detection using different imaging modalities: A systematic review. *Cancers*, 14(21), 5334. <https://doi.org/10.3390/cancers14215334>
- Mienye, I. D. (2025). Deep convolutional neural networks in medical image analysis: a systematic review. *Information*, 16(3), 195. <https://doi.org/10.3390/info16030195>
- Moassefi, M., Singh, Y., Conte, G. M., Khosravi, B., Rouzrokh, P., Vahdati, S., & Erickson, B. (2024). Checklist for reproducibility of deep learning in medical imaging. *Journal of Imaging Informatics in Medicine*, 37, 1664–1673. <https://doi.org/10.1007/s10278-024-01065-2>
- Mohammed, F. A., & al., et. (2024). Medical image classifications using convolutional neural networks. *Inventions*, 6(1), 33. <https://doi.org/10.3390/inventions6010033>
- Müller, D., Soto-Rey, I., & Kramer, F. (2022). Towards a guideline for evaluation metrics in medical image segmentation. *BMC Research Notes*, 15, 210. <https://doi.org/10.1186/s13104-022-06096-y>
- Naeem, A., Anees, T., Fiza, M., Naqvi, R. A., & Lee, S.-W. (2022). SCDNet: A deep learning-based framework for the multiclassification of skin cancer using dermoscopy images. *Sensors*, 22(15), 5652. <https://doi.org/10.3390/s22155652>
- Naqvi, M., Gilani, S. Q., Syed, T., Marques, O., & Kim, H.-C. (2023). Skin cancer detection using deep learning—A review. *Diagnostics*, 13(11), 1911. <https://doi.org/10.3390/diagnostics13111911>
- Nazir, S. (2023). Survey of explainable artificial intelligence (XAI) techniques for biomedical imaging diagnostics. *Artificial Intelligence in Medicine*, 138, 102955. <https://doi.org/10.1016/j.artmed.2023.102955>
- Nirthika, R., Manivannan, S., Ramanan, A., & Wang, R. (2022). Pooling in convolutional neural networks for medical image analysis: A survey and an empirical study. *Neural Computing and Applications*, 34(7), 5321–5347. <https://doi.org/10.1007/s00521-022-06953-8>
- Pang, B., Chen, L., Tao, Q., Wang, E., & Yu, Y. (2024). GA-UNet: A lightweight Ghost and attention U-Net for medical image segmentation. *Journal of Imaging Informatics in Medicine*, 37(4), 1874–1888. <https://doi.org/10.1007/s10278-024-01070-5>
- Perera, R., al., et, Alzubaidi, L., Humaidi, A. J., Al-Shamma, O., Farhan, L., Kumar, A., Waleed, H., Perera, R., & al., et. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Petríková, D., & Cimrák, I. (2023). Survey of recent deep neural networks with strong annotated supervision in histopathology. *Computation*, 11(4), 81. <https://doi.org/10.3390/computation11040081>
- Purwono, P., Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I., Kusuma, F., & Haq, Q. M. U. (2023). Understanding of convolutional neural network (CNN): A review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Rafiq, M. I., Irtaza, A., Iqbal, S., & Mehmood, I. (2023). Detection and classification of histopathological breast images using a fusion of CNN frameworks. *Diagnostics*, 13(11), 1933. <https://doi.org/10.3390/diagnostics13111933>
- Raghu, M., & Others. (2021). A primer on deep learning and convolutional neural networks for clinicians. *Insights into Imaging*, 12(1), 1–18. <https://doi.org/10.1186/s13244-021-01052-z>
- Rahman, M. A. (2025). Advancements in breast cancer detection: A review of machine and deep learning approaches. *Journal of Imaging Technology*, 5(3), 46. <https://doi.org/10.3390/jimaging5030046>
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14, 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- Rane, N. L., Mallick, S. K., Kaya, Ö., & Rane, J. (2024). Tools and frameworks for machine learning and deep learning: A review. In *Applied Machine Learning and Deep Learning: Architectures and Techniques*. [https://doi.org/10.70593/978-81-981271-4-3\\_4](https://doi.org/10.70593/978-81-981271-4-3_4)
- Saleh, N., Hassan, M. A., & Salaheldin, A. M. (2024). Skin cancer classification based on an optimized convolutional neural network and multicriteria decision-making. *Scientific Reports*, 14, 17323. <https://doi.org/10.1038/s41598-024-67424-9>
- Salmi, M., Atif, D., Oliva, D., Abraham, A., & Ventura, S. (2024). Handling imbalanced medical datasets: Review of a decade of research. *Artificial Intelligence Review*, 57, 273. <https://doi.org/10.1007/s10462-024-10884-2>
- Sani, A. F., Khoirunisa, R., Riatma, D. L., & Rachman, Y. F. (2024). Benchmarking GPU passthrough performance on Docker for AI cloud system. *Brilliance: Research of Artificial Intelligence*, 5(2). <https://doi.org/10.47709/brilliance.v5i2.6794>
- Sun, G., Yan, X., Wang, H., Li, F., Yang, R., Xu, J., & Others. (2023). Color restoration based on digital pathology image. *PLOS ONE*, 18(6), e0287704. <https://doi.org/10.1371/journal.pone.0287704>
- Tan, S. L., Selvachandran, G., Ding, W., Paramesran, R., & Kotecha, K. (2024). Cervical cancer classification from Pap smear images using deep convolutional neural network models. *Interdisciplinary Sciences: Computational Life Sciences*, 16. <https://doi.org/10.1007/s12539-023-00589-5>
- Tang, D., Chen, J., Ren, L., Wang, X., Li, D., & Zhang, H. (2024). Reviewing CAM-based deep explainable methods in healthcare. *Applied Sciences*, 14(10), 4124. <https://doi.org/10.3390/app14104124>
- Thambawita, V., Strümke, I., Hicks, S. A., Halvorsen, P., Parasa, S., & Riegler, M. A. (2021). Impact of image resolution on deep learning performance in endoscopy image classification: An experimental study using a large dataset of endoscopic images. *Diagnostics*, 11(12), 2183. <https://doi.org/10.3390/diagnostics11122183>
- Uddin, J. (2024). Attention-based DenseNet for lung cancer classification using CT scan and histopathological images. *Designs*, 8(2), 27. <https://doi.org/10.3390/designs8020027>
- Varoquaux, G., & Cheplygina, V. (2022). Machine learning for medical imaging: Methodological failures and recommendations for the future. *NPJ Digital Medicine*, 5, 48. <https://doi.org/10.1038/s41746-022-00592-y>
- Velastegui, V., & Pedersen, S. (2024). Analysis of the impact of color spaces on skin cancer diagnosis using deep learning techniques. *Research and Innovation in Artificial Intelligence*, 37(6). <https://doi.org/10.18280/ria.370601>
- Voon, W., Hum, Y. C., Tee, Y. K., Yap, W.-S., Nisar, H., Mokayed, H., Gupta, N., & Lai, K. W. (2023). Evaluating the effectiveness of stain normalization techniques in automated grading of invasive ductal carcinoma histopathological images. *Scientific Reports*, 13, 20518. <https://doi.org/10.1038/s41598-023-46619-6>

- Walsh, R., & Tardy, M. (2023). A comparison of techniques for class imbalance in deep learning classification of breast cancer. *Diagnostics*, 13(1), 67. <https://doi.org/10.3390/diagnostics13010067>
- Wang, A. (2025). A review of convolutional neural networks: Evolution, applications, and future directions. *Applied and Computational Engineering*, 166. <https://doi.org/10.54254/2755-2721/2025.TJ24492>
- Wang, J.-Z., Lu, N.-H., Du, W.-C., Liu, K.-Y., Hsu, S.-Y., Wang, C.-Y., Chen, Y.-J., Chang, L.-C., Twan, W.-H., Chen, T.-B., & Huang, Y.-H. (2023). Classification of color fundus photographs using fusion extracted features and customized CNN models. *Healthcare*, 11(15), 2228. <https://doi.org/10.3390/healthcare11152228>
- Wang, Y., Wang, W., Li, Y., Jia, Y., Xu, Y., Ling, Y., & Ma, J. (2024). An attention mechanism module with spatial perception and channel information interaction. *Complex & Intelligent Systems*, 10, 5427–5444. <https://doi.org/10.1007/s40747-024-01445-9>
- Wu, Y., Chen, B., Zeng, A., Pan, D., Wang, R., & Zhao, S. (2022). Skin cancer classification with deep learning: A systematic review. *Frontiers in Oncology*, 12, 893972. <https://doi.org/10.3389/fonc.2022.893972>
- Xie, Y., Yang, B., Guan, Q., Zhang, J., & Wu, Q. (2023). *Attention Mechanisms in Medical Image Segmentation: A Survey*. arXiv. <https://doi.org/10.48550/arXiv.2305.17937>
- Xue, Y., & Yuan, Z. (2022). HDAM: Heuristic Difference Attention Module for Convolutional Neural Networks. *Journal on Internet of Things*, 4(1), 47737. <https://doi.org/10.32604/jiot.2022.025327>
- Yilmaz, M. T. (2025). A comparative study of advanced deep learning architectures for medical image classification. *Results in Engineering*, 17, 100412. <https://doi.org/10.1016/j.rineng.2025.100412>
- Zafar, A., Aamir, M., & Alruban, A. (2022). Convolutional neural networks: A comprehensive evaluation and benchmarking of pooling layer variants. *Symmetry*, 16(11), 1516. <https://doi.org/10.3390/sym16111516>
- Zangana, H. M., Khalid Mohammed, A., Sallow, Z. B., & Mustafa, F. M. (2024). Exploring image representation and color spaces in computer vision: A comprehensive review. *The Indonesian Journal of Computer Science*, 13(3), 3998. <https://doi.org/10.33022/ijcs.v13i3.3998>
- Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., van Ginneken, B., Madabhushi, A., Prince, J. L., Rueckert, D., & Summers, R. M. (2021a). A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises. *Proceedings of the IEEE*, 109(5), 820–838. <https://doi.org/10.1109/JPROC.2021.3054390>
- Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., van Ginneken, B., Madabhushi, A., Prince, J. L., Rueckert, D., & Summers, R. M. (2021b). A review of deep learning in medical imaging. *Proceedings of the IEEE*, 109(5), 820–838. <https://doi.org/10.1109/JPROC.2021.3054390>