

Arsitektur Hibrida CNN–LSTM Berbasis Retinex untuk Deteksi Lesi Periapikal pada Radiograf CBCT–Panoramik

Safar Dwi Kurniawan ^{1*}, David Bani Adam ², Tri Haryo Nugroho ³

¹ Universitas Harkat Negeri 1; safar.kurniawan45@gmail;

² Affiliation 2; e-mail@e-mail.com

* Korespondensi: safar.kurniawan45@gmail

Info Artikel:

Dikirim: 25 Oktober 2025

Direvisi: 21 November 2025

Diterima: 30 November 2025

Abstract: Periapical lesion detection plays a crucial role in endodontic diagnosis; however, manual interpretation of Cone-Beam Computed Tomography (CBCT) and panoramic radiographs remains time-consuming, highly dependent on the clinician's expertise, and susceptible to diagnostic variability. This study proposes a hybrid deep learning framework that integrates a Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) architecture, combined with Retinex-based image enhancement, for the automatic detection and classification of periapical lesions. Retinex enhancement is employed as a preprocessing step to normalize illumination and improve lesion contrast. The hybrid CNN-LSTM model captures both spatial and contextual dependencies through sequential patch-based processing of panoramic and CBCT images. Using a dataset of 1,500 annotated images collected from clinical radiographic datasets and publicly available sources, the proposed model achieved an accuracy of 97.8%, precision of 96.4%, recall of 95.9%, and an F1-score of 0.96, significantly outperforming conventional CNN and U-Net models. These findings demonstrate that the integration of image enhancement and hybrid deep learning improves sensitivity to small lesions while reducing false-negative detections, offering a clinically viable AI-assisted approach for endodontic diagnosis.

Keywords: Deep Learning; CNN-LSTM; Retinex; Periapical Lesions; Cone-Beam Computed Tomography (CBCT); Panoramic Radiography.

Intisari: Deteksi lesi periapikal berperan penting dalam diagnosis endodontik, namun interpretasi manual terhadap Cone-Beam Computed Tomography (CBCT) dan radiograf panoramik masih memerlukan waktu, bergantung pada pengalaman klinisi, serta rentan terhadap variasi diagnostik. Penelitian ini mengusulkan kerangka deep learning hibrida yang mengintegrasikan arsitektur Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM), dikombinasikan dengan peningkatan kualitas citra berbasis Retinex, untuk mendeteksi dan mengklasifikasikan lesi periapikal secara otomatis. Peningkatan Retinex diterapkan sebagai tahap praproses untuk menormalkan iluminasi dan meningkatkan kontras lesi. Model hibrida CNN-LSTM menangkap dependensi spasial dan kontekstual melalui pemrosesan patch sekuensial dari citra panoramik dan CBCT. Dengan menggunakan dataset 1.500 citra beranotasi yang dikumpulkan dari dataset radiografi klinis dan sumber terbuka, model yang diusulkan mencapai akurasi 97,8%, presisi 96,4%, recall 95,9%, dan F1-score 0,96, serta mengungguli model pembanding CNN dan U-Net secara signifikan. Hasil ini menunjukkan bahwa integrasi peningkatan citra dan deep learning hibrida dapat meningkatkan sensitivitas terhadap lesi kecil serta menurunkan false negative, sehingga menawarkan pendekatan yang layak secara klinis untuk diagnosis endodontik berbantuan AI.

Kata Kunci: Deep Learning; CNN-LSTM; Retinex; Lesi Periapikal; CBCT; Radiograf Panoramik

1. Pendahuluan

Lesi periapikal merupakan kondisi patologis pada apeks akar gigi yang umumnya disebabkan oleh nekrosis pulpa atau infeksi bakteri yang menyebar melalui sistem saluran akar. Lesi ini termasuk salah satu kondisi inflamasi yang paling sering ditemukan dalam endodontik dan dapat muncul sebagai granuloma, kista, atau abses. Apabila tidak ditangani, kondisi tersebut berpotensi menyebabkan destruksi tulang alveolar, mobilitas gigi, dan nyeri kronis [1], [2]. Diagnosis dini dan akurat terhadap lesi periapikal sangat penting untuk menentukan strategi perawatan yang tepat serta mencegah komplikasi seperti osteomielitis atau kehilangan gigi. Namun, interpretasi manual terhadap radiograf dental, baik radiograf periapikal, panoramik, maupun Cone-Beam Computed Tomography (CBCT), masih sangat bergantung pada keahlian klinisi dan rentan terhadap variabilitas antar-pengamat [3].

Perkembangan CBCT telah meningkatkan visualisasi patologi periapikal dibandingkan radiografi konvensional [4]. Meskipun demikian, lesi kecil dengan resorpsi tulang yang terbatas atau lesi yang berada pada area anatomi kompleks, misalnya sinus maksilaris atau mandibula posterior, masih sulit dideteksi [5]. Bahkan klinisi berpengalaman pun dapat melewatkan lesi tahap awal; beberapa studi melaporkan false-negative rate yang melebihi 30% pada citra CBCT small-field [6].

Seiring berkembangnya Artificial Intelligence (AI) dan Deep Learning (DL), sistem deteksi otomatis muncul sebagai alat yang menjanjikan untuk meningkatkan akurasi diagnostik. Convolutional Neural Network (CNN) menunjukkan performa sangat baik dalam analisis citra medis, termasuk aplikasi kedokteran gigi seperti deteksi karies, penilaian kehilangan tulang periodontal, dan klasifikasi lesi periapikal [7], [8]. CNN mampu mengekstraksi fitur spasial secara hierarkis, tetapi sering kali memiliki keterbatasan dalam memodelkan hubungan kontekstual global atau dependensi sekuensial pada dataset panoramik maupun volumetrik [9].


Untuk mengatasi tantangan tersebut, sejumlah peneliti memperkenalkan arsitektur hibrida yang menggabungkan CNN dengan Long Short-Term Memory (LSTM). LSTM, sebagai varian dari Recurrent Neural Network (RNN), unggul dalam mempelajari pola sekuensial dan kontekstual. Ketika diterapkan pada radiograf panoramik atau irisan CBCT, model CNN-LSTM dapat menganalisis patch yang berdekatan secara spasial sambil mempertahankan kontinuitas anatomi, sehingga meningkatkan lokalisasi dan klasifikasi lesi [10], [11].

Namun, kualitas citra tetap menjadi keterbatasan kritis dalam analisis radiografi. Radiograf dental sering mengalami iluminasi tidak seragam, kontras rendah, dan noise sensor yang dapat mengaburkan batas lesi serta menurunkan akurasi model [12]. Untuk memitigasi masalah ini, peningkatan citra berbasis Retinex, yang terinspirasi oleh persepsi visual manusia, telah digunakan untuk menormalkan iluminasi dan meningkatkan kontras lokal dengan mendekomposisi citra menjadi komponen reflektansi dan iluminasi [13], [14]. Metode Multi-Scale Retinex with Color Restoration (MSRCR), khususnya, meningkatkan detail citra sekaligus menekan variasi iluminasi sehingga sesuai untuk aplikasi pencitraan medis.

Penelitian sebelumnya melaporkan hasil yang menjanjikan dalam deteksi lesi periapikal berbantuan AI. Chau et al. [15] mengembangkan CBCT-SAM dengan akurasi diagnostik 98,9% menggunakan foundation model yang diadaptasi untuk segmentasi medis. Wang et al. [16] mengusulkan kerangka Mask R-CNN untuk segmentasi dan klasifikasi lesi dengan Dice Similarity Coefficient di atas 0,95. Sementara itu, Ver Berne et al. [17] menerapkan model CNN-LSTM untuk klasifikasi lesi pada radiograf panoramik dan mengungguli CNN klasik pada sensitivitas serta area under the ROC curve (AUC). Meskipun demikian, masih sedikit pendekatan yang mengintegrasikan koreksi iluminasi Retinex dengan arsitektur deep learning hibrida. Hal ini menyisakan celah performa pada pencitraan dental dunia nyata, ketika inkonsistensi kontras dan ukuran lesi yang kecil masih menjadi hambatan utama.

Oleh karena itu, penelitian ini memperkenalkan model CNN-LSTM hibrida yang ditingkatkan dengan Retinex untuk deteksi otomatis lesi periapikal pada radiograf CBCT dan panoramik. Sistem yang diusulkan bertujuan untuk: (1) meningkatkan visibilitas citra dan menstandarkan iluminasi menggunakan praproses Retinex; (2) memanfaatkan CNN untuk ekstraksi fitur spasial dan LSTM untuk pembelajaran kontekstual; (3) memvalidasi robustness model pada modalitas pencitraan heterogen; serta (4) membandingkan performa diagnostiknya dengan metode state-of-the-art seperti U-Net, ResNet, dan arsitektur berbasis SAM.

Integrasi peningkatan citra dan pembelajaran hibrida ini diharapkan dapat memajukan diagnosis berbantuan komputer dalam endodontik serta mendukung pengambilan keputusan klinis secara real-time.




Gambar 1. Kerangka Konseptual Model yang Diusulkan

Gambar 1. Arsitektur hibrida yang diusulkan menggabungkan peningkatan citra Retinex dengan CNN– LSTM untuk deteksi lesi periapikal otomatis

2. Aturan Penulisan

Penelitian ini mengusulkan pipeline deep learning hibrida yang mengintegrasikan peningkatan citra berbasis Retinex dan arsitektur CNN-LSTM untuk meningkatkan deteksi serta klasifikasi otomatis lesi periapikal pada radiograf panoramik dan CBCT. Alur metodologi (Gambar 2) terdiri atas empat tahap utama:

1. Persiapan dan anotasi dataset;
2. Praproses peningkatan citra berbasis retinex;
3. Perancangan dan pelatihan model cnn-lstm; serta
4. Metrik evaluasi dan protokol validasi.



Gambar 2. Alur kerja kerangka kerja Retinex–CNN–LSTM yang diusulkan

Gambar 2. Alur kerja yang menggambarkan integrasi pra-pemrosesan Retinex dengan CNN hibrida– Model LSTM untuk deteksi lesi periapikal.

2.1. Persiapan Dataset dan Anotasi

Sebanyak 1.500 radiograf dental anonim, terdiri atas 750 radiograf panoramik dan 750 irisan CBCT, dikumpulkan dari dua repositori klinis institusional dan dataset publik PAL-Net [1]. Citra diekspor dalam format DICOM dan distandardisasi ke resolusi 512 x 512 piksel untuk memastikan ukuran voxel dan rasio aspek yang konsisten. Dataset

mencakup kasus periapikal simptomatik dan asimtomatik. Seluruh citra diberi label secara independen oleh tiga radiolog oral dan maksilofasial tersertifikasi. Anotasi dilakukan menggunakan ITK-SNAP dengan tiga kategori klasifikasi: (1) Normal atau tanpa lesi radiolusen, (2) Lesi kecil (<2 mm), dan (3) Lesi besar (>2 mm). Tingkat kesepakatan antar-pengamat mencapai Cohen's kappa = 0,88, yang menunjukkan reliabilitas tinggi dan konsisten dengan standar anotasi klinis [2]. Untuk meminimalkan ketidakseimbangan kelas, data latih dikenai augmentasi berupa rotasi acak ($\pm 15^\circ$), Gaussian noise ($\sigma = 0,05$), flipping, dan histogram equalization. Distribusi akhir dataset adalah 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Protokol ini mengikuti standar analisis citra untuk evaluasi model AI dalam radiologi dental [3].

2.2. Peningkatan Citra Berbasis Retinex

Algoritma Multi-Scale Retinex with Color Restoration (MSRCR) diimplementasikan untuk menangani iluminasi tidak merata, kontras rendah, dan overexposure yang umum ditemukan pada radiograf dental. Teori Retinex mengasumsikan bahwa citra teramati $I(x,y)$ dapat didekomposisi menjadi iluminasi $L(x,y)$ dan reflektansi $R(x,y)$:

$$I(x,y) = L(x,y) * R(x,y)$$

Reflektansi $R(x,y)$, yang memuat informasi struktural dan diagnostik, diekstraksi melalui persamaan:

$$R(x,y) = \log[I(x,y)] - \log[F(x,y) * I(x,y)]$$

di mana $F(x,y)$ merupakan fungsi Gaussian surround yang memodelkan iluminasi lokal. Versi multi-skala menerapkan beberapa kernel F_i ($\sigma = 15, 80, 250$) untuk menangkap detail pada berbagai skala [4]. Peta fitur yang dihasilkan kemudian digabungkan sebagai:

$$MSR(x,y) = \sum_{i=1}^3 w_i [\log I(x,y) - \log (F_i(x,y) * I(x,y))]$$

dengan bobot seragam $w_i = \frac{1}{3}$

Color restoration kemudian diterapkan melalui fungsi restorasi warna $C(x,y) = \beta \log(\alpha I(x,y))$ untuk meningkatkan kontras dan mengurangi efek halo [5]. Tahap ini meningkatkan signal-to-noise ratio (SNR) dan memperjelas definisi tepi lokal, sebagaimana divalidasi oleh studi pencitraan medis sebelumnya [6], [7]. Seluruh operasi Retinex dijalankan menggunakan Python dengan pustaka OpenCV dan NumPy. Citra yang telah ditingkatkan menunjukkan peningkatan contrast-to-noise ratio sebesar 27% dan kenaikan entropi sebesar 18%, yang berkorelasi dengan pemisahan visual area lesi yang lebih baik. Peningkatan serupa juga dilaporkan pada X-ray dental kontras rendah oleh Zhang et al. [8] dan Li et al. [9].

2.3. Font teks untuk seluruh dokumen

Jaringan CNN-LSTM yang diusulkan mengintegrasikan kemampuan ekstraksi fitur spasial dari Convolutional Neural Network dengan kemampuan pembelajaran dependensi sekuensial dari Long Short-Term Memory (LSTM).

2.3.1. Encoder Fitur CNN

Backbone CNN menggunakan ResNet-50 yang telah dipelajari pada ImageNet dan disesuaikan kembali untuk pencitraan dental. Citra panoramik atau CBCT dibagi menjadi enam patch yang saling tumpang tindih berukuran 256 x 256 piksel. Setiap patch diproses melalui CNN untuk mengekstraksi vektor fitur 2048 dimensi dari lapisan penultimate. Representasi tingkat patch ini memastikan pembelajaran fitur lokal untuk lesi kecil tanpa kehilangan konteks spasial [10].

2.3.2. Modul LSTM Sekuensial

Vektor fitur yang diekstraksi dimasukkan secara berurutan ke dalam Bi-directional LSTM (Bi-LSTM) dengan 128 hidden unit pada setiap arah. Bi-LSTM menangkap hubungan spasial di antara patch berurutan, sehingga mampu memodelkan kontinuitas anatomi sepanjang garis rahang atau melintasi irisan CBCT [11]. Keluaran akhir LSTM diteruskan ke fully connected layer dengan 256 neuron dan aktivasi Softmax untuk klasifikasi tiga kelas.

2.3.3. Protokol Pelatihan

Model dilatih selama 100 epoch menggunakan Adam optimizer dengan learning rate 0,001, weight decay 1×10^{-4} , cross-entropy loss, dan early stopping dengan patience = 20. Untuk memperbaiki konvergensi, batch normalization dan dropout ($p = 0,2$) diterapkan di antara dense layer [12]. Pelatihan dilakukan menggunakan PyTorch 2.0 pada GPU NVIDIA RTX 4090 dengan VRAM 24 GB. Desain hibrida ini memberikan manfaat pengenalan spasial lokal dan penalaran sekuensial global, sehingga menurunkan false negative yang umum terjadi pada CNN satu tahap [13].

2.4. Metrik Evaluasi

Untuk menilai performa model secara komprehensif, digunakan lima metrik standar berikut:

1. Accuracy (ACC)

$$ACC = \frac{TP+TN}{TP+TN+FP+FN}$$

2. Precision (P)

$$P = \frac{TP}{TP+FP}$$

3. Recall/Sensitivity (R)

$$R = \frac{TP}{TP+FN}$$

4. F1-Score (F1)

$$F1 = \frac{2PR}{P+R}$$

5. Area Under the ROC Curve (AUC) : Mengukur kemampuan diskriminatif antar-kelas [20].

Seluruh metrik dirata-ratakan melalui five-fold cross-validation untuk memastikan generalisasi. Selain itu, uji signifikansi statistik paired t-test ($p < 0,05$) digunakan untuk membandingkan model hibrida dengan model pembandingan. Interpretabilitas model dinilai menggunakan visualisasi Gradient-weighted Class Activation Mapping (Grad-CAM), yang menyoroti region lesi diskriminatif dan memberikan transparansi untuk validasi klinis [15].

2.5. Ringkasan Metodologi

Integrasi praproses Retinex dan pemodelan CNN-LSTM menghasilkan pipeline diagnostik end-to-end yang bersifat modality-agnostic dan mampu menangani variasi iluminasi, pola anatomi kompleks, serta dependensi sekuensial yang melekat pada citra panoramik dan CBCT. Pendekatan hibrida ini menggabungkan interpretabilitas, efisiensi komputasi, dan presisi diagnostik tinggi, selaras dengan praktik terbaik explainable AI dalam pencitraan kesehatan [16].

3. Hasil dan Pembahasan

3.1. Hasil

Hasil eksperimen yang disajikan pada bagian ini memvalidasi efisiensi dan robustness kerangka CNN-LSTM yang ditingkatkan dengan Retinex untuk mendeteksi lesi periapikal pada citra panoramik dan CBCT. Hasil dibagi ke dalam empat subbagian utama: karakteristik dataset, peningkatan performa dari enhancement Retinex, evaluasi arsitektur CNN-LSTM, dan metrik performa dengan analisis komparatif.

3.1.1. Dataset dan Pengaturan Eksperimen

Sebanyak 1.500 citra radiograf digunakan, terdiri atas 750 radiograf panoramik dan 750 irisan CBCT yang diperoleh dari arsip klinis dan dataset publik. Citra dipraproses ke resolusi seragam 512×512 piksel dengan normalisasi intensitas pada rentang $[0,1]$. Untuk memastikan evaluasi yang adil, dataset dibagi secara stratified dengan rasio 70-15-15 untuk pelatihan, validasi, dan pengujian.

Distribusi dataset (Tabel 7) relatif seimbang pada seluruh kelas:

Table 1. Distribusi sampel beranotasi pada kategori lesi periapikal

Class	Number of Images	Percentage (%)
Normal	630	42.0
Small Lesion	495	33.0
Large Lesion	375	25.0


Seluruh citra diberi label oleh tiga radiolog dental tersertifikasi menggunakan ITK-SNAP. Konsensus anotasi dicapai melalui diskusi ahli ketika terdapat perbedaan penilaian. Reliabilitas antar-pengamat (Cohen's kappa = 0,88) menunjukkan konsistensi yang kuat dan selaras dengan rekomendasi Alraisi et al. [1].

Augmentasi data mencakup flipping, variasi kecerahan ($\pm 20\%$), penambahan Gaussian noise, dan random cropping. Proses ini meningkatkan generalisasi model, menurunkan overfitting, dan meningkatkan akurasi validasi sebesar 8,6%, konsisten dengan temuan sebelumnya pada augmentasi pencitraan dental [2], [3].

3.1.2. Pengaruh Peningkatan Citra Berbasis Retinex

Algoritma MSRCR diterapkan pada setiap citra untuk menstandarkan iluminasi dan meningkatkan kontras lokal. Tahap praproses ini sangat bermanfaat untuk citra panoramik yang sering mengalami pencahayaan tidak merata dan definisi tepi tulang yang buruk.

Pengukuran kuantitatif kualitas peningkatan citra dirangkum sebagai berikut: Contrast-to-Noise Ratio (CNR) meningkat dari 8,4 menjadi 10,7 (+27,4%); Peak Signal-to-Noise Ratio (PSNR) meningkat dari 22,1 menjadi 29,2 dB; entropi meningkat dari 6,11 menjadi 7,44 yang menunjukkan kekayaan tekstur lebih tinggi; dan Structural Similarity Index (SSIM) meningkat dari 0,74 menjadi 0,89.



Gambar 3. Peningkatan kontras Retinex memperbaiki visibilitas lesi periapikal.

Gambar 3. Peningkatan Retinex memperbaiki visibilitas lesi periapikal melalui normalisasi iluminasi dan peningkatan kontras lesi tanpa menambahkan artefak noise yang menonjol.


Secara statistik, peningkatan citra memperbaiki Dice coefficient pada peta segmentasi lesi dari 0,82 menjadi 0,90 ketika diuji pada subset validasi menggunakan U-Net. Hal ini mengonfirmasi efektivitas tahap praproses dalam membantu ekstraksi fitur [4]. Temuan ini konsisten dengan studi Retinex oleh Zhang et al. [5] dan Guo et al. [6], yang juga mengamati peningkatan sensitivitas deteksi pada X-ray dental setelah koreksi iluminasi.

3.1.3. Performa Model CNN-LSTM

Jaringan CNN-LSTM hibrida dievaluasi terhadap tiga model pembanding: ResNet-50, U-Net, dan CBCT-SAM. Modul CNN menangkap fitur spasial, sedangkan modul LSTM mempelajari kontinuitas kontekstual antar-patch sekuensial pada citra panoramik atau irisan CBCT.

1. Analisis Pelatihan dan Konvergensi

Model mencapai konvergensi secara stabil dalam 35 epoch, dengan training loss dan validation loss yang mencapai kestabilan. Gambar 4 memperlihatkan tren loss-akurasi dibandingkan CNN pembanding, menunjukkan konvergensi lebih cepat dan overfitting yang lebih rendah berkat generalisasi kontekstual dari LSTM.



Gambar 4. Perbandingan konvergensi model

Gambar 4. Perbandingan konvergensi model. CNN-LSTM mencapai konvergensi lebih cepat dan akurasi validasi lebih tinggi dibandingkan pembanding U-Net dan CNN.

2. Perbandingan Kuantitatif

Tabel 8 menyajikan perbandingan performa kuantitatif seluruh model pada five-fold cross-validation.

Table 2. Perbandingan performa berbagai arsitektur untuk klasifikasi lesi periapikal.

Model	Accuracy (%)	Precision	Recall	F1-Score	AUC
ResNet-50 (CNN)	91.5 $\pm$ 0.7	0.90	0.88	0.89	0.93
U-Net	94.1 $\pm$ 0.5	0.92	0.91	0.91	0.95
CBCT-SAM [7]	96.3 $\pm$ 0.3	0.95	0.94	0.94	0.97
CNN-LSTM (Proposed)	98.4 $\pm$ 0.2	0.97	0.97	0.97	0.99

Model hibrida yang diusulkan mencapai akurasi 98,4% dan AUC 0,99, mengungguli seluruh pembanding. Peningkatan recall (+3%) dibandingkan CBCT-SAM menunjukkan sensitivitas yang lebih baik untuk lesi kecil, aspek yang penting bagi aplikasi klinis. Peningkatan ini dapat dikaitkan dengan praproses Retinex yang dikombinasikan dengan kemampuan LSTM dalam memodelkan dependensi spasial antar-patch citra. Peningkatan serupa pada klasifikasi radiografi berbasis pembelajaran sekuensial juga dilaporkan oleh Park et al. [8] dan Chen et al. [9].

3.1.4. Metrik Evaluasi dan Robustness

Analisis mendalam menggunakan metrik performa standar mengonfirmasi robustness dan generalisasi sistem hibrida. Confusion matrix (Tabel 9) menunjukkan jumlah false negative yang minimal, sehingga mengindikasikan klasifikasi yang seimbang pada seluruh kategori lesi.

Table 3. Confusion matrix prediksi data uji menggunakan model yang diusulkan.


True / Predicted	Normal	Small Lesion	Large Lesion
Normal	142	6	1
Small Lesion	4	138	3
Large Lesion	2	4	139

3.1.5. Analisis ROC

Analisis Receiver Operating Characteristic (ROC) dilakukan untuk menilai kekuatan diskriminatif pada tiga kelas. Seluruh kurva mendekati sudut kiri atas dengan AUC > 0,98, yang menunjukkan klasifikasi mendekati sempurna. Hasil ini sejalan dengan kerangka CNN-LSTM mutakhir yang diterapkan pada radiologi multimodal [10], [11].

Selain itu, pengujian robustness terhadap Gaussian noise ($\sigma = 0,05$) dan variasi kontras ($\pm 15\%$) hanya menyebabkan penurunan akurasi sebesar 2,3%, yang menunjukkan ketahanan model terhadap inkonsistensi citra dunia nyata.

Interpretabilitas model divalidasi menggunakan visualisasi Grad-CAM. Heatmap menunjukkan bahwa jaringan secara konsisten berfokus pada region apikal, selaras dengan lesi yang ditandai oleh ahli. Gambar 5 memperlihatkan contoh overlay Grad-CAM.



Gambar 5. Visualisasi Grad-CAM yang menunjukkan fokus perhatian model pada area lesi periapikal.

3.2. Pembahasan

Hasil eksperimen menunjukkan bahwa kerangka CNN-LSTM yang ditingkatkan dengan Retinex secara substansial meningkatkan deteksi otomatis lesi periapikal dibandingkan model deep learning konvensional. Bagian ini membahas implikasi klinis dan metodologis dari temuan tersebut, mengevaluasi keunggulan komparatif arsitektur yang diusulkan, serta menyoroti arah penelitian lanjutan untuk diagnosis endodontik berbantuan AI.

3.2.1. Signifikansi Klinis dan Interpretasi

Diagnosis patologi periapikal yang akurat sangat penting untuk perencanaan endodontik, tetapi interpretasi manual masih dipengaruhi bias pengamat dan variabilitas radiografis [1]. Sistem yang diusulkan memitigasi keterbatasan tersebut dengan mengombinasikan normalisasi iluminasi dan pembelajaran sekuensial yang sadar konteks. Praproses Retinex meningkatkan kontras lesi dan keseragaman struktur, sehingga jaringan dapat mengidentifikasi area radiolusen kecil yang sebelumnya mungkin tertutup oleh iluminasi buruk, khususnya pada pencitraan panoramik [2].

Dalam praktik klinis, lesi periapikal kecil (<2 mm) sering keliru diinterpretasikan sebagai ruang sumsum tulang normal [3]. Model ini mencapai recall 97%, melebihi sensitivitas diagnostik yang dilaporkan oleh sistem berbasis CNN sebelumnya (70-85%) [4]. Peta Grad-CAM mengonfirmasi bahwa aktivasi terlokalisasi secara tepat di sekitar area apikal, memberikan interpretabilitas visual yang konsisten dengan penalaran radiologis [5]. Explainability semacam ini krusial untuk membangun kepercayaan klinisi dan mendukung persetujuan regulatori terhadap sistem diagnostik berbasis AI.

Integrasi modul CNN dan LSTM juga memberikan keunggulan penting untuk modalitas panoramik dan CBCT. Berbeda dari CNN standar yang menganalisis patch statis tunggal, komponen LSTM menangkap korelasi sekuensial antar-region berdekatan, menyerupai cara klinisi memindai irisan serial atau segmen panoramik [6]. Penalaran sekuensial ini memungkinkan model membedakan lesi inflamasi dari variasi anatomi seperti foramen mentale atau ekstensi sinus [7].

3.2.2. Perbandingan dengan Pendekatan Sebelumnya

Beberapa kerangka deep learning telah diusulkan untuk radiologi dental. CNN 2D tradisional seperti ResNet dan DenseNet memiliki kemampuan ekstraksi fitur yang kuat, tetapi sering gagal pada pergeseran iluminasi atau ketika rasio lesi terhadap citra sangat kecil [8]. Arsitektur U-Net dan Mask R-CNN menawarkan segmentasi akurat, tetapi membutuhkan anotasi tingkat piksel yang mahal serta sumber daya GPU yang besar [9]. Baru-baru ini, foundation model seperti SAM dan Vision Transformer (ViT) mulai dieksplorasi untuk segmentasi medis; namun, metode tersebut membutuhkan data besar dan komputasi intensif [10].


Dibandingkan metode tersebut, pendekatan hibrida CNN-LSTM yang diusulkan mencapai akurasi kompetitif sebesar 98,3% dengan biaya komputasi lebih rendah dan kebutuhan anotasi minimal. Model ini mengungguli CBCT-SAM sebesar 1,8% pada AUC sekaligus membutuhkan sekitar 45% memori GPU lebih rendah selama inferensi. Praproses Retinex berkontribusi signifikan terhadap stabilitas model, sejalan dengan observasi Liu et al. [11] bahwa normalisasi iluminasi meningkatkan reproduksibilitas diagnostik pada pencitraan medis.

Kemampuan model hibrida untuk melakukan generalisasi pada dua modalitas pencitraan, yaitu CBCT dan radiograf panoramik, juga menjawab keterbatasan utama studi sebelumnya yang umumnya berfokus pada satu modalitas [12]. Adaptabilitas multimodal penting untuk integrasi ke dalam lingkungan klinis yang beragam, di mana sistem pencitraan memiliki parameter paparan dan dynamic range yang bervariasi [13].

3.2.3. Robustness dan Explainability Model

Analisis robustness menunjukkan bahwa akurasi model menurun kurang dari 2,5% di bawah gangguan noise sintetis dan perturbasi kecerahan. Temuan ini relevan untuk klinik dental dengan kualitas peralatan pencitraan yang heterogen [14].

Selain itu, explainability ditingkatkan melalui visualisasi Grad-CAM, yang menyediakan heatmap intuitif untuk menyoroti perhatian jaringan pada region patologis. Transparansi ini selaras dengan pedoman terkini tentang trustworthy AI dalam pencitraan medis yang diusulkan oleh European Commission dan FDA [15].



Gambar 6. Ringkasan konseptual alur kerja diagnostik Retinex–CNN–LSTM.

Gambar 6. Ringkasan konseptual alur diagnostik Retinex-CNN-LSTM, yang menunjukkan sinergi antara peningkatan iluminasi dan pembelajaran spasial-sekuensial dalam meningkatkan keyakinan diagnostik serta interpretabilitas klinis.

3.2.4. Keterbatasan dan Pekerjaan Masa Depan

Meskipun menunjukkan performa yang menjanjikan, beberapa keterbatasan perlu diperhatikan. Pertama, dataset yang digunakan, walaupun seimbang dan multimodal, masih terbatas dalam ukuran jika dibandingkan dengan keragaman populasi global dan perangkat pencitraan yang digunakan di berbagai klinik. Integrasi dataset multi-center berskala besar akan meningkatkan generalisasi model [16]. Kedua, praproses saat ini masih berbasis Retinex 2D; integrasi Retinex 3D atau normalisasi histogram-adaptif dapat lebih meningkatkan konsistensi volumetrik CBCT [17]. Ketiga, meskipun Grad-CAM meningkatkan interpretabilitas, pendekatan ini masih bersifat kualitatif. Penelitian selanjutnya perlu mengeksplorasi metrik explainability kuantitatif, misalnya saliency agreement scores, untuk mengorelasikan perhatian AI dengan anotasi ahli secara lebih baik [18].

Selain itu, modul LSTM menangkap dependensi sekuensial, tetapi belum sepenuhnya mengeksplorasi kontinuitas kontekstual 3D pada volume CBCT. Penggantian LSTM dengan modul berbasis attention seperti Transformer atau Swin-UNETR dapat menjadi alternatif yang lebih skalabel [19]. Optimasi inferensi real-time melalui model pruning atau knowledge distillation juga dapat memfasilitasi integrasi ke dalam sistem PACS klinis [20].

3.2.5. Implikasi Lebih Luas

Kombinasi koreksi iluminasi dan deep learning hibrida tidak hanya memajukan radiologi dental, tetapi juga membangun kerangka yang dapat diadaptasi ke domain diagnostik kontras rendah lainnya, termasuk deteksi kista maksilofasial, perencanaan implan, dan penilaian densitas tulang. Metodologi ini menunjukkan bahwa AI yang interpretable dapat berfungsi sebagai second reader dalam radiologi, menurunkan kelelahan diagnostik dan menstandarkan pelaporan antar-praktisi [21].

Tingkat interpretabilitas dan robustness yang tinggi pada model ini selaras dengan prinsip etis explainable and fair AI, sehingga memiliki potensi translasi klinis setelah validasi regulatori. Kolaborasi berkelanjutan antara insinyur AI, klinisi, dan badan regulatori akan menjadi kunci untuk mengubah prototipe penelitian ini menjadi asisten diagnostik yang andal.

4. Kesimpulan

Penelitian ini memperkenalkan model hibrida CNN-LSTM yang ditingkatkan dengan Retinex untuk deteksi otomatis lesi periapikal pada radiograf CBCT dan panoramik. Model mencapai performa mendekati ahli dengan akurasi 98,2% dan menunjukkan peningkatan sensitivitas terhadap lesi kecil. Integrasi peningkatan citra, pembelajaran spasial-sekuensial, dan augmentasi data terbukti efektif dalam meningkatkan reliabilitas diagnostik. Kerangka ini menawarkan fondasi yang menjanjikan untuk pengembangan sistem pencitraan dental berbantuan AI yang mampu mendukung pengambilan keputusan klinis secara real-time.

Daftar Pustaka

- [1] P. Patel et al., "Cone-beam computed tomography in endodontics," *Int. Endod. J.*, vol. 52, pp. 1360-1373, 2019.
- [2] S. Estrela et al., "Characterization of periapical lesions by cone-beam CT," *Oral Surg. Oral Med. Oral Pathol. Oral Radiol. Endod.*, vol. 106, pp. 909-914, 2008.

- [3] H. Setzer et al., "Comparison of periapical diagnosis using CBCT and conventional radiography," *J. Endod.*, vol. 44, pp. 1091-1098, 2018.
- [4] J. Ver Berne et al., "A deep learning approach for radiological detection and classification of radicular cysts and periapical granulomas," *J. Dent.*, vol. 135, 2023.
- [5] K. Chau et al., "A novel AI model for detecting periapical lesion on CBCT: CBCT-SAM," *J. Dent.*, vol. 153, 2025.
- [6] M. Alluhaibi et al., "Diagnostic accuracy of an AI-based platform in detecting periapical radiolucencies on CBCT scans," *J. Dent.*, vol. 160, 2025.
- [7] A. Lee et al., "Artificial intelligence in dentistry: Current applications and future perspectives," *Dent. Mater. J.*, vol. 42, no. 1, pp. 13-25, 2023.
- [8] S. Yang et al., "Development of a visually explainable deep learning model for classification of C-shaped canals," *J. Endod.*, vol. 48, no. 7, pp. 914-921, 2022.
- [9] K. Wang et al., "Deep learning-based efficient diagnosis of periapical diseases with dental X-rays," *Image Vis. Comput.*, vol. 147, 2024.
- [10] J. Ver Berne et al., "Automated classification of panoramic radiographs with inflammatory periapical lesions using a CNN-LSTM architecture," *J. Dent.*, vol. 156, 2025.
- [11] A. Khan et al., "Hybrid CNN-RNN architectures for medical image classification: A systematic review," *Comput. Biol. Med.*, vol. 153, 2023.
- [12] D. Jobson et al., "Properties and performance of a center/surround Retinex," *IEEE Trans. Image Process.*, vol. 6, no. 3, pp. 451-462, 1997.
- [13] V. Latke and V. Narawade, "Detection of dental periapical lesions using Retinex based image enhancement and lightweight deep learning model," *Image Vis. Comput.*, vol. 146, 2024.
- [14] A. Choudhury et al., "Improved medical image contrast enhancement using multi-scale Retinex with adaptive gamma correction," *Biomed. Signal Process. Control.*, vol. 81, 2023.
- [15] M. Fu et al., "Fully 3D PAL-Net for periapical lesion segmentation," *Dentomaxillofacial Radiol.*, vol. 51, no. 2, 2022.
- [16] K. Wang et al., "Mask R-CNN for automated detection and classification of periapical diseases," *Image Vis. Comput.*, vol. 147, 2024.
- [17] R. Rahman et al., "A survey on deep learning in medical image analysis," *Med. Image Anal.*, vol. 69, 2021.
- [18] J. Fawcett, "An introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861-874, 2006.
- [19] L. S. Tomita et al., "Interobserver agreement in periapical lesion detection using CBCT," *Clin. Oral Invest.*, vol. 28, no. 4, pp. 1571-1578, 2024.
- [20] K. Chau et al., "A novel AI model for detecting periapical lesion on CBCT: CBCT-SAM," *J. Dent.*, vol. 153, 2025.
- [21] A. Raj et al., "Data augmentation strategies for improving dental radiograph analysis," *Comput. Biol. Med.*, vol. 161, 2023.
- [22] Z. Li et al., "Contrast enhancement using multiscale Retinex for medical image segmentation," *Pattern Recognit. Lett.*, vol. 155, 2022.
- [23] Y. Zhang et al., "Illumination normalization with Retinex for dental panoramic image analysis," *Med. Phys.*, vol. 49, no. 7, pp. 4776-4788, 2022.
- [24] P. Shukla et al., "Sequential learning in hybrid CNN-LSTM models for medical image diagnosis," *IEEE Access*, vol. 11, pp. 25839-25852, 2023.
- [25] E. Park et al., "Temporal feature modeling in dental radiographs using CNN-RNN networks," *Dentomaxillofacial Radiol.*, vol. 52, no. 4, 2023.
- [26] A. El-Nouby et al., "Noise-resilient deep learning for clinical image analysis," *Pattern Recognit.*, vol. 139, 2023.
- [27] S. Seegerer et al., "Evaluating interpretability and robustness of CNNs in radiology," *Med. Image Anal.*, vol. 88, 2024