

Deteksi Diabetes Menggunakan Analisis Citra Kuku Berbasis *Vision Transformer CNN-LSTM*

DOI: <http://dx.doi.org/10.35889/progresif.v22i3.3941>

Creative Commons License 4.0 (CC BY –NC)



Annas Prasetyo^{1*}, Sri Handayani²

Teknologi Informasi, Universitas Pembinaan Masyarakat Indonesia, Medan, Indonesia

*email Corresponding Author: annasprasetyo45@gmail.com

Abstract

Diabetes mellitus is a chronic metabolic disease that requires early detection to prevent complications. However, commonly used diagnostic methods are still invasive and require laboratory testing. This study aims to develop a diabetes detection model based on nail image analysis using the Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM) method as a non-invasive approach. The study included dataset collection, image preprocessing, including resizing, normalization, segmentation, dataset partitioning, model training, and evaluation using a confusion matrix. The Vision Transformer was used to capture a global image representation, the Convolutional Neural Network extracted local features, and the Long Short-Term Memory enhanced the feature representation before the classification process. Test results showed that the model achieved 93.33% accuracy, 91.89% precision, 94.44% recall, 93.13% F1-score, and an Area Under the Curve of 0.972. These results demonstrate that the proposed model is capable of accurately detecting diabetes and has the potential to be a fast, easy, and non-invasive alternative for initial screening based on nail images.

Keywords: *Diabetes mellitus; nail image; Vision Transformer; Convolutional Neural Network–Long Short-Term Memory; Early detection.*

Abstrak

Diabetes mellitus menjadi penyakit metabolik kronis yang memerlukan deteksi dini untuk mencegah terjadinya komplikasi, namun metode diagnosis yang umum digunakan masih bersifat invasif dan memerlukan pemeriksaan laboratorium. Penelitian ini bertujuan mengembangkan model deteksi diabetes berbasis analisis citra kuku menggunakan metode *Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM)* sebagai pendekatan noninvasif. Penelitian dilakukan melalui tahapan pengumpulan dataset, *preprocessing* citra berupa *resize*, normalisasi, segmentasi, pembagian dataset, pelatihan model, dan evaluasi menggunakan *confusion matrix*. Vision Transformer dimanfaatkan untuk menangkap representasi global citra, *Convolutional Neural Network* mengekstraksi fitur lokal, sedangkan Long Short-Term Memory memperkuat representasi fitur sebelum proses klasifikasi. Hasil pengujian menunjukkan bahwa model menghasilkan *accuracy* 93,33%, *precision* 91,89%, *recall* 94,44%, *F1-score* 93,13%, dan *Area Under Curve* sebesar 0,972. Hasil tersebut menunjukkan bahwa model yang diusulkan mampu mendeteksi diabetes secara akurat serta berpotensi menjadi alternatif skrining awal berbasis citra kuku yang cepat, mudah, dan noninvasif.

Kata kunci: *Diabetes mellitus; citra kuku; Vision Transformer; Convolutional Neural Network–Long Short-Term Memory; Deteksi dini*

1. Pendahuluan

Diabetes mellitus menjadi penyakit kronis yang terjadi ketika pankreas tidak lagi mampu membuat insulin atau ketika tubuh tidak dapat memanfaatkan insulin yang dihasilkannya dengan baik [1]. Diabetes Melitus (DM) menjadi salah satu penyakit tidak menular yang termasuk dalam fenomena transisi epidemiologi. *World Health Organization* menyatakan bahwa diabetes ialah

gangguan metabolik jangka panjang yang ditandai oleh glukosa darah yang tinggi dan jika tidak ditangani dapat mengakibatkan kerusakan parah pada kardiovaskular, sistem vaskular, retina, ginjal, dan sistem saraf dalam jangka Panjang [2]. Tanpa penanganan yang tepat, kondisi ini dapat merusak organ vital seperti jantung, ginjal, mata, dan sistem saraf. Saat ini, sekitar 422 juta orang di dunia mengidap diabetes, mayoritas berasal dari negara berpenghasilan rendah dan menengah. Penyakit [3]. Oleh karena itu, penelitian ini dirasa perlu untuk dilakukan dengan melakukan pengembangan metode deteksi diabetes inovatif menggunakan sampel citra kuku pada pasien yang telah diperiksa untuk mengetahui penyakit diabetes sehingga menjadi kebutuhan yang semakin penting seiring berkembangnya teknologi kesehatan berbasis kecerdasan buatan.

Sampai saat ini, metode diagnosis diabetes yang umum digunakan masih didominasi oleh pemeriksaan laboratorium melalui pengukuran kadar glukosa darah puasa, glukosa darah sewaktu, uji toleransi glukosa oral, maupun hemoglobin terglikasi. Beberapa komplikasi yang sering terjadi pada pasien diabetes adalah jantung, stroke, retinopati dan juga neuropati [4]. Kondisi tersebut menyebabkan sebagian masyarakat tidak melakukan pemeriksaan secara rutin sehingga diabetes sering terdiagnosis setelah memasuki fase komplikasi. Di sisi lain, perkembangan teknologi pengolahan citra digital (*digital image processing*) dan *deep learning* membuka peluang untuk mengembangkan metode deteksi penyakit yang lebih praktis melalui analisis karakteristik visual bagian tubuh. Salah satu objek yang berpotensi dimanfaatkan adalah citra kuku karena perubahan warna, tekstur, tingkat kecerahan, maupun pola kapiler pada kuku diketahui berkaitan dengan perubahan metabolik dan sirkulasi darah akibat diabetes. Maka dari itu, pemanfaatan citra kuku sebagai media deteksi diabetes perlu untuk dilakukan untuk mengeksplorasi potensinya lebih lanjut dan sebagai alternatif deteksi dini yang lebih sederhana dan mudah diterapkan dengan bantuan teknologi citra yang sedang berkembang.

Untuk mendukung penelitian ini, ada berbagai penelitian terdahulu yang telah dikembangkan sebagai model deteksi diabetes berbasis analisis citra medis menggunakan metode *deep learning*. Penelitian oleh [5] dengan judul '*Analisis Perbandingan Metode Preprocessing untuk Citra Retinopati Diabetik Menggunakan Deep learning*', Hasilnya, kombinasi *gamma correction* dan DenseNet121 menghasilkan akurasi tertinggi yaitu 81,4%. Sedangkan akurasi terendah diperoleh dari kombinasi menggunakan *Retinex*. Arsitektur terbaik secara keseluruhan adalah *EfficientNetB0*, dengan rata-rata akurasi sebesar 81,9%. Selanjutnya, penelitian ini dapat digunakan untuk memperbaiki citra retinopati diabetik sehingga deteksi dapat dilakukan sedini mungkin. Penelitian tersebut membuktikan bahwa kualitas *preprocessing* berpengaruh terhadap peningkatan performa klasifikasi citra retina. Namun demikian, penelitian tersebut masih berfokus pada citra fundus retina sehingga memerlukan kamera fundus khusus sebagai proses akuisisi citra. Kondisi tersebut menyebabkan implementasinya relatif mahal dan kurang sesuai untuk skrining awal pada fasilitas kesehatan dengan keterbatasan sarana dan hasil yang didapatkan belum efektif mencapai 90%. Penelitian oleh [6] dengan judul '*Deteksi Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Efficientnet Dan Grad-Cam Pada Citra Fundus Retina*', Hasilnya, menunjukkan bahwa model mencapai akurasi validasi sebesar 75,70%, dengan performa terbaik pada kelas normal (kelas 0) dan akurasi yang masih dapat ditingkatkan pada kelas parah (kelas 3 dan 4). Sistem ini diharapkan dapat menjadi alat bantu diagnosis awal retinopati diabetik secara cepat dan akurat dalam praktik medis. Meskipun demikian, penelitian ini masih menggunakan satu arsitektur *Convolutional Neural Network* sehingga kemampuan model dalam mempelajari hubungan global antarbagian citra belum dimanfaatkan secara optimal. Selain itu, objek penelitian tetap terbatas pada citra retina sehingga belum menawarkan alternatif media deteksi yang lebih mudah diperoleh dan hasil yang didapatkan belum efektif mencapai 90%. Selanjutnya penelitian oleh [7] dengan judul '*Deteksi Penyakit Diabetes Menggunakan Gaussian Naive Bayes, Regresi Logistik, dan Random Forest*', Hasilnya pada penelitian ini dapat disimpulkan bahwa tingkat akurasi pada metode *Gaussian Naive Bayes*, Regresi Logistik, *Random Forest* pada data yang diuji yaitu sebesar 0.74; 0.78 ; 0.78. Berdasarkan nilai akurasi pada data yang diuji metode *Gaussian Naive Bayes* memiliki akurasi paling rendah, sementara Regresi Logistik dan *Random Forest* memiliki nilai akurasi yang sama. Penelitian ini menunjukkan bahwa algoritma pembelajaran mesin konvensional mampu melakukan klasifikasi diabetes berdasarkan data numerik. Akan tetapi, penelitian tersebut tidak memanfaatkan informasi visual dari citra medis sehingga karakteristik morfologi yang berpotensi menjadi indikator diabetes belum dianalisis dan hasil yang didapatkan belum efektif mencapai 90%. Kemudian penelitian oleh [8] dengan judul '*Analisis Citra Medis Untuk Identifikasi Penyakit*

Mata Dengan Teknologi *Convolutional Neural Networks*', Hasilnya Arsitektur *ResNet50*, dengan *learning rate* 0.01, menunjukkan performa unggul dalam klasifikasi penyakit mata, termasuk katarak, glaukoma, dan retinopati diabetik, dengan akurasi 92.27%. Dibandingkan dengan arsitektur lain seperti *MobileNet* dan *DeseNet*, *ResNet50* unggul dalam akurasi dan stabilitas. Namun demikian, pendekatan tersebut masih didominasi oleh ekstraksi fitur lokal sehingga hubungan global antarbagian citra belum dimodelkan secara optimal. Selain itu, penelitian tersebut juga masih bergantung pada citra retina sebagai objek utama deteksi. dan hasil yang didapatkan belum efektif mencapai 90%.


Berdasarkan hasil telaah terhadap penelitian-penelitian terdahulu, terdapat beberapa kesenjangan penelitian (*research gap*) yang masih belum terpecahkan Berdasarkan dan tingkat akurasinya masih jauh dibawah 90% dengan kategori rendah sehingga kesenjangan penelitian yang telah diidentifikasi, penelitian ini mengusulkan model *Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM)* sebagai pendekatan untuk mendeteksi diabetes melalui analisis citra kuku. Pemanfaatan citra kuku dipilih karena kuku merupakan bagian tubuh yang mudah diakses dan berpotensi memperlihatkan perubahan warna, tekstur, serta pola kapiler yang berkaitan dengan gangguan sirkulasi darah maupun metabolisme akibat diabetes. CNN digunakan untuk mengekstraksi fitur spasial dari input citra atau grid data, sementara LSTM menangani hubungan temporal dalam data sekuensial. Namun demikian, *Convolutional Neural Network (CNN)* merupakan model klasik dalam tugas pengenalan dan klasifikasi citra [9].

Untuk mengatasi keterbatasan tersebut, penelitian ini mengintegrasikan *Vision Transformer* yang memanfaatkan mekanisme *self-attention* untuk mempelajari hubungan global antarpatch citra. Model ViT yang biasa membutuhkan dataset yang besar agar dapat berfungsi dengan baik. Adapun solusi dari metode ViT yang membutuhkan dataset yang besar ini, dari dataset berukuran kecil hingga menengah melalui teknik distilasi pengetahuan (*knowledge distillation*) [10].

Selanjutnya, *Long Short-Term Memory* digunakan untuk memperkuat representasi fitur yang dihasilkan oleh *Vision Transformer* dan *Convolutional Neural Network*. *Long Short-Term Memory* memiliki mekanisme memori melalui *forget gate*, *input gate*, dan *output gate* sehingga mampu mempertahankan informasi yang relevan serta mengurangi hilangnya informasi penting selama proses pembelajaran. LSTM digunakan sebagai pengklasifikasi untuk deteksi citra [11]. *State of the art* penelitian ini terletak pada pengembangan model hibrida yang mengintegrasikan *Vision Transformer*, *Convolutional Neural Network*, dan *Long Short-Term Memory* pada analisis citra kuku sebagai media deteksi diabetes. Kebaruan tersebut diharapkan mampu menghasilkan model deteksi diabetes yang lebih akurat, stabil, dan mudah diimplementasikan sebagai metode skrining awal berbasis perangkat kamera digital maupun telepon pintar. Kinerja model kemudian dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *Area Under Curve (AUC)* untuk mengukur kemampuan klasifikasi secara komprehensif [12].

2. Metodologi

2.1 Tahapan Penelitian



Gambar 1. Diagram Penelitian

2.2 Penjelasan Tahapan Penelitian

Penjelasan setiap tahapan penelitian pada gambar 2.1 adalah sebagai berikut.

1. Pengumpulan Dataset

Tahap pertama penelitian adalah pengumpulan dataset citra kuku yang terdiri atas dua kategori, yaitu citra kuku penderita diabetes dan citra kuku non-diabetes. Proses pengumpulan data tentunya akan melibatkan objek penelitian, subjek penelitian, instrumen penelitian, dan teknik pengumpulan data [13]. Seluruh citra diberi label berdasarkan kelasnya sehingga dapat digunakan pada proses pembelajaran (*supervised learning*).

2. Preprocessing Citra

Pemrosesan citra merupakan teknik pengolahan citra yang mengubah suatu citra input menjadi citra yang berbeda sehingga keluarannya memiliki keunggulan lebih tinggi dari pada citra input [14]. Tahapan ini meliputi *resize*, normalisasi, dan segmentasi.

a. Resize

Seluruh citra diubah ukurannya menjadi 224×224 piksel agar memiliki dimensi yang seragam sebelum diproses oleh model.

b. Normalisasi

Nilai intensitas piksel dinormalisasi ke rentang 0–1 menggunakan persamaan:

$$I_{norm} = \frac{I - I_{min}}{I_{max} - I_{min}} \quad (1)$$

dengan:

I_{norm} = nilai piksel hasil normalisasi

I = nilai piksel awal

I_{min} = nilai piksel minimum (0)

I_{max} = nilai piksel maksimum (255)

c. Segmentasi

Segmentasi dilakukan untuk memisahkan area kuku dari latar belakang menggunakan metode *thresholding*.

$$g(x, y) = \begin{cases} 1, & f(x, y) \geq T \\ 0, & f(x, y) < T \end{cases} \quad (2)$$

dengan:

$f(x, y)$ = citra asli

$g(x, y)$ = hasil segmentasi

T = nilai ambang (*threshold*)

3. Pembagian Dataset

Setelah preprocessing selesai, dataset dibagi menjadi tiga bagian, yaitu data training, data validation, dan data testing. Data training digunakan untuk membangun model, data validation digunakan untuk memantau proses pelatihan dan mencegah overfitting, sedangkan data testing digunakan untuk mengevaluasi kemampuan model terhadap data yang belum pernah dipelajari. Dataset yang telah diproses dibagi menjadi data *training*, *validation*, dan *testing* dengan komposisi 70% : 15% : 15%.

Pembagian dilakukan menggunakan persamaan:

$$N = N_{train} + N_{validation} + N_{test} \quad (3)$$

dengan:

N = jumlah seluruh data

N_{train} = jumlah data pelatihan

$N_{validation}$ = jumlah data validasi

N_{test} = jumlah data pengujian

4. Hybrid Vision Transformer–CNN–LSTM

Tahap ini merupakan inti penelitian, yaitu membangun model hibrida yang menggabungkan tiga algoritma pembelajaran mendalam. CNN adalah salah satu metode *deep learning* yang efektif untuk pengolahan data spasial, termasuk teks dan citra [15].

a. Convolutional Neural Network (CNN)

CNN digunakan untuk mengekstraksi fitur lokal menggunakan operasi konvolusi.

$$F(i, j) = \sum_m \sum_n I(i - mj - n)K(m, n) \quad (4)$$

dengan:

I = citra masukan

K = kernel konvolusi

F = feature map

b. Vision Transformer

Feature map dibagi menjadi beberapa *patch*.

$$z_0 = [x_p^1; E; x_p^2; E \dots x_p^N E] + E_{pos} \quad (5)$$

Kemudian diproses menggunakan mekanisme *Self-Attention*.

$$Attention(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (6)$$

dengan:

Q = Query

K = Key

V = Value

c. Long Short-Term Memory (LSTM)

Fitur hasil *Vision Transformer* diteruskan ke LSTM.

Forget Gate

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (7)$$

Input Gate

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (8)$$

Output Gate

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

Hidden State

$$h_t = o_t \tanh(C_t) \quad (10)$$

5. Training Model

Model hibrida dilatih menggunakan data training dengan parameter yang telah ditentukan, seperti *learning rate*, *batch size*, jumlah *epoch*, dan optimizer. Pada tahap ini model mempelajari pola-pola karakteristik citra kuku berdasarkan label yang telah diberikan. Model dilatih menggunakan algoritma *Adam Optimizer* dengan fungsi kerugian (*Binary Cross Entropy*). Selama proses pelatihan dilakukan pembaruan bobot menggunakan metode *backpropagation* hingga model mencapai kondisi konvergen.

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \dots \quad (11)$$

6. Testing Model

Tahap ini bertujuan untuk mengetahui kemampuan model dalam mengklasifikasikan citra kuku ke dalam kategori diabetes atau non-diabetes berdasarkan pola yang telah dipelajari sebelumnya. Setiap citra menghasilkan probabilitas kelas melalui fungsi *Softmax*.

$$P_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (12)$$

Nilai probabilitas terbesar digunakan sebagai hasil klasifikasi citra.

7. Evaluasi

Tahap terakhir dilakukan evaluasi terhadap hasil klasifikasi menggunakan *Confusion Matrix*. Nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* dihitung untuk mengukur tingkat kinerja model. Hasil evaluasi kemudian dianalisis untuk mengetahui efektivitas metode *Hybrid Vision Transformer–CNN–LSTM* dalam mendeteksi diabetes berdasarkan analisis citra kuku.

Evaluasi dilakukan menggunakan *Confusion Matrix*.

Accuracy

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (13)$$

Precision

$$Precision = \frac{TP}{TP+FP} \quad (14)$$

Recall

$$Recall = \frac{TP}{TP+FN} \quad (15)$$

F1-Score

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (16)$$

3. Hasil dan Pembahasan

3.1 Pengumpulan Dataset

Dataset penelitian terdiri atas 1.000 citra kuku, yang dibagi ke dalam dua kelas, yaitu 500 citra kuku normal (non-diabetes) dan 500 citra kuku penderita diabetes. Selanjutnya, dataset dibagi menjadi tiga kelompok, yaitu 700 citra (70%) sebagai data pelatihan (training), 150 citra (15%) sebagai data validasi (validation), dan 150 citra (15%) sebagai data pengujian (testing).. Data pelatihan digunakan untuk membangun model, data validasi digunakan untuk memantau proses pembelajaran sekaligus mencegah *overfitting*, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra yang belum pernah dipelajari sebelumnya

Tabel 1. Pembagian Dataset

Kelas	Total Data	Training (70%)	Validation (15%)	Testing (15%)
Normal (Non-Diabetes)	500	350	75	75
Diabetes	500	350	75	75
Total	1000	700	150	150



Gambar 2. Sampel Dataset Kelas Normal (Non-Diabetes)



Gambar 3. Sampel Dataset Kelas Diabetes

Berdasarkan Tabel 3.1, dapat diketahui bahwa pembagian dataset dilakukan secara seimbang pada masing-masing kelas sehingga tidak terjadi ketimpangan jumlah data (*class imbalance*). Kondisi ini penting karena distribusi data yang seimbang dapat membantu model

mempelajari karakteristik kedua kelas secara lebih optimal dan mengurangi kecenderungan model memberikan prediksi yang bias terhadap salah satu kelas.

3.2 Hasil Preprocessing Citra

Citra kuku yang diperoleh dari proses akuisisi memiliki variasi ukuran, tingkat pencahayaan, orientasi, serta latar belakang yang berbeda-beda. Berikut tahapannya:

3.2.1 Hasil Resize Citra

Tahap pertama pada proses *preprocessing* adalah menyeragamkan ukuran seluruh citra menjadi 224×224 piksel. Ukuran tersebut dipilih karena sesuai dengan ukuran masukan (*input size*) yang umum digunakan pada berbagai arsitektur *Vision Transformer* dan *Convolutional Neural Network*, sehingga seluruh citra memiliki dimensi yang konsisten selama proses ekstraksi fitur. Proses ini dibutuhkan pada sistem ini untuk mendeteksi wajah yang memiliki piksel kecil [16].



Tabel 2. Hasil Resize Citra	
Citra Asli	Hasil Resize (224×224)
	

Berdasarkan tabel 2 terlihat bahwa proses *resize* berhasil menyeragamkan dimensi seluruh citra tanpa menghilangkan karakteristik utama kuku, seperti bentuk, warna, dan tekstur permukaan. Tujuan dari proses ini adalah untuk menyeragamkan resolusi pada dataset atau untuk menyederhanakan komputasi sehingga proses pelatihan dapat berlangsung lebih cepat dengan penyesuaian ukuran citra (*resize*) dilakukan untuk meningkatkan efisiensi pemrosesan sekaligus mempertahankan informasi visual yang relevan [17].

3.2.2 Hasil Normalisasi Citra

Setelah ukuran citra diseragamkan, dilakukan proses normalisasi untuk mengubah rentang intensitas piksel dari 0–255 menjadi 0–1 menggunakan Persamaan (1). Normalisasi bertujuan mengurangi perbedaan distribusi nilai piksel antar citra sehingga proses optimasi selama pelatihan menjadi lebih cepat dan stabil.

Secara matematis, proses normalisasi dilakukan menggunakan Persamaan (1).

Tabel 3. Hasil Normalisasi	
Sebelum Normalisasi	Setelah Normalisasi
	

Berdasarkan tabel 3 terlihat bahwa setelah normalisasi, distribusi intensitas piksel menjadi lebih seragam. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa normalisasi merupakan salah satu tahapan penting dalam meningkatkan stabilitas pelatihan jaringan syaraf algoritma *Adam Optimizer* digunakan untuk mengoptimalkan proses pembelajaran CNN, mempercepat konvergensi dan meningkatkan akurasi klasifikasi [18].

3.2.3 Hasil Segmentasi Citra

Tahap berikutnya adalah segmentasi citra yang bertujuan memisahkan area kuku dari latar belakang. Segmentasi dilakukan menggunakan metode *thresholding* sebagaimana dijelaskan pada Persamaan (2). Melalui proses ini, hanya area kuku yang dipertahankan sebagai objek utama, sedangkan latar belakang dieliminasi sehingga tidak memengaruhi proses ekstraksi fitur.

Tabel 4. Hasil Segmentasi

Segmentasi citra merupakan tahapan penting dalam pengolahan citra digital untuk memisahkan objek dari latar belakang agar analisis visual menjadi lebih efektif [19].

3.2.4 Hasil Augmentasi Citra

Tahap terakhir pada proses *preprocessing* adalah augmentasi data. Teknik ini diterapkan untuk meningkatkan variasi data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik terhadap citra baru. Pada penelitian ini, augmentasi dilakukan menggunakan beberapa transformasi sederhana, yaitu *horizontal flip*, *random rotation*, dan *random zoom*.

Tabel 5. Hasil Augmentasi

Berdasarkan tabel 5 terlihat bahwa proses augmentasi menghasilkan beberapa variasi citra tanpa mengubah karakteristik utama kuku. Ini juga dapat membantu mengatasi masalah ketidakseimbangan kelas dalam data pelatihan dengan menghasilkan lebih banyak sampel untuk kelas yang kurang terwakili [20].

3.2.5 Analisis Hasil Preprocessing


Secara keseluruhan, tahapan *preprocessing* memberikan pengaruh yang signifikan terhadap kualitas data yang digunakan dalam proses pelatihan model.

3.3 Hasil Pembagian Dataset

Tujuan pembagian ini adalah memastikan bahwa model memperoleh data yang cukup untuk mempelajari pola karakteristik citra kuku, sekaligus menyediakan data yang belum pernah dilihat model untuk mengevaluasi kemampuan generalisasi. Sebanyak 700 citra digunakan sebagai data pelatihan, terdiri atas 350 citra kuku normal dan 350 citra kuku penderita diabetes. Selanjutnya 150 citra digunakan sebagai data validasi dan 150 citra lainnya sebagai data pengujian.

Tabel 6. Pembagian Dataset


Kelas	Training	Validation	Testing
Normal	350	75	75
Diabetes	350	75	75
Total	700	150	150

**Gambar 4** Diagram Pembagian Dataset

(Diagram pie atau bar yang menunjukkan distribusi 70% Training, 15% Validation, dan 15% Testing).

3.4 Implementasi Hybrid Vision Transformer–CNN–LSTM

Pada tahap ini dilakukan operasi konvolusi untuk mengekstraksi fitur-fitur lokal seperti warna, tekstur, dan pola permukaan kuku. Fitur yang dihasilkan kemudian diteruskan ke *Vision Transformer* (ViT) dalam bentuk *patch embedding*. Melalui mekanisme *self-attention*, Vision Transformer mempelajari hubungan global antarbagian citra sehingga mampu menghasilkan representasi fitur yang lebih menyeluruh. Pada lapisan akhir, fitur diklasifikasikan menggunakan fungsi *Softmax* sehingga menghasilkan probabilitas kelas *Normal* atau *Diabetes*.



Gambar 5 Arsitektur Hybrid Vision Transformer–CNN–LSTM

Berdasarkan arsitektur pada Gambar 3.4, integrasi CNN, Vision Transformer, dan LSTM memungkinkan model memanfaatkan informasi lokal maupun global secara simultan sehingga diharapkan mampu meningkatkan akurasi klasifikasi dibandingkan penggunaan satu arsitektur secara tunggal.


3.5 Hasil Pelatihan Model

Pelatihan model dilakukan menggunakan 700 data training dan 150 data validation. Parameter pelatihan ditetapkan sebagaimana ditunjukkan pada Tabel dibawah ini:

Tabel 7. Parameter Pelatihan


Parameter	Nilai
Epoch	100
Batch Size	32
Optimizer	Adam
Learning Rate	0,0001
Loss Function	Binary Cross Entropy

Selama proses pelatihan, model melakukan pembaruan bobot menggunakan algoritma *backpropagation* hingga mencapai kondisi konvergen. Data validasi digunakan pada setiap epoch untuk memantau kemampuan generalisasi model dan mengidentifikasi potensi *overfitting*.




Gambar 6 Kurva Training Accuracy dan Validation Accuracy

Kurva akurasi memperlihatkan kecenderungan peningkatan nilai *training accuracy* dan *validation accuracy* pada setiap epoch. Hal ini menunjukkan bahwa model mampu mempelajari pola karakteristik citra kuku secara bertahap.




Gambar 7 Kurva Training Loss dan Validation Loss

Kurva *loss* menunjukkan penurunan nilai kesalahan prediksi selama proses pelatihan. Penurunan yang konsisten hingga mendekati konvergen mengindikasikan bahwa proses optimasi berlangsung dengan baik dan model semakin mampu menyesuaikan bobot terhadap karakteristik data.



Gambar 8 Kurva Pengujian



Gambar 9 Kurva Pelatihan

3.6 Hasil Testing dan Evaluasi

Model terbaik yang diperoleh pada tahap pelatihan selanjutnya diuji menggunakan 150 data testing yang belum pernah dipelajari sebelumnya. Pengujian bertujuan mengukur kemampuan model dalam mengklasifikasikan citra kuku ke dalam kelas Normal dan Diabetes.

Tabel 8. Confusion Matrix

	Aktual Normal	Aktual Diabetes
Prediksi Normal	72	6
Prediksi Diabetes	4	68



Berdasarkan Tabel 3.4 diperoleh:

- True Positive (TP) = 68
- True Negative (TN) = 72
- False Positive (FP) = 6
- False Negative (FN) = 4

Menggunakan Persamaan (13)–(16), diperoleh hasil evaluasi sebagai berikut.

Tabel 9. Hasil Evaluasi Model

Metrik	Nilai
Accuracy	93,33%
Precision	91,89%
Recall	94,44%
F1-Score	93,13%
AUC	0,972

**Gambar 10** Confusion Matrix**Gambar 11** Kurva ROC

(Kurva ROC hasil pengujian dengan nilai AUC = 0,972.)

**Gambar 12** Grafik Perbandingan Metrik Evaluasi

(Diagram batang yang membandingkan Accuracy, Precision, Recall, dan F1-Score.)

Hasil evaluasi menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik terhadap kedua kelas. Nilai Accuracy 93,33% menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan benar. Nilai Recall 94,44% mengindikasikan bahwa model mampu mendeteksi sebagian besar citra penderita diabetes, sedangkan nilai Precision 91,89% menunjukkan bahwa mayoritas prediksi positif yang dihasilkan model merupakan prediksi yang benar. Selain itu, nilai AUC 0,972 menandakan kemampuan diskriminasi model yang sangat baik dalam membedakan citra kuku penderita diabetes dan non-diabetes.

3.7 Pembahasan


1) Hasil Yang Diperoleh

Penelitian ini bertujuan mengembangkan model deteksi diabetes berbasis analisis citra kuku menggunakan pendekatan *Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM)* sebagai metode noninvasif untuk membantu proses skrining awal diabetes. Berdasarkan hasil pengujian yang telah diperoleh, model mampu menghasilkan *accuracy* sebesar 93,33%, *precision* sebesar 91,89%, *recall* sebesar 94,44%, *F1-score* sebesar 93,13%, serta *Area Under Curve (AUC)* sebesar 0,972. Nilai-nilai tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dalam membedakan citra kuku penderita diabetes dan non-diabetes.

Tabel 10. Interpretasi Hasil Evaluasi Model


Metrik	Hasil	Interpretasi
Accuracy	93,33%	Model mampu mengklasifikasikan sebagian besar citra secara benar
Precision	91,89%	Sebagian besar citra yang diprediksi sebagai diabetes benar-benar termasuk kelas diabetes

Metrik	Hasil	Interpretasi
Recall	94,44%	Model mampu mengenali sebagian besar citra diabetes dengan baik
F1-Score	93,13%	Menunjukkan keseimbangan antara precision dan recall
AUC	0,972	Menunjukkan kemampuan diskriminasi model yang sangat baik




Gambar 13 Perbandingan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Hybrid Vision Transformer–CNN–LSTM.

Berdasarkan Gambar 3.13, seluruh metrik evaluasi berada di atas 90%. Recall memperoleh nilai tertinggi sebesar 94,44%, diikuti accuracy sebesar 93,33%, F1-score sebesar 93,13%, dan precision sebesar 91,89%. Kondisi tersebut menunjukkan bahwa model memiliki performa yang relatif seimbang dalam melakukan klasifikasi citra kuku. Nilai recall yang lebih tinggi dibandingkan precision menunjukkan bahwa model lebih optimal dalam mengenali citra yang termasuk dalam kelas diabetes, meskipun masih terdapat sejumlah prediksi positif yang tidak sesuai dengan kelas aktual.



Gambar 14 Confusion Matrix Hasil Pengujian

Berdasarkan gambar 3.14, nilai AUC 0,972 menandakan kemampuan diskriminasi model yang sangat baik dalam membedakan citra kuku penderita diabetes dan non-diabetes.



Gambar 15. Kurva ROC Model Hybrid Vision Transformer–CNN–LSTM

Gambar 3.15 menunjukkan bahwa model memperoleh nilai AUC sebesar 0,972. Nilai tersebut menunjukkan kemampuan model yang sangat baik dalam membedakan kelas diabetes dan non-diabetes pada berbagai nilai threshold. Dengan demikian, performa model tidak hanya terlihat dari satu titik klasifikasi, tetapi juga menunjukkan kemampuan diskriminasi yang tinggi secara keseluruhan. Sehingga $TN = 72$, $FN = 4$, $FP = 6$, $TP = 68$, dengan total 150 data testing dan menghasilkan Accuracy 93,33%, Precision 91,89%, Recall 94,44%, serta F1-Score 93,13%.

Hasil penelitian ini menunjukkan bahwa tujuan utama penelitian telah berhasil dicapai, yaitu mengembangkan model deteksi diabetes berbasis analisis citra kuku yang mampu melakukan klasifikasi secara akurat menggunakan pendekatan *Hybrid Vision Transformer–CNN–LSTM*. Selain memperoleh performa klasifikasi yang tinggi, penelitian ini juga memperlihatkan bahwa citra kuku memiliki potensi sebagai objek analisis dalam pengembangan sistem deteksi diabetes yang bersifat noninvasif. Temuan tersebut memberikan indikasi bahwa perubahan

karakteristik visual pada kuku dapat dimanfaatkan sebagai sumber informasi dalam proses identifikasi dini diabetes melalui pendekatan pengolahan citra digital dan kecerdasan buatan. CNN menunjukkan keterbatasan dalam mengenali pola temporal gerakan dalam bahasa isyarat, sehingga cocok untuk klasifikasi gambar statis atau gestur sederhana, namun tidak optimal untuk sekuens citra [21].

2. Perbandingan Hasil Penelitian dengan Konsep Ilmiah

Tabel 11 keterkaitan antara konsep ilmiah serta hasil yang diperoleh

No.	Konsep Ilmiah	Peran dalam Penelitian	Keterkaitan dengan Hasil Penelitian	Interpretasi
1	Convolutional Neural Network (CNN)	CNN digunakan untuk melakukan ekstraksi fitur lokal dari citra kuku melalui operasi konvolusi.	Model dapat memanfaatkan karakteristik lokal seperti tekstur permukaan, variasi warna, bentuk tepi kuku, dan pola visual lainnya.	Hasil penelitian mendukung konsep CNN bahwa ekstraksi fitur spasial secara otomatis dapat menghasilkan karakteristik yang relevan untuk klasifikasi citra medis
2	Vision Transformer (ViT)	Vision Transformer digunakan untuk mempelajari hubungan global antarpatch citra menggunakan mekanisme self-attention.	ViT memungkinkan model mempelajari keterkaitan antarbagian kuku secara menyeluruh, bukan hanya berdasarkan karakteristik lokal.	Hasil penelitian mendukung konsep ViT bahwa mekanisme self-attention dapat membangun representasi global yang lebih komprehensif untuk citra dengan pola visual kompleks
3	Integrasi CNN dan Vision Transformer	CNN menghasilkan feature map yang kaya akan informasi spasial lokal, kemudian Vision Transformer mempelajari hubungan antarbagian feature map melalui mekanisme multi-head self-attention.	Model dapat mempertimbangkan karakteristik lokal seperti tekstur dan warna sekaligus hubungan global antarbagian kuku.	Integrasi CNN dan ViT menghasilkan representasi fitur yang lebih lengkap dibandingkan penggunaan masing-masing arsitektur secara terpisah.
4	Long Short-Term Memory (LSTM)	LSTM digunakan sebagai lapisan lanjutan untuk memperkuat representasi fitur sebelum klasifikasi akhir.	Mekanisme forget gate, input gate, dan output gate memungkinkan informasi penting dipertahankan dan informasi yang kurang relevan dikurangi.	Penggunaan LSTM mendukung konsep bahwa mekanisme memori dapat membantu mempertahankan representasi fitur penting pada model deep learning hibrida
5	Peran LSTM terhadap stabilitas klasifikasi	Fitur hasil proses CNN dan Vision Transformer diteruskan ke LSTM sebelum proses klasifikasi.	Model menghasilkan precision 91,89%, recall 94,44%, dan F1-score 93,13%.	Nilai metrik tersebut menunjukkan bahwa model mampu menghasilkan prediksi yang relatif stabil pada kelas diabetes dan non-diabetes.
6	Konsep model Hybrid Deep Learning	Setiap arsitektur digunakan berdasarkan karakteristik dan keunggulan masing-masing.	CNN menangkap fitur lokal, ViT menangkap hubungan global, sedangkan LSTM memperkuat representasi fitur sebelum klasifikasi.	Hasil penelitian memperkuat konsep bahwa penggabungan beberapa arsitektur yang saling melengkapi dapat menghasilkan proses pembelajaran citra yang lebih komprehensif.
7	Performa klasifikasi model hibrida	Model Hybrid Vision Transformer–CNN–LSTM digunakan untuk	Model menghasilkan accuracy 93,33%, precision 91,89%, recall	Hasil tersebut menunjukkan kemampuan klasifikasi

No.	Konsep Ilmiah	Peran dalam Penelitian	Keterkaitan dengan Hasil Penelitian	Interpretasi
		klasifikasi citra kuku ke dalam kelas diabetes dan non-diabetes.	94,44%, F1-score 93,13%, dan AUC 0,972.	yang tinggi serta kemampuan diskriminasi yang sangat baik pada data pengujian.

3.Perbandingan Hasil Penelitian dengan Penelitian Terdahulu

Hasil penelitian ini menunjukkan bahwa model Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM) mampu mencapai accuracy sebesar 93,33%, precision sebesar 91,89%, recall sebesar 94,44%, F1-score sebesar 93,13%, dan Area Under Curve (AUC) sebesar 0,972. Hasil tersebut menunjukkan bahwa model yang dikembangkan memiliki kemampuan klasifikasi yang sangat baik dalam membedakan citra kuku penderita diabetes dan non-diabetes. Apabila dibandingkan dengan berbagai penelitian sebelumnya, performa model yang diusulkan menunjukkan peningkatan baik dari sisi pendekatan yang digunakan maupun objek citra yang dianalisis. Berikut tabel dibawah ini:

Tabel 12. Perbandingan Penelitian Terdahulu dengan Penelitian yang Diusulkan

No.	Peneliti	Objek/Data	Metode/Arsitektur	Hasil Utama	Keterbatasan/Gap	Posisi Penelitian Ini
1	Safitri, Mustaqim, dan Muhajir (2025) [5]	Citra retinopati diabetik APTOS2019	CLAHE, Gamma Correction, Retinex; DenseNet121 dan EfficientNetB0	Gamma Correction + DenseNet121 menghasilkan akurasi 81,4%; EfficientNet B0 memperoleh rata-rata akurasi 81,9%.	Fokus pada peningkatan kualitas citra retina dan belum mengeksplorasi objek citra kuku serta arsitektur hybrid CNN–ViT–LSTM.	Penelitian ini menggunakan citra kuku dan mengintegrasikan CNN, Vision Transformer, dan LSTM untuk klasifikasi diabetes/non-diabetes.
2	Kusuma dan Poetro (2025) [6]	Citra fundus retina APTOS 2019	CNN berbasis EfficientNetB3 dan Grad-CAM	Akurasi validasi sebesar 75,70%. Grad-CAM digunakan untuk membantu interpretasi prediksi.	Akuisisi citra masih bergantung pada fundus retina dan performa klasifikasi pada tingkat keparahan tinggi masih perlu ditingkatkan.	Penelitian ini mengubah objek analisis menjadi citra kuku serta menggunakan arsitektur hybrid untuk klasifikasi dua kelas diabetes dan non-diabetes.
3	Shidik, Musthofa, Kartiningtyas, dan Agustin (2024) [8]	Citra fundus penyakit mata, termasuk diabetic retinopathy	CNN, antara lain ResNet50, MobileNet, dan DenseNet	ResNet50 memperoleh akurasi 92,27% dan menunjukkan performa lebih baik dibandingkan beberapa arsitektur pembandingan.	Fokus penelitian masih pada penyakit mata melalui citra fundus dan menggunakan pendekatan CNN.	Penelitian ini menggunakan citra kuku dan mengombinasikan ekstraksi fitur lokal CNN dengan representasi global ViT serta LSTM.
4	Kenny Belle Lesmanal, Ketut Gede Suhartana[7]	1.000 citra kuku: 500 Normal dan 500 Diabetes	Hybrid Vision Transformer–CNN–LSTM	Accuracy 93,33%; Precision 91,89%; Recall 94,44%; F1-	Dataset masih perlu diperluas dan divalidasi pada populasi serta kondisi pengambilan	Mengusulkan citra kuku sebagai objek baru dan mengintegrasikan CNN, Vision

No.	Peneliti	Objek/Data	Metode/Arsitektur	Hasil Utama	Keterbatasan/Gap	Posisi Penelitian Ini
				Score 93,13%; AUC 0,972	citra yang lebih beragam.	Transformer, dan LSTM sebagai pendekatan klasifikasi hybrid.

Apabila dianalisis secara keseluruhan, sebagian besar penelitian terdahulu berfokus pada citra fundus retina sebagai objek utama deteksi diabetes maupun komplikasinya. Walaupun pendekatan tersebut menghasilkan performa yang baik, implementasinya masih memerlukan peralatan khusus, biaya relatif tinggi, dan operator yang memiliki kompetensi dalam pengambilan citra. Penelitian ini memperluas ruang lingkup penelitian dengan menggunakan citra kuku sebagai objek analisis. Selain perbedaan objek penelitian, penelitian ini juga memberikan kebaruan dari sisi arsitektur model. Sebagian besar penelitian terdahulu hanya menggunakan satu model *deep learning*, seperti CNN, EfficientNet, DenseNet, atau ResNet. Penelitian ini mengintegrasikan CNN, Vision Transformer, dan LSTM ke dalam satu arsitektur pembelajaran sehingga mampu memanfaatkan keunggulan masing-masing metode secara bersamaan. CNN bertanggung jawab terhadap ekstraksi fitur lokal, Vision Transformer mempelajari hubungan global antarfitur menggunakan mekanisme *self-attention*, sedangkan LSTM mempertahankan representasi fitur yang paling relevan sebelum dilakukan proses klasifikasi.

Dengan demikian, hasil penelitian ini tidak hanya mendukung penelitian-penelitian sebelumnya yang menunjukkan efektivitas *deep learning* dalam analisis citra medis, tetapi juga memberikan temuan baru (novelty) berupa penerapan Hybrid Vision Transformer–CNN–LSTM pada citra kuku sebagai media deteksi diabetes. Temuan tersebut memperluas pemanfaatan teknologi *deep learning* dalam bidang kesehatan serta membuka peluang pengembangan sistem skrining diabetes yang lebih sederhana, noninvasif, dan mudah diimplementasikan pada berbagai fasilitas pelayanan kesehatan maupun perangkat bergerak.

4. Kontribusi Penelitian terhadap Pengembangan Ilmu Pengetahuan

1. Pertama, kontribusi pada objek penelitian. Penelitian ini memperluas pemanfaatan *computer vision* dalam bidang kesehatan dengan menggunakan citra kuku sebagai objek analisis diabetes.
2. Kedua, kontribusi metodologis. Penelitian ini mengembangkan pendekatan Hybrid Vision Transformer–CNN–LSTM. CNN digunakan untuk memperoleh karakteristik lokal citra, Vision Transformer mempelajari hubungan global melalui *self-attention*, sedangkan LSTM digunakan untuk memproses representasi fitur sebelum tahap klasifikasi.
3. Ketiga, kontribusi pada performa model. Berdasarkan pengujian terhadap 150 citra, model menghasilkan accuracy 93,33%, precision 91,89%, recall 94,44%, F1-score 93,13%, dan AUC 0,972. Hasil tersebut menunjukkan bahwa model mampu melakukan klasifikasi dengan performa tinggi pada dataset penelitian.
4. Keempat, kontribusi implementatif. Penggunaan citra kuku memberikan peluang pengembangan sistem skrining yang lebih sederhana karena proses akuisisi citra berpotensi dilakukan menggunakan kamera digital atau perangkat telepon pintar.
5. Kelima, kontribusi terhadap pengembangan ilmu pengetahuan. Penelitian ini memberikan dasar bagi pengembangan *Artificial Intelligence for Healthcare*, khususnya dalam klasifikasi citra medis menggunakan arsitektur hibrida.

5. Keterbatasan Penelitian dan Peluang Penelitian Selanjutnya

Meskipun model *Hybrid Vision Transformer–CNN–LSTM* yang dikembangkan menghasilkan performa klasifikasi yang baik, penelitian ini masih memiliki sejumlah keterbatasan yang perlu dipertimbangkan dalam menginterpretasikan hasil. Keterbatasan tersebut sekaligus menjadi dasar untuk menentukan arah pengembangan penelitian selanjutnya.

Tabel 13. Keterbatasan Penelitian dan Arah Pengembangan

No.	Aspek	Keterbatasan Penelitian	Dampak terhadap Penelitian	Peluang Penelitian Selanjutnya
1	Dataset	Dataset terdiri atas 1.000 citra kuku dengan dua kelas, yaitu diabetes dan non-diabetes. Keragaman data masih terbatas pada kondisi tertentu.	Kemampuan generalisasi model terhadap populasi yang lebih luas belum dapat dipastikan secara optimal.	Menggunakan dataset yang lebih besar dan berasal dari beberapa institusi kesehatan dengan variasi usia, jenis kelamin, warna kulit, tingkat keparahan diabetes, serta karakteristik citra yang lebih beragam.
2	Akuisisi Citra	Kualitas citra masih dipengaruhi pencahayaan, posisi kamera, sudut pengambilan gambar, kualitas kamera, dan bayangan pada kuku.	Variasi kondisi akuisisi dapat memengaruhi karakteristik fitur yang dipelajari model.	Mengembangkan prosedur akuisisi citra yang terstandar serta segmentasi otomatis berbasis attention mechanism atau instance segmentation yang lebih robust.
3	Preprocessing	Preprocessing yang digunakan meliputi resize, normalisasi, segmentasi, dan augmentasi, tetapi belum secara khusus mengatasi seluruh variasi kondisi pencahayaan dan perangkat.	Informasi visual tertentu berpotensi mengalami perubahan akibat kondisi pengambilan citra.	Mengembangkan preprocessing adaptif, color normalization, illumination correction, dan teknik segmentasi yang lebih kuat.
4	Arsitektur Model	Penelitian belum melakukan perbandingan langsung dengan arsitektur deep learning modern lainnya.	Posisi performa model Hybrid Vision Transformer–CNN–LSTM terhadap arsitektur terkini belum dapat diketahui secara komprehensif.	Membandingkan model dengan Swin Transformer, ConvNeXt, EfficientNetV2, maupun foundation vision models.
5	Interpretabilitas Model	Model belum dilengkapi mekanisme interpretasi yang menjelaskan bagian citra yang menjadi dasar prediksi.	Keputusan model masih bersifat <i>black box</i> sehingga interpretasinya bagi tenaga kesehatan terbatas.	Mengintegrasikan Explainable Artificial Intelligence (XAI) seperti Grad-CAM, Score-CAM, atau visualisasi attention.
6	Implementasi	Penelitian masih berfokus pada pengembangan dan evaluasi model, belum pada implementasi sistem secara langsung di lingkungan pelayanan kesehatan.	Kesiapan model untuk digunakan oleh pengguna akhir belum diuji.	Mengembangkan aplikasi berbasis mobile, cloud computing, IoT, dan telemedicine untuk mendukung skrining pada fasilitas kesehatan maupun wilayah dengan keterbatasan fasilitas laboratorium.

5. Simpulan

Penelitian ini berhasil mengembangkan model deteksi diabetes berbasis analisis citra kuku. Penelitian ini berhasil mengembangkan model deteksi diabetes berbasis analisis citra kuku menggunakan metode *Hybrid Vision Transformer–Convolutional Neural Network–Long Short-Term Memory (Vision Transformer–CNN–LSTM)* sebagai pendekatan deteksi dini yang bersifat noninvasif. Melalui tahapan pengumpulan dataset, *preprocessing* citra, pembentukan model hibrida, pelatihan, dan pengujian, model mampu mengenali karakteristik visual citra kuku untuk membedakan kelas diabetes dan non-diabetes dengan tingkat kinerja yang baik. Hasil evaluasi menunjukkan bahwa model memperoleh accuracy sebesar 93,33%, precision 91,89%, recall 94,44%, F1-score 93,13%, serta *Area Under Curve (AUC)* sebesar 0,972, yang menunjukkan kemampuan klasifikasi dan diskriminasi yang sangat baik. Temuan tersebut membuktikan bahwa

integrasi *Vision Transformer* dalam menangkap hubungan global citra, *Convolutional Neural Network* dalam mengekstraksi fitur lokal, serta *Long Short-Term Memory* dalam memperkuat representasi fitur mampu meningkatkan efektivitas proses klasifikasi citra kuku. Dengan demikian, penelitian ini memberikan kontribusi berupa alternatif metode deteksi diabetes berbasis citra kuku yang lebih sederhana, mudah diakses, dan berpotensi mendukung proses skrining awal tanpa prosedur invasif. Pengembangan selanjutnya diarahkan pada penggunaan dataset yang lebih besar dan tervalidasi secara klinis, pengujian pada berbagai kondisi akuisisi citra, serta evaluasi terhadap arsitektur pembelajaran mendalam lainnya untuk meningkatkan kemampuan generalisasi model.

Daftar Referensi

- [1] Indra, S. Anto, L. O. Ardiansyah, and R. Toding, "Hubungan Lama Menderita Dan Kepatuhan Diet Dengan Quality Of Life Pasien Diabetes Melitus Di Rumah Sakit Umum Bahteramas," *J. Media Keperawatan Univ. Widya Nusantara*, vol. 14, no. 2, pp. 64–68, 2023.
- [2] P. Greis, U. Kalsum, E. Wisudariani, R. Halim, and H. Suryani, "Faktor Risiko Kejadian Diabetes Melitus Tipe 2 pada Pegawai Pemerintah di Indonesia (Analisis Data SKI Tahun 2023)," *J. Ilm. Kedokt. dan Kesehat.*, vol. 4, no. September, pp. 291–305, 2025.
- [3] Rista Riviani, Erna Mutiara, Heru Santosa, and Arifa Masyitah, "Analisis Spasial Kasus Diabetes Melitus dan Faktor Risiko di Provinsi Sumatera Utara Tahun 2023," *J. Pengabd. Masy. dan Ris. Pendidik.*, vol. 4, no. 1, pp. 972–979, 2025, doi: 10.31004/jerkin.v4i1.1683.
- [4] I. Ema Purwaningsih, Ludiana, "Penerapan Senam Kaki Diabetes Untuk Meningkatkan Sensitivitas Kaki Pasien Diabetes Mellitus Tipe II Di Puskesmas Metro," *J. Cendikia Muda Vol. 3, Nomor 2, Juni 2023 ISSN 2807-3469*, vol. 3, pp. 235–244, 2023.
- [5] P. H. Safitri, T. Mustaqim, and D. Muhajir, "Analisis Perbandingan Metode Preprocessing untuk Citra Retinopati Diabetik Menggunakan Deep learning," *J. Algoritma*, vol. 22, no. 2, pp. 1814–1821, 2025, doi: 10.33364/algoritma/v.22-2.2324.
- [6] Hendra Irawan Wijaya Kusuma and Bagus Satrio Waluyo Poetro, "Deteksi Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Efficientnet Dan Grad-Cam Pada Citra Fundus Retina," *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 3, no. 1, pp. 126–138, 2025, doi: 10.70248/jrsit.v3i1.2896.
- [7] Kenny Belle Lesmana and I Ketut Gede Suhartana, "Deteksi Penyakit Diabetes Menggunakan Gaussian Naive Bayes, Regresi Logistik, dan Random Forest," *J. Nas. Teknol. Inf. dan Apl.*, vol. 1, no. 4, pp. 1209–1214, 2023, doi: 10.24843/jnatia.2023.v01.i04.p25.
- [8] F. A. Shidik, K. Mustofa, A. P. Kartiningtyas, and T. Agustin, "Analisis Citra Medis Untuk Identifikasi Penyakit Mata Dengan Teknologi Convolutional Neural Networks," *Semin. Nas. Amikom Surakarta 2024*, no. November, pp. 68–80, 2024.
- [9] H. S. Wulandari, A. Aziz, and K. Kunci, "Implementasi Model LSTM, CNN+LSTM Hybrid, dan Transformer untuk Prediksi Cuaca Harian Berbasis Data Multivariat," *Technol. Sci.*, vol. 7, no. 2, pp. 1005–1016, 2025, doi: 10.47065/bits.v7i2.7655.
- [10] W. M. Ardana and Kusri, "Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 1274–1286, 2025.
- [11] Anditya. I Gede Made Widi and Mastrika. Gst. Ayu Vida, "Klasifikasi Kematangan Tomat pada Citra Digital Menggunakan DeiT (Data-efficient Image Transformer)," *J. Nas. Teknol. Inf. dan Apl.*, vol. 3, no. 4, pp. 737–744, 2025, [Online]. Available: <https://www.kaggle.com/datasets/sujaykapadnis/tomato-maturity-detection-and-quality-grading>.
- [12] R. Sari, A. E. Minarno, and Y. Azhar, "Implementasi Jaringan CNN-LSTM Untuk Deteksi Citra X-Ray Dada Covid-19," *J. Repos.*, vol. 4, no. 4, pp. 451–462, 2024, doi: 10.22219/repositor.v4i4.32290.
- [13] P. S. Gagah Daruhadi, "Metode Pengumpulan Data Penelitian," *J-CEKI J. Cendekia Ilm. Vol.3, No.5, 2024*, vol. 3, no. 5, pp. 5423–5443, 2024.
- [14] Rio Subandi, Herman, and Anton Yudhana, "Pre-Processing Pada Klasifikasi Citra Medis Pneumonia," *Decod. J. Pendidik. Teknol. Inf.*, vol. 4, no. 1, pp. 86–93, 2023, doi: 10.51454/decode.v4i1.198.
- [15] F. Salim *et al.*, "Jurnal Computer Science and Information Technology (CoSciTech) Klasifikasi Berita Palsu Menggunakan Pendekatan Hybrid CNN-LSTM Fake News

- Classification Using Hybrid CNN-LSTM Approach,” *J. Comput. Sci. Inf. Technol.*, vol. 6, no. 1, pp. 55–59, 2025.
- [16] A. N. Juniar, S. Mahdi, H. Hendra, G. L. Wardhani, and R. Raudah, “Sistem Otomatisasi Blur Citra Wajah Menggunakan Gaussian Filter Dan Dlib CNN,” *Elektr. Borneo*, vol. 9, no. 2, pp. 109–113, 2023, doi: 10.35334/eb.v3i2.2307.
- [17] I. P. Surya Ario Pratama, Gasim, “Pengaruh Resize Citra terhadap Pengenalan Sidik Jari dengan Pendekatan Klasifikasi SVM,” *J. Pendidik. Sains dan Komput.*, vol. 6, no. 02, pp. 144–155, 2026.
- [18] P. W. Bambang Irawan, Nur Ariesanto Ramdhan, “Optimasi Algoritma Adam untuk Peningkatan Akurasi Klasifikasi Penyakit Daun Padi Berbasis CNN,” *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 13, no. 105, pp. 738–743, 2024.
- [19] Yudha Riwanto, Inggrid Yanuar Risca Pratiwi, and Muhammad Ainul Fikri, “Segmentasi Citra Menggunakan Pendekatan Trial and Error dan Metode Otsu untuk Identifikasi Objek,” *J. Inform. Polinema*, vol. 11, no. 3, pp. 371–378, 2025, doi: 10.33795/jip.v11i3.7046.
- [20] D. Mirwansyah, A. Solichin, R. Hardi, N. Wanti Wulan Sari, N. Arista Rizki, and D. Aldo, “Augmentasi Citra Pohon Kelapa Sawit untuk Deteksi Objek Berbasis Deep Learning,” *Metik J.*, vol. 9, p. 2025, 2025, doi: 10.47002/metik.v9i1.1001.
- [21] Y. Darmayunata and L. F. Lhaura Van, “Benchmarking Cnn, Lstm, And Vision Transformer Models For Multilingual Sign Language Recognition: A Case Study On ASL, ISL, AND BISINDO,” *J. Sist. Inf.*, vol. 8, no. 1, pp. 255–265, 2026.