



Penerapan Learning Vector Quantization Dalam Pengolahan Citra Digital Untuk Deteksi Penyakit Kulit

Rizki Akbar Pratama^{*1}, Barry Ceasar Octariadi², Syarifah Putri Agustini Alkadri³

Email: ¹rizkiakbarpratama@outlook.com, ²barry.ceasaro@unmuhpnk.ac.id, ³agustini.putri@unmuhpnk.ac.id

¹Program Studi Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Muhammadiyah Pontianak

²Program Studi Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Muhammadiyah Pontianak

³Program Studi Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Muhammadiyah Pontianak

Diterima: 26 Mei 2025 | Direvisi: 04 Agustus 2025 | Disetujui: 10 Agustus 2025

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Kulit merupakan organ terbesar manusia, dengan luas lebih dari dua meter persegi dan menyumbang sekitar 15% dari massa tubuh. Terdiri dari tiga lapisan utama (epidermis, dermis, dan jaringan subkutan), kulit berfungsi sebagai pelindung fisik dan penghalang terhadap infeksi, cedera, serta radiasi UV. Penyakit kulit seperti cacar air, cacar monyet, campak, dan herpes menjadi tantangan medis yang memerlukan diagnosis cepat dan akurat. Penelitian ini menggunakan 520 citra digital (130 per kategori) dari Mendeley Data dan sumber daring. Algoritma Learning Vector Quantization (LVQ) diterapkan untuk klasifikasi citra berdasarkan fitur yang diekstraksi. Hasil menunjukkan akurasi keseluruhan sebesar 90,74%, dengan akurasi masing-masing: 97% (cacar air), 98% (cacar monyet), 91% (campak), dan 100% (herpes). Evaluasi menggunakan confusion matrix menghasilkan nilai accuracy, precision, recall, dan F1-score sebesar 0,91, menunjukkan performa model yang kuat. Temuan ini menunjukkan potensi LVQ sebagai alat bantu diagnosis penyakit kulit berbasis citra digital.

Kata kunci: *Learning Vector Quantization, Pengolahan Citra Digital, Deteksi Penyakit Kulit, Local Binary Pattern*

Application of Learning Vector Quantization in Digital Image Processing for Skin Disease Detection

Abstract

Skin, as the largest human organ, covers more than two square meters and accounts for about 15% of body mass. Consisting of three main layers of epidermis, dermis, and subcutaneous tissue, the skin serves as a physical shield and barrier against infection, injury, and UV radiation. Skin diseases such as chickenpox, monkey pox, measles and herpes are medical challenges that require quick and accurate diagnosis. This study used 520 digital images (130 per category) from Mendeley Data and online sources. The Learning Vector Quantization (LVQ) algorithm was applied for image classification based on the extracted features. Results showed an overall accuracy of 90.74%, with respective accuracies: 97% (chickenpox), 98% (monkey pox), 91% (measles), and 100% (herpes). Evaluation using confusion matrix resulted in accuracy, precision, recall, and F1-score values of 0.91, indicating strong model performance. These findings demonstrate the potential of LVQ as a digital image-based skin disease diagnosis tool.

Keywords: *Learning Vector Quantization, Skin Diseases Detection, Digital Image Processing, Local Binary pattern*

1. PENDAHULUAN

Kulit merupakan organ terbesar manusia dengan luas lebih dari dua meter persegi dan menyumbang sekitar 15% dari massa tubuh [1]. Terdiri dari epidermis, dermis, dan jaringan subkutan, kulit berfungsi sebagai pelindung terhadap patogen, cedera


eksternal, sinar UV, serta berperan dalam pengaturan suhu, produksi vitamin D, dan fungsi hormonal[2][3][4]. Selain itu, kulit memiliki sistem imun yang penting dalam pertahanan tubuh dan penyembuhan luka[2][5].

Penyakit kulit seperti cacar air, campak, dan cacar monyet masih menjadi masalah kesehatan masyarakat, termasuk di Indonesia yang mencatat 13.527 kasus cacar air pada tahun 2022. Gejala penyakit ini serupa, meliputi demam, ruam, dan lesi pada kulit[6][7][8][9][10]. Oleh karena itu, deteksi dini sangat penting untuk mencegah komplikasi dan memastikan pengobatan yang tepat. Kemajuan teknologi seperti jaringan saraf tiruan dan pengolahan citra digital telah meningkatkan akurasi diagnosis penyakit kulit. *Learning Vector Quantization* (LVQ) metode ini membantu mengurangi gangguan atau noise dan membuat penyortiran menjadi lebih akurat. *Learning Vector Quantization* (LVQ) sangat bagus dalam menghilangkan noise dalam data, yang membuatnya sempurna untuk kumpulan data yang banyak berubah atau tidak jelas. Kecepatan kerja *learning vector quantization* (LVQ) yang cepat merupakan nilai tambah yang besar, terutama dalam situasi di mana data perlu diproses dengan cepat. *Learning Vector Quantization* (LVQ) efektif dalam melakukan klasifikasi untuk *multiple* kelas, yang membawa manfaat penting dalam beragam aplikasi[11]. Sebagai perbandingan, penelitian lain menggunakan pendekatan *Support Vector Machine* (SVM) untuk klasifikasi penyakit kulit, dan memperoleh akurasi sebesar 86,42%[12]


Salah satu metode yang menjanjikan adalah *Learning Vector Quantization* (LVQ), yang menggunakan arsitektur berlapis dan pembelajaran terawasi. Metode ini efektif dalam klasifikasi multi-kelas, tahan terhadap *noise*, dan mampu bekerja dengan cepat. Evaluasi dengan *confusion matrix* menunjukkan nilai presisi 85%, recall 82%, dan akurasi 83%, menandakan potensi besar LVQ dalam mendukung diagnosis berbasis citra[13].

2. METODE PENELITIAN

Pada Gambar 1 dan Gambar 2 dijabarkan secara rinci alur penelitian serta tahapan pengolahan data yang diperlukan agar hasil yang diperoleh memiliki kemampuan deteksi yang optimal dalam mendiagnosis penyakit kulit.



Gambar 1 Diagram Alir Penelitian



Gambar 2 Alur Preprocessing dan Pelatihan LVQ.


2.1. Dataset

Pada tahap ini dilakukan pengumpulan dataset dari Mendeley Data, Roboflow, dan scraping data. Dataset awal dari Mendeley Data terdiri atas 279 citra cacar monyet, 107 cacar air, 91 campak, dan 293 normal. Untuk menyeimbangkan jumlah data, dilakukan penyesuaian sehingga masing-masing kelas berisi 130 citra. Kelas “normal” diganti menjadi “herpes” untuk fokus

pada deteksi penyakit kulit. Total dataset terdiri dari 520 citra, masing-masing 130 citra untuk cacar air, campak, cacar monyet, dan herpes. Dataset ini dikembangkan oleh Department of Computer Science and Engineering, Islamic University, Kushtia-7003, Bangladesh, 23 February 2023. Bala, Diponkor; Hossain, Md Shamim (2023), “Monkeypox Skin Images Dataset (MSID)”, Mendeley Data, V6, doi: 10.17632/r9bfpnvxtr.6[14].

2.2. Preprocessing

Preprocessing citra merupakan tahap awal yang krusial dalam pemrosesan citra, bertujuan untuk menyiapkan citra mentah agar siap untuk analisis, interpretasi, atau manipulasi lanjutan. Proses ini mencakup dua kategori utama, yaitu restorasi citra untuk menghilangkan keburaman, serta penyempurnaan citra guna meningkatkan kontras, kecerahan, dan detail visual[15].




Gambar 3 Alur Preprocessing

Penelitian ini menggunakan 520 citra penyakit kulit dalam format JPG dan PNG. Augmentasi dilakukan dengan teknik seperti *flip*, *crop*, *rotasi*, serta penyesuaian saturasi, *brightness*, dan penambahan *noise*, sehingga total dataset menjadi 1080 citra (270 per kelas). Seluruh citra dikonversi ke skala abu-abu dan diubah ukurannya menjadi 500×500 piksel untuk menyederhanakan fitur visual dan memastikan konsistensi resolusi. Dataset yang telah diproses ini digunakan untuk pelatihan dan pengujian model klasifikasi.

2.3. Ekstraksi Fitur

Ekstraksi fitur bertujuan menghasilkan representasi ringkas dari data piksel mentah untuk mempermudah tugas analisis citra seperti klasifikasi, pengenalan, dan segmentasi. Sebelum era *deep learning*, ekstraksi dilakukan menggunakan metode tradisional berbasis fitur buatan ahli, meskipun pendekatan ini sering menghadapi keterbatasan dalam adaptasi terhadap berbagai jenis citra[15].



Gambar 4 Alur Ekstraksi Fitur

Setelah *preprocessing*, citra dinormalisasi ke rentang 0–255 untuk kompatibilitas dengan metode LBP. Fitur LBP dihitung menggunakan parameter $P=32$, $R=4$ dan metode *uniform* untuk menangkap pola tekstur lokal. Hasilnya dikonversi menjadi histogram frekuensi yang kemudian dinormalisasi agar totalnya satu, dan disimpan sebagai array fitur untuk pelatihan model.

2.4. Min-Max Scaling

Min-Max Scaling adalah teknik normalisasi yang mentransformasikan nilai fitur ke dalam rentang [0,1] secara proporsional, dengan memetakan nilai minimum menjadi 0 dan maksimum menjadi 1. Teknik ini diterapkan untuk menjaga keseimbangan kontribusi setiap fitur dalam proses klasifikasi dan mencegah dominasi fitur dengan nilai numerik besar[16]. Transformasi *Min-Max Scaling* diaplikasikan mengikuti persamaan 1.

$$X' = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) \quad (1)$$

X' menunjukkan hasil normalisasi dari nilai asli X , dengan X_{min} dan X_{max} masing-masing merepresentasikan nilai minimum dan maksimum dalam distribusi fitur.

2.5. Pembangunan Model Learning Vector Quantization (LVQ)

Proses *learning vector quantization* (LVQ) terdiri dari beberapa tahap untuk mengoptimalkan klasifikasi berdasarkan kedekatan vektor *input* dengan vektor prototipe. Vektor fitur awal dipetakan ke *neuron* pada lapisan Kohonen, yang mewakili prototipe tiap

kelas. Jarak antara vektor *input* dan semua prototipe dihitung menggunakan metrik *Euclidean*, *neuron* dengan jarak terkecil dipilih sebagai pemenang. Bobot *neuron* pemenang disesuaikan mendekati vektor *input* jika kelasnya sama, atau menjauh jika berbeda dengan laju pembelajaran tertentu. Proses ini berlangsung hingga iterasi maksimum atau tercapai *konvergensi*. Setelah pelatihan, model siap mengklasifikasikan data baru berdasarkan jarak ke vektor prototipe[17].

Manfaat utama dari penggunaan jaringan syaraf tiruan *learning vector quantization* (LVQ) adalah kemampuannya untuk memberikan pelatihan pada lapisan kompetitif. Algoritma *learning vector quantization* (LVQ) yang dimulai dari inisialisasi bobot awal (W) dan parameter dari *learning vector quantization* (LVQ). Kemudian tentukan J sedemikian rupa sehingga $\|X_i - W_j\|$ dengan menggunakan rumus jarak *Euclidian*, yang dihitung menggunakan rumus 2.

$$D(j) = \sum (W_{ij} - x_i)^2 \quad (2)$$

Selanjutnya, perbarui bobot W_j menggunakan Rumus 3 jika kelas target (T) sama dengan kelas prototipe (C_j), dan gunakan Rumus 4 jika kelasnya berbeda.[13].

$$W_j(t+1) = W_j(t) + \alpha(t) [x(t) - W_j] \quad (3)$$

$$W_j(t+1) = W_j(t) - \alpha(t) [x(t) - W_j] \quad (4)$$

2.6. Pengujian

Confusion matrix merupakan alat penting dalam evaluasi kinerja model *machine learning*, khususnya dalam klasifikasi. Matriks ini menyajikan representasi tabel yang menunjukkan jumlah prediksi benar dan salah pada data uji, sehingga memungkinkan analisis akurasi klasifikasi secara menyeluruh. Melalui *confusion matrix*, dapat diketahui sejauh mana model mengklasifikasikan objek dengan tepat maupun keliru[18].

Tabel 1 *Confusion Matrix*

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

Berdasarkan struktur *confusion matrix* ini, kita dapat dengan mudah menghitung nilai akurasi, *recall*, dan presisi dari sistem yang dievaluasi. Berikut adalah rumus perhitungannya:

$$\text{Classification Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% = \quad (5)$$

Keterangan :

True Positive (TP) = Data positif diprediksi dengan benar.

True Negative (TN) = Data negatif yang juga diprediksi dengan benar.

False Positive (FP) = Data negatif salah diprediksi sebagai positif.

False Negative (FN) = Data positif salah diprediksi sebagai negatif

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% = \quad (6)$$

Keterangan :

True Positive (TP) = Data positif diprediksi dengan benar.

False Positive (FP) = Data negatif salah diprediksi sebagai positif.

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% = \quad (7)$$

Keterangan:

True Positive (TP) = Data positif diprediksi dengan benar.

False Negative (FN) = Data positif salah diprediksi sebagai negatif.

$$F1 - \text{Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

Confusion matrix merupakan metode evaluasi umum dalam klasifikasi untuk menilai akurasi dan *recall*. Matriks ini terdiri dari empat komponen, TP (*True Positive*), data positif yang diklasifikasikan benar, TN (*True Negative*), data negatif yang diklasifikasikan benar, FP (*False Positive*), data negatif yang salah diklasifikasikan sebagai positif, dan FN (*False Negative*), data positif yang salah diklasifikasikan sebagai negatif[19][20].

3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan hasil penelitian dan analisis mendalam terhadap kinerja aplikasi deteksi penyakit kulit yang dikembangkan menggunakan algoritma *Learning Vector Quantization* (LVQ).


3.1. Preprocessing

Tahap ini melibatkan proses data *cleaning* untuk memastikan data dalam kondisi optimal sebelum pelatihan model. Langkah ini mencakup pembersihan dari kesalahan, ketidakkonsistenan, dan informasi tidak relevan guna meningkatkan efektivitas pelatihan dan akurasi model[21].

3.1.1. Augmentasi Data

Augmentasi dilakukan di *Roboflow* dengan menghasilkan tiga varian per citra melalui transformasi geometrik (*flip*, rotasi) dan intensitas (*zoom*, *grayscale parsial*, *saturasi*, *brightness*, *noise*). Proses ini meningkatkan keragaman data dan generalisasi model.


Tabel 2 menunjukkan contoh hasil augmentasi dari tiga kategori utama: rotasi, saturasi, dan *brightness*, sebagai ilustrasi visual. Meskipun hanya tiga yang ditampilkan, augmentasi dataset mencakup kombinasi seluruh teknik yang telah dijelaskan sebelumnya.



Tabel yang berisi gambar diatas merupakan hasil dari augmentasi data, yang awalnya masing-masing kelas memiliki 130 data citra setelah dilakukan augmentasi maka menjadi 270 data citra untuk masing-masing kelas.


3.1.2. Konversi Grayscale

Konversi ke *grayscale* dilakukan menggunakan *OpenCV* untuk menyederhanakan data citra tanpa kehilangan informasi penting, dengan mengubah citra berwarna menjadi skala abu-abu.



Gambar 5 Asli Penyakit Kulit

Gambar 5 menampilkan citra asli penyakit kulit sebelum proses konversi *grayscale*.




Gambar 6 Konversi Grayscale

Gambar 6 menunjukkan hasil konversi *grayscale* yang digunakan dalam model.

3.1.3. Resize Citra

Pengubahan ukuran gambar dilakukan menggunakan *OpenCV* dengan menyesuaikan lebar dan tinggi piksel. Proses ini dapat mempertahankan atau mengubah rasio aspek, dan berpengaruh terhadap akurasi model.




Gambar 7 Resize Citra

Hasil dari *resize* citra akan tampak sebagai gambar yang telah diubah ukurannya sesuai dengan dimensi baru yang ditentukan yaitu 500x500 *pixel*. Gambar yang dilakukan *resizing* akan tampak seperti gambar asli dengan perubahan ukuran.

3.2. Ekstraksi Fitur

Ekstraksi fitur citra bertujuan mengambil informasi penting dan merepresentasikannya sebagai vektor numerik yang dapat diolah oleh algoritma analisis atau klasifikasi.


3.2.1. Visualisasi Histogram *Local Binary Pattern*



Gambar 8 Histogram Local Binary Pattern

Gambar 8 menampilkan histogram LBP dari citra sampel ($P=32$, $R=4$), dengan sumbu *horizontal* menunjukkan pola LBP dan sumbu *vertikal* frekuensi yang dinormalisasi. Frekuensi tertinggi muncul pada bin ke-34 (sekitar 29%), mengindikasikan dominasi pola *non-uniform* dan tekstur kompleks. Peningkatan frekuensi pada bin 12–18 menunjukkan adanya pola *edge* atau *corner*.

3.2.2. Visualisasi Citra *Local Binary Pattern*




Gambar 9 Tekstur Citra *Local Binary Pattern*

Gambar 9 menunjukkan hasil transformasi *Local Binary Pattern* (LBP) pada citra sampel. Visualisasi ini memperlihatkan kemampuan *Local Binary Pattern* (LBP) dalam mengekstraksi pola tekstur, dengan area kanan menunjukkan pola teratur dan area tengah hingga kiri menampilkan pola acak. Variasi intensitas mencerminkan perbedaan pola *Local Binary Pattern* (LBP) dalam citra asli.

3.3. *Min-Max Scaling*

Untuk mengevaluasi efektivitas *Min-Max Scaling*, dilakukan analisis komparatif terhadap distribusi fitur *Local Binary Pattern* (LBP) sebelum dan sesudah proses normalisasi, yang divisualisasikan.


3.3.1. Analisis Distribusi Fitur Sebelum *Min-Max Scaling*



Gambar 10 Top 10 lbp sebelum *Min-max scaling*

Analisis menunjukkan LBP_33 memiliki rentang nilai tertinggi, sedangkan LBP_32 mengandung banyak outlier. Fitur LBP_15 hingga LBP_20 sebagian besar terdistribusi di bawah nilai 0.1. Ditemukan juga ketidakseimbangan skala antar fitur, dengan beberapa fitur memiliki rentang yang jauh lebih besar.


Pada Gambar 12 menampilkan distribusi kuartil dari 34 fitur LBP sebelum dilakukan normalisasi *Min-Max*.



Gambar 11 Distribusi Kuartil *Min-Max Scaling*

Sebagian besar fitur LBP memiliki rentang nilai sempit (0–0,1), dengan LBP_14–LBP_17 menunjukkan nilai maksimum sedikit lebih tinggi, sementara LBP_32 dan LBP_33 mencapai puncak signifikan (sekitar 0,68 dan sekitar 0,72). Distribusi kuartil mayoritas fitur terkonsentrasi pada 0–0,02 (minimum–Q1), median <0,05, dan Q3 ≤0,1. Terdapat perbedaan jelas antara LBP_0–LBP_31 yang stabil dan LBP_32 – LBP_33 dengan distribusi lebih luas serta nilai maksimum tinggi, mengindikasikan variasi skala yang perlu dipertimbangkan dalam normalisasi.


3.3.2. Evaluasi Distribusi Fitur Setelah *Min-Max Scaling*



Gambar 12 Top 10 Lbp Setelah *Min-Max Scaling*

Setelah normalisasi, semua fitur berada dalam rentang 0–1, dengan LBP_24 memiliki *median* tertinggi (sekitar 0,62). Distribusi menjadi lebih seimbang, memungkinkan perbandingan antarfitur, meskipun LBP_13 dan LBP_21 menunjukkan rentang lebih sempit.

Pada Gambar 14 menampilkan distribusi kuartil dari fitur *Local Binary Pattern* (LBP) yang sama setelah diterapkan normalisasi *Min-Max*.



Gambar 13 Distribusi Kuartil Setelah *Min-Max Scaling*

Setelah normalisasi *Min-Max Scaling*, semua fitur berada dalam rentang 0–1. Distribusi kuartil bervariasi: Q1 (0,05–0,45), *median* (0,1–0,6), dan Q3 (0,3–0,7). Beberapa fitur (LBP_12, LBP_19, LBP_22, LBP_24) memiliki *median* dan Q3 lebih tinggi, sedangkan LBP_31 terendah. LBP_33, yang sebelumnya dominan, kini lebih seimbang. Transformasi ini meningkatkan keseragaman skala, mendukung interpretasi dan pemodelan klasifikasi yang lebih akurat.

Min-Max Scaling meningkatkan kinerja model secara signifikan, dengan *learning vector quantization* (LVQ) mencapai akurasi, presisi, *recall*, dan *F1-score* 91% setelah normalisasi - naik dari 76% tanpa normalisasi. Hasil ini membuktikan efektivitas normalisasi dalam meningkatkan representasi fitur *Local Binary Pattern* (LBP).

3.4 Pembangunan Model *Learning Vector Quantization*

Model dievaluasi menggunakan 70:30 split data dan confusion matrix, dengan hasil dijelaskan berikutnya.

Tabel 3 Hasil Pelatihan Model

No	Epoch	Learning Rate	Akurasi	No	Epoch	Learning Rate	Akurasi
1.	10	0.01	0.87	21.	200	0.03	0.90
2.	30	0.01	0.88	22.	300	0.03	0.89
3.	50	0.01	0.89	23.	400	0.03	0.89
4.	100	0.01	0.89	24.	500	0.03	0.89
5.	200	0.01	0.90	25.	10	0.04	0.88
6.	300	0.01	0.90	26.	30	0.04	0.90
7.	400	0.01	0.90	27.	50	0.04	0.91
8.	500	0.01	0.90	28.	100	0.04	0.90
9.	10	0.02	0.88	29.	200	0.04	0.89
10.	30	0.02	0.89	30.	300	0.04	0.89
11.	50	0.02	0.89	31.	400	0.04	0.89
12.	100	0.02	0.90	32.	500	0.04	0.89
13.	200	0.02	0.91	33.	10	0.05	0.89
14.	300	0.02	0.90	34.	30	0.05	0.90
15.	400	0.02	0.91	35.	50	0.05	0.90
16.	500	0.02	0.90	36.	100	0.05	0.90
17.	10	0.03	0.88	37.	200	0.05	0.89
18.	30	0.03	0.89	38.	300	0.05	0.89
19.	50	0.03	0.90	39.	400	0.05	0.89
20.	100	0.03	0.90	40.	500	0.05	0.89

Tabel 3 menampilkan 40 kombinasi parameter epoch dan learning rate. Model terpilih (epoch=400, learning rate=0.02) dipilih berdasarkan akurasi tertinggi, seperti yang disorot dalam tabel.

3.5. Pengujian

Tabel 4 Evaluasi Confusion Matrix

No	Metrik Evaluasi	Skor
1	<i>Accuracy</i>	0.91
2	<i>Precision</i>	0.91
3	<i>Recall</i>	0.91
4	<i>F1-Score</i>	0.91

Tingkat akurasi pengenalan dihitung menggunakan Persamaan 9, yaitu dengan membagi jumlah prediksi yang benar terhadap total data uji dan dikalikan 100%.

$$\frac{\sum \text{Benar}}{\sum \text{Data Uji}} \times 100\% \quad (9)$$

Berdasarkan hasil pengujian LVQ pada Tabel 5, diperoleh akurasi masing-masing sebesar 91% untuk cacar monyet, 98% untuk cacar air, 99% untuk campak, dan 100% untuk herpes.

Tabel 5 Analisis Pengujian Learning Vector Quantization

No	Penyakit Kulit	Banyak Citra Penyakit Kulit	Berhasil	Tidak	Akurasi
1.	Cacar Monyet	100	91	9	91%
2.	Cacar Air	100	98	2	98%
3.	Campak	100	99	1	99%
4.	Herpes	100	100	0	100%

4. KESIMPULAN

Penelitian ini mengembangkan model deteksi penyakit kulit berbasis LVQ yang berhasil mengklasifikasikan empat jenis penyakit dengan akurasi tinggi. Hasil evaluasi menunjukkan performa komprehensif (accuracy=0.91, precision=0.91, recall=0.91, F1-score=0.91) dengan akurasi per kelas: 91% (cacar monyet), 98% (cacar air), 99% (campak), dan 100% (herpes). Peningkatan performa dicapai melalui preprocessing (resize citra dan ekstraksi fitur), dan model telah terimplementasi.

DAFTAR PUSTAKA

- [1] M. M. K. Nielsen, E. Aryal, E. Safari, B. Mojsoska, H. Jenssen, and B. K. Prabhala, "Current state of slc and abc transporters in the skin and their relation to sweat metabolites and skin diseases," 2021. doi: 10.3390/teomes9020023.
- [2] A. T. Slominski, R. M. Slominski, C. Raman, J. Y. Chen, M. Athar, and C. Elmets, "Neuroendocrine signaling in the skin with a special focus on the epidermal neuropeptides," 2022. doi: 10.1152/AJPCCELL.00147.2022.
- [3] I. Peate, "The skin: largest organ of the body," *British Journal of Healthcare Assistants*, vol. 15, no. 9, 2021, doi: 10.12968/bjha.2021.15.9.446.
- [4] K. Davies and C. Hewitt, "Biological basis of child health 13: structure and functions of the skin, and common children's skin conditions," *Nurs Child Young People*, vol. 34, no. 2, 2022, doi: 10.7748/ncyp.2021.e1359.
- [5] D. Datta, B. Madke, and A. Das, "Skin as an endocrine organ: A narrative review," 2022. doi: 10.25259/IJDVL_533_2021.
- [6] P. A. Siregar, N. A. Azwa, A. D. Mrp, and S. Maghfirah, "EPIDEMIOLOGI PENYAKIT MENULAR CACAR AIR," *JK: Jurnal Kesehatan*, vol. 1, no. 1, pp. 10–24, 2023.
- [7] K. Chadaga *et al.*, "Application of Artificial Intelligence Techniques for Monkeypox: A Systematic Review," Mar. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/diagnostics13050824.
- [8] M. Catalina Castro and P. Rojas, "Preventive effectiveness of varicella vaccine in healthy unexposed patients," *Medwave*, vol. 20, no. 06, pp. e7982–e7982, Jul. 2020, doi: 10.5867/medwave.2020.06.7982.
- [9] Q. Liu *et al.*, "Clinical Characteristics of Human Mpox (Monkeypox) in 2022: A Systematic Review and Meta-Analysis," *Pathogens*, vol. 12, no. 1, p. 146, Jan. 2023, doi: 10.3390/pathogens12010146.

- [10] G. Sun *et al.*, “Herpes simplex virus type 1 modifies the protein composition of extracellular vesicles to promote neurite outgrowth and neuroinfection,” *mBio*, vol. 15, no. 2, Feb. 2024, doi: 10.1128/mbio.03308-23.
- [11] S. Samsir *et al.*, “Implementation Learning Vector Quantization Using Neural Network for Classification of Ear, Nose and Throat Disease,” *J Phys Conf Ser*, vol. 2394, no. 1, p. 012016, Dec. 2022, doi: 10.1088/1742-6596/2394/1/012016.
- [12] A. D. R. Wibisono, E. P. Mandyartha, and M. M. Al Haromainy, “KLASIFIKASI PENYAKIT KULIT BERBASIS SUPPORT VECTOR MACHINE DENGAN EKSTRAKSI FITUR ABCD RULE,” *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 1, pp. 686–698, Jan. 2025, doi: 10.29100/jipi.v10i1.6039.
- [13] R. I. Borman, Y. Fernando, and Y. Egi Pratama Yudoutomo, “Identification of Vehicle Types Using Learning Vector Quantization Algorithm with Morphological Features,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 2, pp. 339–345, Apr. 2022, doi: 10.29207/resti.v6i2.3954.
- [14] D. Bala *et al.*, “MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification,” *Neural Networks*, vol. 161, pp. 757–775, Apr. 2023, doi: 10.1016/j.neunet.2023.02.022.
- [15] R. Archana and P. S. E. Jeevaraj, “Deep learning models for digital image processing: a review,” *Artif Intell Rev*, vol. 57, no. 1, 2024, doi: 10.1007/s10462-023-10631-z.
- [16] I. Tangkawarow, D. P. Hostiadi, N. S. Fatonah, Mohammad Yazdi, and E. Hariyanti, “Analisis Seleksi Fitur untuk Optimasi Metode Klasifikasi k-NN pada Studi Kasus Penilaian Kinerja Karyawan,” *Jurnal Sistem dan Informatika (JSI)*, vol. 18, no. 1, pp. 18–28, Nov. 2023, doi: 10.30864/jsi.v18i1.593.
- [17] R. AŞLIYAN, “Examining Variants of Learning Vector Quantizations According to Normalization and Initialization of Vector Positions,” *European Journal of Science and Technology*, 2022, doi: 10.31590/ejosat.1222296.
- [18] I. N. Abrar, A. Abdullah, and S. Sucipto, “Liver Disease Classification Using the Elbow Method to Determine Optimal K in the K-Nearest Neighbor (K-NN) Algorithm,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 12, no. 2, pp. 218–228, Jul. 2023, doi: 10.32736/sisfokom.v12i2.1643.
- [19] M. Heydarian, T. E. Doyle, and R. Samavi, “MLCM: Multi-Label Confusion Matrix,” *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [20] E. Ismanto, A. Fadlil, and A. Yudhana, “Analisis Perbandingan Model Fully Connected Neural Networks (FCNN) dan TabNet Untuk Klasifikasi Perawatan Pasien Pada Data Tabular,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 5, no. 3, Dec. 2024, [Online]. Available: <https://ejournal.umri.ac.id/index.php/coscitech/article/view/8256>
- [21] R. Raynold and A. H. Muhammad, “Deep Learning Detection and Classification of Tomato Leaf Disease Using ResNet-50,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 1, Apr. 2025, doi: 10.37859/coscitech.v6i1.8501.