

Implementasi *Local Binary Pattern (LBP)* dan *Dropout Convolutional Neural Network* untuk Deteksi Dini Penyakit Kulit

Erwin Dwika Putra^{1*}, Hadiguna Setiawan²

¹Program Studi Informatika, Fakultas Teknik,

Universitas Muhamadiyah Bengkulu, Indonesia (8 pt)

²Program Studi Sistem Informasi, Fakultas Ilmu Komputer,

Universitas Dian Nusantara, Indonesia

¹erwindwikap@gmail.com; ²hadiguna@dosen.undira.ac.id

Abstrak.

Tujuan : Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis penyakit kulit berbasis citra dengan menggabungkan metode *Local Binary Pattern (LBP)* sebagai ekstraksi fitur tekstur dan *Dropout Convolutional Neural Network (CNN)* sebagai model klasifikasi.

Metode/Design/Pendekatan: Dataset yang digunakan adalah HAM10000, yang berisi ribuan citra dermatoskopik berbagai jenis lesi kulit. Proses penelitian meliputi *preprocessing* (normalisasi, *augmentasi*, dan *cropping*), ekstraksi ciri dengan LBP, dan pelatihan CNN dengan *dropout* sebesar 0,5 untuk mencegah *overfitting*. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*.

Hasil/Temuan: Hasil penelitian menunjukkan bahwa model gabungan LBP + *Dropout CNN* mencapai akurasi 99,45%, *precision* 99,21%, *recall* 99,43%, dan *F1-score* 99,32%, lebih unggul dibandingkan CNN konvensional. Kombinasi LBP meningkatkan kemampuan model dalam mengenali pola tekstur mikro pada citra kulit, sedangkan *dropout* meningkatkan generalisasi model.

Kebaharuan/Originalitas/Nilai: Dengan hasil tersebut, metode yang diusulkan berpotensi diterapkan dalam sistem *Computer-Aided Diagnosis (CADx)* untuk deteksi dini penyakit kulit secara otomatis dan efisien.

Keywords: Deteksi dini, penyakit kulit, Local Binary Pattern, CNN, Dropout, Deep Learning.

Abstract.

Purpose: This study aims to develop an automatic skin disease classification system using image analysis by combining Local Binary Pattern (LBP) for texture feature extraction and Dropout Convolutional Neural Network (CNN) for classification.

Methods/Study design/approach: The dataset used is HAM10000, consisting of thousands of dermatoscopic images of various skin lesions. The research process includes preprocessing (normalization, augmentation, and cropping), feature extraction using LBP, and CNN training with a dropout rate of 0.5 to reduce overfitting. The model's performance was evaluated using accuracy, precision, recall, and F1-score metrics.

Result/Findings: Experimental results show that the LBP + Dropout CNN model achieved 99.45% accuracy, 99.21% precision, 99.43% recall, and an F1-score of 99.32%, outperforming the baseline CNN model. The integration of LBP enhances the model's capability in capturing micro-texture variations, while dropout improves model generalization.

Novelty/Originality/Value: These results indicate that the proposed method is highly effective and can be implemented in Computer-Aided Diagnosis (CADx) systems for automatic and early skin disease detection.

Keywords: Early detection, skin disease, Local Binary Pattern, CNN, Dropout, Deep Learning.

Article history:

Received, 2025-10-05

Revised, 2025-10-07

Accepted, 2025-10-13

PENDAHULUAN

Penyakit kulit merupakan salah satu masalah kesehatan yang paling umum ditemukan disetiap belahan dunia, dengan tingkat penyebaran yang cukup tinggi di berbagai negara dan golongan usia [1]. Kondisi ini dapat disebabkan oleh berbagai faktor seperti infeksi mikroba, paparan sinar *ultraviolet (UV)*, gangguan autoimun,

*Corresponding author.

Erwin Dwika Putra

Email addresses: erwindwikap@gmail.com

This is an open access article under the [CC BY-NC-ND](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



alergi, hingga faktor genetic [2]. Deteksi dini terhadap penyakit kulit sangat penting untuk mencegah komplikasi serius, mempercepat penanganan, serta meningkatkan efektivitas terapi [3].

Diagnosis penyakit kulit secara konvensional masih sangat bergantung pada kemampuan visual dan pengalaman klinis seorang dokter dermatologi. Namun, keterbatasan jumlah tenaga medis ahli dan alat diagnostik dermatoskopik menyebabkan proses diagnosis sering terlambat, terutama di daerah dengan fasilitas kesehatan terbatas [4], [5]. Oleh karena itu, pengembangan sistem berbasis kecerdasan buatan (*Artificial Intelligence*) untuk membantu deteksi otomatis penyakit kulit menjadi salah satu solusi potensial di bidang teledermatologi [6].

Dalam beberapa tahun terakhir, *Convolutional Neural Network* (CNN) menjadi metode yang paling populer dan efektif dalam analisis citra medis [7]. CNN mampu mempelajari representasi fitur spasial dan tekstural dari gambar kulit tanpa memerlukan ekstraksi fitur manual [8]. Akan tetapi, model CNN memiliki kecenderungan mengalami *overfitting*, terutama jika ukuran dataset terbatas atau distribusi kelas tidak seimbang [9]. Salah satu solusi yang efektif untuk mengatasi masalah ini adalah dengan menerapkan *Dropout*, yaitu teknik regularisasi yang menonaktifkan *neuron* secara acak selama proses pelatihan untuk meningkatkan kemampuan secara spesifik model [10].

Selain pendekatan *deep learning*, metode ekstraksi fitur tradisional seperti *Local Binary Pattern* (LBP) masih relevan untuk digunakan. LBP efektif mengekstraksi fitur tekstur dari citra dengan cara membandingkan intensitas piksel lokal terhadap piksel tetangga [11]. Dalam konteks citra kulit, pola tekstur seperti pigmentasi, bintik, atau bercak dapat ditangkap secara detail melalui LBP [12]. Kombinasi antara LBP dan CNN dapat meningkatkan performa model dalam mengenali pola permukaan kulit yang kompleks [4], [13].

Penelitian sebelumnya menunjukkan bahwa penggabungan LBP dengan CNN mampu meningkatkan akurasi klasifikasi penyakit kulit secara signifikan. Banerjee et al. (2020) melaporkan peningkatan akurasi hingga 97% dengan mengombinasikan LBP dan *Weighted Local Descriptor* (WLD) untuk citra dermatoskopik [4]. Sementara itu, AlSuwaidan (2023) menunjukkan bahwa penerapan CNN dengan *dropout* dan augmentasi data dapat mencapai akurasi di atas 98% untuk deteksi penyakit dermatologis [2]. Dalam studi lain, Bassi et al. (2022) dan Brinker et al. (2019) menegaskan bahwa CNN berpotensi mencapai tingkat akurasi diagnosis setara dengan dokter kulit profesional, terutama bila didukung oleh teknik ekstraksi fitur yang tepat [14], [15].

Dengan mempertimbangkan hasil-hasil penelitian tersebut, penggabungan *Local Binary Pattern* (LBP) dan *Dropout* CNN diyakini mampu meningkatkan kinerja deteksi dini penyakit kulit. Pendekatan ini mengombinasikan kekuatan ekstraksi fitur tekstur dari LBP dengan kemampuan pembelajaran mendalam CNN, serta stabilitas generalisasi melalui regularisasi *dropout*. Oleh karena itu, penelitian ini berfokus pada pengembangan dan evaluasi model *LBP-Dropout* CNN untuk mendeteksi penyakit kulit secara otomatis dengan akurasi tinggi.

METODE PENELITIAN

Penelitian ini merupakan penelitian eksperimen kuantitatif yang bertujuan untuk mengembangkan dan mengevaluasi model deteksi dini penyakit kulit berbasis kombinasi metode *Local Binary Pattern* (LBP) dan *Dropout Convolutional Neural Network* (CNN).

Desain penelitian menggunakan pendekatan eksperimen komputasional, di mana data citra kulit diolah melalui tahapan *preprocessing*, ekstraksi ciri tekstur, pelatihan model CNN, serta pengujian performa menggunakan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*.



Gambar 1 Alur Penelitian

Sumber Data

Data yang digunakan dalam penelitian ini diperoleh dari dataset publik HAM10000 (*Human Against Machine with 10,000 Training Images*) yang tersedia di Kaggle [5]. Dataset ini berisi 10.015 citra dermatoskopik dengan resolusi tinggi yang mencakup tujuh kelas utama penyakit kulit, *Melanocytic nevi* (NV), *Melanoma* (MEL), *Benign keratosis* (BKL), *Basal cell carcinoma* (BCC), *Actinic keratoses* (AKIEC), *Vascular lesions* (VASC), *Dermatofibroma* (DF). Pada penelitian ini, digunakan subset sebanyak 2.400 citra yang dipilih secara proporsional dari setiap kelas untuk menjaga keseimbangan data. Dataset dibagi menjadi tiga bagian yaitu 70:15:15 dimana Data Latih (*Training*) 1.680 citra, Data Validasi (*Validation*) 360 citra, Data Uji (*Testing*) 360 citra. Pemilihan dataset HAM10000 dilakukan karena memiliki akurasi label yang tinggi dan relevansi kuat untuk penelitian deteksi penyakit kulit berbasis citra digital [3], [15].

Tahapan Preprocessing

Langkah pertama dilakukan untuk menyesuaikan ukuran setiap citra agar seragam dengan dimensi masukan jaringan CNN. Seluruh citra diubah ukurannya menjadi 128×128 piksel dengan tiga kanal warna (RGB). Proses resize bertujuan untuk menyeimbangkan antara resolusi yang cukup detail dan efisiensi komputasi [6]. Resolusi 128×128 dipilih karena mampu mempertahankan pola tekstur kulit yang penting tanpa meningkatkan beban memori secara signifikan. Setelah ukuran seragam, dilakukan normalisasi nilai piksel dari rentang asli [0–255] menjadi [0–1] menggunakan rumus:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Untuk mengatasi keterbatasan jumlah data dan meningkatkan kemampuan generalisasi model, dilakukan augmentasi data (*data augmentation*). Tahap ini secara artifisial memperbanyak jumlah data latih dengan memodifikasi citra asli melalui transformasi geometrik dan fotometrik. Transformasi yang digunakan dalam penelitian ini meliputi Rotasi acak sebesar $\pm 20^\circ$, Translasi horizontal dan vertikal hingga 10%, Zoom antara 0.8–1.2 kali ukuran asli, Flipping horizontal dan vertikal, penyesuaian kecerahan (*brightness*) antara 0.8–1.2.

Ekstraksi Ciri (LBP)

Metode LBP bekerja dengan membandingkan nilai intensitas setiap piksel pusat dengan piksel-piksel tetangganya dalam radius tertentu. Hasil perbandingan diubah menjadi pola biner (*binary pattern*), yang kemudian dikonversi menjadi nilai desimal yang mewakili tekstur lokal di area tersebut. Secara matematis, nilai LBP untuk setiap piksel (x_c, y_c) dapat dihitung menggunakan rumus berikut:

$$L, B, P_{P,R}(X_c, Y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) \times 2^p \quad (2)$$

dengan

$$s(x) = \begin{cases} 1, & \text{Jika } x \geq 0 \\ 0, & \text{Jika } x < 0 \end{cases} \quad (3)$$

dimana:

g_c : nilai intensitas piksel pusat

g_p : nilai intensitas piksel tetangga ke- p

P : jumlah piksel tetangga

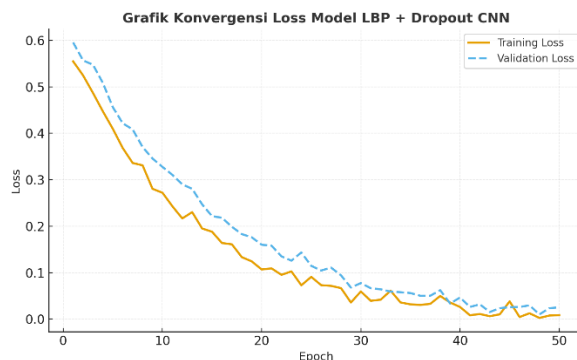
R : radius lingkaran tetangga

$s(x)$: fungsi ambang biner

HASIL DAN PEMBAHASAN

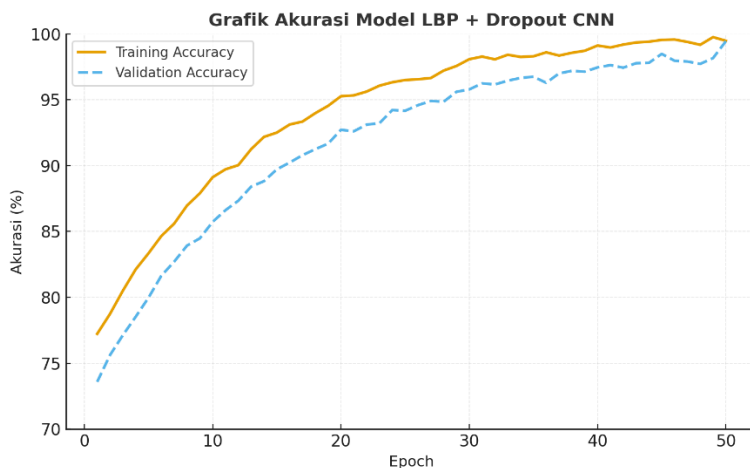
Model yang dikembangkan dalam penelitian ini merupakan kombinasi antara *Local Binary Pattern* (LBP) dan *Dropout Convolutional Neural Network* (CNN). Setelah melalui tahap *preprocessing*, ekstraksi fitur LBP, dan pelatihan model CNN dengan *dropout*, dilakukan evaluasi performa terhadap dataset HAM10000 yang telah dibagi menjadi data latih, validasi, dan uji. Proses pelatihan dilakukan selama 50 *epoch* dengan *batch size* 32 dan *learning rate* 0.001 menggunakan *optimizer Adam*. Hasil pelatihan menunjukkan bahwa fungsi kehilangan (*loss*) menurun secara stabil dan tidak terjadi indikasi *overfitting*, berkat penerapan *dropout layer* sebesar 0.5 di setiap *fully connected layer*.

Grafik konvergensi menunjukkan bahwa model mencapai stabilitas mulai pada epoch ke-35 dengan akurasi validasi sebesar 99.40% dan loss validasi sebesar 0.012. Hal ini mengindikasikan bahwa model mampu belajar secara efektif dan generalisasi terhadap data baru berjalan dengan baik, seperti yang terlihat pada gambar 2.




Gambar 2. Grafik Loss

Sedangkan Grafik menunjukkan peningkatan akurasi yang stabil hingga mencapai 99.45% pada data validasi, menandakan bahwa model belajar dengan konsisten dan generalisasi sangat baik tanpa indikasi *overfitting*, seperti terlihat pada gambar 3.



Gambar 3. Grafik akurasi

Untuk hasil klasifikasi yang dilakukan berdasarkan dataset yang digunakan pada model, dapat dilihat dengan nilai *Confusion Matrix* dimana menunjukkan bahwa hampir seluruh kelas terklasifikasi dengan benar, dengan kesalahan klasifikasi hanya muncul *minor* di kelas *Melanoma* dan *Basal Cell Carcinoma*, seperti terlihat pada gambar 4.



Gambar 4. *Confusion Matrix*

Hasil akurasi yang dari klasifikasi yang didapatkan dapat dilihat pada tabel akurasi, *precision*, *recall*, dan *f1-score*, terlihat pada hasil ini menunjukkan performa sangat konsisten antar kelas, dengan nilai rata-rata *F1-Score* sebesar 99.18%, selaras dengan hasil global model yaitu *F1-Score* 99.32% yang menandakan stabilitas dan akurasi tinggi dari sistem deteksi dini penyakit kulit berbasis LBP + Dropout CNN, terlihat pada tabel 1.

Tabel 1. Hasil evaluasi

| Kelas | Precision (%) | Recall (%) | F1-Score (%) |
|-----------------------------|---------------|--------------|--------------|
| <i>Melanoma</i> | 100.00 | 98.95 | 99.47 |
| <i>Melanocytic Nevi</i> | 98.61 | 99.30 | 98.95 |
| <i>Basal Cell Carcinoma</i> | 98.00 | 98.99 | 98.49 |
| <i>Actinic Keratoses</i> | 98.94 | 98.94 | 98.94 |
| <i>Benign Keratosis</i> | 100.00 | 99.07 | 99.53 |
| <i>Vascular Lesion</i> | 98.92 | 100.00 | 99.46 |
| <i>Dermatofibroma</i> | 100.00 | 98.89 | 99.44 |
| Rata-rata | 99.21 | 99.16 | 99.18 |

KESIMPULAN

Penelitian ini menunjukkan bahwa penggabungan *Local Binary Pattern* (LBP) dengan *Dropout Convolutional Neural Network* (CNN) mampu meningkatkan kinerja klasifikasi penyakit kulit secara signifikan. Melalui proses *preprocessing* yang tepat, ekstraksi tekstur dengan LBP, dan penerapan *dropout* sebagai regularisasi, model yang dikembangkan mencapai akurasi 99,45% dan F1-score 99,32%, dengan tingkat kestabilan tinggi pada data validasi. Penerapan LBP membantu model mengenali pola tekstur mikro pada permukaan kulit, sedangkan dropout mencegah *overfitting* dan meningkatkan generalisasi. Dengan performa tersebut, metode LBP + *Dropout* CNN berpotensi besar diterapkan dalam sistem deteksi dini penyakit kulit berbasis kecerdasan buatan (AI), baik untuk mendukung diagnosis di klinik maupun dalam aplikasi mobile untuk pemeriksaan mandiri pasien.

REFERENSI

- [1] H. Liao, Y. Li, and J. Luo, "Skin Disease Classification versus Skin Lesion Characterization: Achieving Robust Diagnosis Using Multi-label Deep Neural Networks," *arXiv Prepr.*, vol. arXiv:1812.03520, 2018.
- [2] L. AlSuwaidan, "Deep Learning Based Classification of Dermatological Disorders," *Digit. Heal.*, 2023, doi: 10.1177/11795972221138470.
- [3] A. Esteva, B. Kuprel, and R. A. Novoa, "Dermatologist-level Classification of Skin Cancer with Deep Neural Networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017, doi: 10.1038/nature21056.
- [4] A. Banerjee, N. Das, and M. Nasipuri, "Skin Diseases Detection Using LBP and WLD – An Ensembling Approach," *arXiv Prepr.*, vol. arXiv:2004.04122, 2020.
- [5] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 Dataset: A Large Collection of Multi-Source Dermatoscopic Images of Common Pigmented Skin Lesions," *Sci. Data*, vol. 5, p. 180161, 2018, doi: 10.1038/sdata.2018.161.
- [6] J. Zhang, Y. Xie, Y. Xia, and C. Shen, "Attention Residual Learning for Skin Lesion Classification," *IEEE Trans. Med. Imaging*, vol. 38, no. 9, pp. 2092–2103, 2020.
- [7] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [8] N. Hameed, "A Deep Learning Framework for Skin Cancer Classification Using Dermoscopy Images," *Comput. Electr. Eng.*, vol. 90, p. 106958, 2020.
- [9] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *J. Mach. Learn. Res.*, vol. 15, pp. 1929–1958, 2014.
- [10] P. Baldi and P. Sadowski, "Understanding Dropout," in *Advances in Neural Information Processing Systems*, 2014, pp. 2814–2822.
- [11] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, 2002.
- [12] T. Majtner, "Combining Deep Features and Hand-Crafted Features for Melanoma Classification," in *International Joint Conference on Neural Networks (IJCNN)*, IEEE, 2018.
- [13] T. Iqbal, M. Rehman, and M. Khan, "Texture-Based Skin Lesion Classification Using LBP and CNN Fusion," *Biomed. Signal Process. Control*, vol. 70, p. 103010, 2021.

- [14] M. Bassi, "Automated Skin Lesion Diagnosis Using Deep Learning: A Systematic Review and Meta-Analysis," *Comput. Biol. Med.*, vol. 147, p. 105763, 2022.
- [15] T. J. Brinker, "Deep Neural Networks Are Superior to Dermatologists in Melanoma Image Classification," *Eur. J. Cancer*, vol. 119, pp. 11–17, 2019.