

Klasifikasi Penyakit Kulit Berbasis Citra Menggunakan Algoritma Support Vector Machine

Dedek Intan Afriana^{1*}, Sriwinar², Imam Muslem³

¹ Program Studi Informatika, Universitas Almuslim, Jl. Tengku Abdurrahman No. 37, Peusangan, Bireuen, Aceh 24261, Indonesia. e-mail: dedekintanafriana@gmail.com

² Program Studi Informatika, Universitas Almuslim, Jl. Tengku Abdurrahman No. 37, Peusangan, Bireuen, Aceh 24261, Indonesia. e-mail: sriwinarafifa@gmail.com

³ Program Studi Informatika, Universitas Almuslim, Jl. Tengku Abdurrahman No. 37, Peusangan, Bireuen, Aceh 24261, Indonesia. e-mail: imamtkj@gmail.com

*Corresponding Author:

Dedek Intan Afriana

dedekintanafriana@gmail.com

ORCID: <https://orcid.org/0009-0009-6623-8613>

ARTICLE INFO

Article History:

Received : 29 April 2026

Revised : 26 Mei 2026

Accepted : 11 Juni 2026

Keywords:

skin disease classification,
Support Vector Machine, digital
image, machine learning

Kata kunci:

klasifikasi penyakit kulit,
Support Vector Machine,
gambar digital, pembelajaran
mesin



This work is licensed under a
[Creative Commons
Attribution-4.0 Internasional
License](https://creativecommons.org/licenses/by/4.0/)

NOVAKOMPUTA

Jurnal Ilmu Komputer dan Informatika
Vol 01 No 02 | Juni 2026

ABSTRACT

[Image-Based Skin Disease Classification Using Support Vector Machine Algorithm] Skin disease is a global health problem that requires early and accurate diagnosis. The limited number of dermatologists in many regions, particularly in remote areas, underscores the need for an automated diagnosis system based on artificial intelligence. This study aims to develop an image-based skin disease classification model using the Support Vector Machine (SVM) algorithm. The dataset was obtained from the Kaggle platform, comprising 3,020 images distributed across five categories: acne, eczema, impetigo, melanoma, and normal skin. Preprocessing steps included pixel array conversion, normalization, label encoding, and an 80:20 train-test split. Three SVM kernel types were evaluated: linear, Radial Basis Function (RBF), and polynomial. Results demonstrated that the RBF kernel achieved the highest accuracy of 67% with an F1-score of 0.67, followed by the linear kernel at 64% and the polynomial kernel at 62%. Melanoma and normal skin categories exhibited the best performance, with F1-scores of 0.80 and 0.76 respectively, while eczema and impetigo remained challenging due to their visual similarity. This study concludes that SVM holds potential as an initial classification tool for skin diseases, with recommendations for future work including data augmentation, hyperparameter optimization, and advanced feature extraction methods.

ABSTRAK

Penyakit kulit merupakan permasalahan kesehatan global yang memerlukan penanganan diagnosis secara dini dan akurat. Keterbatasan jumlah tenaga ahli dermatologi di berbagai wilayah, khususnya daerah terpencil, mendorong perlunya sistem diagnosis otomatis berbasis kecerdasan buatan. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit kulit berbasis citra menggunakan algoritma Support Vector Machine (SVM). Dataset yang digunakan berasal dari platform Kaggle, terdiri dari 3.020 citra yang dibagi ke dalam lima kategori: acne, eczema, impetigo, melanoma, dan normal skin. Proses praolah data mencakup konversi citra ke array piksel, normalisasi, encoding label, dan pembagian data dengan rasio 80:20. Pengujian dilakukan terhadap tiga jenis kernel SVM, yaitu linear, Radial Basis Function (RBF), dan polynomial. Hasil penelitian menunjukkan bahwa kernel RBF menghasilkan akurasi tertinggi sebesar 67% dengan F1-score 0,67, diikuti kernel linear sebesar 64%, dan polynomial sebesar 62%. Kategori melanoma dan normal

skin menunjukkan performa terbaik dengan F1-score masing-masing 0,80 dan 0,76, sementara eczema dan impetigo masih menghadapi tantangan klasifikasi akibat kemiripan karakteristik visual. Penelitian ini menyimpulkan bahwa SVM berpotensi dimanfaatkan sebagai alat bantu klasifikasi awal penyakit kulit, dengan rekomendasi pengembangan melalui teknik augmentasi data, optimasi hiperparameter, dan eksplorasi metode ekstraksi fitur yang lebih canggih.

PENDAHULUAN

Sebagai organ terluar tubuh manusia, kulit menjalankan fungsi perlindungan yang sangat vital terhadap paparan lingkungan, patogen, bahan kimia, dan radiasi ultraviolet, sekaligus berperan dalam pengaturan suhu dan keseimbangan cairan [1], [2]. Gangguan pada organ ini dapat ditimbulkan oleh berbagai faktor, mulai dari infeksi bakteri, virus, jamur, dan parasit, hingga kondisi autoimun, alergi, dan predisposisi genetik [3]. Secara epidemiologis, penyakit kulit menempati posisi keempat dalam daftar penyakit yang paling banyak memengaruhi populasi dunia [4], [5]. Di Indonesia, faktor iklim tropis dengan kelembapan dan suhu tinggi menjadi kondisi yang kondusif bagi perkembangan berbagai jenis penyakit kulit, terutama di kalangan masyarakat yang tinggal di daerah terpencil dengan akses layanan kesehatan yang terbatas [6], [7].


Salah satu tantangan terbesar dalam penanganan penyakit kulit adalah keterbatasan tenaga ahli dermatologi yang terdistribusi secara tidak merata [8], [9]. Di banyak daerah, pasien harus menempuh perjalanan jauh hanya untuk mendapatkan diagnosis dari dokter spesialis [6]. Situasi ini diperparah oleh kemiripan gejala klinis antara beberapa jenis penyakit kulit yang berbeda, sehingga diagnosis yang akurat memerlukan pengalaman klinis yang mendalam dan kadang harus didukung oleh pemeriksaan laboratorium [10]. Kondisi inilah yang mendorong pentingnya pengembangan sistem bantu diagnosis berbasis kecerdasan buatan yang mampu mengklasifikasikan penyakit kulit secara otomatis dan efisien [11], [12], [13].

Kemajuan pesat dalam bidang machine learning telah membuka peluang yang signifikan untuk menjawab permasalahan ini [14], [15], [16], [17]. Berbagai algoritma seperti Decision Tree [18], Random Forest [19], K-Nearest Neighbor [20], Neural Network [21], [22], dan Support Vector Machine (SVM) [23] telah banyak diterapkan dalam persoalan klasifikasi medis berbasis citra [24]. SVM menonjol di antara pendekatan tersebut karena kemampuannya mengelola data berdimensi tinggi, resistensinya terhadap overfitting pada dataset berukuran kecil hingga sedang, serta fleksibilitasnya dalam menangani data non-linier melalui mekanisme kernel [25], [26], [27]. Wilantikasari et al. SVM mampu mengklasifikasikan penyakit kulit dengan akurasi yang memuaskan, sementara [28] menunjukkan bahwa kombinasi SVM dengan metode Gray Level Co-occurrence Matrix (GLCM) dapat meningkatkan ketepatan deteksi lebih lanjut. [29] juga melaporkan akurasi SVM hingga 80% pada kasus klasifikasi penyakit stroke dengan kernel polynomial.

Meski demikian, sebagian besar penelitian yang ada masih terbatas pada dataset tertentu dengan jumlah kelas yang sedikit. Belum banyak studi yang secara eksplisit membandingkan pengaruh jenis kernel SVM terhadap performa klasifikasi citra penyakit kulit pada dataset multikelas yang mencakup kondisi berupa kulit normal sebagai pembanding. Kesenjangan inilah yang menjadi fokus penelitian ini. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit kulit berbasis citra menggunakan algoritma SVM dengan membandingkan tiga varian kernel – linear, RBF, dan polynomial – terhadap dataset yang terdiri dari lima kelas: acne, eczema, impetigo, melanoma, dan normal skin. Kontribusi utama penelitian ini adalah analisis komparatif performa kernel SVM secara sistematis, termasuk identifikasi kelas-kelas yang memiliki tantangan klasifikasi tinggi akibat kemiripan karakteristik visual.

METODE

Penelitian ini bersifat eksperimental komputasional. Seluruh proses pengolahan data dan pemodelan dilakukan menggunakan platform Google Colaboratory berbasis cloud dengan bahasa pemrograman Python 3.x. Pustaka utama yang dimanfaatkan mencakup scikit-learn untuk implementasi SVM dan evaluasi model, NumPy dan Pandas untuk pengolahan data, serta Matplotlib untuk visualisasi. Perangkat keras yang digunakan adalah laptop ASUS dengan prosesor Intel Core i3, RAM 4 GB, dan sistem operasi Windows 11. Alur kerja penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian dan Distribusi Data per Kelas

A. Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle dengan nama Balanced Skin Disease Image Classification Dataset. Dataset ini dipilih karena memiliki distribusi jumlah citra yang relatif seimbang antar kelas, sehingga meminimalkan risiko bias model terhadap kelas mayoritas. Secara keseluruhan, dataset terdiri dari 3.020 citra digital dalam format .jpg dan .png dengan resolusi minimal 100×100 piksel. Citra-citra tersebut dibagi ke dalam lima kelas sesuai kondisi kulit yang ditampilkan, sebagaimana tercantum pada Tabel 1.

Tabel 1. Distribusi Dataset Klasifikasi Penyakit Kulit

No.	Kelas	Total	Data Latih (80%)	Data Uji (20%)	Sumber
1	Acne	570	456	114	Kaggle
2	Eczema	545	436	109	Kaggle
3	Impetigo	513	411	102	Kaggle
4	Melanoma	744	595	149	Kaggle
5	Normal Skin	648	518	130	Kaggle
Total		3.020	2.416	604	—

Setiap kelas disimpan dalam folder terpisah dengan nama folder yang menjadi label kelas. Struktur ini memungkinkan proses pemberian label secara otomatis tanpa memerlukan berkas metadata tambahan. Pembagian data dilakukan dengan rasio 80% untuk pelatihan dan 20% untuk pengujian menggunakan teknik stratifikasi, sehingga proporsi setiap kelas terjaga pada kedua subset.

Penelitian ini mencakup lima kategori kondisi kulit yang umum dijumpai dalam praktik dermatologi. Acne merupakan kondisi peradangan kronik pada unit pilosebacea yang ditandai dengan komedo, papula, dan pustula, sering dipicu oleh perubahan hormonal [30]. Eczema (dermatitis atopik) adalah peradangan kulit yang bersifat kronis dan residif disertai rasa gatal intens, biasanya muncul sejak masa bayi [31]. Impetigo merupakan infeksi bakteri superfisial yang sangat menular, umumnya disebabkan oleh *Staphylococcus aureus*, dan berpotensi menimbulkan komplikasi seperti glomerulonefritis pascainfeksi [32], [33]. Melanoma adalah keganasan yang berasal dari sel melanosit dan bertanggung jawab atas sekitar 90% kematian akibat tumor kulit [34]. Sementara normal skin berfungsi sebagai kelas referensi untuk membedakan kondisi kulit sehat dari kondisi yang bermasalah.

B. Praolah Data (Preprocessing)

Tahap praolah data dimulai dengan pembersihan dataset, yakni pemeriksaan seluruh berkas citra untuk mengidentifikasi file yang rusak, tidak dapat dibaca, atau memiliki format yang tidak sesuai. File-file bermasalah dihapus sebelum proses lebih lanjut. Selanjutnya, seluruh citra diubah ukurannya

menjadi dimensi yang seragam, kemudian diratakan (flattened) menjadi array satu dimensi yang merepresentasikan nilai piksel RGB. Nilai piksel dinormalisasi ke rentang [0, 1] dengan membaginya dengan 255 untuk memastikan stabilitas numerik selama pelatihan.

Label kelas yang awalnya berupa teks—seperti "acne", "eczema", dan seterusnya—dikonversi ke representasi numerik menggunakan metode Label Encoding dari scikit-learn. Langkah ini diperlukan karena algoritma SVM tidak dapat memproses target berbentuk teks secara langsung. Proses ekstraksi fitur dan pembagian data ditunjukkan pada Gambar 2 dan Gambar 3.

```
✓ 0s ▶ def load_images_from_classes(base_path, img_size=(100, 100)):
    images = []
    labels = []
    for class_name in os.listdir(base_path):
        class_path = os.path.join(base_path, class_name)
        if not os.path.isdir(class_path):
            continue
        for img_file in os.listdir(class_path):
            img_path = os.path.join(class_path, img_file)
            try:
                img = load_img(img_path, target_size=img_size)
                img_array = img_to_array(img).flatten()
                images.append(img_array)
                labels.append(class_name)
            except Exception as e:
                print(f"Error loading {img_path}: {e}")
    return np.array(images), np.array(labels)
```

Gambar 2. Kode Program Ekstraksi Fitur dan Label dari Struktur Folder Dataset


```
✓ [11] # Split data ke train/test
      X_train, X_test, y_train, y_test = train_test_split(
          X, y_encoded, test_size=0.2, stratify=y_encoded, random_state=42
      )
```

Gambar 3. Kode Program Pembagian Dataset dengan Stratifikasi

Pembagian dataset dilakukan menggunakan fungsi `train_test_split` dari scikit-learn dengan parameter `stratify=y` untuk menjaga representasi yang seimbang dari setiap kelas pada data latih maupun data uji. Parameter `random_state` ditetapkan secara konsisten untuk memastikan reproduisibilitas hasil eksperimen.

C. Algoritma Support Vector Machine (SVM)

SVM merupakan algoritma pembelajaran terawasi yang dikembangkan oleh Boser, Guyon, dan Vapnik pada 1992, dan pertama kali dipresentasikan pada Annual Workshop on Computational Learning Theory [35]. Prinsip kerja SVM adalah menemukan hyperplane optimal yang memaksimalkan margin antara dua atau lebih kelas data. Margin didefinisikan sebagai jarak antara hyperplane dengan titik-titik data terdekat dari masing-masing kelas, yang disebut support vector.



Gambar 4. Ilustrasi Hyperplane dan Margin Maksimum pada SVM

Untuk menangani data yang tidak dapat dipisahkan secara linier, SVM memanfaatkan fungsi kernel yang memetakan data ke ruang berdimensi lebih tinggi. Fungsi kernel $K(x_i, x_j)$ memungkinkan komputasi dalam ruang berdimensi tinggi tanpa perlu menghitung transformasi secara eksplisit (kernel trick). Tiga kernel yang diujikan dalam penelitian ini adalah:

- 1) Kernel Linear
Mengasumsikan data dapat dipisahkan oleh hyperplane linier di ruang fitur asli. Cocok untuk data yang memiliki pemisahan linier yang jelas, namun tidak efektif untuk pola yang kompleks.
- 2) Kernel RBF (Radial Basis Function)
Menggunakan fungsi Gaussian $K(x_i, x_j) = \exp(-\gamma |x_i - x_j|^2)$ untuk memetakan data ke ruang berdimensi sangat tinggi. Unggul dalam menangani data non-linier dan menjadi pilihan utama untuk klasifikasi citra.
- 3) Kernel Polynomial
Memetakan data menggunakan fungsi polinomial $K(x_i, x_j) = (\gamma x_i x_j + r)^d$, di mana d adalah derajat polinomial. Mampu menangkap hubungan non-linier, namun rentan terhadap overfitting jika derajat tidak dikalibrasi dengan tepat.

Untuk mengakomodasi masalah klasifikasi multikelas (lima kelas), SVM dalam penelitian ini menggunakan strategi One-vs-Rest (OvR), di mana setiap kelas dilatih sebagai kelas positif terhadap gabungan kelas lainnya.

D. Metrik Evaluasi

Kinerja model dievaluasi menggunakan empat metrik standar. Akurasi mengukur proporsi prediksi benar dari seluruh data uji. Precision mengukur ketepatan prediksi positif untuk setiap kelas. Recall mengukur kemampuan model dalam mendeteksi seluruh sampel dari suatu kelas. F1-score merupakan rata-rata harmonik antara precision dan recall, dan lebih representatif dibandingkan akurasi tunggal ketika distribusi kelas tidak sepenuhnya seimbang. Confusion matrix digunakan secara tambahan untuk memvisualisasikan distribusi prediksi yang benar maupun salah pada setiap kelas.

HASIL DAN PEMBAHASAN

A. Perbandingan Performa Tiga Kernel SVM

Pengujian dilakukan dalam tiga skenario, masing-masing menggunakan satu jenis kernel SVM yang berbeda. Seluruh model dilatih pada data latih yang sama dan diuji pada data uji yang sama, sehingga perbandingan antar kernel dapat dilakukan secara adil. Ringkasan hasil evaluasi dari ketiga kernel disajikan pada Tabel 2.


Tabel 2. Perbandingan Performa Tiga Kernel SVM pada Data Uji (n = 604)

Kernel SVM	Akurasi	Precision	Recall	F1-Score
Linear	64%	0,62	0,64	0,62
RBF	67%	0,68	0,67	0,67
Polynomial	62%	0,60	0,62	0,60


Dari Tabel 2 terlihat bahwa kernel RBF secara konsisten menghasilkan nilai terbaik pada semua metrik. Kernel linear menghasilkan akurasi 64%, sementara polynomial berada di posisi terendah dengan 62%. Perbedaan performa ini mencerminkan kemampuan masing-masing kernel dalam menangani distribusi fitur yang bersifat non-linier pada data citra.

B. Analisis Skenario 1 (Kernel Linear)

Model SVM dengan kernel linear mencatat akurasi sebesar 64% pada data uji, sebagaimana ditunjukkan pada laporan klasifikasi Gambar 5. Kernel ini bekerja dengan asumsi bahwa data dari berbagai kelas dapat dipisahkan oleh sebuah hyperplane linier di ruang fitur piksel. Pada kenyataannya, citra penyakit kulit memiliki distribusi fitur yang sangat kompleks dan tidak linier, sehingga asumsi ini tidak sepenuhnya terpenuhi.



Gambar 5. Laporan Klasifikasi Skenario 1 (Kernel Linear)




Gambar 6. Confusion Matrix Skenario 1 (Kernel Linear)


Analisis confusion matrix pada Gambar 6 mengungkap bahwa kelas melanoma dan acne memiliki tingkat pengenalan yang lebih baik dibandingkan kelas lainnya. Sebaliknya, eczema dan impetigo menunjukkan tingkat kesalahan klasifikasi yang tinggi satu sama lain. Kedua penyakit ini memiliki manifestasi visual serupa berupa area kulit yang memerah dan bersisik, sehingga pemisahan linier di ruang fitur tidak mampu menangkap perbedaan yang subtil di antara keduanya.

C. Analisis Skenario 2 (Kernel RBF)

Kernel RBF menghasilkan performa terbaik di antara ketiga kernel yang diuji. Laporan klasifikasinya ditampilkan pada Gambar 7. Dengan akurasi 67%, precision 0,68, recall 0,67, dan F1-score 0,67, model berbasis RBF secara konsisten melampaui kedua kernel lainnya pada semua metrik evaluasi. Keunggulan ini dapat dikaitkan dengan kemampuan RBF memetakan data piksel ke ruang berdimensi sangat tinggi melalui fungsi Gaussian, sehingga pola-pola non-linier yang tidak dapat ditangkap oleh kernel linear dapat direpresentasikan dengan lebih baik.



Gambar 7. Laporan Klasifikasi Skenario 2 (Kernel RBF)




Gambar 8. Confusion Matrix Skenario 2 (Kernel RBF)


Confusion matrix pada Gambar 8 memperlihatkan bahwa kelas melanoma dan normal skin mendapat prediksi terbaik pada skenario ini. Melanoma memiliki ciri visual yang relatif distingtif berupa lesi asimetris dengan variasi warna yang jelas, sehingga lebih mudah dikenali oleh model. Normal skin, di sisi lain, tidak menampilkan tanda-tanda lesi apapun, sehingga model dapat membedakannya dari kelas lain dengan lebih tegas. Meskipun demikian, pasangan eczema-impetigo masih menunjukkan konfusi yang cukup tinggi bahkan pada kernel terbaik ini.

D. Analisis Skenario 3 - Kernel Polynomial

Kernel polynomial menghasilkan performa terendah dengan akurasi 62% dan F1-score 0,60, sebagaimana terlihat pada Gambar 9 dan Gambar 10. Meskipun kernel ini secara teoritis mampu memodelkan hubungan non-linier dengan kompleksitas lebih tinggi dari kernel linear, derajat polinomial yang tidak dikalibrasi secara optimal berpotensi menyebabkan overfitting pada data pelatihan sekaligus penurunan kemampuan generalisasi pada data pengujian.



Gambar 9. Laporan Klasifikasi Skenario 3 (Kernel Polynomial)



Gambar 10. Confusion Matrix Skenario 3 (Kernel Polynomial)

Pola kesalahan klasifikasi pada confusion matrix Gambar 10 serupa dengan skenario 1: melanoma tetap menjadi kelas dengan prediksi paling konsisten, sementara eczema dan impetigo kembali mencatatkan tingkat kesalahan antar kelas yang paling tinggi.

E. Analisis Per Kelas pada Kernel RBF

Mengingat kernel RBF memberikan performa terbaik secara keseluruhan, analisis mendalam dilakukan terhadap performa per kelas pada skenario ini. Hasil lengkap disajikan pada Tabel 3.

Tabel 3. Performa Per Kelas pada Kernel RBF (Skenario 2)

Kelas	Precision	Recall	F1-Score	Support
Acne	0,65	0,69	0,67	114
Eczema	0,57	0,52	0,54	109
Impetigo	0,59	0,55	0,57	102
Melanoma	0,78	0,83	0,80	149
Normal Skin	0,73	0,79	0,76	130
Rata-rata	0,67	0,67	0,67	604

Dari Tabel 3 terlihat bahwa terdapat variasi performa yang cukup signifikan antar kelas. Melanoma mencatat F1-score tertinggi (0,80) berkat karakteristik visual yang khas lesi asimetris berwarna gelap dengan tepi tidak beraturan yang memudahkan model membentuk batas keputusan yang jelas. Normal skin menyusul dengan F1-score 0,76 karena ketidakhadiran lesi apapun menjadi pembeda yang kuat dari kelas penyakit lainnya.

Di sisi lain, eczema (F1-score 0,54) dan impetigo (0,57) menunjukkan performa paling rendah. Keduanya memiliki manifestasi klinis yang saling tumpang tindih secara visual: area kulit kemerahan, bersisik, dengan tekstur yang menyerupai satu sama lain. Hal ini merupakan tantangan inheren dalam klasifikasi berbasis piksel mentah tanpa ekstraksi fitur yang lebih selektif. Acne memperoleh F1-score moderat sebesar 0,67—meskipun karakteristik visual jerawat cukup khas, variasi ukuran, tingkat keparahan, dan lokasi lesi dalam dataset menyulitkan model untuk membentuk representasi yang seragam.

F. Perbandingan dengan Penelitian Terdahulu

Akurasi 67% yang diperoleh penelitian ini berada dalam rentang yang wajar untuk pendekatan SVM berbasis piksel mentah pada data citra multikelas. Putri et al. [14] melaporkan akurasi Binary Decision Tree SVM sebesar 97,14% untuk dua kelas penyakit kulit menggunakan data Puskesmas Dinoyo, namun perbandingan langsung tidak dapat dilakukan karena perbedaan jumlah kelas, ukuran dataset, dan metode ekstraksi fitur. Sulaeman et al. [6] mencatat akurasi SVM 76–80% untuk klasifikasi penyakit stroke dengan data klinis terstruktur, yang secara intrinsik lebih mudah dipisahkan dibandingkan data piksel citra. Tantika dan Kudus [15] melaporkan akurasi SVM sebesar 83,85% untuk klasifikasi penyakit tiroid, lagi-lagi menggunakan data klinis numerik. Perbedaan performa yang cukup jauh dibandingkan studi-studi tersebut menunjukkan bahwa klasifikasi citra multikelas membutuhkan representasi fitur yang lebih kaya dari sekadar array piksel datar.

Studi ini menggarisbawahi bahwa penerapan teknik ekstraksi fitur seperti Histogram of Oriented Gradients (HOG), Local Binary Pattern (LBP), atau Gabor filter berpotensi meningkatkan kualitas representasi citra sebelum diberikan ke SVM. Pada penelitian-penelitian yang mengintegrasikan ekstraksi fitur dengan SVM, peningkatan akurasi yang substantial secara konsisten dilaporkan [5].

KESIMPULAN

Penelitian ini berhasil membangun model klasifikasi citra penyakit kulit menggunakan algoritma SVM dengan tiga varian kernel—linear, RBF, dan polynomial—pada dataset sebanyak 3.020 citra yang mencakup lima kelas kondisi kulit. Dari ketiga kernel yang diuji, RBF memberikan performa tertinggi dengan akurasi 67% dan F1-score rata-rata 0,67 pada data uji, mengungguli kernel linear (64%) dan polynomial (62%). Kelas melanoma dan normal skin dapat diidentifikasi dengan lebih baik karena memiliki ciri visual yang lebih distingtif, dengan F1-score masing-masing 0,80 dan 0,76. Sementara itu, eczema dan impetigo tetap menjadi tantangan utama akibat tumpang tindih fitur visual yang tinggi, yang tidak dapat diatasi secara memadai hanya dengan representasi piksel mentah.

Temuan ini menegaskan bahwa SVM dengan kernel RBF layak dipertimbangkan sebagai komponen dalam sistem skrining awal penyakit kulit, meskipun masih diperlukan peningkatan yang signifikan sebelum dapat diterapkan secara klinis. Penelitian selanjutnya direkomendasikan untuk mengeksplorasi teknik ekstraksi fitur yang lebih canggih seperti HOG, LBP, atau deep feature dari model CNN; menerapkan augmentasi data untuk memperkaya variasi citra; serta melakukan optimasi hiperparameter secara sistematis menggunakan Grid Search atau Bayesian Optimization. Pendekatan ensemble yang menggabungkan SVM dengan model lain, seperti Random Forest atau CNN, juga berpotensi menghasilkan peningkatan akurasi yang substansial.

PENDANAAN

Penelitian ini tidak didukung oleh pendanaan apapun.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan yang dapat mempengaruhi hasil penelitian maupun interpretasi data dalam artikel ini.

KONTRIBUSI PENULIS

Penulis pertama berperan dalam perumusan konsep penelitian, perancangan metode, serta penulisan naskah awal. Penulis kedua berkontribusi dalam pengumpulan dan pengolahan data serta analisis hasil. Penulis ketiga melakukan validasi hasil, revisi naskah, serta penyempurnaan substansi artikel. Seluruh penulis telah membaca dan menyetujui versi akhir naskah.

DAFTAR PUSTAKA

- [1] A. Rahma and M. E. Lane, "Skin Barrier Function in Infants: Update and Outlook," *Pharmaceutics*, vol. 14, no. 2, p. 433, Feb. 2022, doi: 10.3390/pharmaceutics14020433.
- [2] M. Fayyad-Kazan et al., "Effect of Ultraviolet Radiation and Benzo[a]pyrene Co-Exposure on Skin Biology: Autophagy as a Potential Target," *Int. J. Mol. Sci.*, vol. 24, no. 6, p. 5863, Mar. 2023, doi: 10.3390/ijms24065863.
- [3] R. Agrawal, A. Hu, and W. B. Bollag, "The Skin and Inflamm-Aging," *Biology (Basel)*, vol. 12, no. 11, p. 1396, Nov. 2023, doi: 10.3390/biology12111396.
- [4] C. Karimkhani et al., "Global Skin Disease Morbidity and Mortality," *JAMA Dermatol.*, vol. 153, no. 5, p. 406, May 2017, doi: 10.1001/jamadermatol.2016.5538.
- [5] C. Flohr and R. Hay, "Putting the burden of skin diseases on the global map," *British Journal of Dermatology*, vol. 184, no. 2, pp. 189–190, Feb. 2021, doi: 10.1111/bjd.19704.
- [6] F. J. Adella et al., "Teledermatology to Improve Access to and Quality of Skin Care in Eastern Indonesia," *Am. J. Trop. Med. Hyg.*, vol. 110, no. 2, pp. 364–369, Feb. 2024, doi: 10.4269/ajtmh.23-0218.
- [7] A. Sharma and S. Gupta, "Skin Disease in Tropics: Impacted by Heat, Humidity, and Healthcare Neglect," in *Critical Thinking in Contemporary Dermatology: Cognitive Essays*, Singapore: Springer Nature Singapore, 2024, pp. 229–250. doi: 10.1007/978-981-97-0411-8_16.
- [8] Z. Li, K. C. Koban, T. L. Schenck, R. E. Giunta, Q. Li, and Y. Sun, "Artificial Intelligence in Dermatology Image Analysis: Current Developments and Future Trends," *J. Clin. Med.*, vol. 11, no. 22, p. 6826, Nov. 2022, doi: 10.3390/jcm11226826.
- [9] O. Uwishema et al., "Diagnostic performance of artificial intelligence for dermatological conditions: a systematic review focused on low- and middle-income countries to address resource constraints and improve access to specialist care," *Int. J. Emerg. Med.*, vol. 18, no. 1, p. 172, Sep. 2025, doi: 10.1186/s12245-025-00975-4.
- [10] R. Pangti et al., "A machine learning-based, decision support, mobile phone application for diagnosis of common dermatological diseases," *Journal of the European Academy of Dermatology and Venereology*, vol. 35, no. 2, pp. 536–545, Feb. 2021, doi: 10.1111/jdv.16967.
- [11] M. Goyal, T. Knackstedt, S. Yan, and S. Hassanpour, "Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities," *Comput. Biol. Med.*, vol. 127, p. 104065, Dec. 2020, doi: 10.1016/j.combiomed.2020.104065.
- [12] I. Muslem, I. Irvanizam, A. Almuzammil, and F. Johar, "Adaptive Heuristic-Based Ant Colony Optimization for Multi-Constraint University Course Timetabling with Morning Slot Preference for Energy Efficiency," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 6, pp. 5930–5943, Jan. 2026, doi: 10.52436/1.jutif.2025.6.6.5588.
- [13] I. Muslem R, M. K. M. Nasution, S. Sutarman, and S. Suherman, "A scalable model for Capacitated Vehicle Routing Problem with Pickup and Delivery under dynamic constraints using adaptive heuristic-based ant colony optimization," *Eastern-European Journal of Enterprise Technologies*, vol. 1, no. 3 (133), pp. 57–65, Feb. 2025, doi: 10.15587/1729-4061.2025.319733.
- [14] I. Muslem and D. Armiaady, "A PSO-Based CVRPPD Model with Weather and Traffic Constraints for Two-Wheeled Urban Delivery in Indonesia," *Instal: Jurnal Komputer*, vol. 17, pp. 281–290, 2025, doi: 10.54209/jurnalinstall.v17i05.388.
- [15] D. Armiaady and I. M. R, "Klasifikasi Kualitas Buah Pisang Berdasarkan Citra Buah Menggunakan Stochastic Gradient Descent," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 2, 2023.
- [16] R. Melani, S. Sriwinar, D. Azmi, I. Muslem, and M. Amin, "Klasifikasi Kematangan Cabai Berdasarkan Citra Digital Menggunakan Algoritma K-Nearest Neighbor," *NOVAKOMPUTA: Jurnal Ilmu Komputer dan Informatika*, vol. 1, no. 1, pp. 30–42, 2026.

- [17] D. Fahmi, D. Azmi, I. Muslem, and P. B. N. Simangunsong, "Sistem Pendeteksi Dan Klasifikasi Jenis Hewan Ternak Menggunakan Metode You Only Look Once (YOLO)," *NOVAKOMPUTA: Jurnal Ilmu Komputer dan Informatika*, vol. 1, no. 1, pp. 43–51, 2026.
- [18] N. Rismayanti and S. F. Azzahrah, "Classification of Skin Diseases using Decision Tree Algorithm on an Imbalanced Dataset," *International Journal of Artificial Intelligence in Medical Issues*, vol. 2, no. 2, pp. 83–94, 2024.
- [19] B. Kalpana, A. K. Reshmy, S. S. Pandi, and S. Dhanasekaran, "OESV-KRF: Optimal ensemble support vector kernel random forest based early detection and classification of skin diseases," *Biomed. Signal Process. Control*, vol. 85, p. 104779, 2023.
- [20] M. A. Araaf, K. Nugroho, and D. R. I. M. Setiadi, "Comprehensive analysis and classification of skin diseases based on image texture features using K-nearest neighbors algorithm," *Journal of Computing Theories and Applications*, vol. 1, no. 1, pp. 31–40, 2023.
- [21] L. Luthfi, R. Imam Muslem, D. Armiady, S. Sriwinar, R. Fajri, and I. Iqbal, "Analysis of CNN Method for Image Classification of Coconut Ripeness Levels," in *2023 Eighth International Conference on Informatics and Computing (ICIC)*, IEEE, Dec. 2023, pp. 1–6. doi: 10.1109/ICIC60109.2023.10381964.
- [22] T. Shanthi, R. S. Sabeenian, and R. Anand, "Automatic diagnosis of skin diseases using convolution neural network," *Microprocess. Microsyst.*, vol. 76, p. 103074, 2020.
- [23] D. N. Raju, H. Shanmugasundaram, and R. Sasikumar, "Fuzzy segmentation and black widow-based optimal SVM for skin disease classification," *Med. Biol. Eng. Comput.*, vol. 59, no. 10, pp. 2019–2035, 2021.
- [24] B. M. Rashed and N. Popescu, "Performance Investigation for Medical Image Evaluation and Diagnosis Using Machine-Learning and Deep-Learning Techniques," *Computation*, vol. 11, no. 3, p. 63, Mar. 2023, doi: 10.3390/computation11030063.
- [25] Z. Amanda, I. Muslem, and F. Rizani, "Klasifikasi Kematangan Buah Pepaya Menggunakan Algoritma Support Vector Machine," *Jurnal Ilmu Komputer Aceh*, vol. 3, no. 1, pp. 96–102, Feb. 2026.
- [26] B. Laoli, I. Muslem, and F. Rizani, "Klasifikasi Tingkat Kematangan Buah Pisang Menggunakan Algoritma Support Vector Machine," *Jurnal Ilmu Komputer Aceh*, vol. 3, no. 1, pp. 142–151, Feb. 2026.
- [27] I. R. Muslem, "KLIK: Kajian Ilmiah Informatika dan Komputer Image Classification pada Kasus American Sign Language Menggunakan Support Vector Machine," *Media Online*, vol. 4, no. 2, pp. 1184–1191, 2023, doi: 10.30865/klik.v4i2.1242.
- [28] F. E. Khoirunisa and N. Charibaldi, "Effect of Using GLCM and LBP+ HOG Feature Extraction on SVM Method in Classification of Human Skin Disease Type," *Inform: Jurnal Ilmiah Bidang Teknologi Informasi dan Komunikasi*, vol. 9, no. 2, pp. 145–150, 2024.
- [29] Y. Wu and Y. Fang, "Stroke prediction with machine learning methods among older Chinese," *Int. J. Environ. Res. Public Health*, vol. 17, no. 6, p. 1828, 2020.
- [30] A. K. Leung, B. Barankin, J. M. Lam, K. F. Leong, and K. L. Hon, "Dermatology: how to manage acne vulgaris," *Drugs Context*, vol. 10, pp. 1–18, Oct. 2021, doi: 10.7573/dic.2021-8-6.
- [31] M. Metz, U. Wahn, U. Gieler, P. Stock, J. Schmitt, and U. Blume-Peytavi, "Chronic pruritus associated with dermatologic disease in infancy and childhood: Update from an interdisciplinary group of dermatologists and pediatricians," *Pediatric Allergy and Immunology*, vol. 24, no. 6, pp. 527–539, Sep. 2013, doi: 10.1111/pai.12115.
- [32] S. Wiegele et al., "The epidemiology of superficial Streptococcal A (impetigo and pharyngitis) infections in Australia: A systematic review," *PLoS One*, vol. 18, no. 11, p. e0288016, Nov. 2023, doi: 10.1371/journal.pone.0288016.
- [33] G. Bessa, "Bacterial Infections," in *Dermatology in Public Health Environments*, Cham: Springer International Publishing, 2018, pp. 157–172. doi: 10.1007/978-3-319-33919-1_9.
- [34] B. Bandarchi, C. A. Jabbari, A. Vedadi, and R. Navab, "Molecular biology of normal melanocytes and melanoma cells," *J. Clin. Pathol.*, vol. 66, no. 8, pp. 644–648, Aug. 2013, doi: 10.1136/jclinpath-2013-201471.
- [35] N. Rismayanti and S. F. Azzahrah, "Classification of Skin Diseases using Decision Tree Algorithm on an Imbalanced Dataset," *International Journal of Artificial Intelligence in Medical Issues*, vol. 2, no. 2, pp. 83–94, 2024.