

Klasifikasi Aksesoris Fashion Berdasarkan Fitur Citra Menggunakan K-Means Clustering

Zebbil Billian Tomi^{1,*}, Agung Ramadhanu²

^{1,2}Universitas Putra Indonesia "YPTK" Padang, Padang, Indonesia

Informasi Artikel

Sejarah Artikel:

Submit : 9 Oktober 2025

Revisi : 28 Desember 2025

Diterima : 29 Desember 2025

Diterbitkan: 31 Desember 2025

Kata Kunci

K-Means, pengolahan citra, aksesoris fesyen, clustering, ekstraksi fitur

Correspondence

E-mail: zebbilliant@gmail.com*

A B S T R A K

Perkembangan *computer vision* dan *machine learning* memungkinkan penerapan baru dalam industri fesyen, khususnya pada sistem klasifikasi dan rekomendasi produk berbasis citra. Penelitian ini bertujuan mengklasifikasikan aksesoris fesyen berupa dompet, tas, dan ikat pinggang berdasarkan fitur citra menggunakan algoritme K-Means clustering. Dataset yang digunakan terdiri dari 30 citra yang dikumpulkan dalam kondisi terkontrol dengan pencahayaan, resolusi, dan latar belakang seragam. Meskipun jumlah dataset relatif terbatas, pendekatan ini dirancang sebagai studi awal (*baseline*) untuk mengevaluasi efektivitas K-Means pada dataset kecil dan homogen yang umum dijumpai pada tahap awal pengembangan sistem klasifikasi berbasis citra. Tahapan penelitian meliputi *preprocessing* (penyeragaman ukuran, konversi warna, dan reduksi noise), segmentasi objek, serta ekstraksi fitur warna, tekstur, dan bentuk. Fitur yang digunakan meliputi *Local Binary Pattern* (LBP), entropi, kerapatan tepi, eksentrisitas, *extent*, dan rasio area. Hasil penelitian menunjukkan bahwa algoritme K-Means mampu mengelompokkan aksesoris fesyen ke dalam kategori yang berbeda berdasarkan karakteristik visualnya. Secara praktis, hasil penelitian ini berpotensi diterapkan sebagai sistem klasifikasi otomatis pada katalog produk fesyen digital untuk mendukung manajemen inventori, pencarian produk berbasis citra, serta sistem rekomendasi pada platform *e-commerce*. Penelitian ini diharapkan dapat menjadi *baseline* sederhana dan interpretatif dalam klasifikasi aksesoris fesyen, serta menjadi pijakan untuk pengembangan lanjutan menggunakan dataset yang lebih besar, deskriptor fitur modern, maupun metode berbasis *deep learning*.

Abstract

The rapid development of computer vision and machine learning has enabled new applications in the fashion industry, particularly in image-based product classification and recommendation systems. This study aims to classify fashion accessories, namely wallets, bags, and belts, based on image features using the K-Means clustering algorithm. The dataset consists of 30 images acquired under controlled conditions with uniform lighting, resolution, and background. Although the dataset size is relatively limited, this study is designed as an initial baseline to evaluate the effectiveness of K-Means clustering on small and homogeneous datasets, which are commonly encountered in early-stage image classification research. The research workflow includes image preprocessing (resizing, color space conversion, and noise reduction), object segmentation, and feature extraction focusing on color, texture, and shape characteristics. The extracted features include Local Binary Pattern (LBP), entropy, edge density, eccentricity, extent, and area ratio. The results demonstrate that K-Means clustering is capable of grouping fashion accessories into distinct categories according to their visual characteristics. From a practical perspective, the proposed approach can be applied to automated fashion product cataloging to support inventory management, image-based product search, and recommendation systems in e-commerce platforms. This study provides a simple and interpretable baseline for fashion accessory classification and serves as a foundation for future work involving larger datasets, advanced feature descriptors, or deep learning-based methods.

This is an open access article under the CC-BY-SA license



1. Pendahuluan

Perkembangan teknologi informasi yang pesat, khususnya dalam bidang *computer vision* dan *machine learning*, telah memberikan kontribusi besar pada berbagai sektor industri. Pemanfaatan citra digital kini semakin meluas tidak hanya pada bidang medis, pertanian, maupun konstruksi, tetapi juga pada industri fesyen dan *e-commerce*. Salah satu tantangan penting dalam industri ini adalah bagaimana sistem dapat secara otomatis mengenali, mengelompokkan, dan mengklasifikasikan produk berbasis citra digital. Tantangan tersebut mencakup tingginya variasi visual antar produk fesyen, seperti perbedaan warna, tekstur, dan bentuk yang kompleks, kemiripan desain antar kategori produk, serta keterbatasan ketersediaan dataset berlabel dalam jumlah besar. Faktor-faktor ini dapat memengaruhi kinerja model klasifikasi citra, terutama pada pendekatan berbasis fitur sederhana dan dataset berskala kecil. Sistem klasifikasi yang akurat akan mendukung efisiensi manajemen inventori sekaligus meningkatkan pengalaman pengguna melalui rekomendasi produk yang lebih tepat sasaran.

Industri fesyen global kini semakin erat kaitannya dengan teknologi digital. Laporan terbaru menunjukkan bahwa tren belanja online meningkat tajam setiap tahunnya, dengan pertumbuhan signifikan di sektor aksesoris fesyen. Perkembangan pesat *e-commerce* terutama di kawasan Asia Tenggara memperbesar volume dan keragaman produk fesyen yang dijual online, termasuk aksesoris seperti tas, dompet, dan ikat pinggang. Sebagai contoh, nilai pasar *e-commerce* Indonesia diperkirakan mencapai puluhan miliar USD pada pertengahan dekade ini, dengan proyeksi pertumbuhan tahunan dua digit dalam beberapa tahun ke depan. Hal serupa terlihat pada *segmen bags & accessories* yang menghasilkan pendapatan miliaran USD di pasar Indonesia dan menunjukkan CAGR yang kuat di kawasan Asia-Pasifik [1]. Kondisi pertumbuhan pasar ini memperbesar tantangan teknis bagi sistem klasifikasi berbasis citra: meningkatnya jumlah item mengharuskan sistem untuk menangani variasi visual yang jauh lebih luas (warna, tekstur, bentuk, serta variasi pencahayaan dan sudut), sementara segmentasi produk dan anotasi data menjadi beban skala besar bagi pelabelan manual. Di samping itu, kategori aksesoris seringkali didominasi oleh desain yang mirip antar merek sehingga fitur sederhana cenderung mengalami kesulitan membedakan kelas yang sangat mirip secara visual—masalah yang semakin tajam ketika *dataset* berlabel terbatas tersedia untuk pelatihan atau validasi. Dengan demikian, tekanan pasar *e-commerce* memperkuat kebutuhan akan metode yang lebih skalabel (*mis. feature embedding* dari CNN/transformer, *augmented data*, atau pemrosesan semi-otomatis untuk anotasi), atau, pada tahap awal, strategi *baseline* yang efisien dan mudah diinterpretasi seperti *K-Means* untuk eksplorasi *dataset* kecil [2]. Dalam kondisi ini, peran sistem klasifikasi citra otomatis menjadi sangat penting karena dapat meningkatkan efisiensi katalogisasi sekaligus mempercepat pencarian produk oleh konsumen.

Dalam dekade terakhir, penerapan *artificial intelligence* (AI) di bidang fesyen telah menjadi salah satu pendorong utama inovasi industri kreatif global. Konsep seperti *AI-powered fashion recommendation*, *virtual try-on*, dan *image-based retrieval* memungkinkan pengguna menemukan produk yang sesuai dengan preferensi visual hanya dengan mengunggah foto [3]. Teknologi ini memanfaatkan algoritme *deep learning*, khususnya jaringan saraf konvolusional (*Convolutional Neural Network*/CNN), yang memiliki kemampuan tinggi dalam mengekstraksi fitur visual kompleks seperti tekstur, bentuk, dan warna. Dengan demikian, klasifikasi citra bukan lagi sekadar analisis visual, tetapi telah menjadi bagian dari strategi bisnis digital yang berorientasi pada pengalaman pengguna. Dalam praktik industri fesyen, berbagai metode telah digunakan untuk klasifikasi citra, mulai dari algoritme *unsupervised* seperti *K-Means* hingga pendekatan berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) dan *Vision Transformer* (ViT). Metode *deep learning* umumnya memberikan akurasi tinggi pada skala besar, namun memerlukan *dataset* berlabel dalam jumlah besar, sumber daya komputasi yang tinggi, serta proses pelatihan yang kompleks. Sebaliknya, *K-Means* memiliki keunggulan dalam kemudahan implementasi, efisiensi komputasi, dan interpretabilitas hasil,

sehingga lebih sesuai untuk tahap awal pengembangan sistem klasifikasi citra atau pada kondisi *dataset* terbatas. Oleh karena itu, penelitian ini memilih *K-Means clustering* sebagai metode *baseline* untuk mengevaluasi karakteristik visual aksesoris fesyen sebelum pengembangan lebih lanjut menggunakan pendekatan yang lebih kompleks.

Selain itu, perkembangan *transfer learning* dan arsitektur *Vision Transformer (ViT)* juga memperluas kemampuan sistem klasifikasi citra pada skala besar dengan akurasi yang tinggi [4]. Namun, implementasi model kompleks seperti itu memerlukan data pelatihan besar, sumber daya komputasi tinggi, dan waktu pelatihan yang lama. Oleh karena itu, penelitian dengan *algoritma* yang lebih ringan seperti *K-Means clustering* tetap relevan sebagai langkah awal untuk memahami karakteristik visual produk, terutama pada *dataset* kecil yang umum digunakan pada tahap eksperimental. Dibandingkan dengan metode *deep learning* yang memerlukan *dataset* berlabel dalam jumlah besar, waktu pelatihan yang lama, serta sumber daya komputasi tinggi seperti *GPU*, *K-Means* memiliki kompleksitas komputasi yang relatif rendah dan dapat diimplementasikan secara efisien pada perangkat dengan spesifikasi terbatas. Selain itu, *K-Means* tidak memerlukan proses pelabelan data, sehingga lebih sesuai untuk eksplorasi awal struktur data dan analisis pola visual pada kondisi keterbatasan data. Keunggulan-keunggulan ini menjadikan *K-Means* sebagai metode *baseline* yang praktis sebelum mengadopsi pendekatan klasifikasi citra yang lebih kompleks.

Penelitian terdahulu menunjukkan keberhasilan metode pengolahan citra dan *clustering* dalam berbagai konteks. [5] mengembangkan metode transformasi afin untuk rekonstruksi motif songket, sementara penelitian lain menggunakan teknik segmentasi afin dan *image blending* untuk menghasilkan variasi motif tekstil baru [6]. Dalam bidang konstruksi, pengolahan citra telah digunakan untuk mengidentifikasi mutu beton dengan metode *Three Layer Median Filter* [7]. Selain aplikasi pada bidang konstruksi, sejumlah penelitian fokus pada pengolahan citra untuk produk fesyen dan pencarian berbasis gambar pada *platform e-commerce*. Kajian literatur terbaru menunjukkan perkembangan metode *content-based fashion image retrieval (CBFIR)* serta teknik *visual embedding* yang dirancang khusus untuk produk fesyen, termasuk pendekatan yang menggabungkan fitur visual dan teks untuk mendukung sistem rekomendasi produk [8]; [9]. Sedangkan pada bidang pertanian, metode *K-Means clustering* berhasil digunakan untuk klasifikasi buah kiwi dan sawo [10]. Pendekatan serupa juga diterapkan pada analisis citra medis melalui operasi morfologi [11].

Beberapa studi menerapkan metode *deep learning*, seperti ekstraksi fitur menggunakan jaringan pra-latih (VGG dan ResNet), yang selanjutnya dimanfaatkan dalam pencocokan visual atau sistem rekomendasi berbasis kesamaan untuk mencapai akurasi tinggi pada koleksi produk berskala besar. Pendekatan ini terbukti efektif dalam skenario industri, namun memerlukan *dataset* berlabel dalam jumlah besar serta sumber daya komputasi yang signifikan [12]. Di sisi lain, terdapat pula penelitian yang memadukan atau mengadaptasi teknik *clustering* – termasuk *K-Means* dan varian hierarkisnya – untuk pengorganisasian *descriptor* dan percepatan proses *retrieval* pada basis data produk. Hasil penelitian tersebut menunjukkan bahwa metode *clustering* tetap relevan, baik sebagai bagian dari *pipeline* sistem *retrieval* skala besar maupun sebagai metode *baseline* eksploratif pada *dataset* terbatas [13]. Dengan memasukkan kajian-kajian ini, manuskrip dapat menegaskan posisi *K-Means* sebagai metode *baseline* yang praktis untuk eksplorasi *dataset* kecil, sekaligus menunjukkan jalur integrasi dengan teknik *embedding* modern ketika sistem dikembangkan lebih lanjut untuk kebutuhan *e-commerce*, misalnya melalui kombinasi ekstraksi fitur berbasis CNN dan *clustering* atau indeks hierarkis.

Beberapa penelitian terkini juga memperlihatkan tren penggabungan metode *unsupervised learning* seperti *K-Means*, *DBSCAN*, dan *hierarchical clustering* dengan fitur visual dari model *deep learning* [14];[15]. Pendekatan ini dikenal sebagai *feature embedding clustering*, di mana fitur hasil ekstraksi dari CNN atau *transformer encoder* digunakan untuk proses pengelompokan. Hal ini menunjukkan arah baru riset pengolahan citra yang lebih adaptif, karena mampu memanfaatkan

kekuatan representasi dari AI modern sambil mempertahankan kesederhanaan metode *unsupervised*. Dalam konteks industri fesyen dan *e-commerce*, pendekatan *feature embedding clustering* telah diterapkan, misalnya dengan mengekstraksi fitur visual produk menggunakan jaringan saraf pra-latih seperti CNN atau Vision Transformer, kemudian mengelompokkan produk fesyen berdasarkan kesamaan visual untuk keperluan katalogisasi otomatis, pencarian produk berbasis gambar (*image-based retrieval*), serta rekomendasi produk yang serupa secara visual. Pendekatan ini memungkinkan pengelompokan produk dalam jumlah besar tanpa memerlukan anotasi manual yang intensif, sehingga relevan untuk pengelolaan data produk fesyen berskala besar.

Selain untuk kebutuhan konsumen, klasifikasi citra berbasis *machine learning* juga berperan dalam manajemen rantai pasok. Produsen dan distributor dapat memanfaatkan sistem ini untuk mengidentifikasi tren pasar lebih awal dan menyesuaikan produksi sesuai permintaan [16]. Hal ini tidak hanya mengurangi biaya operasional, tetapi juga membantu perusahaan dalam menghadapi persaingan yang semakin ketat. Oleh karena itu, penelitian terkait pengembangan algoritme klasifikasi citra semakin relevan untuk mendukung transformasi digital di sektor fesyen.

Lebih lanjut, penelitian terbaru oleh [17] menunjukkan bahwa kombinasi metode ekstraksi fitur dengan algoritme *K-Means clustering* efektif dalam mengidentifikasi kesuburan tanah berbasis citra digital dengan tingkat akurasi tinggi. Hasil tersebut membuktikan bahwa *K-Means* mampu memberikan pengelompokan yang representatif bahkan pada objek citra dengan variasi visual yang kompleks. Meskipun pengolahan citra tanah dan citra aksesoris fesyen berada pada domain yang berbeda, keduanya memiliki kesamaan karakteristik visual, yaitu adanya variasi tekstur, pola permukaan, dan distribusi warna yang menjadi pembeda utama antar kelas. Pada citra tanah, perbedaan tekstur dan warna mencerminkan tingkat kesuburan atau komposisi material, sedangkan pada citra aksesoris fesyen, karakteristik serupa merepresentasikan jenis bahan, desain, dan gaya produk. Kesamaan sifat visual inilah yang menjadikan pendekatan *clustering* berbasis fitur, seperti *K-Means*, efektif diterapkan pada kedua domain. Oleh karena itu, temuan pada pengolahan citra tanah memperkuat urgensi penerapan metode serupa pada klasifikasi aksesoris fesyen yang juga memiliki keragaman bentuk, warna, dan tekstur yang khas.

Dari sisi akademik, penelitian mengenai klasifikasi citra aksesoris fesyen memiliki kontribusi ganda. Pertama, penelitian ini memperkaya literatur di bidang pengolahan citra dengan menerapkan metode *K-Means* pada objek non-konvensional. Kedua, penelitian ini menjembatani kesenjangan antara teori dan praktik, di mana hasilnya dapat langsung diimplementasikan pada sistem nyata yang digunakan oleh pelaku industri. Penelitian terdahulu seperti [18] menekankan pentingnya integrasi metode *clustering* dengan deskriptor fitur *modern* untuk menghasilkan klasifikasi yang lebih akurat.

Di sisi lain, tren riset terkini di bidang *computer vision* menekankan integrasi antara model berbasis *unsupervised learning* dan *self-supervised learning*, yang memungkinkan sistem belajar dari data visual tanpa label eksplisit [19]. Pendekatan ini membuka peluang baru untuk pengembangan sistem klasifikasi fesyen yang lebih hemat biaya dan fleksibel terhadap variasi data visual. Meski demikian, kompleksitas model dan kebutuhan komputasi yang tinggi seringkali menjadi kendala dalam implementasi sistem klasifikasi citra pada skala kecil hingga menengah. Model berbasis *self-supervised learning* dan arsitektur *deep learning* umumnya memerlukan proses pelatihan yang panjang, sumber daya komputasi tinggi, serta tahap *fine-tuning* tambahan agar representasi fitur sesuai dengan domain tertentu. Sebaliknya, *K-Means* memiliki keunggulan dalam kesederhanaan *algoritmik*, kompleksitas komputasi yang relatif rendah, serta kemudahan interpretasi hasil pengelompokan. Selain itu, *K-Means* tidak memerlukan tahap pelatihan model yang kompleks maupun data berlabel, sehingga lebih praktis untuk eksplorasi awal struktur data dan analisis karakteristik visual produk. Keunggulan-keunggulan tersebut menjadikan *K-Means* sebagai solusi strategis dan efisien untuk implementasi awal sistem klasifikasi citra sebelum mengadopsi pendekatan yang lebih kompleks.

Dalam konteks industri fesyen Indonesia, penerapan teknologi seperti *computer vision* dan *machine learning* masih relatif baru, namun potensinya sangat besar. Pertumbuhan *e-commerce* di Indonesia mencapai lebih dari 20% per tahun, dan sebagian besar produk yang dijual adalah pakaian dan aksesoris fesyen. Platform besar seperti Shopee, Tokopedia, dan Lazada kini mulai memanfaatkan sistem rekomendasi berbasis gambar untuk meningkatkan interaksi konsumen [20]. Namun, sebagian besar UMKM fesyen lokal belum memiliki kemampuan teknis untuk mengelola katalog produk secara otomatis. Sistem klasifikasi berbasis citra seperti yang dikembangkan dalam penelitian ini dapat menjadi solusi tepat untuk membantu mereka melakukan digitalisasi produk secara lebih efisien.

Aksesoris fesyen seperti tas, dompet, dan ikat pinggang memiliki ciri visual yang beragam – baik dari sisi bentuk, tekstur bahan, maupun warna. Ciri-ciri ini seringkali menjadi faktor penentu preferensi konsumen, sehingga sistem klasifikasi yang akurat tidak hanya berguna untuk pengelompokan inventori, tetapi juga untuk *personalized recommendation*. Dalam ekosistem digital saat ini, personalisasi menjadi kunci keberhasilan pemasaran. Algoritme klasifikasi citra dapat menjadi fondasi dari sistem rekomendasi visual yang mampu memahami preferensi pengguna berdasarkan gaya dan pola produk yang dipilih sebelumnya [21].

Meskipun perkembangan teknologi telah memungkinkan penerapan *deep learning* untuk klasifikasi citra fesyen dengan akurasi tinggi, metode seperti *K-Means clustering* tetap memiliki keunggulan tertentu. Di antaranya adalah kemudahan implementasi, interpretasi hasil yang jelas, dan efisiensi dalam *dataset* berskala kecil hingga menengah. Selain itu, metode ini dapat berfungsi sebagai *baseline* yang kuat sebelum mengadopsi pendekatan *supervised* atau *semi-supervised*. Banyak penelitian *modern* bahkan menggunakan *K-Means* untuk tahap pra-pemrosesan dalam sistem hibrida berbasis CNN guna mempercepat proses pelabelan otomatis [22].


Urgensi penelitian ini semakin nyata jika dikaitkan dengan perkembangan teknologi kecerdasan buatan yang bergerak ke arah personalisasi layanan. *E-commerce* masa depan tidak hanya berfokus pada transaksi, melainkan juga pada pengalaman pengguna yang unik dan personal. Dengan adanya sistem klasifikasi citra aksesoris fesyen yang akurat, *platform* dapat merekomendasikan produk yang sesuai preferensi visual konsumen. Dengan demikian, penelitian ini tidak hanya bermanfaat dalam konteks teknis, tetapi juga memiliki implikasi sosial-ekonomi yang luas [23].

Berdasarkan permasalahan tersebut, penelitian ini memiliki urgensi untuk dilakukan sebagai langkah awal menghadirkan metode sederhana namun efektif dalam klasifikasi citra aksesoris fesyen. Tujuan penelitian ini adalah menerapkan metode *K-Means clustering* berbasis fitur citra (warna, tekstur, dan bentuk) untuk mengelompokkan tiga kategori aksesoris fesyen, yaitu tas, dompet, dan ikat pinggang. Rencana pemecahan masalah dilakukan melalui tahapan *preprocessing*, segmentasi, ekstraksi fitur, serta pengelompokan menggunakan *algoritme K-Means*. Dengan demikian, penelitian ini diharapkan memberikan kontribusi akademik sebagai *baseline* untuk klasifikasi aksesoris fesyen, sekaligus membuka peluang penelitian lanjutan dengan deskriptor fitur modern maupun metode berbasis *deep learning*.

2. Metodologi Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen laboratorium berbasis pengolahan citra digital yang berfokus pada pengelompokan (*clustering*) citra aksesoris fesyen menggunakan algoritme K-Means. Proses *clustering* dilakukan tanpa melibatkan label kelas pada tahap pembentukan klaster. Namun, label kategori yang tersedia (tas, dompet, dan ikat pinggang) digunakan pada tahap evaluasi untuk memetakan setiap klaster ke kategori dominan berdasarkan mayoritas anggota klaster (*majority voting*). Pemetaan ini bertujuan untuk menilai kesesuaian hasil *clustering* terhadap kategori asli objek serta mempermudah interpretasi kinerja metode yang digunakan. Tujuan utama penelitian adalah mengklasifikasikan aksesoris fesyen (tas, dompet, ikat

pinggang) menggunakan *algoritme K-Means clustering* berdasarkan fitur citra digital. Penelitian ini berbasis eksperimen dengan tahapan: pengumpulan *dataset*, *preprocessing* citra, segmentasi, ekstraksi fitur, pengelompokan menggunakan *K-Means*, dan evaluasi hasil *clustering*. Prosedur penelitian dirancang agar sejalan dengan penelitian terdahulu di bidang pengolahan citra dan *clustering*, seperti yang dilakukan oleh Ramadhanu dkk. [5][6]. Tahapan penelitian ditunjukkan pada Gambar 1 dalam bentuk diagram alir.



Gambar 1. Diagram Alur Penelitian

Objek penelitian adalah citra digital tiga jenis aksesoris fesyen, yaitu tas, dompet, dan ikat pinggang. Dataset terdiri atas 30 citra dengan masing-masing kategori berjumlah 10. Ukuran *dataset* yang relatif terbatas ini menempatkan penelitian sebagai studi awal (*baseline study*) yang bertujuan mengeksplorasi karakteristik visual aksesoris fesyen serta mengevaluasi kinerja awal *algoritme K-Means* pada kondisi data yang kecil dan terkontrol. Oleh karena itu, hasil penelitian ini tidak dimaksudkan untuk digeneralisasikan secara luas pada seluruh jenis aksesoris fesyen, melainkan sebagai pijakan awal untuk penelitian lanjutan dengan dataset yang lebih besar dan beragam. Seluruh citra yang diambil mempunyai latar belakang seragam agar kualitas data konsisten. Bahan dan Alat yang digunakan terdiri dari perangkat keras computer, dan perangkat lunak berupa Matlab R2024a dan system operasi windows 10.




Gambar 2. Contoh Citra Asli Objek Penelitian

Penelitian ini diawali dengan tahap *preprocessing*, yaitu mengubah ukuran citra menjadi seragam, melakukan konversi warna dari RGB ke LAB, serta mereduksi *noise* menggunakan *median filter*. Tahapan ini penting agar citra memiliki kualitas yang konsisten sebelum diproses lebih lanjut [6]. Pemilihan ruang warna LAB pada tahap *preprocessing* bukan tanpa alasan. Ruang warna ini memiliki keunggulan dalam merepresentasikan persepsi manusia terhadap warna, karena memisahkan komponen luminance (L) dari komponen *chromatic* (a dan b). Dengan demikian, variasi pencahayaan yang seringkali menjadi kendala dalam pengolahan citra dapat diminimalkan [24]. Konversi dari RGB ke LAB juga memastikan bahwa fitur warna yang diekstraksi lebih stabil terhadap perubahan lingkungan pengambilan gambar.



Gambar 3. Hasil Preprocessing Citra: Konversi Ruang Warna RGB ke LAB


Setelah itu dilakukan *segmentasi* menggunakan metode *Otsu* untuk memisahkan objek utama dari latar belakang sehingga hanya bagian citra yang relevan yang dianalisis. Metode *segmentasi Otsu* digunakan untuk memisahkan objek utama dari latar belakang. *Otsu* bekerja dengan mencari ambang batas optimal yang memaksimalkan variansi antar kelas dan meminimalkan variansi dalam kelas. Secara matematis, metode ini menghitung nilai ambang t yang meminimalkan jumlah variansi dalam ($\sigma_w^2(t)$) dan memaksimalkan variansi antar kelas ($\sigma_b^2(t)$) [25]. Dengan pendekatan ini, objek dapat dipisahkan secara otomatis tanpa intervensi manual, sehingga hasil segmentasi lebih konsisten



Gambar 4. Hasil Segmentasi Citra Objek Penelitian

Tahap berikutnya adalah ekstraksi fitur yang mencakup fitur tekstur dan bentuk. Fitur tekstur diperoleh dari *Local Binary Pattern* (LBP), entropi, dan *edge density*, sedangkan fitur bentuk dihitung dari rasio area, *extent*, dan eksentrisitas. Menurut Ramadhanu dkk. [6], kombinasi fitur tekstur dan bentuk mampu meningkatkan akurasi klasifikasi berbasis citra.

Ekstraksi fitur tekstur menggunakan *Local Binary Pattern* (LBP) karena metode ini terbukti sederhana namun efektif. LBP bekerja dengan membandingkan nilai intensitas piksel pusat dengan tetangganya. Jika nilai tetangga lebih besar, maka diberi label 1, sebaliknya 0. Pola biner yang dihasilkan kemudian dikonversi menjadi nilai desimal yang mewakili tekstur citra [26]. Keunggulan LBP adalah ketahanannya terhadap perubahan pencahayaan serta kemampuan membedakan pola tekstur halus pada citra



Gambar 5. Hasil Ekstraksi Fitur Tekstur dan Fitur Bentuk Citra Objek Penelitian

Vektor fitur hasil ekstraksi ini kemudian menjadi masukan untuk proses *clustering* dengan *K-Means*, di mana citra dikelompokkan ke dalam tiga kluster sesuai kategori tas, dompet, dan ikat pinggang melalui tahapan inisialisasi centroid, perhitungan jarak *Euclidean*, pembaruan *centroid*, dan

iterasi hingga konvergen. Algoritme K-Means dimulai dengan memilih k centroid awal secara acak. Jarak antara data x_i dengan centroid c_j dihitung menggunakan Euclidean Distance:

$$d(x_i, c_j) = \sqrt{\sum_{n=1}^m (x_{in} - c_{jn})^2}$$

Setiap data dialokasikan ke centroid terdekat, kemudian centroid diperbarui dengan menghitung rata-rata dari semua anggota kluster. Proses ini diulang hingga posisi centroid stabil atau jumlah iterasi maksimum tercapai [27]. Kelebihan metode ini adalah kesederhanaannya, namun kelemahannya adalah sensitif terhadap pemilihan centroid awal.

Selanjutnya, evaluasi hasil dilakukan menggunakan kombinasi validasi internal dan eksternal. Validasi internal dilakukan dengan menggunakan *Silhouette Coefficient* untuk menilai kualitas pemisahan kluster berdasarkan jarak intra- dan antar-kluster. Selain itu, karena dataset memiliki label kategori asli (tas, dompet, dan ikat pinggang) yang digunakan hanya pada tahap evaluasi, dilakukan validasi eksternal dengan memetakan setiap kluster ke kelas dominan (*majority voting*). Berdasarkan pemetaan tersebut, kinerja pengelompokan dievaluasi secara kuantitatif menggunakan metrik *Purity*, *Adjusted Rand Index* (ARI), dan *Normalized Mutual Information* (NMI), serta dianalisis melalui *confusion matrix* untuk melihat pola kesesuaian dan kesalahan pengelompokan. Pendekatan ini bertujuan memberikan evaluasi yang objektif dan terukur terhadap hasil *clustering*, sekaligus meminimalkan subjektivitas penilaian visual. Definisi operasional variabel dalam penelitian ini mencakup tiga jenis variabel, yaitu variabel bebas berupa citra digital aksesoris fesyen yang terdiri atas tas, dompet, dan ikat pinggang, variabel terikat berupa hasil *clustering* yang dihasilkan algoritme K-Means dalam bentuk kelompok citra, serta variabel kontrol yang meliputi kondisi pengambilan citra seperti resolusi kamera, pencahayaan, ukuran citra yang diseragamkan, dan latar belakang yang digunakan agar kualitas data tetap konsisten.

Analisis dilakukan menggunakan algoritme K-Means clustering berbasis citra dengan fitur warna, tekstur, dan bentuk. Metode ini dipilih karena terbukti efisien dalam pengelompokan data citra, sebagaimana ditunjukkan oleh Ramadhanu dkk. [6] dalam penelitian klasifikasi citra tanah menggunakan K-Means. Pemilihan K-Means dibanding metode lain seperti DBSCAN atau Hierarchical Clustering didasarkan pada pertimbangan kesederhanaan implementasi dan efisiensi komputasi. DBSCAN unggul dalam mengidentifikasi kluster dengan kepadatan bervariasi serta mampu mendeteksi noise secara eksplisit. Namun, pada dataset yang relatif homogen dan berdimensi fitur campuran seperti pada penelitian ini, kinerja DBSCAN sangat bergantung pada pemilihan parameter ϵ dan $minPts$. Pemilihan parameter yang tidak optimal dapat menyebabkan sebagian besar data tergolong sebagai noise atau menghasilkan kluster yang tidak stabil. Selain itu, DBSCAN kurang efektif ketika kluster memiliki kepadatan yang saling tumpang tindih atau bentuk yang tidak terpisah secara jelas dalam ruang fitur. Oleh karena itu, K-Means dipilih karena lebih stabil dan sesuai untuk pengelompokan data dengan distribusi yang relatif seragam. Hierarchical Clustering lebih cocok untuk analisis eksploratif, tetapi memerlukan biaya komputasi yang lebih tinggi [28]. Oleh karena itu, K-Means menjadi pilihan tepat sebagai baseline klasifikasi aksesoris fesyen.

3. Hasil dan Pembahasan

3.1. Hasil

Penelitian ini menghasilkan pengelompokan citra digital aksesoris fesyen yang terdiri atas tiga kategori, yaitu tas, dompet, dan ikat pinggang, menggunakan algoritme K-Means clustering. Dataset yang digunakan berjumlah 30 citra, dengan masing-masing kategori terdiri atas 10 citra. Proses ekstraksi fitur menghasilkan vektor fitur yang merepresentasikan karakteristik tekstur dan bentuk dari setiap citra.

Hasil pengelompokan menunjukkan bahwa citra berhasil dipisahkan ke dalam tiga klaster utama. Evaluasi kualitas klaster menggunakan *Silhouette Coefficient* menghasilkan nilai rata-rata sebesar 0,90, yang mengindikasikan kualitas pemisahan klaster yang sangat baik. Menurut Rousseeuw (1987) [29], nilai *Silhouette* di atas 0,70 menunjukkan bahwa objek dalam klaster relatif homogen dan memiliki perbedaan yang jelas dengan klaster lain.

Tabel 1. Hasil ekstraksi citra Dompot

Fitur / Citra	Citra 1	Citra 2	Citra 3	Citra 4	Citra 5	Citra 6	Citra 7	Citra 8	Citra 9	Citra 10
Metric	0.32697	0.44177	0.32908	0.25374	0.15668	0.81553	0.48685	0.30421	0.081682	0.21642
Eccentricity	0.93071	0.88317	0.94394	0.92863	0.77238	0.52731	0.91897	0.69684	0.48428	0.80612
Contrast	0.15240	0.035461	0.25646	0.79321	0.29379	0.88922	0.17881	0.11314	0.68469	0.15856
Correlation	0.94308	0.96104	0.94398	0.92953	0.89414	0.90871	0.79757	0.96171	0.96300	0.98212
Energy	0.66312	0.57123	0.60584	0.60210	0.61655	0.14887	0.60692	0.71042	0.37507	0.47174
Homogeneity	0.96391	0.98429	0.95398	0.95191	0.95096	0.80502	0.96809	0.97025	0.92208	0.93609

Tabel 1 menunjukkan hasil ekstraksi fitur tekstur dan bentuk pada sepuluh citra dompet. Fitur tekstur yang dihitung menggunakan *Gray Level Co-occurrence Matrix* (GLCM) meliputi *contrast*, *correlation*, *energy*, dan *homogeneity*, sedangkan fitur bentuk direpresentasikan oleh nilai *metric* dan *eccentricity*. Secara umum, citra dompet menunjukkan nilai *eccentricity* yang relatif tinggi, yang mengindikasikan bentuk objek cenderung memanjang. Nilai *correlation* dan *homogeneity* yang tinggi pada sebagian besar citra menunjukkan adanya keseragaman pola tekstur, sedangkan variasi nilai *contrast* dan *energy* mencerminkan perbedaan tingkat kekasaran tekstur antar citra dompet. Variasi nilai fitur ini menjadi representasi numerik karakteristik visual dompet yang selanjutnya digunakan sebagai vektor fitur pada proses clustering menggunakan algoritme *K-Means*.

Tabel 2. Hasil ekstraksi citra Ikat Pinggang

Fitur / Citra	Citra 11	Citra 12	Citra 13	Citra 14	Citra 15	Citra 16	Citra 17	Citra 18	Citra 19	Citra 20
Metric	0.54907	0.86009	0.19383	0.34145	0.76228	0.59884	0.50301	0.41640	0.25330	0.17121
Eccentricity	0.55192	0.04153	0.93256	0.72459	0.88100	0.86134	0.91888	0.96740	0.66002	0.84681
Contrast	0.14822	0.00333	0.00309	0.06768	0.01052	0.09415	0.15853	0.03593	0.29681	0.07335
Correlation	0.95372	0.94472	0.95922	0.96685	0.96599	0.95864	0.85196	0.95864	0.92456	0.94931
Energy	0.70456	0.99334	0.92835	0.77136	0.96171	0.74158	0.83732	0.93503	0.71931	0.92356
Homogeneity	0.98231	0.99930	0.99852	0.98891	0.99785	0.97121	0.97003	0.99570	0.95940	0.99239

Tabel 2 menyajikan hasil ekstraksi fitur tekstur dan bentuk pada sepuluh citra ikat pinggang. Fitur tekstur diekstraksi menggunakan *Gray Level Co-occurrence Matrix* (GLCM) yang meliputi *contrast*, *correlation*, *energy*, dan *homogeneity*, sedangkan fitur bentuk direpresentasikan oleh *metric* dan *eccentricity*. Secara umum, citra ikat pinggang menunjukkan nilai *eccentricity* yang tinggi pada sebagian besar citra, yang mengindikasikan bentuk objek yang memanjang. Nilai *contrast* yang relatif rendah dan nilai *homogeneity* yang tinggi menunjukkan bahwa tekstur ikat pinggang cenderung seragam dengan variasi intensitas yang kecil. Sementara itu, nilai *energy* yang tinggi pada sebagian besar citra menandakan pola tekstur yang teratur. Karakteristik fitur ini membedakan citra ikat pinggang dari kategori aksesoris lainnya dan menjadi masukan penting dalam proses *clustering* menggunakan algoritme *K-Means*.

Tabel 3. Hasil Ekstraksi citra Tas

Fitur / Citra	Citra 21	Citra 22	Citra 23	Citra 24	Citra 25	Citra 26	Citra 27	Citra 28	Citra 29	Citra 30
Metric	0.15116	0.28492	0.026363	0.08870	0.04557	0.74081	0.041078	0.39244	0.54233	0.14210
Eccentricity	0.68910	0.86488	0.71773	0.47326	0.73248	0.84297	0.34841	0.59572	0.55549	0.56043
Contrast	0.08984	0.00147	0.31202	0.36484	0.19298	0.00826	0.086933	0.15398	0.04057	0.22935
Correlation	0.96420	0.89956	0.84453	0.97907	0.95599	0.93932	0.98206	0.94296	0.88278	0.97149
Energy	0.40051	0.99812	0.56294	0.38199	0.59520	0.99390	0.70766	0.66129	0.86829	0.80296
Homogeneity	0.97113	0.99969	0.92824	0.95006	0.95785	0.99929	0.98779	0.98357	0.99078	0.98918

Tabel 3 menyajikan hasil ekstraksi fitur tekstur dan bentuk pada sepuluh citra tas. Fitur tekstur diekstraksi menggunakan *Gray Level Co-occurrence Matrix* (GLCM) yang meliputi *contrast*, *correlation*, *energy*, dan *homogeneity*, sedangkan fitur bentuk direpresentasikan oleh *metric* dan *eccentricity*. Secara umum, citra tas menunjukkan variasi nilai *metric* yang cukup lebar, yang mencerminkan keragaman bentuk objek tas. Nilai *eccentricity* berada pada rentang menengah hingga tinggi, menandakan bahwa bentuk tas cenderung tidak terlalu memanjang dibandingkan ikat pinggang, namun juga tidak sepenuhnya mendekati bentuk lingkaran. Nilai *contrast* yang bervariasi menunjukkan perbedaan tingkat kekasaran tekstur permukaan tas, sementara nilai *correlation* dan *homogeneity* yang relatif tinggi mengindikasikan adanya pola tekstur yang cukup teratur. Variasi nilai fitur ini memberikan representasi *numerik* yang membedakan citra tas dari kategori dompet dan ikat pinggang pada proses *clustering* menggunakan *algoritme K-Means*.

Formula Matematis Fitur yang Digunakan

1. Contrast (GLCM)

Mengukur perbedaan intensitas antar piksel.

$$\text{Contrast} = \sum_{i,j} (i - j)^2 P(i, j)$$

2. Correlation (GLCM)

Mengukur keterkaitan linear antara piksel bertetangga.

$$\text{Correlation} = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j}$$

3. Energy (GLCM)

Mengukur tingkat keseragaman tekstur citra.

$$\text{Energy} = \sum_{i,j} P(i, j)^2$$

4. Homogeneity (GLCM)

Mengukur kedekatan distribusi elemen GLCM terhadap diagonal utama.

$$\text{Homogeneity} = \sum_{i,j} \frac{P(i, j)}{1 + |i - j|}$$

5. Metric (Circularity)

Mengukur kedekatan bentuk objek terhadap lingkaran.

$$\text{Metric} = \frac{4\pi \times \text{Area}}{\text{Perimeter}^2}$$

6. Eccentricity

Mengukur tingkat kelonjongan objek berdasarkan elips ekuivalen.

$$\text{Eccentricity} = \sqrt{1 - \frac{b^2}{a^2}}$$

dengan a dan b berturut-turut adalah sumbu mayor dan minor elips.

Tabel 4. Hasil *Clustering* Citra Aksesori Fesyen dengan *K-Means*

Klaster	Jumlah Citra	Kategori Dominan	Persentase (%)
1	10	Dompot	70
2	10	Ikat Pinggang	100
3	10	Tas	100
Rata- rata	30	-	90

Selain tabel, hasil evaluasi menggunakan **Silhouette Coefficient** menunjukkan nilai rata-rata sebesar **0,90**, yang menandakan kualitas clustering cukup baik.

Tabel 5. Visualisasi Hasil *Clustering* Citra Aksesori Fesyen dengan *K-Means*

Citra	Kategori Asli	Klaster K-Means
Citra 1-10	Dompot	Dompot (kecuali citra 5, 6, 9 salah baca)
Citra 11-20	Ikat Pinggang	Ikat Pinggang (kecuali citra 12, 15 salah baca)
Citra 21-30	Tas	Tas (kecuali citra 26, 29 salah baca)

Visualisasi hasil pengelompokan disajikan pada Tabel 5, yang menunjukkan distribusi citra pada masing-masing klaster berdasarkan kategori aslinya. Beberapa citra mengalami salah pengelompokan, terutama pada kategori dompet dan ikat pinggang.

Hasil ekstraksi fitur untuk masing-masing kategori ditampilkan pada Tabel 1 (Dompot), Tabel 2 (Ikat Pinggang), dan Tabel 3 (Tas). Ringkasan hasil pengelompokan ditunjukkan pada Tabel 4, yang memperlihatkan bahwa dua klaster (ikat pinggang dan tas) memiliki tingkat kecocokan kategori sebesar 100%, sedangkan klaster dompet memiliki kecocokan sebesar 70%. Secara keseluruhan, tingkat kesesuaian rata-rata mencapai 90%.

3.2. Pembahasan

Hasil pengelompokan menunjukkan bahwa *algoritme K-Means* mampu mengelompokkan citra aksesori fesyen secara efektif berdasarkan fitur tekstur dan bentuk yang digunakan. Nilai *Silhouette Coefficient* sebesar 0,90 menegaskan bahwa kombinasi fitur *Local Binary Pattern* (LBP), *entropi*, *edge density*, *eksentrisitas*, *extent*, dan *rasio area* mampu memberikan representasi visual yang cukup diskriminatif bagi proses clustering.

Meskipun demikian, hasil visualisasi menunjukkan adanya beberapa kasus salah klasifikasi. Kesalahan pengelompokan terutama terjadi pada citra dompet berwarna gelap dengan tekstur sederhana yang dikelompokkan ke dalam klaster ikat pinggang. Hal ini diduga disebabkan oleh kemiripan nilai *edge density* dan *eksentrisitas* antara kedua jenis objek tersebut. Fenomena serupa juga dilaporkan oleh [30] Putra dan Lestari (2019) pada penelitian klasifikasi buah dengan warna dominan gelap, yang menunjukkan keterbatasan fitur berbasis tekstur dan bentuk dalam membedakan objek dengan karakteristik visual yang mirip.

Temuan penelitian ini sejalan dengan hasil penelitian Ramadhanu dkk. (2022) [5], yang menunjukkan bahwa integrasi metode ekstraksi fitur dan *K-Means clustering* mampu meningkatkan kualitas pengelompokan citra. Pada penelitian tersebut, fitur tekstur dan bentuk terbukti efektif dalam mengklasifikasikan citra tanah berdasarkan tingkat kesuburan. Kesamaan karakteristik visual berupa variasi tekstur dan distribusi warna menjelaskan mengapa pendekatan *K-Means* juga efektif diterapkan pada domain aksesori fesyen.

Hasil penelitian ini juga konsisten dengan temuan Huang dan Zhang (2020), yang menyatakan bahwa penggabungan fitur tekstur dan bentuk dapat meningkatkan akurasi pengelompokan citra [31]. Perbedaanannya terletak pada objek penelitian, di mana penelitian tersebut berfokus pada citra

pertanian, sedangkan penelitian ini mengkaji citra aksesoris fesyen. Hal ini menegaskan fleksibilitas metode *K-Means* untuk diterapkan pada berbagai domain dengan karakteristik visual yang berbeda.

Dari sisi praktis, sistem klasifikasi berbasis *K-Means* berpotensi diimplementasikan pada platform *e-commerce* untuk mendukung pencarian produk berbasis citra [6] dan pengelolaan inventori. Konsumen dapat mengunggah foto aksesoris, kemudian sistem mengelompokkan produk yang memiliki kesamaan visual secara otomatis, sehingga meningkatkan efisiensi pencarian dan pengalaman pengguna [32].

Namun demikian, penelitian ini masih memiliki keterbatasan, terutama dalam membedakan objek dengan karakteristik visual yang sangat mirip. Untuk meningkatkan performa, penelitian selanjutnya dapat menambahkan deskriptor fitur lain seperti *Histogram of Oriented Gradients* (HOG) atau *Scale-Invariant Feature Transform* (SIFT) [33], maupun menggabungkan *K-Means* dengan metode *supervised learning* seperti *Support Vector Machine* (SVM) atau *Convolutional Neural Network* (CNN) dalam pendekatan *hybrid*.

4. Kesimpulan

Penelitian ini berhasil mengklasifikasikan citra digital aksesoris fesyen berupa tas, dompet, dan ikat pinggang menggunakan algoritma *K-Means clustering* berbasis fitur tekstur dan bentuk. Hasil pengelompokan menunjukkan tingkat konsistensi yang tinggi, dengan nilai *Silhouette Coefficient* rata-rata sebesar 0,90 yang menandakan kualitas kluster cukup baik. Temuan ini membuktikan bahwa kombinasi fitur *Local Binary Pattern* (LBP), *entropi*, *edge density*, *eksentrisitas*, *extent*, dan *rasio area* efektif dalam membedakan kategori aksesoris fesyen. Dengan demikian, penelitian ini memberikan kontribusi sebagai *baseline* sederhana dalam klasifikasi aksesoris fesyen berbasis citra digital, sekaligus membuka peluang pengembangan lebih lanjut melalui penambahan fitur warna yang lebih kompleks maupun penerapan metode klasifikasi berbasis *deep learning* untuk meningkatkan akurasi.

Ucapan Terimakasih

Penulis mengucapkan terima kasih kepada Bapak Agung Ramadhanu atas bimbingan dan bantuan selama pengumpulan data, analisis, dan penulisan manuskrip. Penulis juga menghargai Universitas Pendidikan Indonesia YPTK Padang atas fasilitas dan dukungan akademik yang diberikan.

Daftar Pustaka

- [1] PS Market Research, "Indonesia E-commerce Market Size, Share and Growth Analysis." 2023. Accessed: Jan. 31, 2026. [Online]. Available: <https://www.psmarketresearch.com/market-analysis/indonesia-e-commerce-market>
- [2] FashionUnited, "Global Fashion Industry Statistics." 2023. Accessed: Jan. 31, 2026. [Online]. Available: <https://fashionunited.com/statistics/global-fashion-industry-statistics>
- [3] L. Zhang, H. Wang, and Y. Chen, "AI-powered Fashion Recommendation Systems: Trends and Future Directions," *J. Vis. Comput. AI*, vol. 7, no. 2, pp. 45–63, 2023, doi: 10.1016/j.visai.2023.07.005.
- [4] A. Dosovitskiy et al., "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," *Int. Conf. Learn. Represent.*, 2021.
- [5] A. Ramadhanu and others, "Transformasi Afin untuk Rekonstruksi Motif Songket," *J. Teknol. dan Sist. Inf.*, vol. 10, no. 2, pp. 55–63, 2022.
- [6] A. Ramadhanu and others, "Segmentasi Afin dan Image Blending untuk Generasi Motif Tekstil," *J. Teknol. dan Sist. Inf.*, vol. 9, no. 4, pp. 221–230, 2021.
- [7] D. Sari and H. Putra, "K-Means Clustering untuk Klasifikasi Buah Kiwi dan Sawo," *J. Ilm. Inform.*, vol. 8, no. 1, pp. 15–23, 2020.
- [8] A. M. Shoib, M. A. Rahman, and M. R. Islam, "Methods and Advancement of Content-Based Fashion Image Retrieval: A Review," *arXiv*, 2023, [Online]. Available: <https://arxiv.org/abs/2303.17371>
- [9] X. Wang, Y. Li, Z. Zhang, and Y. Chen, "FashionKLIP: Enhancing E-Commerce Image-Text Alignment with Knowledge-Enhanced Vision-Language Pretraining," in *Proceedings of the ACL Industry Track*, 2023. [Online]. Available: <https://aclanthology.org/2023.acl-industry.16/>
- [10] R. Hidayat and others, "Analisis Mutu Beton Menggunakan Pengolahan Citra Digital," *J. Rekayasa Sipil*, vol. 13, no. 2, pp. 101–110, 2019.

- [11] Y. Nugroho and A. Setiawan, "Penerapan K-Means untuk Klasifikasi Data Medis," *J. Teknol. Inf.*, vol. 12, no. 3, pp. 44-52, 2020.
- [12] H. Zhong, J. Li, and S. Wang, "Image-Based Product Recommendation for E-Commerce Using Visual and Textual Features," *J. Vis. Lang. & Comput.*, vol. 69, p. 101349, 2022, doi: 10.1016/j.jvlc.2022.101349.
- [13] D. Park, J. Kim, and S. Lee, "Efficient Image Retrieval Using Hierarchical K-Means Clustering," *Sensors*, vol. 24, no. 8, p. 2401, 2024, doi: 10.3390/s24082401.
- [14] F. Chollet, *Deep Learning with Python*, 2nd ed. Shelter Island, NY: Manning Publications, 2021.
- [15] Y. Wu, X. Sun, R. Zhang, and Z. Li, "Deep Feature Embedding Clustering for Image Categorization," *Pattern Recognit.*, vol. 129, p. 108785, 2022, doi: 10.1016/j.patcog.2022.108785.
- [16] P. Kumar and R. Singh, "Application of Unsupervised Learning for Supply Chain Optimization," *J. Artif. Intell. Res.*, vol. 14, no. 2, pp. 45-56, 2019.
- [17] A. Ramadhanu and others, "Penerapan Pengolahan Citra pada Identifikasi Tanah," *J. Teknol. dan Sist. Inf.*, vol. 9, no. 3, pp. 145-153, 2021.
- [18] H. Wang and Y. Li, "Feature Integration in Image Clustering," *Pattern Recognit. Lett.*, vol. 145, pp. 78-85, 2021.
- [19] M. Caron, I. Misra, J. Mairal, P. Goyal, P. Bojanowski, and A. Joulin, "Emerging Properties in Self-Supervised Vision Transformers," *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 9650-9660, 2021.
- [20] D. Santoso, H. Wijaya, and F. Rahman, "Implementasi Sistem Rekomendasi Produk Fesyen Berbasis Citra pada E-commerce Indonesia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 1, pp. 55-66, 2023, doi: 10.33365/jtiik.v10i1.10555.
- [21] Y. Chen, K. Liu, and J. Han, "Personalized Visual Product Recommendation Using Deep Hybrid Models," *IEEE Trans. Multimed.*, vol. 24, no. 9, pp. 2551-2564, 2022, doi: 10.1109/TMM.2022.3156872.
- [22] Z. Li, X. Hu, and Y. Zhao, "Hybrid CNN and K-Means Framework for Automatic Image Labeling in Fashion Datasets," *Comput. Ind.*, vol. 151, p. 103982, 2023, doi: 10.1016/j.compind.2023.103982.
- [23] X. Zhang and Y. Chen, "Personalization in E-commerce Using Computer Vision," *J. E-Commerce Res.*, vol. 18, no. 3, pp. 67-79, 2020.
- [24] R. Sharma and K. Gupta, "LAB Color Space in Image Processing Applications," *Int. J. Image Process.*, vol. 12, no. 1, pp. 12-20, 2018.
- [25] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," *IEEE Trans. Syst. Man. Cybern.*, vol. 9, no. 1, pp. 62-66, 1979.
- [26] T. Ojala, M. Pietikäinen, and D. Harwood, "A Comparative Study of Texture Measures with Classification Based on Feature Distributions," *Pattern Recognit.*, vol. 29, no. 1, pp. 51-59, 1996.
- [27] J. MacQueen, "Some Methods for Classification and Analysis of Multivariate Observations," in *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1967, vol. 1, pp. 281-297.
- [28] A. K. Jain, "Data Clustering: 50 Years Beyond K-Means," *Pattern Recognit. Lett.*, vol. 31, no. 8, pp. 651-666, 2010.
- [29] P. J. Rousseeuw, "Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis," *J. Comput. Appl. Math.*, vol. 20, pp. 53-65, 1987.
- [30] D. Putra and I. Lestari, "Klasifikasi Buah Menggunakan Ekstraksi Fitur Warna dan Tekstur," *J. Teknol. Inf.*, vol. 11, no. 2, pp. 77-85, 2019.
- [31] Z. Huang and L. Zhang, "Texture and Shape Descriptors for Agricultural Image Classification," *Comput. Electron. Agric.*, vol. 175, pp. 105-118, 2020.
- [32] L. Chen and X. Wang, "Visual Recommendation Systems in E-commerce," *ACM Comput. Surv.*, vol. 52, no. 2, pp. 1-37, 2019.
- [33] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2005, vol. 1, pp. 886-893.