

# Pencarian Visual Berbasis Jaringan Convolutional Neural Network untuk Platform Pemasaran Digital Produk UMKM

Kevin Harlis Oktaviano<sup>1</sup>, Arman Hakim Nasution<sup>2</sup>

<sup>1</sup> Sekolah Interdisiplin Manajemen dan Teknologi, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

<sup>2</sup> Business Management Department, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia,

## Article Info

### Article history:

Diterima 29 Juli 2024

Revisi 6 Agustus 2024

Diterbitkan 4 Oktober 2024

### Keywords:

Deep Learning

Convolutional Neural Network

Visual Search

E-commerce

Produk UMKM

## ABSTRAK

Usaha Mikro, Kecil, dan Menengah (UMKM) memainkan peran penting dalam perekonomian Indonesia. Namun, UMKM seringkali menghadapi tantangan dalam hal manajemen produk dan interaksi dengan pelanggan terutama dalam pemasaran digital dan E-commerce. Penelitian ini bertujuan untuk mengembangkan platform pencarian visual berbasis Deep Learning untuk identifikasi produk UMKM guna mengatasi tantangan tersebut. Metode penelitian diawali dengan studi literatur tentang Deep Learning dan CNN (Convolutional Neural Network). Selanjutnya dilakukan pengumpulan data berupa gambar produk UMKM, diikuti pra-pemrosesan dan augmentasi data. Kemudian dirancang model menggunakan arsitektur CNN VGG16 yang terdiri dari 16 lapisan untuk pencarian visual dan klasifikasi produk UMKM. Model terbaik yang memenuhi target performa kemudian diintegrasikan pada prototipe platform berbasis web. Hasil penelitian menunjukkan bahwa platform ini mampu meningkatkan efisiensi operasional UMKM dan pengalaman pelanggan dalam mencari dan menemukan produk yang mereka butuhkan. Pengujian dilakukan melalui beberapa skenario pencarian gambar menggunakan query yang berada di luar dataset dan berbeda terhadap semua kategori. Pengujian ini dilakukan sebanyak tiga kali terhadap masing-masing kategori untuk memastikan konsistensi dan keandalan model dalam mengenali gambar yang relevan dan tidak. Secara keseluruhan, penelitian ini bertujuan mendukung pertumbuhan UMKM di Indonesia melalui adopsi teknologi Deep Learning.

*This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.*



## Corresponding Author:

Kevin Harlis Oktaviano,

Sekolah Interdisiplin Manajemen dan Teknologi, Institut Teknologi Sepuluh November, Surabaya 60111, Indonesia

Email: kevinharlis@gmail.com

## 1. PENDAHULUAN

Usaha Mikro Kecil dan Menengah UMKM memainkan peran sentral dalam ekonomi, menyediakan berbagai produk yang mendukung perkembangan ekonomi lokal dan membuka peluang kerja. Di Indonesia, jumlah *UMKM* terus bertambah setiap tahunnya, memberikan dampak positif bagi perekonomian [1]. Terhitung berdasarkan Data dari Kementerian Koperasi dan UMKM RI, pertumbuhan *UMKM* meningkat dari 59.269.772 pada 2015 menjadi 65.465.497 pada 2019. Hingga 2022, pertumbuhan ini terus berlanjut, kemudian dengan adanya peluncuran platform *OSS RBA* untuk pendaftaran usaha. Pada 2022, 8,71 juta *UMKM* telah terdaftar di *OSS*, dengan mayoritas di Jawa Barat, Jawa Tengah, dan Jawa Timur.

Namun, *UMKM* menghadapi tantangan di era digital yang mengubah perilaku konsumen. Inovasi dan adaptasi teknologi digital, seperti pemasaran melalui media sosial dan platform *E-commerce*, menjadi kunci untuk bersaing [2]. Salah satu tantangan yang dihadapi oleh *UMKM* dalam hal manajemen produk dan interaksi dengan pelanggan yaitu keterbatasan kualitas Sumber Daya Manusia (SDM) dan lemahnya jaringan usaha dan kemampuan penetrasi pasar [3]. Pada zaman saat ini penggunaan teknologi adalah sesuatu yang sudah tidak

bisa dihindari lagi bagi UMKM [4]. Pelanggan saat ini semakin terbiasa dengan teknologi dan mengharapkan informasi produk yang rinci serta pengalaman belanja yang interaktif, ditambah dengan kemudahan penggunaan perangkat mobile untuk mendapatkan informasi produk di mana saja [5]. Dalam penerapan *E-commerce* sebagai platform jual beli pada UMKM terdapat beberapa permasalahan diantaranya, pemilik UMKM masih sering salah dalam melakukan *Tagging* saat upload produk yang menyebabkan produk tidak muncul dalam pencarian. Disisi lain *customer* juga masih kesusahan dalam melakukan pencarian manual menggunakan text. Pencarian *Visual* pada *E-commerce* berbasis *Deep Learning* menjadi solusi dalam menghadapi masalah klasifikasi produk di *E-commerce*, yang sering mengakibatkan penurunan penjualan jika dilakukan secara manual. Pencarian *Visual* juga memungkinkan pengguna melakukan pencarian produk secara *visual* dengan memasukkan *query* berupa gambar dan akan menghasilkan gambar keluaran yang sejenis. [6]. Platform pencarian visual yang dikembangkan dengan *Deep Learning* dapat mengklasifikasikan gambar dengan akurasi tinggi, membantu pemilik UMKM dan konsumen dalam mencari produk dengan cepat dan tepat [7][8].

Penelitian ini bertujuan mengembangkan platform pencarian visual khusus untuk UMKM, yang diharapkan dapat meningkatkan efisiensi operasional, memperluas aksesibilitas produk, dan meningkatkan pengalaman pelanggan. Dengan demikian, UMKM dapat beradaptasi lebih baik di era digital dan memberikan kontribusi yang lebih besar bagi perekonomian.

## 2. METODE

Penelitian ini dilaksanakan mulai dari survey produk UMKM yang akan digunakan termasuk memilih kategori produk dan jumlah gambar produk yang digunakan. Tahap kedua melibatkan pengambilan data untuk konfigurasi model. Data primer berupa 1200 gambar produk UMKM meliputi makanan, minuman, pakaian, dan aksesoris & kerajinan, masing - masing kategori memiliki 300 gambar produk UMKM yang dikumpulkan. Gambar-gambar tersebut kemudian divalidasi ulang kualitasnya, diberi label secara otomatis, dipotong, disamakan dimensinya, dan ditingkatkan kualitasnya.

Model arsitektur Convolutional Neural Network yang digunakan yaitu arsitektur VGG16 yang dikembangkan oleh Simonyan dan Sizzerman [9] dirancang dan dievaluasi pada tahap ini. Model yang dikembangkan terdiri dari Visual Search dan klasifikasi *Tagging* produk UMKM, kedua model ini nantinya akan di integrasi ke dalam platform yang dibagi menjadi *Frontend* untuk pencarian visual dan *Backend* untuk klasifikasi *Tagging* produk.

## 3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengembangkan sebuah platform dengan dua model yaitu pencarian *visual* untuk memudahkan identifikasi produk, dan klasifikasi *Tagging* produk untuk menghindari salah klasifikasi serta diharapkan produk dapat muncul di hasil pencarian dengan tepat [10]. Pemanfaatan pencarian visual dalam sistem E-commerce menjadi hal yang sangat penting karena memberikan berbagai keuntungan. Pertama, interaksi menjadi lebih nyaman. Kedua, pencarian visual lebih unggul dibandingkan pencarian teks dalam memberikan deskripsi yang lebih rinci. Ketiga, pencarian visual menciptakan koneksi yang lebih baik antara skenario daring dan luring [11]. Dengan tujuan utama untuk mempermudah UMKM dalam mengelola inventaris produk mereka di platform *E-commerce* dan meningkatkan pengalaman pelanggan dalam mencari produk sesuai kebutuhan. Penelitian ini mengintegrasikan teknologi untuk mengatasi beberapa tantangan yang dihadapi oleh UMKM. Penelitian ini dibagi menjadi beberapa tahap diantaranya:

### 3.1. Pengumpulan Data

Penelitian ini menggunakan dataset yang terdiri dari gambar-gambar produk UMKM untuk melatih dan menguji model *Deep Learning*. Dataset yang digunakan mencakup empat kategori utama produk UMKM meliputi: makanan, minuman, pakaian, aksesoris, dan kerajinan. Setiap kategori dipilih untuk mewakili keragaman produk yang ditawarkan oleh UMKM, dengan total 1200 gambar yang tersebar secara merata di antara kategori-kategori tersebut. Sumber data yang digunakan dalam penelitian ini berasal dari berbagai UMKM yang beroperasi di area Tapal Kuda, khususnya di kota Jember, Bondowoso dan Situbondo. Untuk memastikan keragaman dan representasi yang baik dari setiap kategori produk, data juga diperoleh dari berbagai event pameran dan bazar UMKM yang diadakan di wilayah tersebut. Hal ini memungkinkan peneliti untuk mendapatkan sampel yang lebih luas dan variatif, mencakup berbagai jenis produk yang diproduksi oleh UMKM lokal. Dataset yang berkualitas tinggi memungkinkan model CNN untuk mempelajari fitur-fitur penting dari setiap kategori produk dengan lebih efektif, sehingga meningkatkan akurasi dan reliabilitas hasil pencarian.

### 3.2. Pra-Pemrosesan Data

Setelah data dikumpulkan tahapan selanjutnya yaitu pra-pemrosesan data dalam penelitian ini meliputi empat tahap utama. Pertama, dilakukan pemotongan gambar (*cropping*) untuk menghilangkan area yang tidak relevan dan mempertajam fokus pada objek utama yang akan dianalisis. Kedua, dilakukan penyesuaian ukuran (*resizing*) dengan mengubah semua gambar produk UMKM menjadi ukuran 128x128 piksel guna memastikan konsistensi dalam pelatihan model *Convolutional Neural Network (CNN)*, khususnya VGG16. Ketiga, penambahan dimensi batch diterapkan untuk memastikan bahwa data gambar berada dalam format yang sesuai untuk dimasukkan ke dalam model CNN. Terakhir, normalisasi warna dilakukan untuk menyesuaikan nilai piksel dalam gambar sehingga semua gambar memiliki distribusi warna yang seragam, mengurangi variasi warna yang tidak diinginkan, dan memastikan kualitas yang konsisten untuk pelatihan model.

### 3.3. Pengembangan Model

Pengembangan model merupakan inti dari penelitian ini, yang berfokus pada penciptaan sistem pencarian *visual* dan klasifikasi *Tagging* produk berbasis *Convolutional Neural Network (CNN)* untuk mendukung manajemen platform jual beli online produk Usaha Mikro Kecil dan Menengah (UMKM). Pentingnya pengembangan model ini terletak pada kemampuannya untuk secara otomatis mengenali dan mengkategorikan gambar produk, yang tidak hanya meningkatkan efisiensi pengelolaan inventaris tetapi juga memperkaya pengalaman pengguna dalam mencari produk. Pengembangan model dalam penelitian ini dibagi menjadi 2 tahapan yaitu pemilihan model arsitektur dan tahapan dari pengembangan model itu sendiri.

#### 3.3.1. Model Arsitektur

Penelitian ini menggunakan arsitektur model VGG16, sebuah *Convolutional Neural Network (CNN)* yang terdiri dari 16 lapisan terlatih, termasuk 13 lapisan konvolusi dan 3 lapisan *fully connected*. VGG 16 merupakan pembelajaran mendalam dalam cabang dari *Machine Learning* yang terdiri dari algoritma pemodelan abstraksi tingkat tinggi untuk menunjukkan bagaimana mesin harus mengubah parameter internal yang digunakan untuk menghitung representasi di setiap lapisan dari representasi di lapisan sebelumnya [12]. Konvolusi sendiri adalah istilah matematis yang berarti mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang [13]. Ketika menguji keberadaan fitur pada gambar baru, CNN akan mencoba semua 29 kemungkinan posisi pada gambar [14].

VGG16 dipilih karena kemampuannya yang luar biasa dalam mengekstraksi fitur *visual* yang mendalam dan relevan, serta keseimbangan antara kedalaman jaringan dan performa komputasi. Model VGG16 yang digunakan telah di-pra-latih sebelumnya, tetapi peneliti membekukan semua bobot dalam model dasar VGG16. Ini berarti bahwa bobot-bobot ini tidak akan diperbarui selama pelatihan. Pembekuan ini dilakukan untuk mempertahankan fitur-fitur yang telah dipelajari model VGG16 dari dataset *ImageNet*, sehingga fokus pelatihan dapat beralih ke lapisan-lapisan baru yang akan ditambahkan di atas model dasar untuk penyesuaian terhadap dataset spesifik yang digunakan dalam penelitian ini. Membekukan bobot *pre-trained* berarti kita tidak memperbarui parameter-parameter dalam lapisan-lapisan tersebut selama pelatihan lebih lanjut. Keuntungan utama dari pendekatan ini adalah pengurangan waktu dan sumber daya komputasi yang diperlukan. Selain itu, model *pre-trained* yang dibekukan membantu dalam mencegah *overfitting*, terutama ketika kita memiliki dataset yang relatif kecil untuk tugas khusus. Dengan membekukan lapisan-lapisan awal, model dapat mempertahankan generalisasi fitur-fitur dasar yang sudah dipelajari, sementara lapisan-lapisan akhir dapat disesuaikan untuk tugas khusus kita dengan dataset yang lebih kecil. Secara keseluruhan, penggunaan model *pre-trained* yang dibekukan memungkinkan pengembangan model yang lebih efisien dan efektif, memanfaatkan kekuatan dari model yang sudah dilatih secara ekstensif pada dataset besar.

#### 3.2.2. Tahapan Pengembangan Model

Dalam penelitian ini, pengembangan model dimaksudkan untuk meningkatkan efisiensi dan akurasi pencarian *Visual* dan klasifikasi *Tagging* produk pada dataset gambar melalui beberapa tahapan kunci yang meliputi *Import Library*, pengorganisasian data, membagi dataframe, menetapkan ukuran batch untuk pelatihan, validasi, dan pengujian, *Augmentasi Data*, penggunaan model arsitektur, ekstraksi fitur, klasifikasi dan proses pencarian gambar. Proses ini dimulai dengan memasukkan *library* yang dibutuhkan kemudian membagi dataset berdasarkan kategori dan jumlah untuk proses pelabelan seperti yang terlihat pada gambar dibawah ini.

```

                                filepath      labels
0  D:\img\UMKMno300data\Aksesoris & Kerajinan\Aks...  Aksesoris & Kerajinan
1  D:\img\UMKMno300data\Aksesoris & Kerajinan\Aks...  Aksesoris & Kerajinan
2  D:\img\UMKMno300data\Aksesoris & Kerajinan\Aks...  Aksesoris & Kerajinan
3  D:\img\UMKMno300data\Aksesoris & Kerajinan\Aks...  Aksesoris & Kerajinan
4  D:\img\UMKMno300data\Aksesoris & Kerajinan\Aks...  Aksesoris & Kerajinan
Labels
Aksesoris & Kerajinan    300
Makanan                  300
Minuman                  300
Pakaian                 300
Name: count, dtype: int64

```

Gambar 1. Proses pengorganisasian data

Proses selanjutnya membagi *DataFrame* menjadi tiga *subset*: *train\_df* untuk pelatihan (80%), *test\_df* untuk pengujian (10%), dan *valid\_df* untuk validasi (10%). *DataFrame* asli dibagi menjadi dua bagian, *train\_df* untuk pelatihan dan *dummy\_df* untuk sisa data, dengan data diacak untuk memastikan distribusi yang merata. Setelah proses pembagian, tahap selanjutnya menetapkan ukuran gambar yang akan diproses dan ukuran batch untuk pelatihan, validasi, dan pengujian. Menghitung ukuran *batch* terbaik untuk data pengujian, memastikan *batch* dapat diproses dengan efisien. Penggunaan model VGG16 *pre-trained* sebagai basis, tanpa lapisan *top*, dan dengan bobot yang dilatih pada dataset *ImageNet*, serta membekukan bobot model sehingga tidak diubah selama pelatihan model kita. Terdapat model *Sequential* yang dibangun dengan beberapa lapisan: *base\_model* (VGG16), *Flatten* untuk meratakan *output* dari *base\_model*, *Dense* dengan 128 unit dan aktivasi '*relu*', *Dropout* untuk mengurangi *overfitting*, dan *Dense* terakhir dengan jumlah unit sesuai jumlah kelas dan aktivasi '*softmax*' untuk klasifikasi. Mengompilasi model dengan *optimizer Adam*, *loss categorical\_crossentropy*, dan *matrix* akurasi untuk mengevaluasi performa model, kemudian melatih model menggunakan data pelatihan dan memvalidasi dengan data validasi, serta menyimpan hasil pelatihan dalam variabel *history*.

Tahap berikutnya adalah ekstraksi fitur yang dirancang untuk mengekstraksi fitur dari setiap gambar dalam dataset. Fungsi ini menerima parameter seperti *filepath* yang berisi daftar *path* gambar, model VGG16 yang telah di-pra-latih, fungsi pra-pemrosesan yang sesuai untuk model VGG16, dan *target size* yang dalam penelitian ini ditetapkan sebagai 128x128 piksel. Proses ekstraksi dimulai dengan memuat gambar, mengonversinya ke *array numpy*, dan menambahkan dimensi *batch* untuk memastikan kompatibilitas dengan model CNN. Setelah itu, gambar diproses melalui model VGG16 untuk mengekstraksi fitur-fitur dasar yang kemudian diratakan dan disimpan dalam daftar *features*. Fitur-fitur yang diekstraksi dari gambar-gambar ini disimpan dalam file *numpy* untuk kemudahan akses di masa depan atau penggunaan kembali, sementara *path* dan label gambar disimpan dalam file *pickle* menggunakan modul *pickle*.

Setelah fitur diekstraksi dan disimpan, tahap selanjutnya adalah proses pencarian gambar menggunakan fungsi *find\_similar\_images*. Fungsi ini bertujuan untuk menemukan gambar-gambar yang paling mirip dengan gambar query dalam dataset berdasarkan fitur yang diekstraksi oleh model VGG16. Proses ini melibatkan pengekstrakan fitur dari gambar query, menghitung kesamaan *Cosine Similarity* antara fitur gambar *query* dan fitur-fitur dalam dataset, serta mengurutkan hasil berdasarkan kesamaan dari yang tertinggi ke yang terendah. Parameter *ranking top 5* dibuat untuk menentukan bahwa hanya lima gambar dengan kesamaan tertinggi yang akan dipilih dan ditampilkan, memungkinkan fokus pada subset gambar yang paling relevan dalam konteks *query* yang diberikan. Hasil pencarian kemudian ditampilkan beserta nilai kemiripan dan labelnya, menunjukkan bahwa gambar *query* memiliki kemiripan tertinggi dengan beberapa gambar dalam dataset tertentu. Tahap terakhir dalam pengembangan model ini adalah menampilkan gambar *query* dan gambar serupa yang telah dihasilkan dalam bentuk visual.



Gambar 2. Visualisasi Model Visual Search

Proses pengembangan model ini memastikan bahwa fitur visual yang kaya dari dataset gambar UMKM dapat diekstraksi, disimpan, dan dianalisis dengan efisien, memungkinkan pencarian gambar serupa atau klasifikasi dengan lebih mudah dan akurat, serta mengoptimalkan sumber daya komputasi dan waktu



yang dibutuhkan untuk memproses dataset yang besar, memberikan dasar yang kuat untuk analisis visual yang mendalam dan akurat.

### 3.4. Pengujian dan Evaluasi Model

Pengujian dan evaluasi model dilakukan untuk memastikan bahwa model yang telah dikembangkan mampu beroperasi dengan efektivitas yang diharapkan. Proses pengujian dibagi menjadi 2 langkah, langkah pertama dilakukan terhadap model *Visual Search* dan langkah kedua terhadap klasifikasi *Tagging* produk. Untuk pencarian visual hal ini melibatkan penerapan model pada dataset uji yang belum pernah dilihat sebelumnya, guna menguji kemampuannya dalam menghadapi data nyata dan situasi aplikatif yang beragam. Sementara pada klasifikasi *Tagging* produk akan dilakukan dengan memunculkan hasil grafik yang menunjukkan *Loss* dan Akurasi selama pelatihan dan validasi, dan juga akurasi dari klasifikasi *Tagging* produk. Selain itu kedua model juga akan diuji menggunakan *Confusion Matrix* untuk mendapatkan nilai *Precision*, *Recall*, dan *F1 – Score*.

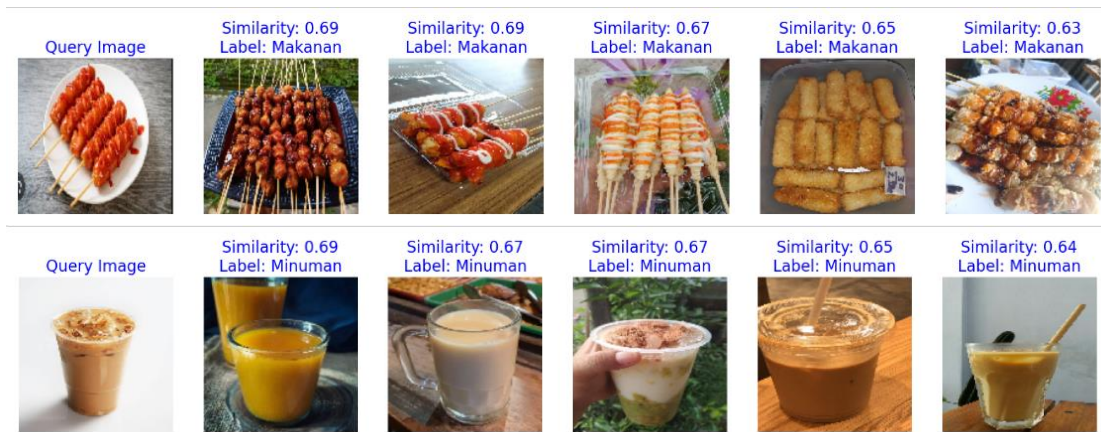
#### 3.4.1. Visual Search

Pengujian terhadap model *Visual Search* dilakukan di mana setiap fungsi dalam skrip akan diuji secara individual. Tujuan dari pengujian ini adalah untuk memverifikasi bahwa setiap fungsi beroperasi sesuai dengan harapan, menerima input yang valid, dan menangani kesalahan secara efisien. Kegiatan ini penting untuk menjamin keandalan dan stabilitas dari komponen-komponen model. Pengujian selanjutnya yaitu pengujian kinerja akan dilakukan untuk mengevaluasi waktu eksekusi skrip dalam memproses gambar dan mengekstraksi fitur. Evaluasi ini esensial untuk menentukan kemampuan skrip dalam mengelola volume data gambar yang besar dalam batas waktu yang cepat dan dapat diterima, aspek kritical untuk aplikasi di lingkungan produksi yang menuntut kecepatan dan efisiensi. Diakhiri dengan pengukuran keakuratan hasil menggunakan *Matrix Cosine Similarity* untuk menilai kemampuan model dalam menemukan gambar serupa dari data baru yang belum pernah dilihat sebelumnya.

Pengujian unit dilakukan untuk memverifikasi komponen model, mendeteksi kesalahan, dan memperbaikinya pada tahap awal dengan memberikan input valid dan memeriksa outputnya. Pengujian pertama fokus pada arsitektur model VGG16, memastikan struktur dan jumlah parameter yang benar (14.714.688 parameter). Pengujian kedua memverifikasi fungsi ekstraksi fitur, memastikan vektor fitur yang konsisten dan akurat. Pengujian ketiga menguji fungsi *find similar images*, memastikan kemampuan mengidentifikasi dan mengembalikan gambar serupa. Hasil menunjukkan bahwa model VGG16 efektif dalam mengidentifikasi pola visual dan struktur yang relevan, serta mampu mempertahankan performa meskipun ada variasi kecil dalam gambar input.

Pengujian kinerja dilakukan untuk mengukur waktu yang dibutuhkan dalam memproses gambar dan mengekstraksi fitur, memastikan skrip mampu menangani jumlah gambar besar dalam waktu singkat. Hal ini penting untuk platform pencarian visual seperti *Google Lens*, *Pinterest*, dan *Bing* yang melakukan pencarian secara *real-time*. Meski kemajuan signifikan telah dicapai dalam membangun sistem pencarian visual skala web, hanya ada sedikit publikasi yang menjelaskan dan mengungkapkan rincian teknis di balik sistem-sistem tersebut [15]. Jika proses terlalu lama, pengalaman pengguna akan menurun dan jumlah pengguna aktif bisa berkurang. Oleh karena itu, script harus cepat dan efisien. Pengujian dilakukan dengan dua model: model 1 menyimpan fitur yang diekstraksi, sementara model 2 mengekstraksi fitur setiap kali pencarian. Hasil pengujian menunjukkan bahwa model 1 lebih efisien dan cocok untuk platform pencarian visual karena kecepatan pencarian *real-time* dan manajemen data yang terstruktur.

Pengujian akurasi ini bertujuan untuk mengevaluasi kinerja dan kemampuan generalisasi model terhadap gambar yang tidak termasuk dalam dataset pelatihan, memastikan model tidak hanya unggul pada data yang dikenal tetapi juga mampu mengenali dan mengklasifikasikan gambar baru dengan akurasi tinggi. Pengujian dilakukan melalui beberapa skenario pencarian gambar menggunakan query yang berada diluar dataset dan juga berbeda terhadap semua kategori. Pengujian juga dilakukan sebanyak 3 kali terhadap masing – masing kategori untuk memastikan konsistensi dan keandalan model dalam mengenali gambar yang relevan dan tidak. Dibawah ini merupakan proses pengujian mulai dari pencarian gambar yang relevan dan tidak relevan, adapun tabel yang menunjukkan kriteria pencarian relevan dan tidak relevan, barulah setelah pengujian tersebut didefinisikan proses selanjutnya yaitu menghitung hasil TP, FP, TN, dan FN serta *Confusion Matrixnya* untuk kemudian menentukan hasil nilai *Precision*, *Recall*, dan *F1 – Score*.



Gambar 3. Hasil pengujian akurasi

Tabel 1. Indikator dan deskripsi untuk gambar pencarian visual

Indikator	Deskripsi
True Positive (TP)	Hasil pencarian yang benar-benar relevan sesuai dengan query. Misalnya untuk kategori makanan, gambar sosis atau sejenisnya muncul sebagai hasil pencarian untuk query "sosis" dan tampilan, label, serta bentuknya sesuai.
False Positive (FP)	Hasil pencarian yang salah namun dianggap relevan. Misalnya, gambar nasi pecel muncul sebagai hasil pencarian untuk query "sosis" tetapi bentuk dan tampilannya tidak sesuai
True Negative (TN)	Tidak relevan dan tidak muncul dalam pencarian. (Dalam penelitian ini, sulit untuk menentukan TN tanpa dataset negatif)
False Negative (FN)	Gambar relevan yang tidak muncul dalam hasil pencarian

Hasil dari masing-masing tabel *Confusion Matrix* dan perhitungan nilai *Precision*, *Recall*, dan *F1 Score* untuk setiap kategori makanan, minuman, pakaian, dan aksesoris akan digabungkan. Penggabungan ini dilakukan untuk memberikan gambaran komprehensif mengenai performa keseluruhan dari setiap arsitektur dalam mengklasifikasikan berbagai kategori. Selain menggabungkan tabel *Confusion Matrix* dan nilai perhitungan *Precision*, *Recall*, dan *F1 score* per kategori, juga dilakukan penghitungan penggabungan nilai *Precision*, *Recall*, dan *F1 Score* menggunakan metode *Macro Average*. Perhitungan ini bertujuan untuk memberikan pandangan keseluruhan mengenai performa setiap model tanpa mempengaruhi hasil oleh kategori dengan jumlah sampel yang berbeda. Dengan menggunakan *Macro Average*, nilai *Precision*, *Recall*, dan *F1 Score* dari setiap kategori dihitung secara rata-rata, sehingga menghasilkan satu nilai tunggal yang merepresentasikan kinerja model secara keseluruhan. Langkah ini penting untuk memberikan evaluasi yang adil dan merata bagi setiap model dalam tugas klasifikasi yang dilakukan.

Tabel 2. Confusion matrik VGG16

Kategori	TP
Makanan	12
Minuman	10
Pakaian	15
Aksesoris	14

Perhitungan *Macro Average* merupakan metode evaluasi performa model yang menghitung rata-rata nilai *precision*, *recall*, dan *F1 score* dari setiap kategori tanpa memperhitungkan proporsi jumlah sampel dalam setiap kategori. Dalam konteks ini, *Precision*, *Recall*, dan *F1 - score* dihitung untuk masing-masing kategori makanan, minuman, pakaian, aksesoris terlebih dahulu, kemudian nilai-nilai tersebut dirata-ratakan untuk mendapatkan satu nilai tunggal yang mewakili performa keseluruhan model. Metode ini digunakan untuk memberikan penilaian yang adil dan merata terhadap kinerja model pada setiap arsitektur.

$$\text{Macro Precision} = \frac{1}{N} \sum_i^n \text{Precision}_i \quad (1)$$

$$\text{Macro Recall} = \frac{1}{N} \sum_i^n \text{Recall}_i \quad (2)$$

$$\text{Macro Precision} = \frac{1}{N} \sum_i^n \text{F1 Score}_i \quad (3)$$

Setelah mendefinisikan rumus untuk macro precision, recall, dan f1 score, langkah selanjutnya adalah melakukan perhitungan nilai-nilai tersebut untuk mengetahui hasilnya.

#### 1. Macro Precision

$$\frac{1}{4} (0.8 + 0.67 + 1.0 + 0.93) = \frac{3.4}{4} = \mathbf{0.85} \quad (4)$$

#### 2. Macro Recall

$$\frac{1}{4} (1.0 + 1.0 + 1.0 + 1.0) = \frac{4.0}{4} = \mathbf{1.0} \quad (5)$$

#### 3. Macro F1-Score

$$\frac{1}{4} (0.89 + 0.80 + 1.0 + 0.96) = \frac{3.65}{4} = \mathbf{0.91} \quad (6)$$

### 3.4.2. Klasifikasi Tagging

Pengujian Klasifikasi *Tagging* produk akan dilakukan dengan memunculkan hasil grafik yang menunjukkan *Loss* dan Akurasi selama pelatihan dan validasi, serta akurasi dari klasifikasi *Tagging* produk. Selain itu, kedua model juga akan diuji menggunakan *Confusion Matrix* untuk mendapatkan nilai *Precision*, *Recall*, dan *F1-score*. Hasil grafik akan menampilkan perbandingan kinerja model pada dataset pelatihan dan validasi, mengilustrasikan bagaimana model mengoptimalkan parameter-parameter selama proses pelatihan dan seberapa baik model tersebut menggeneralisasi pada data yang tidak terlihat sebelumnya. *Confusion Matrix* akan memberikan gambaran mendetail tentang performa klasifikasi setiap kategori produk, memungkinkan identifikasi area di mana model mungkin memiliki kesulitan. Dari *Confusion Matrix*, kita dapat menghitung nilai *Precision* (ketepatan), *Recall* (daya tangkap), dan *F1-Score* (harmoni ketepatan dan daya tangkap) yang memberikan wawasan lebih mendalam tentang kinerja model di luar sekadar akurasi keseluruhan. Pengujian ini akan mengonfirmasi apakah model mampu melakukan tagging produk dengan tingkat keakuratan yang tinggi dan konsisten, serta apakah model dapat diterapkan pada data produk baru dalam skenario dunia nyata.

Grafik pertama menunjukkan bahwa *loss* pada data pelatihan dan validasi menurun seiring bertambahnya *epoch*. Grafik kedua menunjukkan akurasi pelatihan mencapai sekitar 98%, sedangkan akurasi validasi mencapai puncaknya sekitar 91% pada epoch ke-6 sebelum stabil. Model mencapai akurasi 89.17% pada set uji, menunjukkan performa yang baik pada data baru.



Gambar 4. Grafik *loss* dan *validation* klasifikasi *Tagging*

Untuk *Confusion Matrix* memberikan rincian tentang klasifikasi yang benar dan salah untuk setiap kategori produk sebagai berikut:

1. Aksesoris & Kerajinan: Dari 28 gambar, 22 diklasifikasikan dengan benar, dengan beberapa kesalahan klasifikasi menjadi Makanan, Minuman, dan Pakaian.
2. Makanan: Dari 28 gambar, 25 diklasifikasikan dengan benar, dengan beberapa kesalahan klasifikasi menjadi Aksesoris & Kerajinan dan Minuman.
3. Minuman: Dari 32 gambar, 29 diklasifikasikan dengan benar, dengan beberapa kesalahan klasifikasi menjadi Makanan.
4. Pakaian: Dari 32 gambar, 31 diklasifikasikan dengan benar, dengan satu kesalahan klasifikasi menjadi Aksesoris & Kerajinan.

		Confusion Matrix			
		Aksesoris & Kerajinan	Makanan	Minuman	Pakaian
Actual	Aksesoris & Kerajinan	22	1	3	2
	Makanan	1	25	2	0
	Minuman	0	3	29	0
	Pakaian	1	0	0	31
		Aksesoris & Kerajinan	Makanan	Minuman	Pakaian
		Predicted			

Gambar 5. Nilai *Confusion Matrix* untuk klasifikasi

Sedangkan untuk nilai *Precision*, *Recall*, dan *F1 – Score* menunjukkan hasil sebagai berikut:

1. *Precision*: Menunjukkan persentase prediksi benar dari total prediksi untuk setiap kelas. Nilainya cukup tinggi, menunjukkan model jarang salah dalam prediksi.
2. *Recall*: Menunjukkan persentase data sebenarnya yang diklasifikasikan dengan benar. Nilainya juga tinggi, menunjukkan model mampu mengidentifikasi sebagian besar gambar dengan benar.
3. *F1-Score*: Kombinasi dari *precision* dan *recall*, menunjukkan keseimbangan performa model. Nilainya tinggi di semua kelas, terutama pada kelas Pakaian yang mencapai 0.95.



Classification Report:

```

-----
              precision    recall  f1-score   support

Aksesoris & Kerajinan      0.92      0.79      0.85        28
  Makanan                  0.86      0.89      0.88        28
  Minuman                   0.85      0.91      0.88        32
  Pakaian                   0.94      0.97      0.95        32

   accuracy                   0.89        120
  macro avg                   0.89      0.89      0.89        120
 weighted avg                   0.89      0.89      0.89        120

```

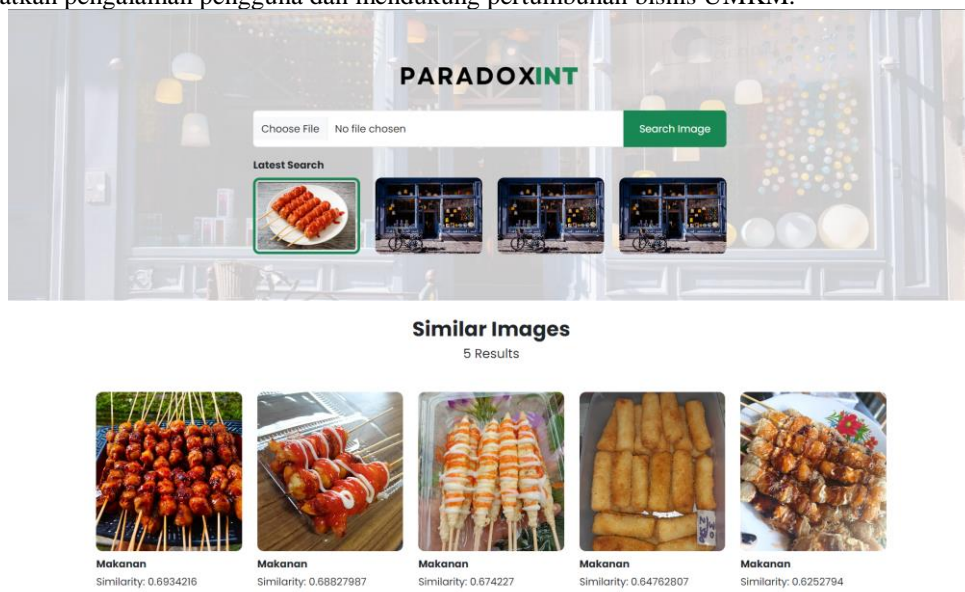
Gambar 6. Nilai *Precision*, *Recall*, dan *F1-Score* untuk klasifikasi *Tagging*

### 3.5. Deployment Model Platform

Tahap *Deployment* adalah bagian penting untuk menciptakan platform pencarian *visual*. *Deployment* model memastikan model dapat diakses oleh pengguna dan sistem tetap responsif. Proses *Deployment* menggunakan *framework Flask*, dengan dua fungsi utama: *visual search* sebagai antarmuka (*front end*) untuk pengguna UMKM dan *backend* untuk *admin* mengelola data produk dan *upload* produk. *Deployment* yang terstruktur memastikan model pencarian visual berfungsi dengan baik dan memberikan manfaat maksimal bagi pengguna.

#### 3.5.1. Frontend

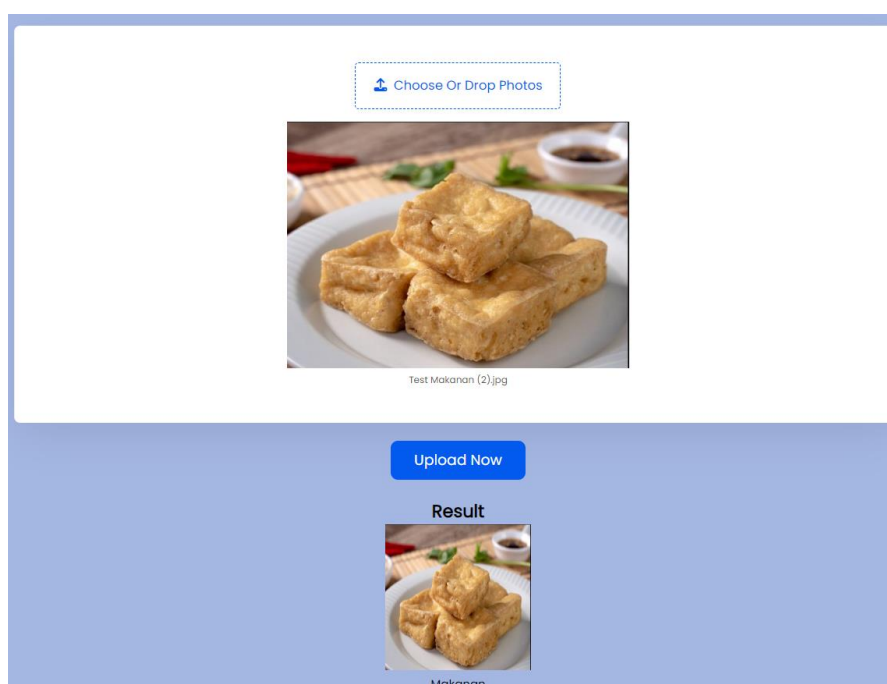
Antarmuka pengguna pada *frontend* platform *visual search* dirancang untuk memberikan pengalaman intuitif dan responsif, memungkinkan pengguna, khususnya *customer* UMKM, untuk mengunggah gambar dan mendapatkan hasil pencarian yang relevan berdasarkan konten *visual*, dengan hasil yang ditampilkan dalam bentuk grid beserta informasi seperti nilai *Cosine Similarity* dan label gambar, menggunakan teknologi web modern seperti *HTML*, *CSS*, dan *JavaScript* untuk memastikan tampilan menarik dan fungsionalitas optimal, serta mendukung fitur tambahan seperti melihat detail produk atau menambahkan ke keranjang belanja, guna meningkatkan pengalaman pengguna dan mendukung pertumbuhan bisnis UMKM.



Gambar 7. Tampilan front end platform visual search

#### 3.5.2. Backend

*Backend* dalam penelitian ini dirancang khusus untuk *owner* atau *admin* UMKM dalam mengelola *upload* produk, melakukan klasifikasi, dan tagging produk secara akurat menggunakan model klasifikasi dan metode *Cosine Similarity* untuk memastikan produk muncul dalam hasil pencarian visual pelanggan, sehingga meminimalkan kesalahan dan meningkatkan visibilitas produk di platform.



Gambar 8. Tampilan backend klasifikasi label

#### 4. KESIMPULAN

Penelitian ini berhasil mengatasi tantangan UMKM dalam mengelola inventaris dan meningkatkan pengalaman pelanggan melalui pengembangan dan implementasi platform pencarian visual berbasis *Convolutional Neural Network* (CNN), khususnya model VGG16. Hasil penelitian menunjukkan bahwa platform ini mampu mencapai akurasi klasifikasi sebesar 89.17% pada set uji, dengan *Macro Precision* 0.85, *Macro Recall* 1.0, dan *Macro F1-Score* 0.91. Pengujian juga menunjukkan bahwa model ini memiliki akurasi pelatihan sekitar 98% dan akurasi validasi mencapai puncaknya sekitar 91% pada epoch ke-6 sebelum stabil. Platform ini memungkinkan pengguna mengunggah gambar produk dan mendapatkan hasil pencarian yang akurat dengan cepat, membantu UMKM mengelola produk lebih efisien, mengurangi kesalahan pelabelan, serta menyediakan pengalaman pencarian yang interaktif dan memuaskan bagi pelanggan. Penggunaan gambar sebagai *query* meningkatkan kepuasan dan potensi penjualan, membuka peluang pengembangan lebih lanjut dalam *E-commerce* dan *Artificial Intelligence* (AI). Selain itu, penelitian ini menggarisbawahi pentingnya penelitian lebih luas yang mencakup pelaku UMKM berbasis kebudayaan lokal dan pengembangan model untuk korporasi guna menciptakan ekosistem e-commerce yang dinamis dan berkelanjutan.

#### UCAPAN TERIMA KASIH

Saya sebagai penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah mendukung dan membantu terlaksananya penelitian ini. Kepada dosen pembimbing saya, Bapak Arman Hakim Nasution, saya sangat berterima kasih atas bimbingan, arahan, dan dukungan yang diberikan selama proses penelitian ini. Tanpa bimbingan dan motivasi dari Bapak, penelitian ini tidak akan dapat diselesaikan dengan baik. Sebagai seorang mahasiswa, saya sangat menghargai kesempatan untuk belajar dan berkembang di bawah bimbingan yang luar biasa ini. Terima kasih atas segala ilmu dan pengalaman berharga yang telah saya peroleh.

#### REFERENSI

- [1] F. Saprianto, "Dilematis UMKM di Era Digital," *Scientific Journal of Reflection: Economic, Accounting, Management and Business*, vol. 3, no. 1, pp. 21-30, 2020.
- [2] N. Nurhidayati, S. Sugiyah, D. Syahyuni, and W. Wianti, "Merubah Tantangan Sebagai Peluang di Masa Pandemi Bagi Komunitas UMKM Naik Kelas Kota Bekasi," *Jurnal Abdimas Ekonomi dan Bisnis*, vol. 1, no. 1, pp. 6-11, 2021.
- [3] D. A. Diartono, Y. Suhari, and A. Supriyanto, "Pengembangan Model Cyber Cluster E-commerce Berbasis CMS dan SEO Produk UMKM," *IJCCS (Indonesian Journal of Computing and Cybernetics*

- Systems), vol. 9, no. 2, pp. 145-156, 2015.
- [4] E. Handayani, P. P. Sari, and M. J. Islami, "Pemanfaatan Teknologi Informasi dan Komunikasi (TIK) oleh UMKM pada Masa Pandemi COVID-19," *Jurnal Komunika: Jurnal Komunikasi, Media Dan Informatika*, vol. 10, no. 2, pp. 113-119, 2021.
- [5] S. Sugiono, "Tantangan dan peluang pemanfaatan augmented reality di perangkat mobile dalam komunikasi pemasaran," *Jurnal Komunika: Jurnal Komunikasi, Media Dan Informatika*, vol. 10, no. 1, pp. 1-12, 2021. [6] A. D. Dwivedi, G. Srivastava, S. Dhar, and R. Singh, "A decentralized privacy-preserving healthcare blockchain for IoT," *Sensors (Switzerland)*, vol. 19, no. 2, pp. 1-17, 2019, doi: 10.3390/s19020326.
- [6] A. Dagan, I. Guy, and S. Novgorodov, "An image is worth a thousand terms? analysis of visual e-commerce search," in *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2021, pp. 102-112.
- [7] Y. Zhang, P. Pan, Y. Zheng, K. Zhao, J. Wu, Y. Xu, and R. Jin, "Virtual ID discovery from E-commerce media at Alibaba: Exploiting richness of user click behavior for visual search relevance," in *Proceedings of the 28th ACM International Conference on Information and Knowledge Management*, 2019, pp. 2489-2497.
- [8] J. Li, H. Liu, C. Gui, J. Chen, Z. Ni, N. Wang, and Y. Chen, "The design and implementation of a real time visual search system on JD E-commerce platform," in *Proceedings of the 19th International Middleware Conference Industry*, 2018, pp. 9-16.
- [9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [10] F. Li, S. Kant, S. Araki, S. Bangera, and S. S. Shukla, "Neural networks for fashion image classification and visual search," *arXiv preprint arXiv:2005.08170*, 2020.
- [11] Y. Zhang, P. Pan, Y. Zheng, K. Zhao, Y. Zhang, X. Ren, and R. Jin, "Visual search at Alibaba," in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, pp. 993-1001.
- [12] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [13] W. S. E. Putra, "Klasifikasi citra menggunakan convolutional neural network (CNN) pada caltech 101," *Jurnal Teknik ITS*, vol. 5, no. 1, 2016.
- [14] B. Rohrer, "How convolutional neural networks work," *Data Science and Robot Blog*, 18 August 2016. [Online]. Available: [https://brohrer.github.io/how\\_convolutional\\_neural\\_networks\\_work.html](https://brohrer.github.io/how_convolutional_neural_networks_work.html)
- [15] Y. Jing, D. Liu, D. Kislyuk, A. Zhai, J. Xu, J. Donahue, and S. Tavel, "Visual search at Pinterest," in *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2015, pp. 1889-1898.