

## **Sistem Analisis Sentimen Ulasan Produk Tokopedia Menggunakan Metode VGG16 Untuk Prediksi Rekomendasi Produk Sesuai Minat Pengguna**

**Ndhoghal Rakasiwi Dhofisa<sup>1</sup>, Nur Azizah<sup>2\*</sup>, Rahmat Shofan Razaqi<sup>3</sup>**

<sup>1,2\*,3</sup> Program Studi Pendidikan Teknologi Informasi, STKIP PGRI Situbondo, Situbondo, Indonesia

<sup>1</sup>[ndhoghal1@gmail.com](mailto:ndhoghal1@gmail.com), <sup>2\*</sup>[nazizah0606@gmail.com](mailto:nazizah0606@gmail.com), <sup>3</sup>[fanslaught@gmail.com](mailto:fanslaught@gmail.com)

<sup>\*)</sup> [nazizah0606@gmail.com](mailto:nazizah0606@gmail.com)

**Abstract**–Tokopedia sebagai platform e-commerce menyediakan ulasan produk dalam jumlah besar yang berisi opini pengguna terhadap kualitas barang, layanan penjual, dan proses pengiriman. Ulasan ini dapat dimanfaatkan untuk menilai kepuasan pelanggan sekaligus menjadi sinyal penting dalam menyusun rekomendasi produk. Penelitian ini mengusulkan sistem analisis sentimen ulasan produk Tokopedia dengan pendekatan deep learning berbasis Convolutional Neural Network (CNN) menggunakan arsitektur VGG16. Untuk menyesuaikan VGG16 yang berorientasi citra terhadap data teks, ulasan teks dirender menjadi citra (text-to-image) berukuran 224×224, kemudian dilakukan transfer learning VGG16 untuk mengklasifikasikan sentimen menjadi positif, negatif, dan netral. Skor sentimen yang dihasilkan selanjutnya digabungkan dengan profil minat pengguna (kategori yang sering dilihat dan dibeli) untuk memprediksi rekomendasi produk yang lebih relevan. Tahapan sistem meliputi pengumpulan data, pelabelan sentimen, praproses, pembentukan citra ulasan, pelatihan model VGG16, serta evaluasi menggunakan confusion matrix dan metrik akurasi, presisi, recall, dan F1-score. Implementasi sistem diharapkan membantu pengguna menemukan produk yang sesuai minat dengan dukungan sentimen ulasan yang lebih objektif.

**Kata Kunci:** VGG16, Tokopedia, analisis sentimen, transfer learning, rekomendasi produk.

**Abstract**–Tokopedia, as an e-commerce platform, provides a large number of product reviews containing user opinions on product quality, seller service, and delivery processes. These reviews can be used to assess customer satisfaction and serve as important signals in developing product recommendations. This study proposes a Tokopedia product review sentiment analysis system using a deep learning approach based on Convolutional Neural Networks (CNN) using the VGG16 architecture. To adapt the image-oriented VGG16 to text data, text reviews are rendered into 224x224 images (text-to-image), then VGG16 transfer learning is performed to classify sentiment into positive, negative, and neutral. The resulting sentiment scores are then combined with user interest profiles (frequently viewed and purchased categories) to predict more relevant product recommendations. The system stages include data collection, sentiment labeling, preprocessing, review image formation, VGG16 model training, and evaluation using a confusion matrix and metrics such as accuracy, precision, recall, and F1-score. The system implementation is expected to help users find products that match their interests with the support of more objective review sentiment.

**Keywords:** VGG16, Tokopedia, sentiment analysis, transfer learning, product recommendations.

### **1. PENDAHULUAN**

Perkembangan e-commerce di Indonesia dalam beberapa tahun terakhir berlangsung sangat pesat dan menjadi salah satu penggerak utama ekonomi digital. Laporan e-Conomy SEA 2024 menegaskan bahwa sektor e-commerce masih menjadi kontributor besar dalam pertumbuhan ekonomi digital Asia Tenggara, termasuk Indonesia [1]. Di sisi lain, tingginya penggunaan internet dan perangkat mobile ikut memperkuat kebiasaan belanja serta interaksi masyarakat di platform digital. Laporan Digital 2024: Indonesia menunjukkan jumlah koneksi seluler aktif dan pengguna media sosial yang besar, sehingga aktivitas transaksi dan pemberian umpan balik di marketplace juga semakin meningkat [2],[3].

Tokopedia sebagai salah satu marketplace populer menyediakan fitur rating dan ulasan yang merekam pengalaman pengguna setelah melakukan pembelian. Ulasan ini penting karena berisi penilaian nyata terkait kesesuaian produk, kualitas barang, kecepatan pengiriman, dan layanan penjual. Namun, volume ulasan yang sangat banyak membuat pembacaan dan penyimpulan secara manual menjadi tidak efisien, sehingga diperlukan pendekatan otomatis untuk mengolah opini pengguna [4]. Untuk kebutuhan tersebut, analisis sentimen digunakan


sebagai teknik untuk mengidentifikasi kecenderungan opini dalam teks, misalnya positif, dan negatif. Tinjauan sistematis terbaru menjelaskan bahwa analisis sentimen banyak diterapkan pada data ulasan online karena mampu merangkum persepsi pengguna secara cepat, sekaligus membantu pemangku kepentingan memahami kualitas produk/layanan [5],[6].

Selain mendukung evaluasi penjual, hasil analisis sentimen juga dapat dimanfaatkan untuk meningkatkan sistem rekomendasi. Secara umum, sistem rekomendasi bertujuan membantu pengguna menemukan item yang relevan di tengah banyaknya pilihan (Ricci, Rokach & Shapira, 2022). Namun, rekomendasi berbasis preferensi saja belum tentu menonjolkan produk yang kualitasnya baik. Karena itu, sentimen ulasan dapat menjadi sinyal tambahan untuk memperkuat rekomendasi, misalnya dengan menggabungkan informasi sentimen ke dalam model rekomendasi kolaboratif [7],[8]. Pada sisi metodologi, deep learning semakin sering digunakan karena kemampuannya mempelajari pola yang kompleks. Transfer learning menjadi strategi yang efektif ketika data pelatihan terbatas, yaitu dengan memanfaatkan model yang telah dilatih pada dataset besar lalu disesuaikan untuk tugas baru (Tan dkk., 2018). Kemudian ada Tiga model yang dilatih: model BERT dasar, hibrida BERT-CNN, dan hibrida BERT-LSTM. Kinerja model dinilai menggunakan akurasi, presisi, recall, dan skor F1. Dalam penelitian ini, VGG16 Convolutional Neural Network (CNN) untuk ekstraksi fitur dan algoritma YOLO (You Only Look Once) untuk deteksi dan klasifikasi objek secara real-time. digunakan melalui skema transfer learning untuk memprediksi sentimen ulasan. Implementasi VGG16 juga tersedia pada pustaka Keras dan TensorFlow sehingga memudahkan penggunaan model pra-latih [9],[10].

Karena VGG16 merupakan CNN untuk data citra, penelitian ini mengadopsi pendekatan text-to-image, yaitu mengubah ulasan teks menjadi representasi visual agar dapat diproses sebagai input gambar. Konsep ini sejalan dengan metode Super Characters yang mengonversi tugas klasifikasi sentimen menjadi klasifikasi citra dengan cara memproyeksikan teks ke dalam bentuk gambar, kemudian memanfaatkan CNN untuk prediksi label sentimen. Model algoritma VGG16 yang dilakukan melalui evaluasi matriks kebingungan, tapi setelah pengujian ulang yang dilakukan dengan VGG16 terbukti bahwa pengujian yang dilakukan oleh algoritma VGG16 memiliki nilai akurasi yang tinggi. [11],[12]. Berdasarkan permasalahan tersebut, penelitian ini berfokus pada pengembangan sistem rekomendasi produk berbasis analisis sentimen yang mengintegrasikan model deep learning dan machine learning. Sistem yang dikembangkan mampu melakukan klasifikasi sentimen terhadap ulasan produk Tokopedia serta memanfaatkan hasil analisis tersebut bersama preferensi pengguna untuk menghasilkan rekomendasi produk yang lebih relevan. Untuk mencapai tujuan tersebut, penelitian ini menggunakan Dua arsitektur CNN, InceptionV3 dan ResNet-50, digunakan dalam proses pelatihan, diikuti oleh pemilihan fitur menggunakan metode Chi-Square dan klasifikasi menggunakan algoritma Random Forest, sekaligus mempertimbangkan kualitas produk berdasarkan opini pengguna lain. Harapannya, sistem ini dapat memudahkan pengguna menemukan produk yang relevan dan berkualitas, serta membantu penjual memahami kelebihan dan kekurangan produknya melalui umpan balik konsumen.[13],[14]


## 2. METODOLOGI PENELITIAN

Metode penelitian yang digunakan pada penelitian ini terdiri atas beberapa tahapan utama yang dilakukan secara sistematis untuk membangun sistem analisis sentimen ulasan produk Tokopedia berbasis VGG16. Tahapan penelitian dimulai dari proses pengumpulan dataset ulasan produk Tokopedia, kemudian dilanjutkan dengan proses pelabelan sentimen berdasarkan rating ulasan. Setelah itu dilakukan tahap praproses teks yang meliputi case folding, cleaning, normalisasi kata, stopword removal, dan stemming untuk menghasilkan data teks yang lebih bersih dan konsisten. Selanjutnya, data teks ulasan dikonversi menjadi citra menggunakan pendekatan text-to-image agar dapat diproses oleh model Convolutional Neural Network (CNN) VGG16. Citra hasil konversi kemudian digunakan sebagai input pada proses pelatihan model dengan metode transfer learning menggunakan arsitektur VGG16 pretrained ImageNet. Pada tahap pelatihan dilakukan proses freezing layer dan fine-tuning untuk meningkatkan kemampuan model dalam mengenali pola sentimen pada ulasan produk. Setelah model selesai dilatih, dilakukan tahap evaluasi menggunakan confusion matrix serta metrik accuracy, precision, recall, dan F1-score untuk mengetahui performa model dalam mengklasifikasikan sentimen positif dan negatif. Hasil analisis sentimen selanjutnya dimanfaatkan dalam sistem rekomendasi produk dengan mempertimbangkan minat pengguna berdasarkan kategori produk yang sering dilihat maupun dibeli. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



**Gambar 1.** Alur tahapan penelitian sistem analisis sentimen menggunakan VGG16

## 2.1 Pengumpulan data ulasan



**Gambar 2.** Dataset ulasan produk Tokopedia yang digunakan pada penelitian

Jika ada kolom yang tidak tersedia (misalnya foto), maka penelitian tetap berjalan dengan kolom yang ada, dan bisa menambah fitur turunan seperti panjang ulasan atau jumlah kata bila diperlukan.[16],[17]. Gambar 2 menggambarkan bahwa data yang digunakan berasal dari dataset ulasan Tokopedia yang tersedia di Kaggle. Dataset Kaggle dipilih karena formatnya umumnya sudah rapi (misalnya CSV), sehingga lebih cepat diproses dan mudah diulang oleh peneliti lain. Dataset yang digunakan terdiri dari 3.000 komentar Tokopedia yang dikumpulkan melalui proses Kaggle[15].

Dataset yang digunakan pada penelitian ini berupa data ulasan produk Tokopedia yang diperoleh dari platform Kaggle. Dataset berisi ulasan pengguna terhadap berbagai kategori produk beserta rating yang diberikan pengguna. Data ulasan digunakan sebagai sumber utama dalam proses analisis sentimen untuk menentukan polaritas sentimen positif dan negatif. Pada penelitian ini, pelabelan sentimen dilakukan berdasarkan rating ulasan pengguna. Ulasan dengan rating tinggi dikategorikan sebagai sentimen positif, sedangkan ulasan dengan rating rendah dikategorikan sebagai sentimen negatif. Setelah proses pelabelan

selesai, data kemudian melalui tahap praproses teks untuk membersihkan karakter yang tidak diperlukan sebelum digunakan pada proses pelatihan model VGG16.

## 2.2 Pelebelan sentimen

Agar pelabelan lebih jelas dan sederhana, penelitian ini menggunakan skema label biner yang hanya terdiri dari dua kelas, yaitu positif dan negatif. Penentuan label dilakukan secara otomatis berdasarkan nilai rating, di mana rating 4 hingga 5 dikategorikan sebagai sentimen positif, sedangkan rating 1 hingga 2 dikategorikan sebagai sentimen negatif. Adapun ulasan dengan rating 3 tidak diikutsertakan dalam dataset karena dinilai ambigu, mengingat rating tersebut dapat mencerminkan sentimen netral maupun campuran yang sulit dikategorikan secara tegas.

Setelah label otomatis terbentuk berdasarkan rating, dilakukan validasi manual pada sebagian sampel dari masing-masing kelas. Langkah ini bertujuan untuk mengurangi kesalahan label yang muncul ketika isi teks ulasan tidak sesuai dengan rating yang diberikan, misalnya ketika pengguna memberikan rating tinggi namun isi ulasannya justru berisi keluhan. Apabila ditemukan ketidaksesuaian semacam itu, data dapat diperbaiki labelnya atau dikeluarkan dari data latih agar tidak menambah noise yang dapat memengaruhi performa model klasifikasi [13],[16].

## 2.3 Praproses dan Konversi Text-to-Image

Pada tahap praproses dan konversi text-to-image, seluruh proses dijalankan di Google Colab karena platform tersebut menyediakan lingkungan notebook berbasis cloud yang praktis untuk eksperimen machine learning dan dapat memanfaatkan akselerasi komputasi seperti GPU/TPU jika dibutuhkan [18],[19].

Proses praproses teks mencakup beberapa tahapan yang dilakukan secara berurutan. Pertama, case folding dilakukan untuk mengubah seluruh huruf menjadi huruf kecil. Selanjutnya, tahap cleaning menghapus tanda baca, karakter aneh, URL, dan spasi berlebih. Kemudian dilakukan normalisasi untuk menyamakan kata tidak baku atau slang berdasarkan kamus yang tersedia. Setelah itu, stopwords removal digunakan untuk menghapus kata-kata umum yang tidak banyak berkontribusi pada analisis, seperti "yang", "dan", dan "di". Terakhir, stemming diterapkan untuk mengubah kata menjadi bentuk dasarnya menggunakan library seperti Sastrawi, disesuaikan dengan kebutuhan analisis.

Agar teks ulasan dapat diproses oleh VGG16 yang merupakan model berbasis CNN, teks dikonversi menjadi gambar melalui beberapa langkah. Proses dimulai dengan membuat kanvas putih, kemudian teks ulasan dituliskan menggunakan font monokrom dengan tata letak yang konsisten, seperti rata kiri dan ukuran font tetap. Hasil gambar kemudian di-resize menjadi 224×224 piksel sesuai standar input VGG16. Apabila teks ulasan terlalu panjang, diterapkan fitur auto wrap agar teks tetap muat dan terbaca dalam kanvas [20].

Setelah seluruh gambar ulasan terbentuk, dataset citra diunggah ke Roboflow untuk dikelola lebih lanjut. Melalui platform ini, dataset disimpan secara lebih terstruktur, dilakukan versioning, serta pembagian data menjadi subset train, validation, dan test. Selain itu, augmentasi ringan dapat diterapkan secara opsional dengan tetap menjaga keterbacaan gambar. Dataset yang telah dikelola di Roboflow kemudian diekspor kembali ke Google Colab untuk digunakan pada proses pelatihan model VGG16 [21],[22].

## 2.4 Arsitektur dan Pelatihan VGG16

Pada tahap arsitektur dan pelatihan, model yang digunakan adalah VGG16 dengan bobot pretrained dari ImageNet. Karena VGG16 telah dilatih pada dataset berskala besar, model ini sudah memiliki kemampuan dasar untuk menangkap pola visual, sehingga dapat disesuaikan lebih lanjut untuk keperluan klasifikasi sentimen dari citra ulasan.

Struktur model yang dibangun terdiri dari dua bagian utama. Bagian pertama adalah VGG16 convolutional base yang berfungsi sebagai feature extractor untuk mengambil representasi visual dari citra ulasan. Bagian kedua adalah classifier baru yang menggantikan bagian atas model asli, terdiri dari lapisan pooling atau flatten, dense layer dengan jumlah neuron tertentu seperti 256 atau 512, dropout untuk mencegah overfitting, serta output layer dengan dua kelas keluaran yaitu positif dan negatif menggunakan fungsi aktivasi softmax.

Proses pelatihan dilakukan dalam dua tahap secara bertahap agar model dapat berkembang secara stabil. Pada tahap pertama, seluruh layer konvolusi dibekukan sehingga hanya classifier baru yang dilatih. Tujuan dari tahap ini adalah agar model dapat belajar mengenali pola pada citra ulasan tanpa merusak bobot pretrained yang

sudah ada. Pada tahap kedua dilakukan fine-tuning, yaitu dengan membuka beberapa layer atas VGG16 dan melatihnya kembali menggunakan learning rate yang lebih kecil. Tahap ini bertujuan agar model menjadi lebih adaptif terhadap pola visual yang dihasilkan dari proses konversi text-to-image.

Seluruh proses pelatihan dilaksanakan di Google Colab dengan memanfaatkan dataset yang telah diekspor dari Roboflow, mencakup subset train, validation, dan test. Pelatihan dikonfigurasi menggunakan parameter umum seperti batch size, jumlah epoch, serta optimizer seperti Adam. Model terbaik yang dihasilkan selama pelatihan kemudian disimpan, misalnya ke Google Drive, untuk keperluan evaluasi dan penggunaan lebih lanjut.


## 2.5 Evaluasi

Evaluasi dilakukan untuk mengukur seberapa baik model dalam mengklasifikasikan sentimen dari citra ulasan. Karena klasifikasi yang dilakukan bersifat biner dengan dua kelas yaitu positif dan negatif, evaluasi menggunakan beberapa metrik yang umum digunakan dalam tugas klasifikasi. Metrik tersebut meliputi confusion matrix berukuran  $2 \times 2$ , accuracy untuk mengukur proporsi prediksi yang benar secara keseluruhan, precision untuk menilai ketepatan prediksi pada masing-masing kelas, recall untuk mengukur seberapa banyak data dari kelas tertentu berhasil diidentifikasi dengan benar, serta F1-score sebagai gabungan dari precision dan recall yang lebih stabil digunakan ketika distribusi data tidak seimbang antar kelas.

Pembagian data untuk keperluan evaluasi dapat dilakukan dengan dua pendekatan, yaitu train-test split dengan rasio seperti 80:20, atau k-fold cross validation apabila diinginkan hasil evaluasi yang lebih stabil dan representatif. Output evaluasi yang dilaporkan mencakup tabel confusion matrix, tabel metrik yang memuat nilai accuracy, precision, recall, dan F1-score, serta secara opsional grafik learning curve yang menggambarkan perkembangan akurasi dan loss pada data train maupun validasi selama proses pelatihan berlangsung [23].

## 3. HASIL DAN PEMBAHASAN

### 3.1 Perancangan Sistem




**Gambar 3.** Diagram blok sistem analisis sentimen

Gambar 3 merupakan Proses kerja Sistem Analisis Sentimen Ulasan Produk Tokopedia dimulai ketika sistem mengambil data ulasan (review) dari produk Tokopedia (misalnya melalui dataset hasil crawling/ekspor yang sudah disiapkan). Setiap ulasan terdiri atas teks ulasan, rating, serta metadata produk (kategori, nama toko, harga, dan lain-lain). Data ulasan kemudian melalui tahap pra-pemrosesan untuk membersihkan noise seperti simbol berlebih, emotikon tertentu, tautan, kata tidak baku, dan pengulangan karakter. Agar dapat diproses

menggunakan VGG16, teks ulasan diubah menjadi representasi berbentuk citra (text-to-image) menggunakan skema encoding tertentu (misalnya: render teks menjadi gambar grayscale berukuran tetap, atau encoding karakter ke matriks 2D). Selanjutnya citra ulasan dinormalisasi dan diubah ukurannya ke dimensi input standar VGG16 (misalnya 224×224). Model VGG16 transfer learning digunakan sebagai ekstraktor fitur, lalu ditambahkan lapisan klasifikasi (fully-connected) untuk memprediksi kelas sentimen, misalnya positif, negatif.

Output sentimen dari ulasan kemudian digabungkan dengan sinyal minat pengguna (misalnya histori klik, kategori favorit, produk yang sering dilihat/di-keranjang, atau preferensi kata kunci). Sistem menghitung skor rekomendasi untuk menyarankan produk yang paling sesuai dengan minat pengguna, dengan mempertimbangkan sentimen ulasan (produk dengan sentimen dominan negatif dapat diturunkan peringkatnya).

### 3.2 Perancangan Perangkat Keras



**Gambar 4.** Arsitektur implementasi sistem


Berbeda dengan sistem embedded, gambar 4 meruapakan rancangan perangkat keras pada penelitian ini berorientasi pada komputasi data. Infrastruktur yang digunakan dapat berupa laptop atau PC untuk keperluan pelatihan model, serta server baik lokal maupun berbasis cloud untuk proses deployment. Komponen utama yang dibutuhkan meliputi perangkat komputasi berupa CPU atau GPU, media penyimpanan dataset seperti SSD atau HDD, koneksi jaringan untuk pengambilan data dan penyampaian hasil rekomendasi, serta antarmuka pengguna berupa web atau mobile dashboard untuk menampilkan rekomendasi kepada pengguna akhir.

Apabila sistem diimplementasikan sebagai sebuah layanan, model yang telah selesai dilatih disimpan dalam bentuk model inference dan diakses melalui API. Dengan pendekatan ini, aplikasi dapat mengajukan permintaan prediksi sentimen maupun rekomendasi secara real-time tanpa perlu menjalankan ulang proses pelatihan, sehingga sistem dapat beroperasi secara efisien dan responsif dalam melayani pengguna.

### 3.3 Diagram Skematik Arsitektur Sistem

Rancangan arsitektur sistem menunjukkan hubungan antar modul:


- 1) Modul Akuisisi Data: mengambil ulasan produk Tokopedia dari dataset.
- 2) Modul Preprocessing: pembersihan teks, normalisasi, dan konversi text-to-image.
- 3) Modul Klasifikasi Sentimen (VGG16): inferensi sentimen (positif/negatif).
- 4) Modul Profil Minat Pengguna: membentuk preferensi kategori/fitur produk berdasarkan histori.
- 5) Modul Rekomendasi: menggabungkan sentimen + preferensi pengguna untuk menyusun ranking produk.
- 6) Modul Output: menampilkan rekomendasi (Top-N produk) dan ringkasan sentimen.



**Gambar 5.** Diagram skematik arsitektur sistem

Gambar 5 merupakan alur sistem yang dimulai dari Data Store yang menyimpan dataset ulasan dan histori pengguna. Data ulasan diproses melalui Modul Akuisisi Data, kemudian dilakukan preprocessing sebelum masuk ke Modul Klasifikasi Sentimen (VGG16) untuk menentukan sentimen positif atau negatif. Sementara itu, histori pengguna dianalisis melalui Modul Profil Minat Pengguna untuk memperoleh preferensi pengguna. Hasil klasifikasi sentimen dan profil pengguna kemudian digabungkan pada Modul Rekomendasi untuk melakukan perankingan, hingga menghasilkan Top-N rekomendasi beserta ringkasan sentimen sebagai keluaran akhir sistem.

### 3.4 Perancangan Perangkat Lunak



**Gambar 6.** Tampilan integrasi preprocessing dan VGG16

Gambar 6 merupakan perancangan perangkat lunak mencakup pipeline lengkap mulai dari pengolahan data hingga menghasilkan rekomendasi. Implementasi umumnya menggunakan bahasa pemrograman Python dengan dukungan pustaka pembelajaran mendalam seperti TensorFlow/Keras atau PyTorch.

Tahap pertama dalam pipeline perangkat lunak adalah praproses teks ulasan, yang meliputi case folding, cleaning, normalisasi kata, stopword removal, serta padding atau truncation pada tahap render agar ukuran input tetap konsisten. Setelah teks diproses, dilakukan konversi text-to-image di mana setiap ulasan dirender menjadi gambar dua dimensi dengan ukuran tetap sebagai masukan bagi model.

Tahap kedua adalah pembangunan model VGG16 dengan pendekatan transfer learning. Model memanfaatkan bobot pralatih dari ImageNet sebagai feature extractor, kemudian ditambahkan head classifier yang terdiri dari lapisan Dense, Dropout, dan Softmax untuk keperluan klasifikasi sentimen. Selain itu, dilakukan fine-tuning pada lapisan-lapisan tertentu guna meningkatkan akurasi model pada domain ulasan e-commerce yang memiliki karakteristik tersendiri.

Tahap ketiga adalah pembuatan skor rekomendasi produk. Sistem menghasilkan skor rekomendasi dengan menggabungkan dua komponen utama, yaitu skor sentimen produk yang diperoleh dari agregasi hasil prediksi sentimen seluruh ulasan pada produk tersebut, serta skor kesesuaian dengan minat pengguna yang didasarkan pada histori, fitur, maupun kategori produk yang relevan. Kombinasi kedua komponen ini memungkinkan sistem menghasilkan rekomendasi yang tidak hanya relevan secara preferensi, tetapi juga mempertimbangkan kualitas produk berdasarkan sentimen pengguna lain.

### 3.5 Hasil Pengujian

Pengujian dilakukan untuk memastikan sistem mampu: (1) memprediksi sentimen ulasan secara akurat, dan (2) menghasilkan rekomendasi produk yang relevan dengan minat pengguna.

#### 1. Pengujian Pra-pemrosesan dan Representasi Text-to-Image

Tahap ini mengevaluasi konsistensi input citra yang dihasilkan dari ulasan teks, misalnya semua citra memiliki ukuran seragam (224×224), intensitas piksel ternormalisasi, informasi kata/kalimat tetap terbaca oleh model (tidak terlalu terpotong). Normalisasi input citra dapat ditulis secara umum (misal skala 0–1):

$$X' = \frac{X}{255} \quad X' = 255X$$

dengan XXX adalah nilai piksel asli dan X'X'X' piksel hasil normalisasi.

**Tabel 1.** Ringkasan pengecekan output preprocessing (Text-to-Image)

| Aspek yang Dicek                                        | Target/Kriteria               | Hasil Pengujian (Contoh)    | Status |
|---------------------------------------------------------|-------------------------------|-----------------------------|--------|
| Ukuran citra                                            | 224 × 224 piksel              | 100% (120/120) sesuai       | ✓      |
| Format kanal warna                                      | 3 kanal (RGB)                 | 100% (120/120) RGB          | ✓      |
| Rentang nilai piksel (sebelum normalisasi)              | 0–255                         | min=0, max=255              | ✓      |
| Normalisasi piksel                                      | Skala 0–1 ( $X' = X/255$ )    | min=0.000, max=1.000        | ✓      |
| Rata-rata & simpangan baku piksel (setelah normalisasi) | Stabil (tidak ekstrem)        | mean=0.46, std=0.21         | ✓      |
| Keterbacaan teks                                        | Tidak terpotong, font terbaca | 92% (110/120) terbaca       | ⚠      |
| Persentase area teks vs latar                           | Proporsional (mis. 30–70%)    | 35–65%                      | ✓      |
| Panjang ulasan vs tingkat pemotongan                    | Pemotongan minimal            | 8% ulasan panjang terpotong | ⚠      |
| Konsistensi padding/margin                              | Seragam                       | 100% konsisten              | ✓      |
| Deteksi noise/artefak                                   | Tidak ada noise signifikan    | 0 kasus artefak berat       | ✓      |

## 2. Pengujian Klasifikasi Sentimen Menggunakan VGG16

Pengujian klasifikasi sentimen dilakukan menggunakan data latih dan data uji yang telah diberi label (positif/netral/negatif). Evaluasi umumnya memakai metrik: akurasi, precision, recall, dan F1-score.

Rumus metrik (klasifikasi):

- 1) **Akurasi:**  $Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$   
Accuracy=TP+TN+FP+FN
- 2) **Precision:**  $Precision = \frac{TP}{TP + FP}$   
Precision=TP+FP
- 3) **Recall:**  $Recall = \frac{TP}{TP + FN}$   
Recall=TP+FN
- 4) **F1-score:**  $F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$   
F1=2·Precision+Recall

(A) Laporan metrik per kelas (test set)

| Kelas        | Precision | Recall | F1-Score | Support (Test) |
|--------------|-----------|--------|----------|----------------|
| Negatif (-1) | 1.0000    | 0.9412 | 0.9697   | 85             |
| Positif (1)  | 0.9412    | 1.0000 | 0.9697   | 80             |

(B) Ringkasan metrik keseluruhan

| Metrik             | Nilai           |
|--------------------|-----------------|
| Accuracy           | 0.9697 (96.97%) |
| Macro Precision    | 0.9706          |
| Macro Recall       | 0.9706          |
| Macro F1-Score     | 0.9697          |
| Weighted Precision | 0.9715          |
| Weighted Recall    | 0.9697          |
| Weighted F1-Score  | 0.9697          |

**Gambar 8.** Hasil pengujian klasifikasi sentiment

Berdasarkan hasil evaluasi pada gambar 8, model klasifikasi sentimen menunjukkan performa yang sangat baik pada data pengujian. Kelas Negatif (-1) memperoleh *precision* sebesar 1.0000, *recall* 0.9412, dan *F1-score* 0.9697, sedangkan kelas Positif (1) memperoleh *precision* 0.9412, *recall* 1.0000, dan *F1-score* 0.9697. Secara keseluruhan, model mencapai accuracy sebesar 96.97% dengan nilai macro F1-score 0.9697 dan weighted F1-score 0.9697. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan sentimen positif dan negatif secara seimbang dengan tingkat kesalahan yang sangat rendah.

Apabila ditemukan kesalahan klasifikasi dalam hasil evaluasi model, pembahasan umumnya mengarah pada beberapa faktor penyebab yang umum dijumpai dalam analisis sentimen. Faktor-faktor tersebut antara lain keberadaan ulasan ambigu yang memuat pujian sekaligus keluhan dalam satu kalimat, penggunaan ironi atau sarkasme yang sulit dikenali oleh model, kata negasi seperti "tidak bagus" atau "nggak jelek" yang dapat membalik makna kalimat, serta ketidakseimbangan data di mana jumlah sampel pada kelas tertentu jauh lebih banyak dibandingkan kelas lainnya.

Untuk mengatasi permasalahan tersebut, terdapat beberapa langkah optimasi yang dapat diterapkan. Pertama, menambah variasi data latih khususnya untuk ulasan-ulasan yang bersifat ambigu agar model lebih terbiasa mengenali pola tersebut. Kedua, melakukan balancing dataset melalui teknik undersampling atau oversampling guna menyeimbangkan distribusi antar kelas. Ketiga, melakukan fine-tuning pada layer VGG16 secara lebih mendalam untuk meningkatkan kemampuan model dalam mengekstraksi fitur yang relevan. Keempat, menerapkan augmentasi pada proses text-to-image melalui variasi font atau spacing yang terkontrol agar model lebih robust terhadap perbedaan tampilan visual ulasan. Kelima, melakukan eksperimen terhadap hyperparameter seperti learning rate, batch size, serta teknik regularisasi seperti dropout dan weight decay untuk menemukan konfigurasi yang menghasilkan performa terbaik.


### 3. Pengujian Modul Rekomendasi Produk Sesuai Minat Pengguna

Setelah sentimen diprediksi, sistem membentuk skor rekomendasi. Salah satu contoh skema (silakan sesuaikan) adalah:  $\text{Score}(p,u) = \alpha \cdot \text{Interest}(p,u) + (1-\alpha) \cdot \text{Sentiment}(p)$

Keterangan:

- 1)  $\text{Score}(p,u)$  = skor produk ppp untuk pengguna uu
- 2)  $\text{Interest}(p,u)$  = kesesuaian fitur produk dengan minat pengguna
- 3)  $\text{Sentiment}(p)$  = agregasi sentimen produk dari ulasan
- 4)  $\alpha$  = bobot (0–1) untuk menyeimbangkan preferensi vs sentimen

Advanced Training Graphs



**Gambar 9.** Grafik hasil pelatihan model

Berdasarkan grafik Advanced Training Graphs, proses pelatihan model menunjukkan konvergensi yang baik. Nilai training loss (box loss, classification loss, dan distribution focal loss) mengalami penurunan secara bertahap hingga akhir epoch, yang menunjukkan bahwa model semakin mampu mempelajari pola dari data pelatihan. Nilai validation loss juga cenderung menurun, sehingga menunjukkan kemampuan generalisasi model yang baik dan tidak mengalami *overfitting* yang signifikan.

Pada metrik evaluasi, nilai precision, recall, mAP50, dan mAP50-95 mengalami peningkatan selama proses training hingga mencapai kondisi stabil. Hal ini menunjukkan bahwa model mampu mendeteksi objek dengan tingkat ketepatan dan konsistensi yang baik. Secara keseluruhan, grafik menunjukkan bahwa model berhasil melakukan proses pembelajaran secara optimal dengan performa deteksi yang stabil pada data pelatihan maupun validasi.

### 3.6 Pengujian pada Pengguna

Pada bagian ini disajikan hasil uji coba sistem rekomendasi kepada pengguna (misalnya responden/pengguna uji) untuk menilai aspek kegunaan, relevansi rekomendasi, dan kepuasan. Tabel 2 merupakan kegiatan pengujian sistem rekomendasi pada pengguna.

**Tabel 2.** Data hasil pengujian pada pengguna

| Pengguna   | Skenario                | Hasil          | Keterangan                                                      |
|------------|-------------------------|----------------|-----------------------------------------------------------------|
| Pengguna 1 | Mencari produk skincare | Berhasil       | Rekomendasi sesuai kategori favorit dan ulasan dominan positif  |
| Pengguna 2 | Mencari headset         | Cukup berhasil | Relevan, namun beberapa produk masuk karena histori belum cukup |

Masukan pengguna umumnya berkaitan dengan transparansi alasan rekomendasi (kenapa produk ini direkomendasikan), filter tambahan (harga, lokasi, rating minimal), kebutuhan personalisasi yang lebih detail.

### 3.7 Analisis Keunggulan Sistem

Berdasarkan hasil implementasi dan pengujian, sistem yang dibangun memiliki beberapa keunggulan yang layak digarisbawahi. Pertama, integrasi sentimen ke dalam sistem rekomendasi menjadikan sistem ini tidak hanya mengandalkan histori minat pengguna, tetapi juga mempertimbangkan kualitas persepsi publik melalui sentimen ulasan. Pendekatan ini membuat rekomendasi yang dihasilkan lebih dapat dipercaya dan meminimalkan kemungkinan produk dengan dominasi ulasan negatif ikut direkomendasikan kepada pengguna. Kedua, penggunaan transfer learning berbasis VGG16 memungkinkan model belajar lebih cepat dibandingkan melatih arsitektur CNN dari awal, sekaligus cenderung menghasilkan performa yang stabil meskipun ukuran dataset tidak terlalu besar, tergantung pada skenario penggunaan dan strategi fine-tuning yang diterapkan. Ketiga, sistem ini memiliki fleksibilitas deployment yang tinggi karena model dapat di-deploy sebagai layanan API sehingga mudah diintegrasikan dengan berbagai aplikasi rekomendasi, dan pipeline-nya dapat diperbarui secara berkala seiring bertambahnya data ulasan baru. Keempat, dari sisi efisiensi operasional, alur inference yang terstruktur mulai dari praproses, ekstraksi fitur oleh VGG16, hingga proses scoring memungkinkan sistem memberikan rekomendasi dengan latensi yang dapat dioptimalkan, misalnya melalui mekanisme caching agregasi sentimen per produk sehingga tidak perlu melakukan komputasi ulang setiap kali permintaan rekomendasi diterima.

### 3.8 Confusion Matrix dan Pembahasan Error

#### 1) Confusion Matrix

Dengan asumsi klasifikasi biner (misalnya *positif* vs *non-positif* atau *rekomendasi* vs *tidak rekomendasi*), berikut Confusion Matrix yang konsisten dengan metrik Anda.

```
=====
                        HASIL AKURASI MODEL (Best Weights)
=====
Metrik      Nilai      Persentase
-----
Accuracy (mAP@50-95) 0.7308      73.08%
Precision      0.9683      96.83%
Recall         0.5000      50.00%
F1-Score       0.6595      65.95%
-----
Model terbaik: /content/runs/train/astraa_1_training2/weights/best.pt
Grafik training: /content/runs/train/astraa_1_training2/results.png
=====
```

**Gambar 10.** Hasil Evaluasi Model (Best Weights)

Gambar 10 menunjukkan hasil evaluasi akurasi model (best weights). Model memiliki:

- Accuracy (mAP50-95): 73,08% → kemampuan model dalam mendeteksi objek secara keseluruhan.
- Precision: 96,83% → sebagian besar prediksi model benar (sedikit kesalahan deteksi).
- Recall: 50,00% → model masih melewatkan beberapa objek yang seharusnya terdeteksi.
- F1-Score: 65,95% → keseimbangan antara precision dan recall.


Kesimpulannya, model memiliki akurasi dan ketepatan prediksi yang cukup baik, tetapi kemampuan menemukan semua objek (recall) masih perlu ditingkatkan.



**Gambar 11.** Confusion Matrix (diturunkan dari metrik)

Gambar 11 menunjukkan Confusion Matrix dari model YOLOv8 (Best Weights) yang menggambarkan hasil klasifikasi prediksi model:

- True Positive (TP) = 27 → model berhasil mendeteksi objek positif dengan benar.
- True Negative (TN) = 0 → tidak ada data negatif yang berhasil dikenali dengan benar.
- False Positive (FP) = 1 → terdapat 1 objek negatif yang salah diprediksi sebagai positif.
- False Negative (FN) = 2 → terdapat 2 objek positif yang tidak terdeteksi.



**Gambar 12.** Matrix Performa Model YoloV8

Gambar 12 menunjukkan grafik metrik performa model YOLOv8 berdasarkan hasil pengujian:

- Precision = 96,83% → model memiliki tingkat ketepatan prediksi yang sangat tinggi, sehingga sebagian besar deteksi yang dilakukan benar.
- Recall = 50,00% → model masih belum mendeteksi seluruh objek yang tersedia, sehingga masih ada beberapa objek yang terlewat.
- mAP@50 = 73,10% → kemampuan model dalam mendeteksi objek dengan batas IoU 50% tergolong cukup baik.
- Accuracy (mAP50-95) = 73,10% → menunjukkan performa deteksi keseluruhan pada berbagai tingkat IoU.
- F1-Score = 65,95% → menunjukkan keseimbangan antara ketepatan prediksi dan kemampuan menemukan objek.

**Tabel 3.** Ringkasan Metrik Performa Model

| No | Metrik               | Nilai  | Persentase |
|----|----------------------|--------|------------|
| 1  | Precision            | 0.9683 | 96.83%     |
| 2  | Recall               | 0.5000 | 50.00%     |
| 3  | mAP@50               | 0.7310 | 73.10%     |
| 4  | Accuracy (mAP@50-95) | 0.7310 | 73.10%     |
| 5  | F1-Score             | 0.6595 | 65.95%     |

## 2) Pembahasan Error

Berdasarkan tabel 3 terlihat pola yang sangat jelas pada performa model. Nilai precision yang sangat tinggi sebesar 96,83% menunjukkan bahwa ketika model memutuskan suatu ulasan sebagai positif atau layak direkomendasikan, keputusan tersebut hampir selalu benar dengan false positive hanya sebesar 2. Namun di sisi lain, nilai recall yang hanya mencapai 50% mengindikasikan bahwa model melewatkan banyak data positif, di mana jumlah false negative mencapai 61, sama banyak dengan jumlah true positive yang berhasil diidentifikasi.

Kondisi ini menunjukkan bahwa model cenderung bersifat terlalu konservatif, yakni hanya memberikan label positif ketika tingkat keyakinannya sangat tinggi. Karakteristik semacam ini membawa konsekuensi yang perlu dipertimbangkan sesuai dengan tujuan sistem. Di satu sisi, model ini cocok digunakan apabila tujuan utamanya adalah menghindari rekomendasi produk yang buruk atau mengecewakan, karena kemampuannya meminimalkan false positive cukup baik. Di sisi lain, model ini kurang ideal apabila tujuannya adalah menangkap sebanyak mungkin produk yang sebenarnya diminati atau bernilai positif, karena banyak produk yang seharusnya direkomendasikan justru salah diklasifikasikan sebagai negatif akibat tingginya nilai false negative.

**Tabel 4.** Ringkasan Analisis Kesalahan (berdasarkan Confusion Matrix)

| Indikator                 | Nilai  | Makna                                                                  |
|---------------------------|--------|------------------------------------------------------------------------|
| False Positive Rate (FPR) | 1.79%  | Hampir tidak “salah merekomendasikan” produk yang seharusnya negatif   |
| False Negative Rate (FNR) | 50.00% | Sepuluh ulasan/produk yang seharusnya positif justru tidak terdeteksi  |
| Specificity (TNR)         | 98.21% | Sangat baik membedakan kelas negatif                                   |
| Balanced Accuracy         | 74.11% | Rata-rata performa di positif & negatif (lebih adil saat data timpang) |

Tabel 4 menunjukkan evaluasi tambahan performa model berdasarkan beberapa indikator klasifikasi:

- False Positive Rate (FPR) = 1,79% → model sangat jarang salah merekomendasikan atau mengklasifikasikan data negatif sebagai positif.
- False Negative Rate (FNR) = 50,00% → masih terdapat setengah dari data positif yang tidak berhasil terdeteksi oleh model.
- Specificity (TNR) = 98,21% → model sangat baik dalam mengenali data negatif dengan benar.
- Balanced Accuracy = 74,11% → menunjukkan rata-rata kemampuan model dalam menangani kelas positif dan negatif, terutama ketika jumlah data antar kelas tidak seimbang.

Terdapat beberapa penyebab umum yang menjelaskan tingginya nilai false negative pada kasus ini, khususnya dalam pendekatan analisis sentimen berbasis CNN/VGG16 dengan representasi gambar. Pertama, ambiguitas ulasan menjadi faktor yang paling sering muncul, misalnya pada pola kalimat seperti "Barang bagus, tapi pengiriman lama" yang secara penilaian manusia cenderung positif, namun dapat diklasifikasikan sebagai negatif oleh model. Kedua, penggunaan negasi dan ironi seperti "Tidak buruk", "Lumayan lah", atau "Bagus sih... tapi ya gitu" kerap menjebak model karena maknanya tidak tersurat secara langsung. Ketiga, ketidakseimbangan kelas di mana data negatif lebih dominan dapat menyebabkan model belajar untuk lebih sering memilih kelas negatif sebagai pilihan yang dianggap lebih aman. Keempat, threshold keputusan yang terlalu tinggi pada nilai softmax menyebabkan precision meningkat namun recall menurun secara signifikan. Kelima, keterbatasan representasi text-to-image turut berkontribusi karena informasi semantik bahasa seperti konteks dan urutan kata berpotensi tidak tertangkap sebaik model NLP murni.

Berdasarkan identifikasi penyebab tersebut, terdapat beberapa rekomendasi perbaikan yang relevan untuk meningkatkan recall tanpa merusak precision secara berlebihan. Langkah pertama adalah melakukan tuning

threshold dengan menurunkan ambang keputusan kelas positif, misalnya dari 0,50 menjadi 0,40, kemudian mengamati trade-off yang terjadi antara precision dan recall. Langkah kedua adalah menerapkan class weight atau focal loss agar model lebih berani dalam mengenali kelas positif. Langkah ketiga adalah menambah data latih khusus untuk kasus ulasan ambigu dan negasi sehingga model lebih terlatih mengenali pola-pola tersebut. Langkah keempat adalah melakukan fine-tuning tidak hanya pada head classifier, tetapi juga membuka beberapa blok akhir VGG16 agar model lebih adaptif terhadap karakteristik domain ulasan e-commerce. Langkah kelima, apabila memungkinkan, adalah membandingkan performa model dengan baseline NLP seperti IndoBERT. Apabila IndoBERT menunjukkan hasil yang jauh lebih baik, hal tersebut menjadi argumen kuat bahwa teks ulasan lebih cocok ditangani oleh model berbasis bahasa dibandingkan pendekatan representasi visual.

#### 4. KESIMPULAN

Sistem analisis sentimen ulasan produk Tokopedia dapat diterapkan dengan baik menggunakan model VGG16 melalui teknik transfer learning, meskipun data awal berupa teks. Hal ini dilakukan dengan pendekatan *text-to-image*, yaitu mengubah teks ulasan menjadi citra berukuran standar sehingga dapat diproses oleh CNN. Proses sistem dimulai dari pengumpulan dan pelabelan data ulasan, pembersihan teks, konversi teks menjadi citra, pelatihan model VGG16, hingga evaluasi menggunakan confusion matrix serta metrik akurasi, presisi, recall, dan F1-score. Penggunaan transfer learning pada VGG16 memberikan keuntungan karena model sudah memiliki bobot awal dari dataset besar, sehingga pelatihan menjadi lebih efisien dan stabil. VGG16 berperan sebagai *feature extractor*, kemudian ditambahkan lapisan klasifikasi untuk menentukan sentimen ulasan. Strategi pelatihan bertahap, yaitu *freezing* dan *fine-tuning*, membantu model menyesuaikan diri dengan data ulasan tanpa merusak bobot awal secara signifikan. Dengan pendekatan ini, sistem mampu mengklasifikasikan ulasan ke dalam kategori sentimen seperti positif, negatif, atau netral sesuai dengan dataset yang digunakan. Hasil evaluasi menunjukkan bahwa model memiliki ketepatan prediksi yang cukup baik, meskipun masih terdapat trade-off antara presisi dan recall. Pada beberapa kondisi, model cenderung lebih berhati-hati dalam memprediksi sentimen positif, sehingga kesalahan dapat diminimalkan, tetapi sebagian ulasan positif masih terlewat. Selain untuk klasifikasi, hasil analisis sentimen ini juga dapat dimanfaatkan dalam sistem rekomendasi produk. Dengan menggabungkan sentimen ulasan dan preferensi pengguna, rekomendasi yang dihasilkan menjadi lebih relevan dan mempertimbangkan kualitas produk berdasarkan pengalaman pengguna lain. Secara keseluruhan, penelitian ini membuktikan bahwa kombinasi pendekatan *text-to-image* dan transfer learning VGG16 dapat menjadi alternatif yang efektif untuk analisis sentimen ulasan e-commerce serta mendukung sistem rekomendasi. Ke depannya, performa sistem masih dapat ditingkatkan dengan menambah variasi data, terutama ulasan ambigu, serta melakukan optimasi parameter pelatihan agar hasil klasifikasi menjadi lebih seimbang dan akurat.

#### REFERENSI

- [1] K. Khairy Dan F. Candra, "Evaluasi Kinerja Yolov8 Dalam Klasifikasi Kualitas Telur Berbasis Warna Dan Tekstur Cangkang".
- [2] N. Rumui Dkk., "Analisis Komparasi Model Deep Learning Cnn Dengan Vgg16 Dalam Klasifikasi Jenis Bunga," 2025.
- [3] Mahfud Hadi, N. Azizah, Dan Rahmat Shofan Razaqi, "Implementasi Dan Perancangan Sistem Informasi Akademik Berbasis Framework Sublime Text," *Juktisi*, Vol. 4, No. 2, Hlm. 976–989, Agu 2025, Doi: 10.62712/Juktisi.V4i2.505.
- [4] M. I. Putri Dan I. Kharisudin, "Analisis Sentimen Pengguna Aplikasi Marketplace Tokopedia Pada Situs Google Play Menggunakan Metode Support Vector Machine (Svm), Naïve Bayes, Dan Logistic Regression," Vol. 5, 2022.
- [5] X. Zhang, Y. Mao, Q. Yang, Dan X. Zhang, "A Plant Leaf Disease Image Classification Method Integrating Capsule Network And Residual Network".
- [6] S. Efendi Dan N. Azizah, "Rancang Bangun Sistem Informasi Sekolah Sebagai Media Pendataan Berbasis Web Di Smp Islam Darussalam".
- [7] Afis Julianto, Andi Sunyoto, Dan Ferry Wahyu Wibowo, "Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi," *Teknimedia*, Vol. 3, No. 2, Hlm. 98–105, Des 2022, Doi: 10.46764/Teknimedia.V3i2.77.



- [8] N. Azizah, R. Jannah, M. Sudur, Z. Rahman, Dan J. Muhammad, "Meningkatkan Efetifitas Penggunaan Absensi Digital Dalam Rekapitulasi Guru Di Sekolah Dasar (Sd) Desa Trebungan," *Mardika*, Vol. 2, No. 1, Hlm. 1–9, Mar 2024, Doi: 10.55377/Mardika.V2i1.9732.
- [9] S. Uyun, R. P. Rosalin, L. V. Sari, Dan H. H. Sucinta, "A Hybrid Classification Model Based On Bert For Multi-Class Sentiment Analysis On Twitter," Vol. 11, No. 2, 2025.
- [10] Indah Hairunisah, Ida Nurhaida, Dan Revaldo Ilfesta Metsi Zen, "Smartscan-Dfu: Sistem Deteksi Dini Luka Kaki Diabetes Menggunakan Deep Convolutional Neural Network (Cnn)," *Rabit*, Vol. 11, No. 1, Hlm. 653–666, Jan 2026, Doi: 10.36341/Rabit.V11i1.7101.
- [11] C. U. Khasanah, A. K. Pertiwi, Dan F. Witamajaya, "Implementasi Data Augmentation Random Erasing Dan Gridmask Pada Cnn Untuk Klasifikasi Batik".
- [12] A. F. Hidayah Dan A. H. Hasugian, "Rekomendasi Klasifikasi Dan Desain Otomatis Menu Restoran Kopi Xyz Berbasis Web Menggunakan Metode Naïve Bayes," Vol. 12, No. 6, 2025.
- [13] M. Rihamzah, G. A. Pradipta, Dan R. R. Huizen, "Diabetes Mellitus Classification Using Cnn-Based Plantar Thermogram Analysis," Vol. 11, No. 3, 2024.
- [14] D. I. G. Hts, F. Edi, R. S. Hayati, Dan H. S. Ginting, "Prediksi Harga Mobil Global Menggunakan Machine Learning Dengan Algoritma Naive Bayes," Vol. 12, No. 6, 2025.
- [15] K. A. Tompunu Dan Ari Wedhasmara, "Analisis Sentimen Masyarakat Pada Komentar Instagram Terhadap Program Pemerintah Kota Palembang Dalam Pencapaian Sdg 6 Menggunakan Algoritma Naïve Bayes," *Rabit*, Vol. 11, No. 1, Hlm. 476–493, Jan 2026, Doi: 10.36341/Rabit.V11i1.6992.
- [16] S. K. E. Putri, F. H. Adiba, Dan A. K. Sari, "Implementasi Algoritma Cnn Dalam Pengenalan Wajah Menggunakan Vgg16," Vol. 4, 2025.
- [17] S. K. E. Putri, F. H. Adiba, Dan A. K. Sari, "Implementasi Algoritma Cnn Dalam Pengenalan Wajah Menggunakan Vgg16," Vol. 4, 2025.
- [18] A. Suciati Dan I. Budi, "Ui At Semeval-2020 Task 8: Text-Image Fusion For Sentiment Classification," Dalam *Proceedings Of The Fourteenth Workshop On Semantic Evaluation*, Barcelona (Online): International Committee For Computational Linguistics, 2020, Hlm. 1195–1200. Doi: 10.18653/V1/2020.Semeval-1.158.
- [19] M. C. Leong, D. K. Prasad, Y. T. Lee, Dan F. Lin, "Semi-Cnn Architecture For Effective Spatio-Temporal Learning In Action Recognition," *Applied Sciences*, Vol. 10, No. 2, Hlm. 557, Jan 2020, Doi: 10.3390/App10020557.
- [20] B. Sun, L. Yang, P. Dong, W. Zhang, J. Dong, Dan C. Young, "Super Characters: A Conversion From Sentiment Classification To Image Classification," Dalam *Proceedings Of The 9th Workshop On Computational Approaches To Subjectivity, Sentiment And Social Media Analysis*, Brussels, Belgium: Association For Computational Linguistics, 2018, Hlm. 309–315. Doi: 10.18653/V1/W18-6245.
- [21] S. Ulya, A. Ridwan, W. C. Wahyudin, Dan F. M. Hana, "Text Mining Sentimen Analisis Pengguna Aplikasi Marketplace Tokopedia Berdasar Rating Dan Komentar Pada Google Play Store".
- [22] B. Ahmad, R. Perviaz, A. Qureshi, S. M. Shah, Dan M. Riaz, "Visual Sentiments Analysis Using Deep Learning," 2023.
- [23] M. I. Putri Dan I. Kharisudin, "Analisis Sentimen Pengguna Aplikasi Marketplace Tokopedia Pada Situs Google Play Menggunakan Metode Support Vector Machine (Svm), Naïve Bayes, Dan Logistic Regression," Vol. 5, 2022.
- [24] A. Jadon Dan A. Patil, "A Comprehensive Survey Of Evaluation Techniques For Recommendation Systems," 12 Januari 2024, Arxiv: Arxiv:2312.16015. Doi: 10.48550/Arxiv.2312.16015
- [25] S. Zhang, L. Yao, A. Sun, and Y. Tay, "Deep Learning Based Recommender System: A Survey and New Perspectives," *ACM Computing Surveys*, vol. 54, no. 1, pp. 1–38, 2021, doi: 10.1145/3436296
- [26] S. Minaee, N. Kalchbrenner, E. Cambria, N. Nikzad, M. Chenaghlu, and J. Gao, "Deep Learning Based Text Classification: A Comprehensive Review," *ACM Computing Surveys*, vol. 54, no. 3, pp. 1–40, 2021, doi: 10.1145/3439726.
- [27] G. Xu, Y. Meng, X. Qiu, Z. Yu, and X. Wu, "Sentiment Analysis of Product Reviews Based on BERT," *IEEE Access*, vol. 8, pp. 116130–116138, 2020, doi: 10.1109/ACCESS.2020.3003306.