

PERSONALISASI OTOMATIS APLIKASI CACA (CARI CAFE) BERBASIS *ARTIFICIAL INTELLIGENCE*

Salma Pusriwijayanti*¹, Agi Prasetiadi², Diandra Chika Fransisca³

^{1,2,3}Program Studi Teknik Informatika, Fakultas Informatika, Institut Teknologi Telkom
Purwokerto

E-mail: *¹19102206@ittelkom-pwt.ac.id, ²agi@ittelkom-pwt.ac.id, ³diandra@ittelkom-pwt.ac.id

Abstrak

Peningkatan produksi kopi menciptakan peluang bisnis olahan kopi, memunculkan banyak cafe. Dalam mengikuti perkembangan zaman, pengusaha perlu menggunakan teknologi terkini dengan menyediakan aplikasi reservasi cafe untuk meningkatkan kepuasan pelanggan dan bersaing di pasar yang semakin kompetitif. Penelitian sebelumnya mengenai aplikasi berbasis mobile dengan Extreme Programming yang fokus pada kepuasan pelanggan, memungkinkan pemesanan makanan lebih awal, dan memantau pesanan pelanggan melalui website. Penelitian ini membuat aplikasi CACA (Cari Cafe) yang dirancang untuk melakukan reservasi cafe dan menyediakan informasi tentang cafe-cafe pada satu aplikasi berbasis website. Dalam mencapai personalisasi otomatis, teknologi artificial intelligence seperti Optical Character Recognition (OCR), Convolutional Neural Network (CNN), dan Siamese Neural Network (SNN) digunakan. Personalisasi otomatis aplikasi CACA melibatkan pembacaan e-KTP sebagai data registrasi, pengenalan gambar wajah pengguna untuk memberikan rekomendasi cafe berdasarkan kesukaan atau kebiasaan, dan pencocokan wajah pengguna untuk verifikasi akun member. Penelitian ini berhasil mengimplementasikan OCR pada gambar e-KTP dengan bounding box di mana nilai box_loss sebesar 0.05211 dan nilai cls_loss sebesar 0.01598. Penggunaan transfer learning model VGG16 dengan fungsi aktivasi sigmoid untuk menebak 11 komponen kesukaan atau kebiasaan pengguna juga mencapai tingkat keberhasilan yang optimal. Selain itu, metode verifikasi menggunakan SNN juga memberikan hasil yang baik, dengan mencocokkan foto pada gambar e-KTP dengan foto selfie dan mencapai akurasi sebesar 0.9285 dengan nilai loss 0.0170.

Kata Kunci— *Personalisasi, Reservasi, Optical Character Recognition, Convolutional Neural Network, Siamese Neural Network.*

1. PENDAHULUAN

Kopi telah menjadi komoditas penting di Indonesia, salah satu dari empat produsen kopi terbesar di dunia [1]. Konsumsi kopi menjadi bagian integral dari gaya hidup masyarakat Indonesia. Pertumbuhan produksi kopi membuka peluang bisnis menarik dalam pengembangan minuman olahan berbahan dasar kopi. Seiring meningkatnya konsumsi kopi di Indonesia [1], cafe bermunculan untuk memenuhi permintaan dan menjadi tempat berkumpul yang populer. Namun, pengelolaan cafe masih menemui kendala, terutama dalam sistem reservasi. Banyak cafe masih menggunakan metode tradisional dengan pelanggan harus datang langsung memesan makanan dan minuman [2]. Oleh karena itu, terdapat peluang pengembangan aplikasi untuk memfasilitasi reservasi cafe secara online, sehingga pelanggan dapat melakukan reservasi sebelum kunjungan dengan lebih nyaman dan efisien.

Dalam perkembangan teknologi informasi saat ini, masih jarang ditemukan aplikasi khusus yang menyediakan layanan reservasi cafe. Aplikasi pesan-antar makanan seperti GoFood, GrabFood, dan ShopeeFood lebih fokus pada pesan antar makanan dan tidak menyediakan opsi reservasi [3], [4]. Kebutuhan untuk aplikasi yang khusus menawarkan reservasi cafe masih belum terpenuhi. Pengusaha cafe dituntut untuk mengikuti perkembangan teknologi dan memanfaatkannya dalam bisnis mereka. Dengan memanfaatkan teknologi terkini, pengusaha cafe dapat meningkatkan kepuasan pelanggan, bersaing dengan kompetitor, dan memenuhi kebutuhan pasar yang terus berkembang.

Dalam penelitian sebelumnya, telah dilakukan beberapa studi dan pengembangan terkait dengan penerapan teknologi artificial intelligence dalam bidang industri makanan dan minuman [5], [6]. Beberapa penelitian telah menunjukkan bahwa personalisasi dapat digunakan untuk mempersonalisasi perilaku pengguna berdasarkan data penggunaan menggunakan teknologi artificial intelligence [5], [6]. Selain itu, penelitian terdahulu juga telah mengidentifikasi faktor-faktor yang mempengaruhi hasil rekomendasi cafe, sehingga rekomendasi yang diberikan sesuai dengan kebutuhan dan preferensi pengguna [7], [8], [9]. Selain itu, penggunaan teknologi Optical Character Recognition (OCR) untuk menerjemahkan gambar menjadi teks serta penggunaan Convolutional Neural Network (CNN) dan Siamese Neural Network (SNN) dalam pengolahan citra dan pengenalan wajah telah menghasilkan kemajuan yang signifikan [10], [11], [12], [13], [14], [15].

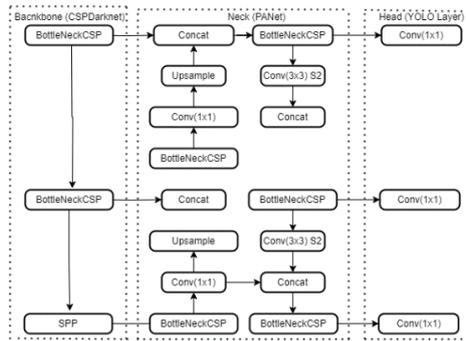
2. METODE PENELITIAN

2.1. Optical Character Recognition (OCR)

OCR adalah teknologi yang digunakan untuk mengubah gambar teks menjadi karakter ASCII. OCR bekerja secara otomatis untuk mengenali karakter menggunakan mekanisme optik. Meskipun tidak sebanding dengan kemampuan membaca manusia, OCR dapat mengidentifikasi teks tulisan tangan dan cetak [16]. Proses OCR digunakan dalam digitalisasi dokumen fisik seperti paspor, invoice, KTP, dan dokumen lainnya. Metode pemrosesan OCR melibatkan pra-pemrosesan, pengenalan, dan pasca-pemrosesan [17].

2.2. YOLOv5

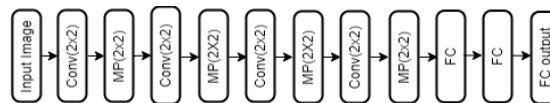
YOLOv5 (You Only Look Once) versi 5 adalah sebuah framework yang mengenali objek dan dikembangkan oleh Glenn Jocher, seorang peneliti dan CEO dari Ultralytics LLC pada tahun 2020. Framework YOLOv5 menggunakan bahasa pemrograman Python dan berbasis pada framework PyTorch. Menurut situs Roboflow, YOLOv5 merupakan hasil pengembangan implementasi YOLOv3 pada framework PyTorch yang juga dikembangkan oleh Glenn Jocher [18]. Gambar 1 menunjukkan arsitektur YOLOv5:



Gambar 1 Arsitektur YOLOv5

2.3 Convolutional Neural Network (CNN)

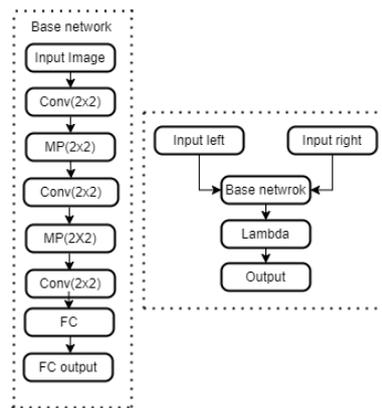
CNN adalah algoritma deep neural network yang digunakan untuk analisis gambar visual. CNN dapat mengenali pola hierarki dalam data dengan mengumpulkan informasi kompleks dari piksel yang lebih kecil. Keunggulan CNN terletak pada kemampuannya dalam mengatasi kompleksitas piksel pada citra. Arsitektur CNN dapat dibagi menjadi dua tahap, yaitu pembelajaran fitur dan klasifikasi. Tahap pembelajaran fitur melibatkan convolution, activation, dan polling, sedangkan tahap klasifikasi menggunakan fully connected layer dan fungsi softmax [19], [20]. CNN telah digunakan dalam berbagai aplikasi seperti pengenalan gambar, sistem rekomendasi, analisis citra medis, dan pemrosesan bahasa alami. Kemajuan dalam pengenalan objek menggunakan CNN telah mencapai tingkat akurasi yang signifikan [21], [22]. Gambar 2 menunjukkan arsitektur CNN:



Gambar 2 Arsitektur CNN

2.3 Siamese Neural Network (SNN)

SNN adalah pendekatan dalam deep learning yang membandingkan dua pola untuk menghasilkan output yang mencerminkan kesamaan antara kedua pola tersebut. SNN sering digunakan untuk memecahkan masalah perbandingan antara dua pola. Penggunaan SNN dalam kombinasi dengan CNN terpopuler untuk pengenalan wajah. SNN memproses pasangan gambar-label dan melakukan proses seperti feature learning dan perhitungan jarak untuk menentukan kemiripan antara dua pola [14], [23]. Gambar 3 menunjukkan arsitektur SNN:



Gambar 3 Arsitektur SNN

2.4 Tahapan Penelitian

Dalam memahami berbagai tahapan dalam penelitian, tahap pertama adalah mengidentifikasi masalah mencakup penemuan bahwa aplikasi CACA berbasis kecerdasan buatan belum memiliki personalisasi otomatis. Tahap selanjutnya adalah studi literatur melibatkan pencarian dan pengumpulan informasi terkait masalah dan tujuan penelitian. Kemudian tahap pengumpulan data, melibatkan pengumpulan data yang diperlukan melalui observasi dan wawancara. Tabel 1 menunjukkan dataset yang digunakan dalam penelitian ini:

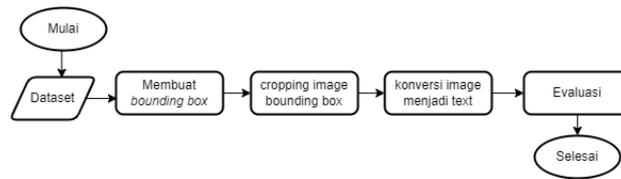
Tabel 1 Dataset

Fungsi	Detail Fungsi	Dataset	Jumlah
Fungsi 1	Membaca gambar e-KTP secara otomatis	Gambar e-KTP.	70 gambar e-KTP.
Fungsi 2	Menebak 11 komponen kesukaan atau kebiasaan pengguna berdasarkan foto selfie.	Foto selfie pengguna.	70 foto selfie pengguna.
		11 Komponen kuesioner.	70 Jawaban kuesioner.
		Info <i>cafe</i>	25 Info <i>cafe</i> .
Fungsi 3	Mencocokkan atau memverifikasi foto pada gambar e-KTP dengan foto selfie pengguna.	a = Foto selfie pengguna.	70 foto selfie pengguna.
		b = Gambar e-KTP.	70 gambar e-KTP.

Setelah itu, tahap pemrosesan data terdiri dari tiga bagian:

- a. Pemrosesan Data Fungsi 1 dengan Tesseract OCR.

Pada tahap ini, dataset Fungsi 1 dimasukkan dan dilakukan pembentukan bounding box menggunakan YOLOv5. Selanjutnya, dilakukan pemangkasan gambar sesuai dengan bounding box yang telah dibuat. Gambar-gambar tersebut kemudian dikonversi menjadi teks menggunakan Tesseract OCR. Selama proses ini, juga dilakukan pembersihan data untuk menghapus atau mengganti data yang tidak relevan. Evaluasi dilakukan menggunakan Word Error Rate (WER). Gambar 5 menunjukkan diagram alir pemrosesan data Fungsi 1 menggunakan Tesseract OCR:



Gambar 5 Pemrosesan data Fungsi 1

b. Pemrosesan Data Fungsi 2 dengan Algoritma CNN.

Pada tahap ini, digunakan algoritma CNN dengan berbagai model, termasuk model CNN khusus, VGG16, dan ResNet50. Proses pelatihan model dilakukan dengan menggunakan dua fungsi aktivasi softmax dan sigmoid. Implementasi CNN melibatkan beberapa layer konvolusi, *MaxPooling2D*, dan *fully connected*. Model CNN juga dilatih menggunakan arsitektur yang sama dengan fungsi aktivasi sigmoid. Tabel 2 menunjukkan arsitektur model CNN dengan fungsi aktivasi *softmax*:

Tabel 2 Arsitektur model CNN *softmax*

<i>Layer</i>	<i>Output Shape</i>
<i>Input</i>	(100, 100, 3)
<i>Conv2D</i>	(98, 98, 32)
<i>MaxPooling2D</i>	(49, 49, 32)
<i>Conv2D</i>	(47, 47, 64)
<i>MaxPooling2D</i>	(23, 23, 64)
<i>Conv2D</i>	(21, 21, 128)
<i>MaxPooling2D</i>	(10, 10, 128)
<i>Conv2D</i>	(8, 8, 256)
<i>MaxPooling2D</i>	(4, 4, 256)
<i>Flatten</i>	(4096)
<i>Dense</i>	(64)
<i>Dropout</i>	(64)
<i>Dense</i>	(11)

Model VGG16 dimodifikasi dengan layer dropout dan Tabel 3 menunjukkan arsitektur model VGG16 tersebut dengan fungsi aktivasi *softmax*:

Tabel 3 Arsitektur model VGG16 *softmax*

<i>Layer</i>	<i>Output Shape</i>
<i>Input</i>	(100, 100, 3)
VGG16 (<i>functional</i>)	(3, 3, 512)
<i>Flatten</i>	(4608)
<i>Dense</i>	(64)
<i>Dropout</i>	(64)
<i>Dense</i>	11

Model ResNet50 dimodifikasi dengan *layer flatten*, *layer dense*, serta *layer dropout* dan Tabel 4 menunjukkan arsitektur model ResNet50 tersebut dengan fungsi aktivasi *softmax*:

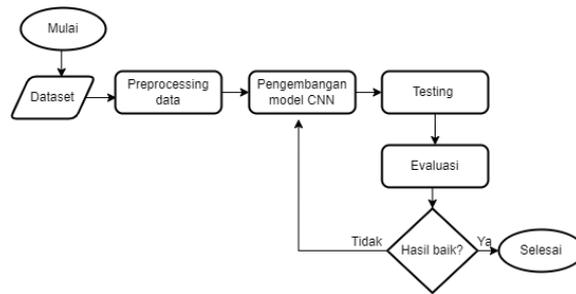
Tabel 4 Arsitektur model ResNet50

<i>Layer</i>	<i>Output Shape</i>
<i>Input</i>	(100, 100, 3)
ResNet50 (<i>functional</i>)	(4, 4, 2048)
<i>Flatten</i>	(32768)
<i>Dense</i>	(64)
<i>Dropout</i>	(64)
<i>Dense</i>	(11)

Model dengan aktivasi sigmoid diimplementasikan pada setiap folder dalam pemrosesan data dengan fungsi aktivasi softmax. Setiap folder merupakan kelas dan terdapat dua sub folder didalamnya. Berikut adalah folder folder tersebut:

- Folder 3jamlebih, memiliki sub folder 3jamlebihtrue dan 3jamlebihfalse. Folder tersebut adalah folder dengan pengguna yang memiliki kesukaan atau kebiasaan menghabiskan waktu di cafe selama lebih dari tiga jam dan tidak lebih dari tiga jam.
- Folder 50ribulebih, memiliki sub folder 50ribulebihtrue dan 50ribulebihfalse. Folder tersebut adalah folder dengan pengguna yang memiliki kesukaan atau kebiasaan menghabiskan uang lebih dari Rp 50.000 dan kurang dari Rp 50.000 saat berkunjung ke cafe.
- Folder asam, memiliki sub folder asamtrue dan asamfalse. Folder tersebut adalah folder dengan pengguna yang menyukai dan tidak menyukai makanan atau minuman asam.
- Folder begadang, memiliki sub folder begadangtrue dan begadangfalse. Folder tersebut adalah folder dengan pengguna yang suka dan tidak suka tidur di atas atau setelah pukul 12 malam.
- Folder ekstrovert, memiliki sub folder ekstroverttrue dan ekstrovertfalse. Folder tersebut adalah folder dengan pengguna yang berkepribadian dan tidak berkepribadian ekstrovert.
- Folder kelamin, memiliki sub folder kelamin_jk_p dan kelamin_jk_l. Folder tersebut adalah folder dengan pengguna yang berjenis kelamin perempuan dan laki-laki.
- Folder keramaian, memiliki sub folder keramaiantrue dan keramaianfalse. Folder tersebut adalah folder dengan pengguna yang menyukai dan tidak menyukai keramaian.
- Folder makan_minum, memiliki sub folder makanminumtrue dan makanminumfalse. Folder tersebut adalah folder dengan pengguna yang memiliki kesukaan atau kebiasaan memesan makanan serta minuman dan tidak memesan makanan serta minuman saat berkunjung ke cafe.
- Folder malamhari, memiliki sub folder malamharitrue dan malamharifalse. Folder tersebut adalah folder dengan pengguna yang hanya berkunjung dan tidak hanya berkunjung ke cafe pada malam hari saja.
- Folder manis, memiliki sub folder manistrue dan manisfalse. Folder tersebut adalah folder dengan pengguna yang menyukai dan tidak menyukai makanan atau minuman manis.
- Folder pahit, memiliki sub folder pahitrue dan pahitfalse. Folder tersebut adalah folder dengan pengguna yang menyukai dan tidak menyukai makanan atau minuman manis.

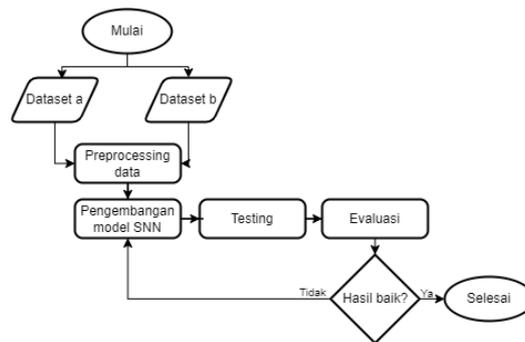
Arsitektur model yang sama digunakan untuk melatih setiap folder, namun perbedaannya terletak pada fungsi aktivasi yang digunakan. Evaluasi dilakukan menggunakan *confusion matrix*. Gambar 6 menunjukkan diagram alir pemrosesan data Fungsi 2 menggunakan CNN:



Gambar 6 Pemrosesan data Fungsi 2

c. Pemrosesan Data Fungsi 3 dengan Algoritma SNN

Pada tahap ini, digunakan algoritma SNN yang bertujuan untuk membandingkan kesamaan atau mencocokkan dua *input* guna menghasilkan output yang sesuai. Terlebih dahulu, dibentuk *base network* yang menerima input gambar dan menghasilkan vektor representasi fitur-fitur gambar. Selanjutnya, jaringan SNN menghubungkan dua input ke base network dan mengukur skor kesamaan. Evaluasi dilakukan menggunakan *confusion matrix*. Gambar 7 menunjukkan diagram alir pemrosesan data Fungsi 3 menggunakan SNN:



Gambar 7 Pemrosesan data Fungsi 3

Setelah pemrosesan data, dilakukan evaluasi hasil. Jika evaluasi menunjukkan hasil yang baik, proses penelitian selesai. Namun, jika evaluasi menunjukkan hasil yang tidak memuaskan, dilakukan pengembangan atau perbaikan pada model yang digunakan.

3. HASIL DAN PEMBAHASAN

3.1 Membaca gambar e-KTP secara otomatis dengan bounding box

Pada fungsi ini, dilakukan implementasi metode OCR (*Optical Character Recognition*) untuk membaca gambar e-KTP secara otomatis. Setiap gambar e-KTP hanya mengambil lima informasi. Terdapat dua pendekatan yang digunakan, yaitu menggunakan *bounding box* dan tanpa *bounding box*. Pendekatan pertama tanpa menggunakan *bounding box*. Dalam pendekatan ini, gambar e-KTP langsung dikonversi menjadi teks tanpa menggunakan *bounding box*. Namun, hasil OCR tanpa *bounding box* memerlukan langkah tambahan untuk memproses dan mengidentifikasi informasi spesifik dari teks secara terpisah, yang dapat menjadi lebih rumit dan memakan waktu. Tabel 5 menunjukkan hasil proses OCR tanpa *bounding box* salah satu gambar e-KTP:

Tabel 5 Hasil proses OCR tanpa *bounding box* adilla.jpg

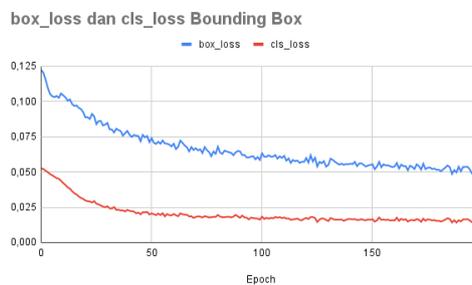
```

ma _ : ADILLAFEBRINA
satfTc Lahir SRRWNATS, 16 E200.

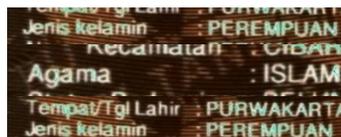
Status Perkawinan: BELUM KAWIN - = == =
Pekerjaan = PELAJAR/MAHASISWA ~ _ 45-02-2019
Kewarganegaraan: WNE ~ SS * + ES
Berlaku Hingga +SEUMUR. HIDUP === SSS =

Scanned by TapScanner
    
```

Pendekatan kedua dengan menggunakan *bounding box*. Pada epoch ke-200 terlihat bahwa hasil pelatihan dan validasi model tingkat kesalahan yang sangat rendah dengan mencapai *loss* sebesar 0, di mana nilai *box_loss* sebesar 0.05211 dan nilai *cls_loss* sebesar 0.01598. Baik *box_loss* maupun *cls_loss* menunjukkan penurunan nilai *loss* seiring peningkatan *epoch*. Model ini memiliki kemampuan yang meningkat dalam memprediksi *bounding box* dan mengklasifikasikan objek. Gambar 11 menunjukkan Grafik *box_loss* dan *cls_loss bounding box*:



Bounding box digunakan untuk menandai area yang berisi informasi yang diinginkan, yaitu nama, tempat tanggal lahir, jenis kelamin, alamat, dan agama. Dalam pendekatan ini, gambar e-KTP dipotong sesuai hasil prediksi lokasi *bounding box*. Hal ini memudahkan fokus pada area yang relevan dan memudahkan pengenalan dan analisis lebih lanjut terhadap masing-masing kelas atau objek dalam gambar e-KTP. Gambar 8 menunjukkan salah satu gambar e-KTP yang telah dipotong sesuai hasil prediksi lokasi *bounding box*:



Gambar 8 Hasil *crop bounding box* adilla.jpg

Hasil OCR dengan *bounding box* memudahkan akses dan pengolahan data. Informasi dapat diambil dan diproses secara terpisah untuk setiap kelas dengan lebih mudah. Tabel 6 menunjukkan hasil proses OCR dengan *bounding box* salah satu gambar e-KTP:

Tabel 6 Hasil proses OCR dengan *bounding box* adilla.jpg

```

[['jk', ' W PEREMPUAN'],
 ['agama', ' ISLAM '],
 ['ttl', 'B BO 2 B PEREMPUAN']]
    
```

Performa OCR dievaluasi menggunakan WER (Word Error Rate), yang mengukur kesalahan per kata antara teks asli dan teks prediksi. Semakin rendah nilai WER, semakin baik performa OCR. Dari 70 gambar e-KTP pengguna yang digunakan, gambar e-KTP dengan nama file “adilla.jpg” menunjukkan hasil terbaik dengan nilai WER rata rata sebesar 0.72.

3.2 Menebak 11 Komponen kesukaan atau kebiasaan pengguna berdasarkan foto selfie dan merekomendasikan cafe

Proses pelatihan model dilakukan dengan menggunakan dua jenis fungsi aktivasi, yaitu softmax dan sigmoid. Aktivasi softmax umumnya digunakan dalam masalah klasifikasi multi kelas, sedangkan aktivasi sigmoid digunakan dalam masalah biner. Setiap jenis fungsi aktivasi diimplementasikan menggunakan tiga model berbeda, yaitu model CNN yang secara khusus dirancang untuk menangani masalah yang sedang diteliti, model VGG16, dan model ResNet50. Tabel 7 dan Tabel 8 menunjukkan perbandingan *accuracy* serta *val_accuracy* model-model dengan aktivasi *softmax* dan *sigmoid*:

Tabel 7 Hasil *accuracy* dan *val_accuracy* model dengan aktivasi *softmax*

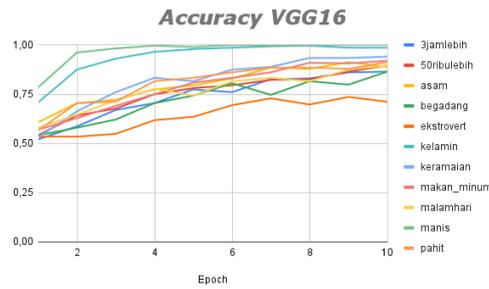
Nama model	<i>Accuracy</i>	<i>Val_accuracy</i>
Klasifikasi 11 Hobi Keseluruhan: CNN	0.091	0.0625
Klasifikasi 11 Hobi Keseluruhan: VGG16	0.0972	0.0966
Klasifikasi 11 Hobi Keseluruhan: ResNet50	0.0922	0.0966

Tabel 8 Hasil *accuracy* dan *val_accuracy* model dengan aktivasi *sigmoid*

Nama model	<i>Accuracy</i>	<i>Val_accuracy</i>
CNN 3jamlebih	0.5104	0.4062
CNN 50ribulebih	0.4653	0.4688
CNN asam	0.4826	0.4062
CNN begadang	0.4653	0.5312
CNN ekstrovert	0.5000	0.5000
CNN kelamin	0.9028	0.8125
CNN keramaian	0.6806	0.5938
CNN makan_minum	0.4688	0.5000
CNN malamhari	0.4653	0.5000
CNN manis	0.9514	1.0000
CNN pahit	0.5035	0.4688
VGG16 3jamlebih	0.8646	0.7812
VGG16 50ribulebih	0.8958	0.8125
VGG16 asam	0.8889	0.8125
VGG16 begadang	0.8646	0.9062
VGG16 ekstrovert	0.7118	0.8750
VGG16 kelamin	0.9340	0.8438
VGG16 keramaian	0.9861	1.0000
VGG16 makan_minum	0.9201	0.8750
VGG16 malamhari	0.8958	0.8750
VGG16 manis	1.0000	1.0000
VGG16 pahit	0.9132	0.9062
ResNet50 3jamlebih	0.4722	0.5000
ResNet50 50ribulebih	0.5104	0.4062
ResNet50 asam	0.5104	0.4062
ResNet50 begadang	0.5069	0.4375
ResNet 50 ekstrovert	0.5139	0.3750
ResNet50 kelamin	0.5104	0.4062

ResNet50 keramaian	0.5035	0.4688
ResNet50 makan_minum	0.5104	0.4062
ResNet50 malamhari	0.5208	0.3125
ResNet50 manis	0.5035	0.4688
ResNet50 pahit	0.5035	0.4688

Model transfer learning VGG16 dengan fungsi aktivasi *sigmoid* menunjukkan performa yang lebih baik dalam klasifikasi data dibandingkan model lain. Gambar 12 dan Gambar 13 menunjukkan grafik *accuracy* dan *loss* model VGG16:



Gambar 12 Grafik *accuracy* model VGG16



Gambar 13 Grafik *loss* model VGG16

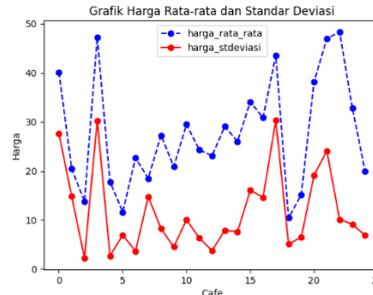
Pelatihan model dengan fungsi aktivasi *sigmoid* dilakukan secara terpisah pada 11 folder yang masing-masing memiliki satu kelas yang dijadikan sebagai output. Evaluasi menggunakan *confusion matrix* untuk mendapatkan pemahaman yang lebih mendalam tentang kemampuan model dalam mengklasifikasikan data dan ditemukan bahwa model berhasil melakukan prediksi dengan akurasi yang tinggi.

Berdasarkan prediksi dari 11 folder yang menggambarkan kesukaan atau kebiasaan pengguna, akan diberikan rekomendasi cafe sesuai dengan hasil prediksi tersebut. Terdapat sembilan kategori setelah beberapa folder memiliki kategori yang sama. Dalam memberikan rekomendasi cafe, kategori-kategori seperti "k_ramai", "k_asam", "k_pahit", dan "k_manis" tidak menjadi pertimbangan karena rasa dan tingkat keramaian bersifat subjektif dan dipengaruhi oleh preferensi individu serta cara pengolahan dan persiapan. Namun, untuk kategori "k_ramai" dan "k_jk", setiap rekomendasi cafe akan mencakup informasi tentang jam ramai cafe dan apakah interior cafe lebih berorientasi pada jenis kelamin tertentu atau tidak. Tabel 6 menunjukkan rincial kategori yang digunakan untuk merekomendasikan hasil prediksi:

Tabel 9 Rincian kategori cafe

Nama folder	Nama kategori	Definisi kategori
3jamlebih	k_wifi	Kategori berdasarkan ketersediaan wifi di cafe
50ribulebih	k_mahal	Kategori berdasarkan harga menu
makan_minum	k_mkn_mnm	Kategori berdasarkan ketersediaan menu makanan dan minuman
malamhari	k_24jam	Kategori berdasarkan jam buka dan tutup cafe
asam	k_asam	Kategori berdasarkan ketersediaan menu asam
pahit	k_pahit	Kategori berdasarkan ketersediaan menu pahit
begadang	k_pahit	Kategori berdasarkan ketersediaan menu pahit
manis	k_manis	Kategori berdasarkan ketersediaan menu manis
ekstrovert	k_ramai	Kategori berdasarkan tingkat keramaian cafe
Keramaian	k_ramai	Kategori berdasarkan tingkat keramaian cafe
kelamin	k_jk	Kategori berdasarkan ketersediaan menu pahit

Kategori mahal (k_mahal) dalam rekomendasi cafe ditentukan berdasarkan harga-harga menu yang ditawarkan oleh setiap cafe. Analisis dilakukan dengan menghitung harga rata-rata dan harga standar deviasi dari menu-menu yang tersedia. Cafe-cafe yang memiliki harga rata-rata lebih dari dua kali standar deviasi di atas rata-rata dikategorikan sebagai cafe k_mahal. Ini membantu mengidentifikasi cafe-cafe dengan harga menu tinggi dan variasi harga yang signifikan, sehingga disebut sebagai cafe k_mahal dalam rekomendasi cafe. Gambar 9 menunjukkan grafik harga rata-rata dan harga standar deviasi:



Gambar 9 Grafik harga rata-rata dan standar deviasi

Dari 25 cafe yang digunakan dalam penelitian, cafe-cafe tersebut dikategorikan ke dalam empat kategori cafe yang sesuai dengan Tabel 9 yang berwarna biru. Tabel 10 menunjukkan rincian klasifikasi cafe yang digunakan untuk perhitungan rekomendasi cafe:

Tabel 10 Rincian klasifikasi café

cafe	k_wifi	k_mahal	k_mkn_mnm	k_24jam
a	0	1	1	0
b	1	0	1	0
c	0	0	1	0
d	0	1	1	0
e	0	0	0	0
f	1	0	1	1

g	0	0	1	0
h	0	0	1	1
i	0	0	1	0
j	1	0	1	0
k	1	0	1	0
l	0	0	0	0
m	0	0	1	0
n	1	0	1	0
o	0	0	1	0
p	1	1	1	1
q	0	0	0	1
r	1	1	0	1
s	1	0	1	1
t	0	0	1	1
u	1	1	1	0
v	0	1	1	0
w	0	1	0	0
x	0	0	1	0
y	0	0	1	0

Untuk setiap foto selfie pengguna yang terdiri dari 70 foto selfie, akan diberikan rekomendasi cafe yang sesuai untuk masing-masing pengguna. Untuk melakukan evaluasi, digunakan metode perhitungan levenshtein distance. Pada penelitian ini, evaluasi performa model dilakukan menggunakan hanya 10 data sebagai acuan untuk mengukur tingkat kesamaan antara hasil prediksi dan data asli. Levenshtein distance dihitung untuk setiap pasangan data, dan hasilnya akan memberikan gambaran tentang sejauh mana hasil prediksi model mendekati data asli. Evaluasi ini membantu untuk menilai keakuratan dan kinerja model dalam mengidentifikasi preferensi pengguna berdasarkan foto selfie. Tabel 11 menunjukkan hasil evaluasi:

Tabel 11 Hasil evaluasi *Levenshtein Distance*

Nama	<i>Levenshtein Distance</i>
Abimanyu	1
Adhe	1
Adilla	2
Alex	0
Altha	2
Andhia	3
Arba	2
Arnas	2
Aulia	1
Bastian	1

3.3 Mencocokkan atau memverifikasi foto pada gambar e-KTP dengan foto selfie pengguna

Pada fungsi ini, dataset dibagi menjadi dua, yaitu dataset a (gambar e-KTP) dan dataset b (foto selfie). Gambar-gambar pada kedua dataset tersebut dipotong untuk memfokuskan pada bagian wajah, yang diperlukan dalam proses pencocokkan atau verifikasi. Data yang telah diproses kemudian diimplementasikan menggunakan SNN. Apabila skor kesamaan bernilai >1 maka kedua gambar dianggap mirip atau sama, sedangkan jika skor penilaian bernilai <0 maka kedua

gambar dianggap tidak mirip atau tidak sama. Gambar 10 menunjukkan hasil skor kesamaan antara dua input secara acak:



Gambar 10 *Similarity score input acak*

Pada proses pelatihan, terjadi penurunan nilai loss yang menunjukkan kemajuan dalam kualitas prediksi model. Hasil implementasi SNN ditunjukkan dalam grafik yang menunjukkan kemajuan pelatihan. Gambar 11 menunjukkan grafik *loss* SNN:



Gambar 11 Grafik *loss* SNN

Evaluasi performa SNN menggunakan *confusion matrix*, ditemukan bahwa model berhasil memprediksi dengan baik data yang sama, namun perlu ditingkatkan dalam mengklasifikasikan data yang berbeda untuk mengurangi kesalahan prediksi.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan, penelitian berhasil merancang dan mengimplementasikan fungsi-fungsi utama pada aplikasi CACA, antara lain membaca gambar e-KTP menggunakan OCR, menebak atau mengetahui 11 kesukaan atau kebiasaan pengguna berdasarkan foto selfie dengan menggunakan CNN, serta mencocokkan atau memverifikasi wajah pada gambar e-KTP dengan foto selfie pengguna menggunakan SNN.

Rekomendasi cafe berdasarkan prediksi model berhasil memberikan rekomendasi yang sesuai dengan preferensi pengguna, antara lain reservasi tempat dan reservasi waktu yang menunjukkan efektivitas aplikasi CACA dalam memberikan rekomendasi tempat makan atau cafe yang cocok berdasarkan data kesukaan atau kebiasaan pengguna.

DAFTAR PUSTAKA

- [1] F. Nurikhsan, W. S. Indirianie, and D. Safitri, "Fenomena coffee shop di kalangan konsumen remaja," pp. 137–144, 2017.
- [2] Riski Wahyu Nugroho, "Rancang Bangun Sistem Informasi Penjualan untuk Startup

- Bisnis Cafe Online pada Cafe di Daerah Caruban Jawa Timur Berbasis Web,” 2018.
- [3] M. Athir Adib Zulfakor and S. Abd Razak, “Café Finder System (Easy Meal),” *UTM Comput. Proc.*, p. 4, 2018.
- [4] F. Nurlaila, “Aplikasi Pemesanan Makanan pada Restoran 1953 Indonesia Berbasis Web,” *J. Inform. Univ. Pamulang*, vol. 4, no. 1, p. 16, 2019, doi: 10.32493/informatika.v4i1.2585.
- [5] A. S. Rajawat and A. R. Upadhyay, “Web personalization model using modified S3VM algorithm for developing recommendation process,” *2nd Int. Conf. Data, Eng. Appl. IDEA 2020*, 2020, doi: 10.1109/IDEA49133.2020.9170701.
- [6] H. Kim, S. Jung, and G. Ryu, “A Study on the Restaurant Recommendation Service App Based on AI Chatbot Using Personalization Information,” *Int. J. Adv. Cult. Technol.*, vol. 8, no. 4, pp. 263–270, 2020, [Online]. Available: <https://www.koreascience.or.kr/article/JAKO202008351737595.page%0Ahttps://doi.org/10.17703/IJACT.2020.8.4.263>.
- [7] A. Meiranny and A. M. Chabibah, “Pengaruh Konsumsi Minuman Berkafein Terhadap Pola dan Kualitas Tidur Mahasiswa : A Literatur Review,” *Mppki*, vol. 5, no. 2, pp. 117–122, 2022.
- [8] O. S. Hidayat, “Pengaruh Model Active Learning Dan Tipe Kepribadian Terhadap Kemampuan Berbicara,” *JPUD - J. Pendidik. Usia Dini*, vol. 12, no. 1, pp. 130–140, 2018, doi: 10.21009/jpud.121.11.
- [9] P. Divya *et al.*, “Web based optical character recognition application using flask and tesseract,” *Mater. Today Proc.*, no. xxxx, 2021, doi: 10.1016/j.matpr.2020.10.850.
- [10] U. B. Perjuangan, T. Rohana, U. B. Perjuangan, D. S. Kusumaningrum, and U. B. Perjuangan, “Implementasi Metode Tesseract OCR (Optical Character Recognition) untuk Deteksi Plat Nomor Kendaraan Pada Sistem Parkir,” vol. III, pp. 59–67, 2022.
- [11] P. M. Alamdari, N. J. Navimipour, M. Hosseinzadeh, A. A. Safaei, and A. Darwesh, “Image-based Product Recommendation Method for E-commerce Applications Using Convolutional Neural Networks,” *Acta Inform. Pragensia*, vol. 11, no. 1, pp. 15–35, 2022, doi: 10.18267/j.aip.167.
- [12] M. F. Naufal, “Comparative Analysis of Image Classification Algorithm for,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 2, pp. 311–318, 2021, doi: 10.25126/jtiik.202184553.
- [13] M. Toby Suwindra, A. Erlansari, and J. W. Supratman Kandang Limun, “Analisis Kemiripan Jenis Burung Menggunakan Siamese Neural Network Analysis of Bird Species Similarity Using Siamese Neural Network,” *J. Rekursif*, vol. 9, no. 2, 2021, [Online]. Available: <http://ejournal.unib.ac.id/index.php/rekursif/193>.
- [14] L. Torres, N. Monteiro, J. Oliveira, J. Arrais, and B. Ribeiro, “Exploring a Siamese Neural Network Architecture for One-Shot Drug Discovery,” *Proc. - IEEE 20th Int. Conf. Bioinforma. Bioeng. BIBE 2020*, pp. 168–175, 2020, doi: 10.1109/BIBE50027.2020.00035.
- [15] D. Z. Putri, D. Puspitaningrum, and Y. Setiawan, “Konversi Citra Kartu Nama ke Teks Menggunakan Teknik OCR dan Jaro-Winkler Distance,” *J. Teknoinfo*, vol. 12, no. 1, p. 1, 2018, doi: 10.33365/jti.v12i1.35.
- [16] K. Ibnutama, Z. Panjaitan, and E. F. Ginting, “J-SISKO TECH Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD Modifikasi Metode Template Matching pada OCR Untuk Meningkatkan Akurasi Deteksi Plat Nomor Kendaraan,” □, vol. 21, no. 2, pp. 21–29, 2019.

- [17] K. A. Baihaqi and C. Zonyfar, “Deteksi Lahan Pertanian Yang Terdampak Hama Tikus Menggunakan Yolo v5,” *Syntax J. Inform.*, vol. 11, no. 02, pp. 1–9, 2022.
- [18] E. Rasywir, R. Sinaga, and Y. Pratama, “Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN),” *Paradig. - J. Komput. dan Inform.*, vol. 22, no. 2, pp. 117–123, 2020, doi: 10.31294/p.v22i2.8907.
- [19] I. Denata, T. Rismawan, and I. Ruslianto, “Implementation of Deep Learning for Classification Type of Orange Using The Method Convolutional Neural Network,” *Telematika*, vol. 18, no. 3, p. 297, 2021, doi: 10.31315/telematika.v18i3.5541.
- [20] H. Fonda, “Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (Cnn),” *J. Ilmu Komput.*, vol. 9, no. 1, pp. 7–10, 2020, doi: 10.33060/jik/2020/vol9.iss1.144.
- [21] A. Rohim, Y. A. Sari, and Tibyani, “Convolution neural network (cnn) untuk pengklasifikasian citra makanan tradisional,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 7, pp. 7038–7042, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5851/2789>.
- [22] K. Kartarina, L. Z. A. Mardedi, M. Madani, M. Jihad, and R. A. Riberu, “Deep Learning Identifikasi Tanaman Obat Menggunakan Konsep Siamese Neural Network,” *JTIM J. Teknol. Inf. dan Multimed.*, vol. 2, no. 4, pp. 223–228, 2021, doi: 10.35746/jtim.v2i4.114.
- [23] K. Kartarina, L. Z. A. Mardedi, M. Madani, M. Jihad, and R. A. Riberu, “Deep Learning Identifikasi Tanaman Obat Menggunakan Konsep Siamese Neural Network,” *JTIM J. Teknol. Inf. dan Multimed.*, vol. 2, no. 4, pp. 223–228, 2021, doi: 10.35746/jtim.v2i4.114.