

INFORMASI INTERAKTIF

JURNAL INFORMATIKA DAN TEKNOLOGI INFORMASI

PROGRAM STUDI INFORMATIKA – FAKULTAS TEKNIK - UNIVERSITAS JANABADRA

INOVASI PEMBELAJARAN DAN TEKNOLOGI BANTU UNTUK MAHASISWA
BERKEBUTUHAN KHUSUS

Andy Ismail, Minarni, Agung Purwanto, Selviana Yunita

ANALISIS DAN PERANCANGAN PEMBUATAN REPORT PADA PENGEMBANGAN APLIKASI CMS
MENGUNAKAN RAD DI PT. DIRGANTARA INDONESIA

Putri Mentari Endraswari, Nurhaeka Tou

KLASIFIKASI JAJANAN TRADISIONAL JAWA TENGAH DENGAN METODE TRANSFER LEARNING
DAN MOBILNETV2

Aloisius Awang Hariman, Dadang Iskandar Mulyana, Mesra Betty Yel

IMPLEMENTASI METODE K-MEANS CLUSTERING PADA PENILAIAN KINERJA
KARYAWAN PT KOPETRI CITRA ABADI

Intan Melani, Bayu Priyatna, Fitria Nurapriani, Shofa Shofia Hilabi

INTEGRASI SISTEM PRESENSI BIOMETRIK DENGAN SISTEM INFORMASI SUMBER DAYA
MANUSIA UNIVERSITAS MUHAMMADIYAH SEMARANG

Mega Pranata

ANALISIS PENGARUH PENERAPAN CRM PADA APLIKASI POSAJA
TERHADAP LOYALITAS PENGGUNA

Yumarlin MZ, Sofyan Lukmanfiandy, Yanu Trinugraha, Yuan Ivo Kurniawan



DEWAN EDITORIAL

- Penerbit** : Program Studi Informatika Fakultas Teknik Universitas Janabadra
- Editor in Chief** : Fatsyahrina Fitriastuti, S.Si., M.T. (Universitas Janabadra)
- Managing Editor** : Yumarlin MZ, S.Kom., M.Pd., M.Kom. (Universitas Janabadra)
- Editor** :
1. Agus Sasmito Aribowo, S.Kom., M.Cs. (UPN Veteran Yogyakarta)
 2. Meilani Nonsi Tentua, S.Si., M.T. (Universitas PGRI Yogyakarta)
 3. Indra Yatini Buryadi, S.Kom., M.Kom. (Universitas Teknologi Digital Indonesia)
 4. Emi Suryadi, S.Kom., M.Kom. (Universitas Teknologi Mataram)
 5. Agustin Setiyorini, S.Kom., M.Kom. (Universitas Janabadra)
 6. Sri Rahayu, S.Kom., M.Eng. (Universitas Janabadra)
- Reviewer** :
1. Abba Suganda Girsang, S.T., M.Cs., Ph.D. (Universitas Bina Nusantara)
 2. Bernard Renaldy Suteja, Ph.D. (Universitas Maranatha Bandung)
 3. Putra Wanda (Universitas Respati Yogyakarta)
 4. Ryan Ari Setyawan, S.Kom., M.Eng. (Universitas Janabadra)
 5. Jemmy Edwin Bororing, S.Kom., M.Eng. (Universitas Janabadra)
 6. Saprina Mamase. S.Kom., M.Cs. (Politeknik Gorontalo)
- Sekretaris** : Taofik Krisdayanto, S.Kom.
- Alamat Redaksi** :
- Program Studi Informatika Fakultas Teknik
Universitas Janabadra
Jl. Tentara Rakyat Mataram No. 55-57
Yogyakarta 55231
Telp./Fax : (0274) 543676
E-mail: informasi.interaktif@janabadra.ac.id
Website : <http://e-journal.janabadra.ac.id/>
- Frekuensi Terbit** : 3 kali setahun

JURNAL INFORMASI INTERAKTIF merupakan media komunikasi hasil penelitian, studi kasus, dan ulasan ilmiah bagi ilmuwan dan praktisi dibidang Informatika. Diterbitkan oleh Program Studi Informatika Fakultas Teknik Universitas Janabadra di Yogyakarta, tiga kali setahun pada bulan Januari, Mei dan September.

DAFTAR ISI

	<i>halaman</i>
Inovasi Pembelajaran Dan Teknologi Bantu Untuk Mahasiswa Berkebutuhan Khusus <i>Andy Ismail, Minarni , Agung Purwanto, Selviana Yunita</i>	1-6
Analisis Dan Perancangan Pembuatan Report Pada Pengembangan Aplikasi CMS Menggunakan RAD Di PT. Dirgantara Indonesia <i>Putri Mentari Endraswari, Nurhaeka Tou</i>	7-14
Klasifikasi Jajanan Tradisional Jawa Tengah Dengan Metode Transfer Learning Dan Mobilnetv2 <i>Aloisius Awang Hariman, Dadang Iskandar Mulyana, Mesra Betty Yel</i>	15-23
Implementasi Metode K-Means Clustering Pada Penilaian Kinerja Karyawan PT. Kopetri Citra Abadi <i>Intan Melani, Bayu Priyatna, Fitria Nurapriani, Shofa Shofia Hilabi</i>	24-30
Integrasi Sistem Presensi Biometrik Dengan Sistem Informasi Sumber Daya Manusia Universitas Muhammadiyah Semarang <i>Mega Pranata</i>	31-37
Analisis Pengaruh Penerapan CRM Pada Aplikasi POSAJA Terhadap Loyalitas Pengguna <i>Yumarlin MZ, Sofyan Lukmanfiandy, Yanu Trinugraha, Yuan Ivo Kurniawan</i>	38-44

PENGANTAR REDAKSI

Puji syukur kami panjatkan kehadiran Allah Tuhan Yang Maha Kuasa atas terbitnya JURNAL INFORMASI INTERAKTIF Volume 8, Nomor 1, Edisi Januari 2023. Pada edisi kali ini memuat 6 (enam) tulisan hasil penelitian dalam bidang informatika.

Harapan kami semoga naskah yang tersaji dalam JURNAL INFORMASI INTERAKTIF edisi Januari tahun 2023 dapat menambah pengetahuan dan wawasan di bidangnya masing-masing dan bagi penulis, jurnal ini diharapkan menjadi salah satu wadah untuk berbagi hasil-hasil penelitian yang telah dilakukan kepada seluruh akademisi maupun masyarakat pada umumnya.

Redaksi

KLASIFIKASI JAJANAN TRADISIONAL JAWA TENGAH DENGAN METODE TRANSFER LEARNING DAN MOBILNETV2

Aloisius Awang Hariman¹, Dadang Iskandar Mulyana², Mesra Betty Yel³

¹²³STIKOM Cipta Karya Informatika

Jl. Raden Inten II No.8, RT.5/RW.14, Duren Sawit, Kec. Duren Sawit, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta 1344

Email : ¹awankkameikatoji@gmail.com, ²mahvin2012@gmail.com, ³bettymesra86@gmail.com

ABSTRAK

Perkembangan zaman di Indonesia telah membawa perubahan sejarah budaya, salah satunya adalah makanan atau jajanan tradisional. Jajanan tradisional merupakan makanan khas dari nenek moyang dan biasanya digunakan untuk acara atau sebuah tradisi. Masyarakat di Indonesia sudah cukup mengenal berbagai jenis jajanan tradisional dari daerah masing-masing namun untuk mengenal jajanan tradisional dari daerah lain dapat terbilang kurang memahami. Banyaknya jajanan tradisional yang ada di Indonesia khususnya di pulau Jawa membuat peneliti tertarik untuk membuat program pengenalan jenis jajanan tradisional yang ada di Jawa Tengah berdasarkan *dataset* foto dengan 6 jenis jajanan tradisional yaitu Grontol, Lanting, Lumpia, Putu Ayu, Serabi Solo dan Wajik menggunakan metode *Transfer Learning*. Implementasi pengenalan citra ini dilakukan dengan memanfaatkan *Pre-Trained* model MobileNetV2 yang diambil fitur ekstraksinya kemudian *training* CNN berjalan pada aplikasi *Google Collaboratory* dan *Tensorflow*. *Dataset* yang digunakan dalam pengujian sebanyak 1800 data *training* atau sebesar 80% dan 450 data *testing* atau sebesar 20% dengan melakukan pengujian sebanyak 50 kali dan *batch size* sebesar 32, maka diperoleh hasil akurasi sebesar 99,11% nilai *loss* sebesar 0.06.

Keywords: Jajanan Tradisional, CNN, MobileNetV2, *Transfer Learning*, *Tensorflow*

ABSTRACT

The time growth in Indonesia has brought changes in cultural history, one of which is traditional food or snacks. Traditional snacks are typical food from their ancestors and are usually used for events or a tradition. People in Indonesia are quite familiar with various types of traditional snacks from their respective regions, but to get to know traditional snacks from other regions, you can say they don't understand much. A large number of traditional snacks in Indonesia, especially on the island of Java, made researchers interested in making a program to introduce the types of traditional snacks in Central Java based on a photo dataset with 6 types of traditional snacks, namely Grontol, Lanting, Lumpia, Putu Ayu, Serabi Solo and Wajik using the method Learning Transfer. The implementation of image recognition is carried out by utilizing the Pre-Trained MobileNetV2 model, the extraction feature is taken, then CNN training runs on the Google Collaboratory and Tensorflow applications. The dataset used in the test is 1,800 training data or 80% and 450 data testing or 20% by testing 50 times and a batch size of 32, the results obtained an accuracy of 99.11% loss value of 0.06.

Keywords: Tradisional Snacks, CNN, MobileNetV2, *Transfer Learning*, *Tensorflow*

1. PENDAHULUAN

Indonesia terdiri dari beberapa pulau dan provinsi yang berpotensi besar dalam wisata makanan (*food tourism*) karena memiliki kekayaan etnis dan budaya, yang masing-masing memiliki makanan atau jajanan khas tersendiri. Hampir setiap daerah di Indonesia memiliki makanan khas yang bisa ditampilkan sebagai daya tarik bagi wisatawan domestik maupun asing. Indonesia masih menyimpan

ribuan jenis makanan dan jajanan tradisional yang berpotensi untuk dikembangkan secara global sebagai daya tarik wisata dengan mempertahankan ciri kedaerahan serta keanekaragaman jenisnya, makanan atau jajanan tradisional menjadi salah satu wujud budaya yang mencerminkan potensi alam dari suatu daerah yang sudah berkembang secara turun-temurun. Namun perkembangan zaman di Indonesia telah membawa perubahan sejarah

budaya, salah satunya adalah makanan atau jajanan tradisional.

Makanan dan jajanan tradisional merupakan makanan khas dari nenek moyang dan biasanya digunakan untuk acara atau sebuah tradisi, selain itu makanan dan jajanan tradisional bisa diartikan pula sebagai nama lain dari berbagai macam jenis salah satu contohnya adalah kue yang pada awalnya di perjual-belikan di pasar-pasar tradisional dan kemudian dikemas dan dijual ditempat penjualan makanan lainnya, seperti di toko kue atau pusat jajanan. Jajanan tradisional juga memiliki berbagai ciri khas dan cita rasa yang beragam mulai dari manis hingga gurih, masyarakat di Indonesia sudah cukup mengenal berbagai jenis jajanan tradisional dari daerah masing-masing namun untuk mengenal jajanan tradisional dari daerah lain dapat terbilang kurang memahami, bahkan jajanan atau kue-kue tradisional sekarang jarang sekali ditemukan, masyarakat Indonesia menganggap makanan dan jajanan tradisional merupakan pangan yang sudah ketinggalan zaman.

Penelitian sebelumnya oleh Refi Fadholi, Yuita Arum Sari dan Fitra Abdurrachman Bachti (2019) telah melakukan Pengenalan Citra Makanan Tradisional menggunakan Fitur *Hue Saturation Value* dan *Fuzzy k-Nearest Neighbor*. Klasifikasi dilakukan menggunakan metode *Fuzzy k-NN* dan *k-Fold Cross Validation*. Hasil pengujian nilai *k* (*k-Fold*) dan *k* (*k-NN*) mendapatkan hasil akurasi rata-rata tertinggi sebesar 53,33%, Hasil pengujian juga menunjukkan bahwa kemiripan citra antar kelas, kualitas data citra yang kurang bagus dan tidak meratanya data membuat nilai akurasi pengujian jadi menurun [1].

Penelitian oleh Fida Dwi Febriani, Yuita Arum Sari dan Randy Cahya Wihandika (2019) telah melakukan Klasifikasi Citra Kue Tradisional Indonesia Berdasarkan Ekstraksi Fitur Warna RGB *Color Moment* Menggunakan *K-Nearest Neighbor*. Pada penelitian ini, terdiri dari 29 objek kue tradisional Indonesia yang akan digunakan, dimana skenario pengujian dibagi menjadi 29 kelas, 8 kelas, 5 kelas dan 3 kelas. Dengan menggunakan metode *K-NN* serta fitur *Color Moment*, mendapatkan nilai evaluasi tertinggi sebesar 60% untuk skenario pengujian terhadap 3 kelas [2].

Penelitian oleh Muhammad Dandi Darajat, Yuita Arum Sari dan Randy Cahya Wihandika (2021) telah melakukan *Convolutional Neural Network* untuk Klasifikasi Citra Makanan Khas

Indonesia. Berdasarkan percobaan yang dilakukan sebanyak 8 kali pada 27 model, memperoleh model terbaik dengan nilai akurasi pengujian yaitu 0,6 dan akurasi evaluasi 0,91. Hal ini menunjukkan bahwa algoritma CNN relatif baik untuk diterapkan pada klasifikasi citra makanan khas Indonesia [3].

Penelitian oleh Ahmad Solihin, Dadang Iskandar Mulyana dan Mesra Betty Yel (2022) telah melakukan Klasifikasi Alat Musik Tradisional Papua menggunakan Metode *Transfer Learning* Dan Data Augmentasi. Dengan menghasilkan nilai *dataset* yang digunakan dalam pengujian sebanyak 979 data *training* dan 143 data *testing* dan menghasilkan nilai evaluasi dengan nilai *precision* 98%, *recall* 98%, *f1-score* 98%, *accuracy* 98,46% serta *loss* 0.051 [4].

Penelitian oleh Elok Iedfitra dan Abas Setiawan (2021) telah melakukan Pengenalan Jamur Yang Dapat DiKonsumsi Menggunakan Metode *Transfer Learning* Pada *Convolutional Neural Network*, Digunakan empat *Base Model* yaitu MobileNets, MobileNetV2, ResNet50 dan VGG19. Setiap *Base Model* akan diterapkan beberapa skenario percobaan seperti, melihat perbedaan nilai *Learning Rate* pada saat *pre-training* dan *fine-tuning*. Hasil pengujian memperlihatkan bahwa metode *Transfer Learning Convolutional Neural Network* dapat mengenali jamur yang bisa dikonsumsi dengan akurasi lebih dari 86%. Hasil nilai akurasi terbaik ialah 92.19% yang didapatkan dari penerapan *base model* MobileNetsV2 dengan nilai *learning rate* 0,00001 pada tahap *pre-training* dan 0,0001 pada tahap *fine-tuning* [5].

Penelitian oleh Mira, Irwan Sembiring dan Hindriyanto Dwi Purnomo (2022) telah melakukan Implementasi *Transfer Learning* Pada Algoritma *Convolutional Neural Network* untuk Mengklasifikasikan *Image* Objek Wisata, Berdasarkan hasil *training* dan evaluasi dari keempat data bahwa 210 data menunjukan akurasi sebesar 0.8598 dengan *loss* 0.3245, sedangkan 290 data menunjukkan akurasi sebesar 0.8685 dengan *loss* 0.2903. Kemudian 594 data menunjukan akurasi sebesar 0.8852 dengan *loss* 0.2756 dan 1000 data menunjukkan akurasi sebesar 0.8833 dengan *loss* 0.2863 [6].

Penelitian oleh Gustavo Tiodorus, Anugrah Prasetya, Luthfi Afrizal Ardhani dan Novanto Yudhistira telah melakukan Klasifikasi citra makanan/nonmakanan menggunakan metode *Transfer Learning* dengan model *Residual*

Network, Hasil yang didapatkan, yaitu model ResNet18 dengan metode *fine tuning* menghasilkan nilai akurasi sebesar 0,981 dan dengan metode *freeze layer* menghasilkan nilai terbaik akurasi sebesar 0,988. Model AlexNet dengan metode *fine tuning* menghasilkan nilai akurasi sebesar 0,970 dan metode *freeze layer* menghasilkan nilai akurasi terbaik sebesar 0,978 [7].

Berdasarkan permasalahan di atas dengan banyaknya jenis jajanan tradisional yang ada di Indonesia khususnya di pulau Jawa membuat peneliti tertarik untuk membuat suatu program pengenalan jenis citra jajanan tradisional khususnya yang ada di Jawa Tengah berdasarkan *dataset* foto atau 6 citra jajanan tradisional yaitu Grontol, Lanting, Lumpia, Putu Ayu, Serabi Solo, dan Wajik dengan menerapkan metode *Transfer Learning* dan memanfaatkan *Pre-Trained* model dari MobileNetV2 pada sampel citra yang kemudian dijadikan sebagai *dataset* proses *training* *Convolutional Neural Network* (CNN). Tujuan penelitian ini diharapkan dapat mengetahui jumlah data yang tepat guna dapat menghasilkan nilai akurasi yang cukup tinggi dari citra jajanan tradisional serta ikut memberikan kontribusi pengenalan jajanan tradisional dalam melestarikan makanan atau jajanan tradisional Indonesia khususnya di Jawa Tengah.

2. TINJAUAN PUSTAKA

2.1 Jajanan Tradisional

Indonesia merupakan sebuah negara kepulauan yang memiliki 34 provinsi dan setiap provinsi memiliki ciri khasnya masing-masing, yang membedakannya dengan daerah lain, terutama dalam hal kebudayaan. Artinya, sebuah kebudayaan yang ada di suatu provinsi belum tentu dapat ditemukan di provinsi lain. Kebudayaan ini tidak hanya mencakup tarian tradisional, senjata, rumah adat, pakaian adat, alat musik dan lagu daerah, akan tetapi juga termasuk kuliner khas didalamnya. Salah satu provinsi yang terkenal dengan berbagai kuliner khasnya adalah Jawa Tengah, Selain terkenal dengan wisata alam, sejarah dan budayanya, Jawa Tengah juga mempunyai banyak makanan dan minuman khas. Tidak hanya makanan utama saja, namun di provinsi ini juga terdapat berbagai jajanan tradisional dan kue khas Jawa Tengah [8]. Berikut inilah Jajanan Tradisional

dari provinsi Jawa Tengah yaitu, Grontol, Lanting, Lumpia, Putu Ayu, Serabi Solo dan Wajik.


2.2 Pengolahan Citra Digital

Proses pengolahan data teks sangat berbeda dengan pengolahan citra. Dalam pengolahan citra ini dilakukan menggunakan beberapa teknik untuk memanipulasi citra agar dapat diketahui perbedaan atau ciri khas yang membedakan antara citra yang satu dengan citra yang lain. Pengolahan citra merupakan proses memanipulasi citra dengan mesin komputer dengan artian agar kualitas citra tersebut menjadi lebih baik. Terdapat satu hal yang penting dalam konsep pengolahan citra yaitu mengekstrak informasi dari citra tersebut, sebagai contoh seperti pengenalan berdasarkan bentuknya. Salah satu metode pengolahan citra yaitu *Edge detection*, yaitu suatu pemrosesan citra terhadap bidang *feature detection* dan *feature extraction*. *Edge* merupakan batas-batas dalam sebuah objek yang digunakan untuk mendeteksi dan mengidentifikasi tepi dalam citra digital [9].

2.3 Klasifikasi

Klasifikasi adalah proses untuk mencari model yang dapat membagi suatu data berdasarkan kelasnya yang dibagi menjadi dua tahapan, yang pertama adalah pelatihan (*learning*) atau tahap pembelajaran terhadap suatu data yang telah diketahui kategorinya sedangkan pengujian (*testing*) adalah tahapan evaluasi terhadap kinerja dari model hasil dari tahap pelatihan dengan data baru sebagai data uji kemudian *output* dari tahap ini berupa tingkat akurasi/keberhasilan suatu model dalam memprediksi data yang belum diketahui kategorinya yaitu dengan data uji [10].

Machine Learning
Gambar 1 Perbedaan *Machine Learning* dan *Deep Learning*



2.4 Machine Learning

Secara definisi, *machine learning* merupakan cabang dari ilmu kecerdasan buatan yang berfokus pada pembangunan dan pembelajaran sebuah sistem agar mampu belajar dari data-data yang diperolehnya. Menurut Arthur Samuel, *machine learning* adalah bidang studi yang memberikan kemampuan program komputer untuk belajar tanpa eksplisit diprogram. Untuk bisa mengaplikasikan teknik-teknik *machine learning* maka diperlukannya sebuah data. Tanpa data maka algoritma pada *machine learning* tidak dapat bekerja. Data yang ada biasanya dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih algoritma, sementara data *testing* digunakan untuk mengetahui performa algoritma yang telah dilatih sebelumnya ketika menemukan data baru yang belum pernah dilihat [11].

2.5 Deep Learning

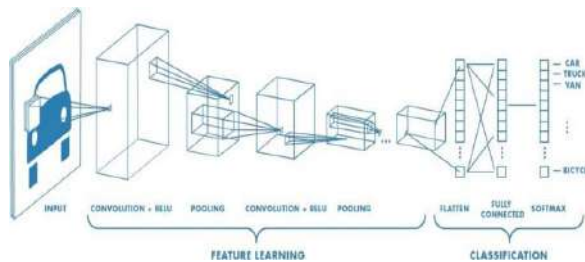
Deep Learning adalah salah satu jenis algoritma jaringan saraf tiruan yang menggunakan data serta memberikan informasi sebagai masukan dan memprosesnya menggunakan sejumlah lapisan tersembunyi (*hidden layer*) transformasi *non linier* dari data masukan untuk menghitung nilai luaran. Algoritma pada *deep learning* memiliki fitur yang unik yaitu sebuah fitur yang mampu mengekstraksi secara otomatis. Hal ini berarti algoritma yang dimiliki secara otomatis dapat menangkap fitur yang relevan sebagai keperluan dalam pemecahan suatu masalah. Algoritma semacam ini sangatlah penting dalam sebuah kecerdasan buatan karena dapat mengurangi beban pemrograman dalam memilih fitur yang eksplisit atau dapat tersampaikan secara langsung. Algoritma ini dapat digunakan untuk memecahkan permasalahan yang perlu pengawasan (*supervised*), tanpa pengawasan (*unsupervised*) dan semi terawasi (*semi supervised*) [12]. Pemodelan jaringan *deep learning* ditunjukkan pada gambar berikut :

2.6 Transfer Learning

Transfer Learning adalah suatu metode ataupun teknik dengan menggunakan model *pre-trained* (sudah dilatih terhadap suatu *dataset*) untuk menyelesaikan permasalahan lain yang serupa dengan cara menggunakannya sebagai *starting point*, kemudian memodifikasi serta mengupdate parameternya sehingga sesuai dengan *dataset* kasus permasalahan yang baru. Contoh dari *Transfer Learning* yaitu menggunakan model *pre-trained* yang kemudian dilatih untuk mengenali mobil, lalu model tersebut digunakan untuk mengenali truk. Mengenai perbedaan antara *Machine Learning* dan *Transfer Learning* dapat dilihat perbedaan yang sangat mencolok, pada *Transfer Learning* terdapat proses *knowledge transfer* antara model A yang merupakan model *pre-trained* dan model B yang nanti akan menjadi model baru untuk kasus yang baru juga. *Transfer Learning* membutuhkan model *pre-trained* yang akan digunakan lalu model itu akan dimodifikasi dan dilakukan *fine-tuning* sesuai dengan kasus baru yang akan diteliti. [13]

2.7 Convolutional Neural Network (CNN)

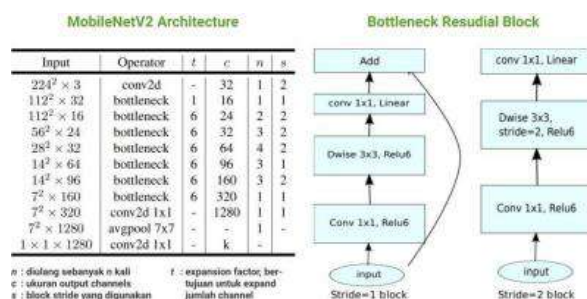
Convolutional Neural Network (CNN) merupakan salah satu jenis *neural networks* yang ada pada *deep learning*. Berbeda dengan ANN dan RNN, CNN merupakan salah satu jenis *neural networks* yang biasanya digunakan untuk mengolah data dalam bentuk citra. CNN bekerja menggunakan *kernel*. Dimana *kernel* tersebut nanti akan mengekstrak fitur dari *input* menggunakan operasi konvolusi. Dapat disimpulkan CNN tidak jauh berbeda dengan *neural network*, *neuron* pada CNN memiliki *weight*, bias, dan *activation function*. Adapun lapisan penyusun dari sebuah CNN terdiri atas *Convolution Layer*, *Activation ReLU Layer*, *Pooling Layer*, dan *Fully Connected Layer*. Cara kerja *Convolutional Neural Network* meniru dari jaringan syaraf otak manusia [4].



Gambar 2 Arsitektur *Convolutional Neural Network*

2.8 MobileNetV2

Arsitektur *Convolutional Neural Networks* (CNN) MobileNetV2 mempunyai nilai *score* akurasi yang cukup tinggi, serta yang menjadi keunggulan utamanya merupakan jumlah *training* parameters yang cukup kecil dibandingkan dengan arsitektur CNN model lainnya, sehingga kebutuhan akan komputasinya lebih ringan. Selain itu model *size* MobileNetV2 ukurannya juga kecil, hanya sekitar 14 MB saja, namun tentunya dengan hasil performa yang baik. Sehingga kedepannya jika model tersebut akan di dibangun kedalam sebuah *real app*, sebagai contoh aplikasi *android* ataupun aplikasi berbasis *website* maka akan ringan dan berukuran kecil.



Gambar 3 Arsitektur MobileNetV2

2.9 Tensorflow

TensorFlow merupakan sebuah *open-source library* untuk *machine learning* yang di *release* oleh Google yang mendukung beberapa bahasa pemrograman. Dalam proses *Transfer Learning*, *Tensorflow* berperan penting untuk memproses *Inception-v3* Model untuk di *training* ulang menggunakan data yang baru dan kemudian menghasilkan *classifier* dengan komputasi yang cepat dan akurasi yang baik. *Tensorflow* juga dapat digunakan pada semua sistem operasi [14].

3. METODE PENELITIAN

Penelitian ini menggunakan metode *Transfer Learning* dengan memanfaatkan model terlatih (*pre-trained model*) dari MobileNetV2 sebagai dasar pembuatan model *final*. Tahap awal yang dilakukan dengan mengumpulkan data-data penelitian yang dijadikan sebagai dataset dan akan di proses lebih lanjut dalam pengujian. Hasil pengujian berupa nilai evaluasi dari keseluruhan hasil pengujian. Berikut merupakan tahapan yang dilakukan.

3.1 Dataset Pengujian

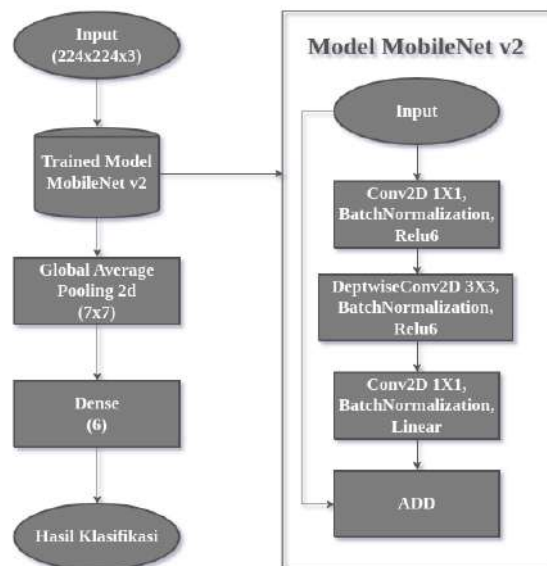
Proses pengambilan data pada penelitian ini menggunakan *dataset public*. *Dataset public* diambil dari *google image* dan *kaggle* lalu *dataset* dari jajanan tradisional tersebut di *download* dengan menggunakan bantuan aplikasi *Fatkun Batch Download Image*. Sedangkan untuk sampel yang digunakan dalam penelitian ini hanya mengambil 6 jenis jajanan tradisional dengan total sampel sebanyak 1800 citra untuk data *training* dan 450 citra untuk data *testing* dengan masing-masing 75 data *test* pada setiap kelasnya. Berikut merupakan 6 jajanan tradisional yang digunakan dalam penelitian seperti pada table 1 yang ada di bawah ini :

Table 1 *Dataset Pengujian*

No.	Variabel	Latih	Uji	Definisi Variabel
1	Grontol	300	75	Citra berupa jajanan tradisional Grontol
2	Lanting	300	75	Citra berupa jajanan tradisional Lanting
3	Lumpia	300	75	Citra berupa jajanan tradisional Lumpia
4	Putu Ayu	300	75	Citra berupa jajanan tradisional Putu Ayu
5	Serabi Solo	300	75	Citra berupa jajanan tradisional Serabi Solo
6	Wajik	300	75	Citra berupa jajanan tradisional Wajik

3.2 Rancangan Pengujian

Berikut merupakan rancangan pengujian yang digunakan dalam penelitian ini :



Gambar 4 Model Pengujian

Pada gambar 4 diatas merupakan *flow diagram* pengujian model yang dilakukan dalam klasifikasi jajanan tradisional. Tahap awal adalah merubah ukuran citra *input* menjadi 224x224x3 yang kemudian dilakukan proses *Featur Scalling* untuk mendapatkan nilai citra, hal ini dilakukan untuk memaksimalkan hasil klasifikasi yang akan di peroleh nantinya. Setelah itu data *input* akan di lakukan proses *training* terlebih dahulu dengan *Pre-Trained Model MobileNetv2* untuk mendapatkan fitur ekstraksinya. Pada proses ekstaksi fitur dilakukan dengan beberapa *stride* (*stride=n*) yang mana dalam setiap *stride* dilakukan dengan beberapa tahapan yang dilakukan hingga *stride n*. Pada gambar 4 sebelah kanan merupakan *block* tahapan yang dilakukan dalam setiap *stride* yang dinamakan *Bottleneck Residual block*.

Pada MobileNetv2 terdapat 17 *stride block* namun untuk mendapatkan ekstraksi fitur kali hanya menggunakan 16 *stride block* penyaringan. Pada citra input terdapat 3-layer konvolusi di *block*. 2 terakhir merupakan *depthwise convolution* yang menyaring input, diikuti oleh *layer* konvolusi 1x1 untuk membuat saluran agar lebih kecil yang dikenal sebagai *layer* proyeksi (*projection layer*), lapisan ini memproyeksikan data dengan jumlah dimensi (saluran) yang tinggi ke dalam *tensor* dengan jumlah dimensi yang jauh lebih rendah. Untuk *depthwise convolution* bekerja pada *tensor* dengan 144 *channel/saluran*, yang kemudian *layer* proyeksi akan menyusut menjadi 24 *channel* yang disebut *bottleneck layer* karena mengurangi jumlah data yang mengalir ke

jaringan. Dari sinilah “*bottleneck residual block*” mendapatkan nama dari *output* di setiap *block* adalah *bottleneck*.

Layer pertama merupakan anak baru *block* yang merupakan konvolusi 1x1 yang bertujuan untuk memperluas jumlah saluran dalam data sebelum masuk ke *depthwise convolution*, oleh karena itu lapisan ekspansi memiliki banyak *output chanel* dibandingkan *chanel* masukan dengan faktor ekspansi default adalah 6 (ReLU6). Pada *Stide block* selanjutnya dilakukan dengan cara yang sama secara berurutan yaitu diikuti konvolusi 1x1 *regular*, *global average pooling layer*, dan *layer* klasifikasi dengan blok pertama menggunakan konvolusi 3x3 dengan 32 *chanel* di dalamnya. Setelah mendapatkan ekstraksi fitur maka dilakukan *Global Average Pooling* berukuran (7x7) dan *dense* sebanyak 6 *neuron* sesuai dengan banyaknya label klasifikasi yang disebut dengan *Softmax*.

4. PEMBAHASAN

Setelah model sebelumnya selesai dibuat, selanjutnya melakukan pelatihan data jajanan tradisional Jawa Tengah kedalam fungsi *his* yaitu fungsi memanggil histori model dengan melakukan melakukan *fit model*. Data citra yang digunakan dalam penelitian ini adalah data 6 kelas jajanan tradisional Jawa Tengah dengan jumlah data latih (*train*) sebanyak 2250 yang dibagi menjadi 1800 data *training* atau sebesar 80% dan 450 data *testing* atau sebesar 20%. Setelah pengujian, selanjutnya kita uji coba untuk melakukan prediksi dari model yang sudah dibuat pada 42 data citra yang terdiri dari 6 kelas. Setelah model *final* selesai dibuat selanjutnya kita masukan kedalam *fit model*, dengan *epoch* sebanyak 50 kali dan *batch size* sebesar 32 *neurons*. *Epoch* merupakan banyaknya jaringan akan melihat seluruh kumpulan data, sedangkan *batch_size* adalah jumlah contoh pelatihan dalam satu *forward/backward pass*. Semakin tinggi nilai suatu *batch_size* maka akan semakin banyak memori yang diperlukan.

4.1 Hasil Pengujian


Table 2 Hasil Pengujian

No.	Data Training		Data Validation	
	Loss	Accuracy	Val_loss	Val_acc
1	1.577384	0.365385	1.282915	0.531250
2	1.136413	0.640271	0.947434	0.741071
3	0.852803	0.782240	0.737928	0.808036


4	0.682074	0.838801	0.603259	0.859375
5	0.567415	0.870475	0.511328	0.895089
6	0.483692	0.895928	0.445808	0.910714
7	0.427706	0.904977	0.395867	0.921875
8	0.383875	0.915724	0.357434	0.930804
9	0.348404	0.924208	0.327016	0.935268
10	0.319162	0.929299	0.300024	0.939732
11	0.295311	0.934955	0.277760	0.948661
12	0.273628	0.938914	0.259202	0.950893
13	0.257108	0.943439	0.241384	0.955357
14	0.242586	0.947398	0.227450	0.957589
15	0.228405	0.948529	0.213575	0.964286
16	0.216966	0.951923	0.202900	0.966518
17	0.203928	0.958145	0.191658	0.968750
18	0.195277	0.958705	0.181412	0.970982
19	0.186840	0.962104	0.174128	0.970982
20	0.176261	0.963235	0.164974	0.970982
21	0.169297	0.965498	0.156475	0.973214
22	0.162513	0.966063	0.150426	0.973214
23	0.156981	0.966629	0.143276	0.973214
24	0.150260	0.966629	0.137457	0.977679
25	0.145118	0.970023	0.132478	0.977679
26	0.139503	0.968891	0.126503	0.979911
27	0.134337	0.971719	0.121510	0.984375
28	0.128697	0.973416	0.116392	0.986607
29	0.123975	0.973982	0.112333	0.988839
30	0.119203	0.977941	0.109252	0.988839
31	0.116760	0.976810	0.105298	0.988839
32	0.111356	0.979072	0.101260	0.988839
33	0.106588	0.979638	0.097595	0.988839
34	0.103923	0.981335	0.094727	0.988839
35	0.102640	0.980769	0.091171	0.988839
36	0.098841	0.981335	0.087699	0.988839
37	0.096098	0.982466	0.085617	0.988839
38	0.093098	0.983032	0.082581	0.988839
39	0.089894	0.984163	0.080401	0.988839
40	0.087580	0.984163	0.078073	0.988839
41	0.084729	0.984163	0.075520	0.988839
42	0.082043	0.985294	0.072912	0.988839
43	0.078278	0.985860	0.070764	0.988839
44	0.077813	0.986991	0.068778	0.988839
45	0.075607	0.986425	0.066978	0.988839
46	0.073077	0.986425	0.065192	0.988839
47	0.069872	0.988688	0.063144	0.988839
48	0.068491	0.989253	0.061359	0.991071
49	0.066981	0.988688	0.060281	0.991071
50	0.064052	0.990385	0.057584	0.991071

Dapat dilihat dari tabel 2 diatas setelah melakukan pelatihan dengan *epoch* sebanyak 50 kali terhadap data *train* dan data *test* bahwa iterasi menghasilkan nilai akurasi dan nilai *loss* yang sangat baik. Nilai akurasi merupakan nilai yang dapat digunakan sebagai acuan dalam mengetahui tingkat keberhasilan/kelayakan model yang telah dibuat dan nilai *loss* merupakan ukuran dari kegagalan/error yang dibuat *networks* yang bertujuan untuk

meminimalisirnya. Pada data *train* diperoleh nilai tertinggi akurasi sebesar 99.04 % dan nilai *loss* terendah sebesar 0.064052 sedangkan pada data validasi diperoleh nilai akurasi tertinggi pada 99,11% dan nilai *loss* terendah sebesar 0.057584. Hasil dari proses pelatihan diatas dapat dilihat dengan visualisasi plot/grafik berikut ini :



Gambar 5 Plot Accuracy Data Train vs Data Validasi



Gambar 6 Plot Loss Data Train vs Data Validasi

Dari gambar 5 dan 6 diatas dapat diketahui bahwa hubungan antara nilai *accuracy* dan nilai *loss* pada data *train* dan data validasi dengan jumlah *epoch*. Hubungan yang terjadi pada nilai akurasi menunjukkan korelasi positif yang memiliki hubungan searah dengan ketentuan semakin banyak jumlah *epoch* yang digunakan maka nilai *accuracy* data *train* dan data *validation* semakin tinggi. Berbanding terbalik dengan nilai *accuracy*, hubungan antara banyaknya *epoch* dengan nilai *loss* merupakan korelasi negatif dimana banyaknya jumlah *epoch* yang digunakan akan mempengaruhi

nilai *loss* yang dihasilkan pada pelatihan data semakin kecil. Berdasarkan hasil tersebut, maka dapat disimpulkan bahwa untuk memperkecil nilai *loss* yang ingin diharapkan maka dapat dilakukan dengan cara memperbanyak jumlah *epoch* pada proses *training*.

4.2 Evaluasi Model

Setelah melakukan *training* dan evaluasi model *final* dengan memanfaatkan fitur ekstraksi model MobileNetv2 terhadap *dataset* sebanyak 2250 citra yang terbagi atas 1800 data *training* atau sebesar 80% dan 450 data *testing* atau sebesar 20% dengan melakukan pengujian sebanyak 50 kali dan *batch size* sebesar 32, maka diperoleh hasil akurasi sebesar 99,11% namun memiliki nilai *loss* sebesar 0.06.

5. KESIMPULAN

Berdasarkan hasil penelitian dan hasil penerapan dari *pre-Trained Model* MobileNetV2 dengan metode *Transfer Learning* dalam mengklasifikasikan 6 jenis Jajanan Tradisional Jawa Tengah, memiliki kesimpulan bahwa citra dapat melewati *preprocessing process* dengan baik dengan merubah ukuran dimensinya menjadi 224x224x3 *pixel* dan dilakukan *Feature Scalling* untuk mendapatkan nilai citra, kemudian *Feature Extraction* dari *pre-Trained Model* MobileNetv2 yang dilatih pada *ImageNet* menghasilkan nilai dimensi 7x7x1280 *pixel*. Nilai akurasi semakin baik apabila data *train* semakin banyak, seperti pengujian kali ini dengan perbandingan jumlah data *training* sebanyak 80% dan data validasi sebanyak 20%. Dengan memanfaatkan *Feature Extraction* dari *pre-Trained Model* MobileNetV2 pada model *final* yang dibuat terhadap *dataset* sebanyak 2250 citra yang terbagi menjadi 1800 data *training* atau sebesar 80% dan 450 data *testing* atau 20% serta melakukan pengujian model sebanyak 50 *epoch* dan *batch size* 32 *neuron*, maka diperoleh hasil akurasi *final* sebesar 99.11% dan nilai *loss* sebesar 0,06.

DAFTAR PUSTAKA

- [1] R. Fadholi, Y. A. Sari, and F. A. Bachtiar, "Pengenalan Citra Makanan Tradisional menggunakan Fitur Hue Saturation Pengenalan Citra Makanan Tradisional menggunakan Fitur Hue Saturation Value dan Fuzzy k-Nearest Neighbor," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 7, pp. 6556–6566, 2019.
- [2] F. D. Febriani, Y. A. Sari, and R. C. Wihandika, "Klasifikasi Citra Kue Tradisional Indonesia Berdasarkan Ekstraksi Fitur Warna RGB Color Moment Menggunakan K-Nearest Neighbor," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 10, pp. 10199–10206, 2019.
- [3] M. Dandi Darajat, Y. A. Sari, and R. C. Wihandika, "Convolutional Neural Network untuk Klasifikasi Citra Makanan Khas Indonesia," vol. 5, no. 11, pp. 4764–4769, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>.
- [4] A. Solihin, D. I. Mulyana, and M. B. Yel, "Klasifikasi Jenis Alat Musik Tradisional Papua menggunakan Metode Transfer Learning dan Data Augmentasi," *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 5, no. 2, pp. 36–44, 2022, doi: 10.47970/siskom-kb.v5i2.279.
- [5] E. I. Haksoro and A. Setiawan, "Pengenalan Jamur Yang Dapat Dikonsumsi Menggunakan Metode Transfer Learning Pada Convolutional Neural Network," *J. ELTIKOM*, vol. 5, no. 2, pp. 81–91, 2021, doi: 10.31961/eltikom.v5i2.428.
- [6] M. Mira, I. Sembiring, and H. D. Purnomo, "Implementasi Transfer Learning Pada Algoritma Convolutional Neural Network untuk Mengklasifikasikan Image Objek Wisata," *Build. Informatics, Technol. Sci.*, vol. 4, no. 1, pp. 209–216, 2022, doi: 10.47065/bits.v4i1.1764.
- [7] G. Thiodorus, A. Prasetya, L. A. Ardhani, and N. Yudistira, "Klasifikasi citra makanan/non makanan menggunakan metode Transfer Learning dengan model Residual Network," *Teknologi*, vol. 11, no. 2, pp. 74–83, 2021, doi: 10.26594/teknologi.v11i2.2402.
- [8] G. Amadeo, "10 Rekomendasi Kue Khas di Daerah Jawa Tengah Yang Unik dan Menggoda, Mana Favoritmu?," *jejakpiknik*, 2022. <https://jejakpiknik.com/kue-khas-jawa-tengah/> (accessed Oct. 29, 2022).
- [9] M. Resa, A. Yudianto, and H. Al Fatta, "Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network," *J. Teknol. Inf.*, vol. 4, no. 2, pp. 182–190, 2020.
- [10] S. Riyadi and D. I. Mulyana, "Optimasi Image Classification pada Wayang Kulit Dengan Convolutional Neural Network," vol. 1, no. September 2021, pp. 1–8, 2022.
- [11] Z. A. Fikriya, M. I. Irawan, and S. Soetrisno., "Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital," *J. Sains dan Seni ITS*, vol. 6, no. 1, 2017, doi: 10.12962/j23373520.v6i1.21754.
- [12] N. Nufus *et al.*, "Sistem Pendeteksi Pejalan Kaki Di Lingkungan Terbatas Berbasis SSD

- MobileNet V2 Dengan Menggunakan Gambar 360° Ternormalisasi,” *Pros. Semin. Nas. Sains Teknol. dan Inov. Indones.*, vol. 3, no. November, pp. 123–134, 2021, doi: 10.54706/senastindo.v3.2021.123.
- [13] A. E. Wijaya, W. Swastika, and O. H. Kelana, “Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray,” *Sainsbertek J. Ilm. Sains Teknol.*, vol. 2, no. 1, pp. 10–15, 2021, doi: 10.33479/sb.v2i1.125.
- [14] P. A. Nugroho, I. Fenriana, and R. Arijanto, “Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia,” *Algor*, vol. 2, pp. 12–21, 2020.