Digital Transformation Technology (Digitech) | e-ISSN: 2807-9000
Volume 4, **Number** 1, Maret 2024
https://doi.org/10.47709/digitech.v4i1.4449

Penerapan *MobileNet Architecture* pada Identifikasi Foto Citra Makanan Indonesia

Muhammad Farid Wijayanto[1*], Daniel Swanjaya[2], Resty Wulanningrum[3]
[1,2,3]Universitas Nusantara PGRI Kediri, Indonesia
[1]faridwijayaaa@email.com, [2]daniel@unpkediri.ac.id, [3]restyw@unpkediri.ac.id

open access
Histori Artikel:
Diajukan: 2 Agustus 2024
Disetujui: 15 Agustus 2024
Dipublikasi: 16 Agustus 2024
Kata Kunci:
Mobilenet, Klasifikasi; Makanan Indonesia, Foto Citra, CNN
Digital Transformation Technology (Digitech) *is an Creative Commons License This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).*

Abstrak
Pengenalan gambar makanan secara otomatis telah menjadi area penelitian yang menarik, terutama dalam pengembangan *MobileNet* berbasis kuliner. Penelitian ini membahas penerapan arsitektur *MobileNet* dalam mengidentifiksi foto citra makanan Indonesia. *MobileNet*, sebagai jaringan saraf konvolusional yang efisien dan ringan, memungkinkan pengenalan gambar dengan cepat dan akurat pada perangkat dengan keterbatasan komputasi. Tujuan dari penelitian ini yaitu untuk mengetahui hasil dari identifikasi foto citra makanan Indonesia menggunakan Arsitektur dari *MobileNet* dan untuk mencapai performa terbaik dari model *Convolutional Neutral Network* menggunakan arsitektur *MobileNet*. Penelitian ini melibatkan pengumpulan dataset gambar makanan Indonesia, pelatihan model *MobileNet*, dan evaluasi kinerja model dalam mengklasifikasikan gambar tersebut. Hasil penelitian menunjukkan bahwa arsitektur *MobileNet* dapat diimplementasikan dengan efektif untuk identifikasi makanan Indonesia, dengan tingkat akurasi yang memuaskan dan waktu pemrosesan yang relatif singkat. Temuan ini diharapkan dapat berkontribusi dalam pengembangan aplikasi pengenalan gambar di bidang kuliner, khususnya untuk makanan Indonesia. Hasil akhir dari penelitian ini menunjukkan bahwa MobileNet berhasil mencapai akurasi sebesar 98.99% dan loss terkecil sebesar 0.05 dalam mengidentifikasi gambar. Keberhasilan dalam penelitian ini membuka peluang untuk pengembangan *MobileNet* berbasis pengenalan gambar makanan yang lebih canggih. Selain itu, penelitian ini juga dapat berkontribusi pada pengembangan teknologi visi komputer secara umum, khususnya dalam bidang klasifikasi gambar objek kecil dan kompleks.

PENDAHULUAN

Pada tahun 2020, *trend* memotret makanan sebelum dimakan sudah menjadi kebiasaan yang membawa kegembiraan bagi pecinta kuliner. Hasil foto makanan yang pernah dicoba, rekomendasi masakan, atau bahkan masakan yang dibuat sendiri selanjutnya diunggah di situs media sosial seperti Facebook dan Instagram. Namun, orang yang melihat foto tersebut seringkali lupa atau tidak mengetahui nama makanan tersebut (R, 2023). Hal ini dikarenakan foto makanan di media sosial seringkali tidak mencantumkan nama makanan tersebut.

Indonesia merupakan salah satu negara yang memiliki beragam kuliner yang dapat dinikmati oleh masyarakatnya. Beberapa jenis makanan yang populer di masyarakat seperti Gudeg, Ayam Betutu, Beberuk Terong, Coto Makassar, Kerak Telor, dan lain sebagainya. Foto-foto makanan Indonesia yang diposting di media sosial tanpa disertai informasi nama makanan dan seringkali hanya setengah bagian, diambil dari sudut vertikal, dan miring mengakibatkan kesulitan bagi orang untuk mengidentifikasi jenis makanan yang ditampilkan.

Klasifikasi gambar seringkali dilakukan dengan menggunakan metode *deep learning*. Metode ini merupakan kecerdasan buatan dengan representasi sederhana dengan lapisan tersembungi untuk mengolah data yang dapat menciptakan konsep yang kompleks. *Deep learning* dapat dilatih untuk mengenali dan mengklasifikasikan objek (Hartono et al., 2022). Salah satu bagian dari *deep neural network* yang sering digunakann dalam pengenalan dan pemrosesan gambar adalah *Convolutional Neural Network* (CNN/ConvNet). Algoritma ini dirancang khusus untuk memproses data piksel dan gambar visual (Trivusi, 2022).

Pada penelitian ini dirancang penerapan *MobileNet Architecture* dengan menggunakan metode CNN untuk mendapatkan performa terbaik dari mengidentifikasi jenis makanan Indonesia. Selain itu penelitian ini bertujuan untuk membantu masyarakat dalam mengetahui nama makanan yang belum diketahui melalui identifikasi foto citra makanan Indonesia yang menggunakan Arsitektur dari *MobileNet.*

STUDI LITERATUR

Klasifikasi merupakan suatu metode pengelompokan objek berdasarkan ciri-ciri yang dimiliki oleh objek yang diklasifikasikan tersebut. Klasifikasi dapat dilakukan secara manual atau dengan bantuan teknologi. Pengklasifikasian yang menggunakan algoritma teknologi dapat dilakukan untuk meningkatkan efektivitas dalam analisis data, seperti penggunaan *Naive Bayes, Support Vector Machines, Decision Trees, Fuzzy,* dan *Artificial Neural Networks* (Wibawa et al., 2018).

Deep learning merupakan proses pembelajaran yang menggunakan algoritma yang berkaitan dengan hukum matematika yang berfungsi seperti otak manusia. Pembelajaran mendalam digunakan untuk berbagai tugas, termasuk memprediksi peluang dan peristiwa, mengenali objek, dan mendiagnosis penyakit. Salah satu kemungkinan penerapan *deep learning* adalah pada bidang pengolahan citra atau pengolahan citra digital. Sistem pengolahan citra bertujuan untuk membantu manusia mengenali atau mengklasifikasikan objek secara efisien, cepat, dan akurat, serta dapat memproses data dalam jumlah besar sekaligus (Maulana & Rochmawati, 2019).

Convolutional Neural Networks merupakan salah satu jenis algoritma *deep learning* yang dapat menerima masukan gambar dan menentukan objek pada gambar, serta dapat digunakan sebagai sumber pengenalan gambar untuk membedakan setiap gambar yang ada (Iswantoro & UN, 2022). CNN menggunakan serangkaian *convolutional layer* untuk melatih dan menguji setiap gambar masukan, kemudian dilakukan proses *pooling* untuk mengekstrak fitur dari gambar masukan yang berurutan dan dilanjutkan dengan gambar kemudian diratakan dan dimasukkan ke dalam *proses fully connected layer* untuk menyelesaikan klasifikasi.

Convolutional layer ini merupakan operasi konvolusi pada keluaran lapisan sebelumnya. Lapisan ini merupakan proses utama yang mendasari CNN dan merupakan lapisan utama terpenting dari sistem yang digunakan dalam CNN. Konvolusi dalam pengolahan citra berarti menerapkan kernel (kotak kuning) ke citra pada semua kemungkinan *offset.* Citra keseluruhannya adalah kotak lipat berwarna hijau. Kernel berpindah dari pojok kiri atas ke pojok kanan bawah. Hasil konvolusi citra ini ditunjukkan pada gambar sebelah kanan (Sandi et al., 2022).

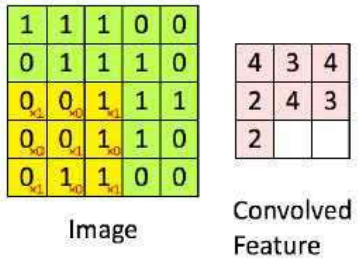

Gambar 1. *Concolutional Layer*
Sumber: (Sandi et al., 2022)

Lapisan penyatuan adalah lapisan yang digunakan untuk mengurangi jumlah fitur yang diambil dari lapisan sebelumnya. Keuntungannya adalah efektivitas model meningkat seiring melakukan pelatihan. Metode *pooling* yang umum digunakan adalah *max pooling*, dan nilai tersebut diperoleh dari hasil *convolutional layer*. Jenis pengumpulan lainnya adalah pengumpulan rata- 13 rata atau pengumpulan norma L2 (Putra et al., 2023). *Fully connected layer* adalah susunan dimana semua neuron yang diaktifkan di lapisan sebelumnya terhubung sepenuhnya ke neuron di lapisan berikutnya, mirip dengan neural network biasa.

Parameter *Convolutional Neural Network* (CNN) merupakan komponen penting yang menentukan kinerja model dalam tugas pengenalan pola pada gambar. Beberapa parameter CNN yang signifikan yaitu:

a. *Kernel-Size,* digunakan untuk mendapatkan fragmen *(strides)* dari gambar (Hendriyana & Maulana, 2020). Penggunaan *Kernel size* ini digunakan untuk menentukan ukuran jendela geser. Disarankan untuk menggunakan ukuran jendela yang lebih kecil, sebaiknya ganjil seperti 1,3,5, dan 7 (Umer, 2023).
b. Fungsi aktiviasi, merupakan fungsi matematika lapisan tersembunyi yang digunakan untuk memodifikasi *Neural Networks* secara nonlinier. Fungsi aktivasi yang tersedia dalam framework TensorFlow meliputi Tanh, Softsign, Sigmoid, Softmax, Softplus, Linear, Relu, Elu, dan Exponential (Gunawan, 2020).
c. Pengeluaran *(dropout)*, fungsi matematika yang digunakan untuk menentukan persentase *dropout* nilai yang dianggap terburuk dari sekumpulan nilai yang dicapai selama suatu masa studi. Tujuan dari penghapusan ini adalah untuk mengurangi *overfitting* pada model, khususnya kondisi dimana nilai akurasi yang dihasilkan terlalu sempurna, misal kondisi bernilai 1 (Gunawan, 2020).
d. Optimasi, merupakan metode pencarian yang memperbarui nilai bobot melalui pengurangan atau penambahan pada model pengembangan ANN sehingga dapat dihasilkan bobot yang optimal (Suradiradja, 2021). Metode optimasi antara lain adalah *Adamax, RMShop, Adam, SGD, Adagrad, Adadelta* (Suradiradja, 2021).

MobileNet merupakan arsitektur *Convolutional Neural Networks* (CNN) yang dapat mengatasi kebutuhan untuk menghitung data dalam jumlah besar. Secara umum, perbedaan mendasar antara arsitektur *MobileNet* dan CNN adalah keduanya menggunakan lapisan konvolusional dengan ketebalan filter yang sama dengan ketebalan

gambar masukan. *MobileNet* membagi konvolusi menjadi *depthwise convolution* dan *pointwise convolution* (Hendriyana & Maulana, 2020).

Pada proses penelitian ini, peneliti menemukan informasi yang merujuk pada beberapa penelitian yang sudah pernah dilakukan dan memiliki kesamaan dengan penelitian yang dilakukan. Penelitian pertama yang dilakukan oleh Wulandari et al., (2020) dengan judul "Klasifikasi Citra Digital Bumbu dan Rempah dengan Algoritma Convolutional Neural Network (CNN)". Hasil pengujian penelitian ini didapatkan nilai akurasi data training sebesar 0,9875 dan nilai loss 0,0769. Nilai akurasi data testing sebesar 0,85 dan nilai loss 0,4773. Sementara itu, pengujian dengan data baru yaitu masing-masing 3 citra untuk setiap kategori menghasilkan akurasi sebesar 88,89%.

Penelitian kedua yaitu penelitian yang dilakukan oleh Fadli et al., (2021) dengan judul "Purwarupa Sistem Deteksi COVID-19 Berbasis Website Menggunakan Algoritma Convolutional Neural Network". Dalam penelitian ini, sistem berbasis situs web untuk mendeteksi virus COVID-19 dari gambar x-ray toraks dikembangkan menggunakan algoritma *convolutional neural network*. Hasil penelitian yang diperoleh menunjukkan bahwa sistem dapat mengklasifikasikan x-ray toraks menjadi tiga kelas yaitu (COVID-19, virus pneumonia, dan normal). Nilai akurasi yang diperoleh mencapai 89,6 µn dan nilai F1 mencapai 87,9%.

Penelitian ketiga merupakan penelitian yang dilakukan oleh Fadlia & Kosasih (2019), dengan judul "Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN)". Pada penelitian ini data yang digunakan adalah 120 gambar yang terdiri dari gambar mobil, sepeda motor, dan sepeda. Hasil pengujian dan evaluasi model pada tiga jenis kendaraan dengan menggunakan paket Keras menunjukkan akurasi sebesar 94,4% pada tahap pelatihan dan 73,3% pada tahap pengujian.

Penelitian keempat yang serupa juga membahas tentang "Convolution Neural Network (CNN) Untuk Pengklasifikasian Citra Makanan Tradisional" yang dilakukan oleh Rohim et al., (2019). Hasil penelitian ini menunjukkan bahwa membangun arsitektur model jaringan saraf konvolusional untuk mengklasifikasikan citra makanan tradisional memerlukan empat lapisan konvolusional, empat lapisan max pooling, dan dua lapisan yang terhubung penuh. Arsitektur ini diperoleh karena mencapai presisi sebesar 73%, recall sebesar 69%, dan Fscore sebesar 69% dengan nilai loss minimal sebesar 0. 000044 dalam 15 epoch selama proses pembelajaran.

Penelitian kelima yang membahas tentang algoritma CNN dilakukan oleh Kholik (2021) dengan judul "Klasifikasi menggunakan Convolutional Neural Network (CNN) pada Tangkapan Layar Halaman Instagram". Dalam penelitian ini, peneliti mengklasifikasikan tangkapan layar halaman Instagram ke dalam lima kelas yaitu (kecantikan, keluarga, kebugaran, mode, dan makanan) serta menargetkan total 3.770 data gambar tangkapan layar halaman Instagram. Hasil uji Confusion Matrix pada penelitian ini menunjukkan skor presisi sebesar 91%, skor presisi sebesar 93%, skor recall sebesar 90%, dan skor F1 sebesar 91%. Model yang dihasilkan juga diuji pada data yang berbeda dari dataset, total 25 data gambar screenshot diuji pada model, dan model mampu memprediksi 20 gambar screenshot halaman Instagram.

METODE

Metode pengumpulan data yang digunakan dalam penelitian ini dilakukan dengan mengumpulkan gambar citra yang berjumlah 18 jenis makanan yang diperoleh melalui laman berikut http://universe.roboflow.com/bangkit/indonesian-food-pedsx/dataset, serta 2 jenis makanan yang diperoleh dengan melakukan *scraping* pada website. Data yang telah dikumpulkan kemudian dilakukan *preprocessing* data. *Preprocessing* data dilakukan agar dataset dapat melanjutkan ke tahap selanjutnya. *Preprocessing* data dapat dilihat pada gambar 2, yaitu:

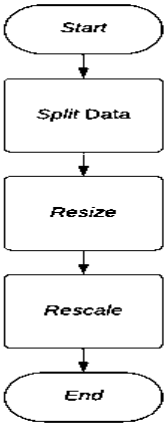

Gambar 2. *Preprocessing* Data

Data yang telah melalui proses *preprocessing* data selanjutnya adalah proses klasfikasi citra menggunakan arsitektur *MobileNet.* Pada tahapan ini terdapat dua langkah, pertama yaitu ekstraksi fitur dan yang kedua adalah klasifikasi citra. Proses ekstraksi fitur disini menggunakan *MobileNetV3* yang telah dilatih sebelumnya oleh *ImageNe*t sebagai ekstraksi fitur. Selanjutnya untuk proses klasifikasi digunakan *Global Average Polling* dengan lapisan konvolusi 1x1 dan lapisan *Dense* dengan aktivasi *Softmax*. *Global Average Polling* merupakan satu peta fitur pada setiap kategori klasifikasi yang dapat mencegah *overfiting* yang disebabkan oleh parameter di *fully connected layer* yang membuat pelatihan menjadi lambat dalam kecepatannya. *Softmax* aktivasi ini digunakan untuk klasifikasi terhadap 20 kelas foto makanan Indonesia yaitu kelas Ayam Betutu, Beberuk Terong, Coto Makassar, Gudeg, Kerak Telor, Mie Aceh, Nasi Kuning, Nasi Pecel, Papeda, Pempek, Peuyuem, Rawon, Rendang, Sate Madura, Serabi, Soto Banjar, Soto Lamongan, Tahu Sumedang, Nasi Goreng, dan Siomay. Gambar 3 merupakan source code dari arsitektur MobileNet yang diusulkan pada penelitian ini.

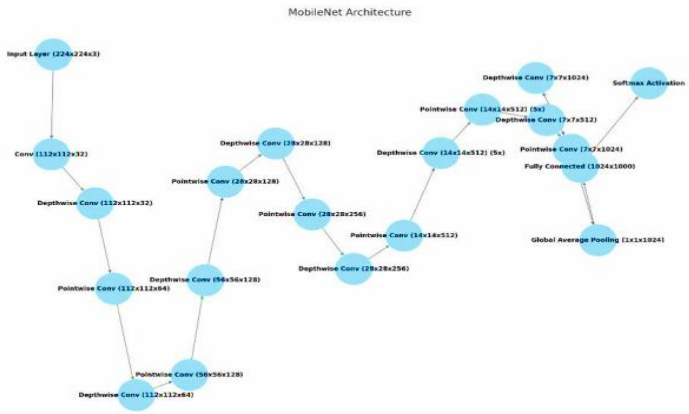

Gambar 3. *MobileNet Architecture*

Setelah dilakukannya klasifikasi, tahap selanjutnya adalah proses pelatihan. Pada proses pelatihan ini, parameter yang diinisialisasikan adalah fungsi *aktivasi (elu, linear, relu, sigmoid, softplus, softsign, serta tanh), batch size* dengan nilai 32, *epoch* (15, 30, 50), *dropout* (0.2, 0.4, 0.8) dan menggunakan *optimize*r adam. Oleh karena itu, pada penelitian ini dilakukan pelatihan menggunakan beberapa fungsi aktivasi, dropout, dan beberapa nilai epoch untuk mencari performa terbaik. Setelah proses pelatihan selesai, step selanjutnya adalah menguji apakah model mampu melakukan klasifikasi citra sesuai dengan kelasnya. Pengujian ini dilakukan dengan menggunakan 199 citra, dan hasil dari pengujian ini berupa sebuah sample hasil citra yang telah dilakukan klasifikasi. Tahapan selanjutnya adalah evaluasi. Kualitas model klasifikasi dapat diukur dari parameter pengukuran kinerja, termasuk akurasi, sensitivitas, dan presisi. Menghitung koefisien-koefisien ini memerlukan suatu matriks, yang biasa disebut confusion matrix. Confusion Matrix berisi nilai: true positif (TP), true negative (TN), false positive (FP), dan false negative (FN). Semua kemungkinan kejadian sebenarnya positif (P) dan semua kemungkinan kejadian sebenarnya negatif (N). Evaluasi juga dapat dilihat pada classification report yang secara langsung menampilkan nilai akurasi, sensitivitas, dan presisi.

Keluaran atau *output* yang dihasilkan dari proses analisa metode Convolutional Neural Networks (CNN) dengan arsitektur MobileNet berupa perbandingan dari tahap training yang dilakukan serta hasil dari identifikasi dari foto citra makanan Indonesia. Desain sistem dari penelitian ini ditunjukkan pada gambar 4, yaitu:

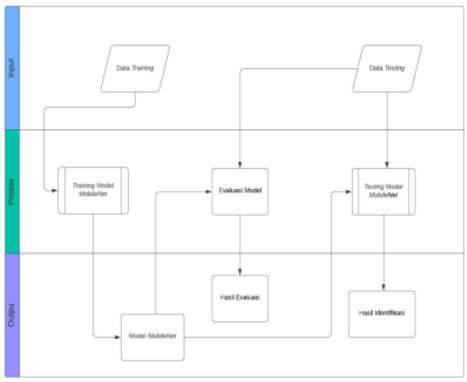

Gambar 4. Desain Sistem

HASIL

a. *Preprocessing* Data

Setelah dilakukannya Split data atau pembagian data untuk data training, dan data testing maka preprocessing data dilakukan. Preprocessing ini mencakup resize dan rescale. Tujuan dari resize ini mengubah ukuran gambar menjadi 224x224 piksel, yang bertujuan juga untuk memastikan semua gambar nantinya yang masuk kedalam model mempunyai dimensi yang sama. Sedangkan, pada proses rescale ini mengubah nilai piksel gambar dan akan dinormalisasikan dari rentang [0,255] menjadi rentang [0,1]. Proses rescale ini membantu dalam mempercepat dan membuat stabil pelatihan model dengan memastikan nilai input lebih kecil dan lebih konsisten. Bisa dilihat dari Gambar 5 adalah contoh data gambar setelah dilakukan proses resize dan rescale.

Gambar 5. Contoh Data Gambar *Resize* dan *Rescale*

Tahap berikutnya ada pada data struktur dan pada penelitian ini terdiri dari 20 kelas dengan rentang jumlah gambar antara 30 - 55. Dataset yang sudah melewati tahap preprocessing diatas kemudian dibagi menjadi beberapa data yaitu, 80% data training dan 20% data testing. Berikut pada tabel 1 disajikan dataset dari penelitian ini.

Tabel 1 Dataset Jumlah Gambar

No.	Label	Total
1	Ayam Betutu	55
2	Beberuk Terong	40
3	Coto Makassar	49
4	Gudeg	54
5	Kerak Telor	45
6	Mie Aceh	40
7	Nasi Kuning	38
8	Nasi Pecel	50
9	Papeda	55
10	Pempek	55
11	Pueyeum	55
12	Rawon	55
13	Rendang	55
14	Sate Madura	55
15	Serabi	55
16	Soto Banjar	44
17	Soto Lamongan	55
18	Tahu Sumedang	48
19	Nasi Goreng	48
20	Siomay	44

b. Klasifikasi

Pada bagian klasifikasi dilakukan eksperimen untuk menciptakan model yang mempunyai performa paling bagus. Eksperimen akan dilakukan dengan hanya menggunakan Optimasi satu jenis bernama ADAM. Kemudian,

pengujian juga dilakukan dengan 2 cara. Cara yang pertama dilakukan untuk melihat hasil sebelum disimpan menjadi model, sedangkan cara yang kedua dilakukan untuk melihat hasil setalah disimpan menjadi model untuk dilihat perbedaannya. Pada penelitian melakukan uji coba dengan menggunakan fungsi aktivasi *Elu, Linear, Relu, Sigmoid, Softplus, Softsign, Tanh,* dengan sama-sama menggunakan *epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi Adam. Tabel 3 menunjukkan hasil percobaan dalam menggunakan fungsi aktivasi dengan Elu.

Tabel 2
Pengujian menggunakan Aktivasi *Elu* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Elu	0.2	adam	95.98	0.13
15	Elu	0.4	adam	95.98	0.14
15	Elu	0.8	adam	90.45	0.39
30	Elu	0.2	adam	95.98	0.16
30	**Elu**	**0.4**	**adam**	**96.48**	**0.16**
30	Elu	0.8	adam	95.98	0.16
50	Elu	0.2	adam	95.98	0.15
50	Elu	0.4	adam	96.48	0.18
50	Elu	0.8	adam	95.98	0.14

Dari hasil pengujian tabel 2, akan dipilih berdasarkan nilai akurasi terbesar yang dihasilkan dan nilai *loss* terkecil yang dihasilkan. Dan dilanjutkan dengan pengujian dengan menggunakan aktivasi *Linear* dengan *epoch*, *dropout*, dan optimasi yang sama.

Tabel 3
Pengujian menggunakan Aktivasi *Linear* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Linear	0.2	adam	95.98	0.17
15	Linear	0.4	adam	93.47	0.26
15	Linear	0.8	adam	94.97	0.16
30	**Linear**	**0.2**	**adam**	**95.98**	**0.14**
30	Linear	0.4	adam	95.48	0.15
30	Linear	0.8	adam	95.98	0.16
50	Linear	0.2	adam	95.98	0.19
50	Linear	0.4	adam	95.48	0.32
50	Linear	0.8	adam	94.47	0.22

Dari hasil pengujian tabel 3, akan dipilih berdasarkan nilai akurasi terbesar yang dihasilkan dan nilai *loss* terkecil yang dihasilkan. Dan dilanjutkan dengan pengujian dengan menggunakan aktivasi *Relu* dengan *epoch*, *dropout*, dan optimasi yang sama.

Tabel 4
Pengujian menggunakan Aktivasi *Relu* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Relu	0.2	adam	97.49	0.12
15	Relu	0.4	adam	96.48	0.15
15	Relu	0.8	adam	56.78	1.86
30	**Relu**	**0.2**	**adam**	**97.49**	**0.08**
30	Relu	0.4	adam	96.98	0.11
30	Relu	0.8	adam	63.82	1.57
50	Relu	0.2	adam	96.98	0.15
50	Relu	0.4	adam	97.49	0.09
50	Relu	0.8	adam	75.88	1.19

Dari hasil pengujian tabel 4, akan dipilih berdasarkan nilai akurasi maksimum dan nilai *loss* minimum

yang dihasilkan. Dan dilanjutkan dengan pengujian dengan menggunakan aktivasi *Sigmoid* dengan *epoch*, *dropout*, dan optimasi yang sama.

Tabel 5
Pengujian menggunakan Aktivasi *Sigmoid* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Sigmoid	0.2	adam	95.98	0.20
15	**Sigmoid**	**0.4**	**adam**	**96.48**	**0.27**
15	Sigmoid	0.8	adam	67.34	1.81
30	Sigmoid	0.2	adam	94.47	0.15
30	Sigmoid	0.4	adam	93.97	0.15
30	Sigmoid	0.8	adam	94.47	0.32
50	Sigmoid	0.2	adam	95.98	0.12
50	Sigmoid	0.4	adam	95.98	0.11
50	Sigmoid	0.8	adam	92.96	0.38

Dari hasil pengujian tabel 5, akan dipilih berdasarkan nilai akurasi tertinggi dan nilai *loss* paling kecil. Dan dilanjutkan dengan pengujian dengan menggunakan aktivasi *Softplus* dengan *epoch*, *dropout*, dan optimasi yang sama.

Tabel 6
Pengujian menggunakan Aktivasi *Sofplus* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Softplus	0.2	adam	95.98	0.12
15	Softplus	0.4	adam	97.49	0.09
15	Softplus	0.8	adam	75.88	1.61
30	Softplus	0.2	adam	97.49	0.12
30	**Softplus**	**0.4**	**adam**	**97.99**	**0.09**
30	Softplus	0.8	adam	93.47	0.61
50	Softplus	0.2	adam	97.49	0.11
50	Softplus	0.4	adam	96.98	0.19
50	Softplus	0.8	adam	94.97	0.25

Berdasarkan pengujian pada tabel 6, dipilih yang memiliki akurasi tertinggi dan loss terkecil. Pengujian kemudian juga dilakukan pada aktivasi *Softsign* menggunakan epoch, dropout, dan optimasi yang sama.

Tabel 7
Pengujian menggunakan Aktivasi *Sofsign* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Softsign	0.2	adam	97.99	0.10
15	Softsign	0.4	adam	97.49	0.09
15	Softsign	0.8	adam	90.45	0.50
30	Softsign	0.2	adam	97.99	0.07
30	Softsign	0.4	adam	97.49	0.08
30	Softsign	0.8	adam	95.48	0.18
50	**Softsign**	**0.2**	**adam**	**98.49**	**0.07**
50	Softsign	0.4	adam	97.99	0.08
50	Softsign	0.8	adam	98.49	0.09

Setelah pengujian terhadap tabel 7, nilai akurasi maksimum dan loss minimum juga dipilih dan ditemukan *dropout* sebesar 0,2 pada epoch 50. Ini kemudian dilakukan dengan aktivasi *Tanh*, dan menggunakan parameter lain yang sama seperti pada tabel sebelumnya.

Tabel 8 Pengujian menggunakan Aktivasi *Tanh* dengan *Epoch* 15, 30, 50 serta *dropout* 0.2, 0.4, 0.8 dan optimasi ADAM

Epoch	Activation	Dropout	Optimation	Accuracy %	loss
15	Tanh	0.2	adam	98.49	0.09
15	Tanh	0.4	adam	97.49	0.09
15	Tanh	0.8	adam	81.91	0.63
30	Tanh	0.2	adam	97.99	0.07
30	**Tanh**	**0.4**	**adam**	**98.99**	**0.05**
30	Tanh	0.8	adam	92.96	0.28
50	Tanh	0.2	adam	97.49	0.08
50	Tanh	0.4	adam	98.99	0.06
50	Tanh	0.8	adam	95.48	0.15

c. Evaluasi

Proses evaluasi dengan menggunakan *Confusion Matriks* dan *Classification Report*. Beberapa nilai di dalam *confusion matrix* yaitu: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Seluruh kemungkinan kejadian sebenarnya positif (P) dan seluruh kemungkinan kejadian sebenarnya negatif (N). *Classification Report* dapat menunjukkan akurasi*, recall* dan *precision*. Gambar 6 menampilkan hasil *confusion matrix.*

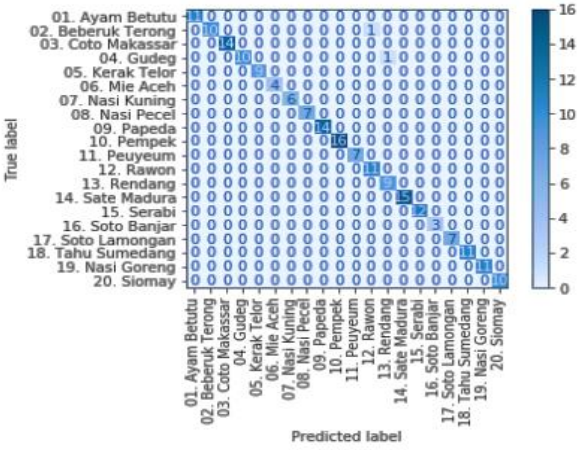

Gambar 6. *Confusion Matrix*

Pada gambar diatas menunjukkan hasil klasifikasi dari model menunjukkan hasil yang baik. Pada kasus ini diambil contoh dengan 11 citra ayam betutu terklasifikasi sebagai ayam betutu, dan keseluruhan data *test* untuk citra ayam betutu adalah 11.

Tabel 9
Report Classification

No	Nama Dataset	*Precission*	*Recall*	*f1-score*
1	Ayam Betutu	1,000000	1,000000	1,000000
2	Beberuk Terong	1,000000	0,909091	0,952381
3	Coto Makassar	1,000000	1,000000	1,000000
4	Gudeg	1,000000	0,909091	0,952381
5	Kerak Telor	1,000000	1,000000	1,000000
6	Mie Aceh	1,000000	1,000000	1,000000
7	Nasi Kuning	1,000000	1,000000	1,000000
8	Nasi Pecel	1,000000	1,000000	1,000000
9	Papeda	1,000000	1,000000	1,000000
10	Pempek	1,000000	1,000000	1,000000
11	Peuyuem	1,000000	1,000000	1,000000
12	Rawon	0,916667	1,000000	0,956522

No	Nama Dataset	*Precission*	*Recall*	*f1-score*
13	Rendang	0,900000	1,000000	0,947368
14	Sate Madura	1,000000	1,000000	1,000000
15	Serabi	1,000000	1,000000	1,000000
16	Soto Banjar	1,000000	1,000000	1,000000
17	Soto Lamongan	1,000000	1,000000	1,000000
18	Tahu Sumedang	1,000000	1,000000	1,000000
19	Nasi Goreng	1,000000	1,000000	1,000000
20	Siomay	1,000000	1,000000	1,000000
Accuracy		0,989950	0,989950	0,989950
Macro avg		0,990833	0,990909	0,990433
Weighted avg		0,990871	0,989950	0,989952

d. Identifikasi Gambar dengan Website

Pada tahap identifikasi ini, peneliti membuat sebuah aplikasi berbasis website yang dapat terintegrasi pada model yang telah dibuat pada tahap tahap sebelumnya. Peneliti menggunakan kerangka kerja dari python yaitu, Flask untuk membangun website ini. Website ini hanya mempunyai satu halaman yaitu, *main page* (halaman utama). Berikut peneliti sajikan gambar 7 yang merupakan tampilan dari main page website ini, dan gambar 8 merupakan contoh hasil dari identifikasi Peuyeum apabila *user* memilih gambar Peuyeum yang ada di penyimpanan lokal untuk diidentifikasi dan menekan tombol "*Identification*". Sistem akan menerima gambar dari user dan akan memprosesnya menggunakan Flask dan model yang telah dilatih sebelumnya. Ketika proses identifikasi selesai user akan diberikan hasil dari prediksi serta berapa akurasi yang didapatkan dari identifikasi.

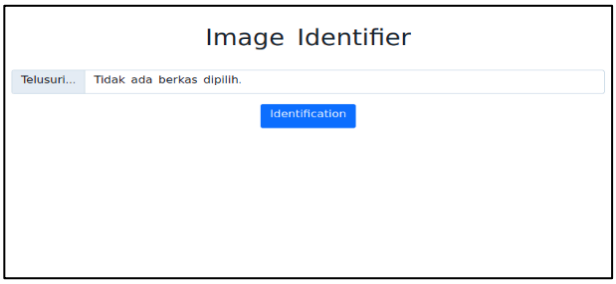

Gambar 7. *Main Page*

Gambar 8. Hasil dari Identifikasi Peuyeum

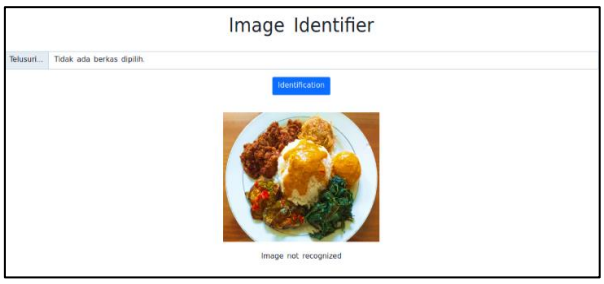

Gambar 9. Hasil dari Identifikasi Nasi Padang

Sedangkan pada gambar 9 diatas dilakukan sebuah uji coba dengan melakukan pengujian makanan yang tidak terdapat pada dataset, dan dapat dilihat pada gambar 9 juga bahwa hasilnya adalah gambar tidak dapat dikenali.

PEMBAHASAN

Berdasarkan percobaan yang dilakukan setelah *preprocessing* data, hasil terbaik dari penelitian ini adalah menggunakan *epoch 30*, fungsi aktivasi *Tanh* dengan nilai *dropout* 0.4 serta menggunakan optimasi "adam" yang menghasilkan akurasi tertinggi 98.99% dengan *loss* 0.05. Jumlah *epoch* 30 dipilih karena dengan beberapa pengujian hasil dari akurasi yang besar dan *loss* terendah. Sedangkan nilai *dropout* menggunakan 0.4, karena untuk mencegah adanya *overfitting* pada model.

Dari *confusion matrix* (gambar 6) dan *classification report* (tabel 9) dapat dilihat bahwa aristektur *MobileNet* dapat mengklasifikasi citra makanan Indonesia dengan baik. Hasil akurasi yang diperoleh 98.99% dengan nilai precission 99% dan nilai recall 98%.

Dari hasil percobaan klasifikasi menggunakan 2 citra makanan menunjukkan bahwa 1 citra terdeteksi sesuai dan 1 citra tidak sesuai, karena hal ini disebabkan oleh citra pada gambar 9 tidak terdapat pada kumpulan data yang dimiliki oleh peneliti. Hasil ini membuktikan bahwa metode secara keseluruhan mampu melakukan klasifikasi citra makanan Indonesia dengan baik.

KESIMPULAN

Penelitian ini bertujuan untuk mengidentifikasi gambar makanan Indonesia menggunakan arsitektur *MobileNet* dan mencapi performa terbaik dari model *Convolutional Neural Network* (CNN). Berdasarkan hasil penelitian, dapat diambil kesimpulan yaitu Arsitektur *MobileNet* mencapai akurasi yang memuaskan dan menunjukkan performa yang lebih baik dibandingkan dengan arsitektur lain seperti *EfficientNetV2* dalam hal komputasi dan akurasi. Sistem yang dikembangkan ini memberikan kemudahan bagi masyarakat, terutama pecinta kuliner, untuk mengidentifikasi jenis makanan Indonesia yang sering diunggah di media sosial tanpa disertai informasi nama makanan. Hasil akhir dari penelitian ini menunjukkan bahwa MobileNet berhasil mencapai akurasi sebesar 98.99% dalam mengidentifikasi gambar makanan Indonesia. Arsitektur *MobileNet* dapat mengidentifikasi gambar makanan Indonesia dengan akurasi yang tinggi dan waktu pemrosesan yang cepat. Sistem ini juga dapat digunakan sebagai dasar untuk pengembangan aplikasi pengenalan gambar di bidang kuliner, khususnya untuk makanan Indonesia.

REFERENSI

Fadli, A., Ramadhani, Y., & Aliim, M. S. (2021). Purwarupa Sistem Deteksi COVID-19 Berbasis Website Menggunakan Algoritma Convolutional Neural Network. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, *5*(5), 876–883. https://doi.org/https://doi.org/10.29207/resti.v5i5.3450

Fadlia, N., & Kosasih, R. (2019). Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Teknologi Dan Rekayasa*, *24*(3), 207–215. https://doi.org/http://dx.doi.org/10.35760/tr.2019.v24i3.2397

Gunawan, I. (2020). Artificial Neural Network Model Optimization For Network Package Classification. *SIMETRIS*, *14*(2), 1–5. https://doi.org/https://doi.org/10.51901/simetris.v14i2.135

Hartono, I., Noertjahyana, A., & Santoso, L. W. (2022). Deteksi Masker Wajah dengan Metode Convolutional Neural Network. *Jurnal Infra*, *10*(1), 197–203. https://publication.petra.ac.id/index.php/teknik-informatika/article/view/12042

Hendriyana, H., & Maulana, Y. H. (2020). Identifikasi Jenis Kayu Menggunakan Convolutional Neural Network dengan Arsitektur Mobilenet. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, *4*(1), 70–76.

Iswantoro, D., & UN, D. H. (2022). Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (Cnn). *Jurnal Ilmiah Universitas Batanghari Jambi*, *22*(2), 900–905. https://doi.org/http://dx.doi.org/10.33087/jiubj.v22i2.2065

Kholik, A. (2021). Klasifikasi menggunakan Convolutional Neural Network (CNN) pada Tangkapan Layar Halaman Instagram. *Jurnal Data Mining Dan Sistem Informasi (JDMSI)*, *2*(2), 10–20. https://ejurnal.teknokrat.ac.id/index.php/JDMSI/article/view/1345

Maulana, F. F., & Rochmawati, N. (2019). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, *1*(02), 104–108. https://doi.org/https://doi.org/10.26740/jinacs.v1n02.p104-108

Putra, C. M., Triayudi, A., & Ningsih, S. (2023). Face Mask Recognition Menggunakan Model Cnn (Convolutional Neural Network) Berbasis Python Dan Opencv. *Journal Of Computer System and Informatics (JOSYC)*, *4*(3), 722–730. https://doi.org/https://doi.org/10.47065/josyc.v4i3.3532

R, A. A. D. (2023). *Kenapa Orang-Orang Suka Mengunggah Foto Makanan Di Media Sosial?* Detikfood. https://food.detik.com/info-kuliner/d-6951794/kenapa-orang-orang-suka-mengunggah-foto-makanan-di-media-sosial#:~:text=Mengunggah foto makanan ternyata tak hanya untuk membuat,%27personal

branding%27 mengenai seperti apa seseorang ingin dilihat.

Rohim, A., Sari, Y. A., & Tibyani, T. (2019). Convolution Neural Network (CNN) Untuk Pengklasifikasian Citra Makanan Tradisional. *Jurnal Pengembangan Teknologi*, *3*(7), 7037–7042. https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5851

Sandi, K. M., Yudha, A. P., Aryanto, N. D., & Farabi, M. A. (2022). Klasifikasi Sampah Menggunakan Convolutional Neural Network. *Indonesian Journal of Data and Science (IJODAS)*, *3*(2), 72–81. https://doi.org/https://doi.org/10.56705/Ijodas.V3i2.33

Suradiradja, K. H. (2021). Algoritme Machine Learning Multi-Layer Perceptron Dan Recurrent Neural Network Untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang. *Faktor Exacta*, *14*(4), 194–205. https://doi.org/http://dx.doi.org/10.30998/faktorexacta.v14i4.10376

Trivusi, T. (2022). *Pengertian Dan Cara Kerja Algoritma Convolutional Neural Network (Cnn)*. Trvusi. https://www.trivusi.web.id/2022/04/algoritma-cnn.html

Umer, A. (2023). *Understanding Convolutional Neural Networks: A Beginner's Journey Into The Architecture*. Medium.

Wibawa, A. P., Purnama, M. G. A., Akbar, M. F., & Dwiyanto, F. A. (2018). Metode-Metode Klasifikasi. *Prosiding Seminar Ilmu Komputer Dan Teknologi Informasi*, *3*(1), 134–138.

Wulandari, I., Yasin, H., & Widiharih, T. (2020). Klasifikasi Citra Digital Bumbu dan Rempah dengan Algoritma Convolutional Neural Network (CNN). *Jurnal Gaussian*, *9*(3), 273–282. https://doi.org/https://doi.org/10.14710/j.gauss.9.3.273-282