

**LAPORAN KEGIATAN
PENELITIAN**



**Model Deep Learning Berbasis VGG19 untuk Klasifikasi Citra
Daging Sapi dan Babi**

TIM PENGUSUL

Dr. KHOERUL ANWAR, S.T, M.T. (NIDN 0004077304)

**STMIK PPKIA PRADNYA PARAMITA MALANG
2024**

HALAMAN PENGESAHAN

LAPORAN PENELITIAN

1	Judul Pengabdian	: Model Deep Learning Berbasis VGG19 untuk Klasifikasi Citra Daging Sapi dan Babi
	a. Bidang Ilmu	: Teknik Informatika
	b. Kategori	: Teknik
2	Ketua Tim Penelitian	
	a. Nama lengkap dan Gelar	: Dr. Khoerul Anwar, S.T., M.T.
	b. Jenis Kelamin	: Laki-laki
	c. NIP/NIDN	: 197307042005011001/0004077304
	d. Jabatan Fungsional	: Lektor
	e. Fakultas/Jurusan	: Teknologi Informasi
	f. Bidang ilmu yang dikaji	: Komputer vision
	g. HP/Surel	: 082226228575 / alqhoir(at)stimata.ac.id
3	Jumlah Anggota dalam TIM	: 0 orang
4	Lokasi Penelitian	: Kota Malang
5	Lama Penelitian	: 8 Bulan
6	Biaya yang diperlukan	
	Dana Internal PT	: -
	Dana Mandiri	: Rp. 2.500.000.,

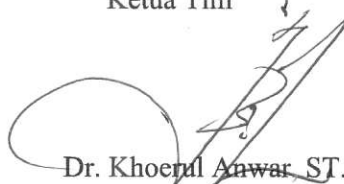
Kota Malang, 20 Juni 2024

Mengetahui
Ketua Program Studi TI
STMIK Pradnya Paramita

Ketua Tim



Samsul Arifin, S.Kom, MMSI
NIK. 14.10.25.004



Dr. Khoerul Anwar, ST., MT
NIP 197307042005011001



Mengesahkan,
Ketua LRPPI

Sujito, S.Kom, MPd, MMSI
NIK. 00.12.01.010

DAFTAR ISI

HALAMAN PENGESAHAN	2
DAFTAR ISI.....	3
RINGKASAN	4
BAB 1 PENDAHULUAN.....	5
1. 1. Latar Belakang.....	5
1. 2. Permasalahan	6
1. 3. Tujuan penelitian	6
BAB 2 TINJAUAN PUSTAKA.....	7
BAB 3 METODE PENELITIAN.....	10
3.1. Datasets.....	10
3.2. Pre – Processing.....	10
3.3. VGG19.....	10
3.4. Arsitektur CNN.....	11
3.5. Convolution.....	12
3.6. Training.....	13
BAB 4 HASIL DAN PEMBAHASAN	14
4.1. Hasil.....	14
KESIMPULAN	16

RINGKASAN

Komputer memiliki keterbatasan dalam hal identifikasi dan mengenali objek, hingga saat ini, tingkat ketepatan dalam mengklasifikasikan objek dalam gambar bahkan tidak mendekati tingkat presisi manusia. Walaupun begitu komputer tetap diperlukan sebagai alat bantu manusia untuk identifikasi dan mengenali objek khususnya untuk keperluan khusus. Permasalahan dalam penelitian ini adalah klasifikasi citra daging sapi dan babi dari citra hasil akuisisi smartphone (visible light) dengan machine learning CNN VGGNet19 dengan Tujuan untuk klasifikasi daging sapi dan babi dari hasil akuisi menggunakan visible light. Pada penelitian ini diajukan teknik klasifikasi dengan menggunakan model VGGNet19 dengan Tensorflow pada Convolution Neural Network. Hasil citra deteksi daging sapi dan babi menggunakan VGG19 diperoleh akurasi 96% dan tingkat kesalahan 0.081%. VGG19 mampu meningkatkan akurasi dari pada metode Backprop – GLCM untuk klasifikasi.

BAB 1 PENDAHULUAN

1. 1. Latar Belakang

Kemampuan manusia untuk mengidentifikasi dan mengenali objek dan tekstur tidak perlu dipertanyakan lagi. Dalam praktiknya, manusia mampu mengenali hampir semua objek dalam sebuah foto atau sebuah gambar terlepas dari pencahayaan, perspektif, gaya, atau bahkan tingkat abstraksi dalam sebuah gambar. Namun, komputer memiliki keterbatasan dalam hal identifikasi dan mengenali objek, hingga saat ini, tingkat ketepatan dalam mengklasifikasikan objek dalam gambar alam bahkan tidak mendekati tingkat presisi manusia. Walaupun begitu komputer tetap diperlukan sebagai alat bantu manusia untuk identifikasi dan mengenali objek khususnya untuk keperluan khusus.

Daging merah adalah salah satu jenis daging paling populer di Indonesia. Konsumsi daging yang terakumulasi atau rusak dalam waktu lama dapat menyebabkan banyak penyakit mematikan. Metode deteksi tradisional saat ini ada dua, yang pertama adalah pengujian sensorik[1], pengujian fisik dan kimia[2], pengujian mikrobiologi, dan analisis instrumen, semuanya rumit, memakan waktu, merusak, dan tidak ekonomis. Pengujian kedua dengan komputasi citra digital dilakukan dengan menggunakan teknologi canggih: *visible near-infrared hyperspectral imaging* [3][4], *FT-NIR spectroscopy* [5], *Vis/NIR spectroscopy* [6], *visible-near infrared*[7][8] teknologi ini relatif mahal (*high cost technology*) dan hanya bisa dilakukan oleh para akademisi, peneliti dan pusat studi (*niche community*). Cara pengujian kedua ini sebenarnya cukup simpel akan tetapi memiliki resistensi dalam biaya dan implementasi di masyarakat umum. Sementara itu di era digital yang ditandai oleh kemunculan *smartphone* dengan kemampuan alat yang cukup canggih dan mudah dioperasikan oleh semua lapisan masyarakat memunculkan peluang untuk digunakan sebagai alat uji.

Perangkat bergerak smart phone (*visible light*) saat ini dapat digunakan untuk mengakuisisi citra dengan hasil citra digital kualitas baik. Menjadi tantangan untuk melakukan research deteksi daging merah khususnya untuk klasifikasi daging sapi dan babi berdasar tekstur citra *visible light*. Citra yang dihasilkan dari peralatan berbasis *smart phone*[9], [10][11] adalah tidak menampakkan ciri khusus (*texture features*) yang menonjol untuk klasifikasi kesegaran daging. Oleh karena itu masih diperlukan proses menemukan ciri khusus dengan komputasi mesin (*Featue Map Convolution*) sebagai kunci untuk pemrosesan klasifikasi berbasis kecerdasan buatan dengan algoritma *Deep Learning*.

1. 2. Permasalahan

Permasalahan dalam penelitian ini adalah klasifikasi citra daging sapi dan babi dari citra hasil akuisisi smartphone (visible light) dengan machine learning CNN VGGNet19.

1. 3. Tujuan penelitian

Tujuan dari penelitian ini adalah untuk klasifikasi daging sapi dan babi dari hasil akuisi menggunakan visible light.

Penelitian daging sapi dan babi berdasarkan citra hasil akuisisi dengan kamera smartphone merupakan pengembangan dari penelitian sebelumnya [irul 2016] tentang pemilihan ciri dari daging sapi dan babi berdasarkan tekstur citra daging, [irul 2020] tentang verifikasi daging sapi dan babi menggunakan voting block berbasis backpropagation neural network. Pada penelitian didapat tingkat akurasi sebesar 76,97%. Hal ini menjadi tantangan untuk melakukan peningkatan akurasi lebih tinggi dengan menggunakan metode lainnya

BAB 2 TINJAUAN PUSTAKA

2.1 *Deep Learning*

Pembelajaran mendalam adalah cabang pembelajaran mesin yang kuat yang memanfaatkan jaringan saraf tiruan dengan beberapa lapisan tersembunyi untuk mempelajari representasi kompleks dari data. Jaringan saraf dalam ini dapat secara otomatis mengekstraksi fitur-fitur yang relevan dan menemukan pola-pola rumit, menjadikannya cocok untuk mengatasi berbagai masalah. Pembelajaran mendalam berkontribusi besar terhadap analisis objek pada proses penelitian. Pembelajaran mendalam saat ini juga digunakan oleh para peneliti diberbagai bidang keilmuan. Model ini memiliki kemampuan yang cukup baik untuk klaster, klasifikasi, segmentasi, dan deteksi, termasuk masalah dalam domain analisis perilaku[12]. Pembelajaran mendalam membuka jalan bagi deteksi dan diagnosis penyakit yang cepat dan akurat, sehingga menghasilkan hasil yang tepat dan tepat. Penelitian menunjukkan bahwa algoritma pembelajaran mendalam telah menunjukkan signifikansinya dalam prediksi, deteksi, dan dengan pengamatan yang cermat.

Pembelajaran mendalam telah memajukan bidang klasifikasi citra medis secara signifikan dengan mengotomatiskan ekstraksi fitur dan memungkinkan analisis data citra berskala besar. Jaringan saraf konvolusional (CNN) telah muncul sebagai pendekatan yang dominan, mencapai kinerja yang unggul di berbagai tugas pencitraan medis. Kemampuan CNN untuk mempelajari representasi hierarkis citra telah menghasilkan terobosan dalam mendiagnosis kondisi dari radiografi, pemindaian MRI, pemindaian CT, dan banyak lagi. Penelitian terkini telah difokuskan pada peningkatan arsitektur model, pengembangan teknik pembelajaran transfer, dan pembuatan kumpulan data beranotasi besar untuk lebih meningkatkan akurasi klasifikasi.[13]

Big Data mengacu pada pengumpulan data yang sangat besar yang dapat dianalisis untuk mengidentifikasi tren dan pola. Deep Learning merupakan salah satu metode analisis data yang dapat dimanfaatkan untuk menemukan pola abstrak dalam data dalam jumlah besar [14]–[16]. Representasi data dan pengetahuan tingkat lanjut dapat diekstraksi dengan bantuan pembelajaran mendalam.

Convolutional Neural Network (CNN) terdiri dari beberapa lapisan. Lapisan konvolusional yang mengekstrak fitur lapisan pengumpulan gambar yang memilih fitur tersebut. Yang ketiga adalah lapisan yang sepenuhnya terhubung atau FC, tugasnya adalah menggabungkan fitur-fitur yang diekstraksi. Recurrent Neural Network (RNN) cocok untuk

data sekuensial dan sebagian besar digunakan untuk audio, video, dan teks. Deep Belief Network (DBN) terdiri dari beberapa RBM. Ini adalah model generatif probabilistik. DBN memiliki banyak varian. Deep Neural Network (DNN) adalah teknik teknologi baru dan canggih di bidang kecerdasan buatan, karena juga dapat bekerja untuk sistem nonlinier yang kompleks[17][13]. Jika model pembelajaran mendalam dikembangkan dengan baik, hal ini dapat membantu mencegah kesalahan diagnosis dan membuang-buang waktu.

2.2 VGGNet19

VGG CNN memiliki enam struktur utama, yang masing-masing utamanya terdiri dari beberapa lapisan konvolusional yang terhubung dan lapisan yang terhubung penuh. Ukuran kernel konvolusional adalah 3×3 , dan ukuran inputnya adalah $224 \times 224 \times 3$. Jumlah lapisan umumnya terkonsentrasi pada 16~19[18].

VGG-19 CNN digunakan sebagai model pra-pemrosesan. Dibandingkan dengan jaringan saraf konvolusional tradisional, kedalaman jaringannya telah ditingkatkan. Ia menggunakan struktur bergantian dari beberapa lapisan konvolusional dan lapisan aktivasi *non-linier*, yang lebih baik daripada konvolusi tunggal. Struktur lapisan dapat mengekstraksi fitur gambar dengan lebih baik, menggunakan *Maxpooling* untuk *downsampling*, dan memodifikasi unit linier (ReLU) sebagai fungsi aktivasi, yaitu, memilih nilai terbesar di area gambar sebagai nilai gabungan area tersebut. Lapisan *downsampling* terutama digunakan untuk meningkatkan kemampuan anti-distorsi jaringan terhadap gambar, sambil mempertahankan fitur utama sampel dan mengurangi jumlah parameter[18].

Arsitektur jaringan pembelajaran mendalam untuk VGGNet meliputi: input, lapisan konvolusional, lapisan tersembunyi dan lapisan yang terhubung sepenuhnya.

2.2.1. Input

VGGNet menerima gambar berukuran 224×224 piksel sebagai input. Untuk mempertahankan ukuran input yang konsisten untuk kompetisi ImageNet, pengembang model memotong 224×224 patch pusat di setiap gambar.

2.2.2. Lapisan Konvolusional

Lapisan konvolusional VGG menggunakan medan reseptif terkecil yang memungkinkan, atau 3×3 , untuk merekam gerakan dari kiri ke kanan dan dari atas ke bawah. Selain itu, 11 filter konvolusional digunakan untuk mengubah input secara linier. Komponen berikutnya adalah unit ReLU, kemajuan signifikan dari AlexNet yang mempersingkat waktu pelatihan. Fungsi aktivasi unit linier yang diperbaiki, atau ReLU, adalah fungsi linier sepotong-sepotong yang,

jika inputnya positif, mengeluarkan input; jika tidak, outputnya nol. Langkah konvolusi ditetapkan pada 1 piksel untuk menjaga resolusi spasial tetap terjaga setelah konvolusi (langkah adalah jumlah pergeseran piksel pada matriks input).

2.2.3. Lapisan Tersembunyi

Semua lapisan tersembunyi jaringan VGG menggunakan ReLU. Normalisasi Respons Lokal (LRN) biasanya tidak digunakan dengan VGG karena meningkatkan penggunaan memori dan waktu pelatihan. Selain itu, tidak meningkatkan akurasi secara keseluruhan.


2.2.4. Lapisan yang Terhubung Sepenuhnya

VGGNet berisi tiga lapisan dengan konektivitas penuh. Dua tingkat pertama masing-masing memiliki 4096 saluran, sedangkan lapisan ketiga memiliki 1000 saluran dengan satu saluran untuk setiap kelas.

BAB 3 METODE PENELITIAN

3.1. Datasets

Data diperoleh dari akusisi dengan menggunakan smartphone SAMSUNG Galaxy A5+ dan smartphonw ASUS. Jumlah data yang digunakan adalah 81 dengan rincian citra daging sapi 60 dan citra daging babi 21. Format citra JPEG dengan ukuran 1944 x 2592 serta 1536 x 2048. Citra daging dicapture pada ruang terbuka pada jam 10:00 – 12:00 pagi hari. Pembagian data latih dan data ujia adalah 70:30. Dataset pada yang digunakan seperti ditunjukkan pada Gambar 1.



Gambar 2. Contoh dataset citra daging sapi dan citra daging babi

3.2. Pre – Processing

Dataset terdiri 81 citra daging sapi dan babi, semua data telah diproses dengan format portrid. Citra yang masuk pada jaringan VGGNet dengan ukuran yang telah disampaikan di Dataset diresize menjadi 224 x 224 x 3 piksel sebagai masukan. Untuk mempertahankan ukuran masukan yang konsisten untuk kompetisi ImageNet, model didesain dengan memotong 224 x 224 patch pusat di setiap gambar. Sementara itu proses *preprocessing* berabasis mesin dengan menggunakan modul *ImageDataGenerator* dengan parameter: *rotation_range=15*, *rescale=1./255*, *shear_range=0.2*, *zoom_range=0.2*, *horizontal_flip=True*, *fill_mode='nearest'*, *width_shift_range=0.1*, *height_shift_range=0.1*. Parameter VGGNet19 tersebut diharapkan mampu mengklasifikasi citra daging sapi dan citra daging babi dengan akurasi yang tinggi.

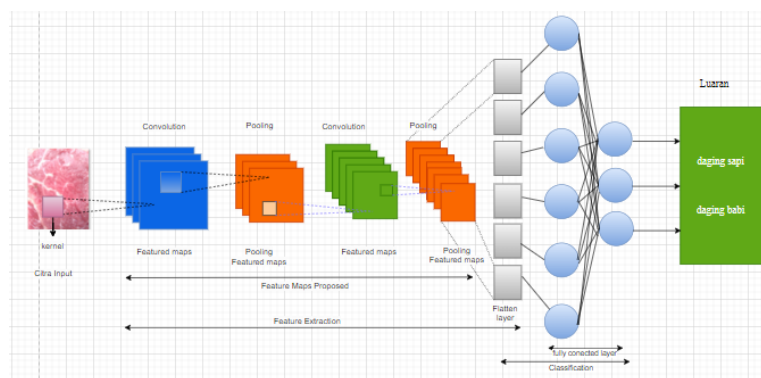
3.3. VGG19

Arsitektur VGG adalah salah satu jaringan saraf pertama dengan banyak lapisan. Pada penelitian ini digunakan VGGNet19[19]–[27] hasil pengembangan VGG sebelumnya. VGG19 menggeneralisasi penggunaan filter kecil kernel berukuran 3×3 dan menggabungkan lima blok dari beberapa lapisan konvolusional. Blok-blok ini mengurangi ukuran data masukan

sekaligus menggandakan jumlah filter, dari 64 menjadi 512. VGGNet19 berisi tiga lapisan dengan konektivitas penuh. Dua tingkat pertama masing-masing memiliki 4096 saluran, sedangkan lapisan ketiga memiliki 1000 saluran dengan satu saluran untuk setiap kelas.

3.4. Arsitektur CNN

Lapisan **Input**: VGG19 (VGGnet19) mengambil gambar masukan berukuran (224, 224, 3), dengan 224 x 224 adalah resolusi spasial gambar, dan 3 mewakili jumlah saluran warna (RGB). **Lapisan Konvolusional**: pada penelitian ini VGG19 memiliki 19 filter dan lima rangkaian lapisan konvolusional yang masing-masing diikuti oleh fungsi aktivasi unit linier yang diperbaiki (ReLU) dan lapisan Max-Pooling 2D. Lapisan konvolusional menggunakan bidang reseptif kecil/filter (3 x 3) dan faktor 1, yang membantu menangkap detail halus pada gambar. Lapisan **Pengumpulan Maks**: Setelah setiap kelompok lapisan konvolusional, lapisan penyatuan maksimum diterapkan untuk mengambil sampel peta fitur dan mengurangi dimensi spasial. Lapisan maxpooling menggunakan jendela 2 x 2 dengan faktor 2, sehingga mengurangi separuh dimensi peta fitur. Lapisan **Terhubung Sepenuhnya**: VGG19 menyertakan serangkaian lapisan yang terhubung sepenuhnya untuk klasifikasi setelah lapisan konvolusional dan penggabungan. Fungsi aktivasi ReLU mengikuti lapisan yang terhubung sepenuhnya dengan 512 jumlah layer. **Flaten Layer**: Sebelum lapisan yang terhubung sepenuhnya, lapisan rata diterapkan untuk mengubah peta fitur 2D menjadi vektor 1D menggunakan *GlobalMaxPooling2D*, yang berfungsi sebagai masukan ke lapisan yang terhubung sepenuhnya. Fungsi aktifasi pada layer output atau lapisan klasifikasi digunakan fungsi sigmoid. Arsitektur yang diusulkan seperti ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur VGGnet19 CNN yang di usulkan

Dalam penelitian ini, citra daging sapi dan citra daging babi disimpan dalam struktur direktori file yang dapat digunakan oleh perpustakaan Keras Python. Kemudian CNN diimplementasikan dengan python menggunakan Keras dengan backend TensorFlow untuk

mempelajari pola yang terkait dengan tanda tangan. Sementara itu untuk optimasi menggunakan Keras dengan backend TensorFlow. Tabel.1 berisi model arsitektur implementasi yang terperinci.

Tabel.1 Model architecture

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv4 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv4 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv4 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
global_max_pooling2d (Global)	(None, 512)	0
dense (Dense)	(None, 512)	262656
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 1)	513
Total params: 20,287,553		
Trainable params: 7,342,593		
Non-trainable params: 12,944,960		

3.5. Convolution

$$G = H * F$$

$$G[i, j] = \sum_{u=-k}^k \sum_{v=-k}^k H[u, v] F[i - u, j - v]$$

G adalah citra hasil convolution, H merupakan citra 2D semula dan F filter 2D. Arti dari tanda negatif pada $F[i-u, j-v]$ adalah pertama kita balikkan filter $F[u, v]$ menjadi $F[-u, -v]$ dan terjemahkan dengan i dan j sehingga akhirnya menjadi filter $F[u, v]$ menjadi $F[i-u, j-v]$. Dan terakhir lakukan perkalian dengan gambar $H[u, v]$ untuk mendapatkan nilai yang dihasilkan $G[i, j]$

3.6. Training


Pertama, variabel yang dapat dilatih didefinisikan sebagai variabel TensorFlow yang nilai awalnya adalah gambar konten. Selanjutnya, suatu fungsi didefinisikan yang menjalankan setiap langkah pelatihan. Dalam fungsi ini dapat menghitung gradien fungsi kerugian relatif terhadap gambar melalui Kerangka Global TensorFlow. Gradien dihitung dengan memanggil fungsi gradien, di mana kerugiannya adalah gaya dan kerugian konten yang dihitung oleh fungsi tersebut. Gambar kemudian diperbarui dengan menerapkan gradien menggunakan metode pengoptimal (pengoptimal Adam). Proses akan memperbaharui bobot dan menyesuaikan gambar yang dihasilkan ke arah mengurangi kerugian. Setelah menerapkan gradien, nilai piksel gambar dipotong ke rentang $[0, 1]$ dengan memanggil fungsi untuk memastikan bahwa gambar mempertahankan nilai piksel yang valid. Selama pelatihan, gambar pelatihan diulang melalubi beberapa perulangan. Secara umum, langkah-langkah pelatihan diulangi untuk satu atau lebih epoch. Pada setiap langkah pelatihan, fungsi kerugian dihitung, dan gradien diterapkan pada gambar untuk memperbarui nilai piksel gambar. Dengan cara ini, gambar yang dihasilkan disesuaikan secara bertahap agar lebih cocok dengan fitur gaya gambar dan fitur konten gambar.

BAB 4 HASIL DAN PEMBAHASAN

4.1. Hasil

Pengujian terhadap arsitektur CNN yang diusul dengan mengujian sejumlah data citra dalam format RGB. Model VGGNet19 ini membaca input berupa sebuah citra, karena ini kasus untuk klasifikasi maka citra input dilabelkan terlebih dahulu dalam dua jenis. Masing-masing jenis citra diletakkan pada direktori berbeda. Implementasi model CNN dengan turning parameter: Epoch =50, Dropout =0.5, learning rate = $1e-4$, momentum = 0.9, batch size 244, 112,56,28,14 dan 7.

Implementasi arsitektur sebagaimana tertera pada Tabel.1 dengan turning parameter tersebut pada proses pelatihan dapat dicermati pada tampilan Grafik akurasi model dan kerugian model yang ditunjukkan pada Gambar 2.



Gambar 2. Grafik akurasi dan kerugian pada fase pelatihan model


Pada penelitian ini digunakan model sekuensial yang mempertimbangkan arsitektur jaringan saraf yang berakar pada pembelajaran mendalam, yang terdiri dari lapisan yang berasal dari VGG19. Setiap lapisan dalam arsitektur ini dibuat khusus untuk memfasilitasi ekstraksi fitur hierarki. Arsitektur VGG19 menggabungkan lapisan konvolusional yang dirancang untuk mengekstrak pola rumit dari data masukan, sehingga menghasilkan bentuk keluaran (None, 224, 224, 3). Model yang disebutkan di atas memiliki jumlah parameter kumulatif sebesar 20,287,553, memungkinkannya memperoleh representasi yang rumit. Mengikuti lapisan konvolusional, proses pengumpulan rata-rata dilakukan untuk mengurangi dimensi spasial, sehingga memfasilitasi konsolidasi informasi. Untuk mengurangi masalah overfitting, lapisan dropout dimasukkan ke dalam proses pelatihan, dimana subset neuron dinonaktifkan secara sengaja dan acak. Lapisan keluaran akhir, yang terdiri dari 5.125 parameter, menghasilkan prediksi dari model.

Model komprehensif ini mencakup 20,287,553 parameter, yang dapat diklasifikasikan ke dalam dua kategori berbeda: dapat dilatih dan tidak dapat dilatih. Parameter yang dapat dilatih, yang berjumlah total 7,342,593, sesuai dengan bobot dan bias yang mengalami pembaruan selama proses pelatihan model. Pada arsitektur VGG16, parameter non-trainable terdiri dari 12,944,960 parameter tetap. Desain arsitektur, yang dicirikan oleh sejumlah besar parameter, mencapai keseimbangan harmonis antara kerumitan dan kemanjuran, memungkinkan model memperoleh karakteristik yang rumit dari data masukan sambil mempertahankan kapasitasnya untuk generalisasi. Memanfaatkan struktur sekuensial memfasilitasi transmisi informasi yang lancar dan efektif di berbagai tingkat hierarki, sehingga mengarah pada pengembangan model pembelajaran mendalam yang efisien dan dapat menerima pelatihan. Hasil yang diperoleh seperti dituliskan pada Tabel 2.

Tabel 2. Nilai akurasi dan kerugian pada proses pelatihan model

train	Accuracy (%)	Loss (%)	Val_ accuracy (%)	Val_ loss
VGGNet19-CNN	100	0.0475	0.9600	0.0813

Pada pengujian atau testing terhadap model yang diusulkan didapat tingkat akurasi mencapai 96% dan tingkat kerugian atau kegagalannya adalah 0.0813%. Hasil pengujian dengan menggunakan 10 citra baru terhadap model diperlihatkan pada Gambar 3.



Gambar 3. Hasil pengujian model yang diusulkan

Tabel 3. Perbandingan model yang diusulkan dengan model sebelumnya

Model klasifikasi	Accuracy (%)	Loss (%)
Backprop - GLCM	79.94	20.06
VGGNet19-CNN	96.00	0.0813

KESIMPULAN

Hasil citra deteksi daging sapi dan babi menggunakan VGG19 diperoleh akurasi 96% dan tingkat kesalahan 0.081%. VGG19 mampu meningkatkan akurasi dari pada metode Backprop – GLCM pada penelitian yang telah dilakukan sebelumnya.

DAFTAR PUSTAKAAN

- [1] Y. Sun, X. Zhai, X. Zou, J. Shi, X. Huang, and Z. Li, "A Ratiometric Fluorescent Sensor Based on Silicon Quantum Dots and Silver Nanoclusters for Beef Freshness Monitoring," *Foods*, vol. 12, no. 7, pp. 1–14, 2023, doi: 10.3390/foods12071464.
- [2] K. Jiang *et al.*, "Smart Indicator Film Based on Sodium Alginate/Polyvinyl Alcohol/TiO₂ Containing Purple Garlic Peel Extract for Visual Monitoring of Beef Freshness," *Polymers (Basel)*, vol. 15, no. 21, 2023, doi: 10.3390/polym15214308.
- [3] A. Aït-Kaddour, S. Jacquot, D. Micol, and A. Listrat, "Discrimination of beef muscle based on visible-near infrared multi-spectral features: Textural and spectral analysis," *Int. J. Food Prop.*, vol. 20, no. 6, pp. 1391–1403, 2017, doi: 10.1080/10942912.2016.1210163.
- [4] S. A. Haughey, H. Montgomery, B. Moser, N. Logan, and C. T. Elliott, "Utilization of Hyperspectral Imaging with Chemometrics to Assess Beef Maturity," *Foods*, vol. 12, no. 24, pp. 1–13, 2023, doi: 10.3390/foods12244500.
- [5] V. Wiedemair, M. De Biasio, R. Leitner, D. Balthasar, and C. W. Huck, "Application of Design of Experiment for Detection of Meat Fraud with a Portable Near-Infrared Spectrometer," *Curr. Anal. Chem.*, vol. 14, no. 1, 2018, doi: 10.2174/1573411013666170207121113.
- [6] T. S. Park, "Development of Beef Freshness Sensor Using NIR Spectroscopy," *J. Biosyst. Eng.*, vol. 29, no. 6, pp. 539–543, 2004, doi: 10.5307/jbe.2004.29.6.539.
- [7] E. J. Moon, Y. Kim, Y. Xu, Y. Na, A. J. Giaccia, and J. H. Lee, "Using a Portable Spectrometer," *Sensors (Switzerland)*, pp. 1–12, 2020.
- [8] C. H. Choi, J. H. Kim, and Y. J. Kim, "Evaluation of beef freshness using visible-near infrared reflectance spectra," *Korean J. Food Sci. Anim. Resour.*, vol. 31, no. 1, pp. 115–121, 2011, doi: 10.5851/kosfa.2011.31.1.115.
- [9] K. Anwar, "Feature Selection Based on Minimum Overlap Probability (MOP) in Identifying Beef and Pork," vol. 7, no. 3, pp. 316–322, 2016.
- [10] K. Anwar, S. Setyowibowo, and S. S., "Voting Block Method for Verification of Beef and Pork using Back Propagation Learning Machines," *Int. J. Comput. Appl.*, vol. 175, no. 18, pp. 33–37, 2020, doi: 10.5120/ijca2020920702.
- [11] I. A. DLY, J. Jasril, S. Sanjaya, L. Handayani, and F. Yanto, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data," *J. Inf. Syst. Res.*, vol. 4, no. 4, pp. 1176–1185, 2023, doi: 10.47065/josh.v4i4.3702.
- [12] L. Frank and A. Babatunde, "Deep Learning for Behavioral Analytics and Prediction Abstract," no. July, 2024.
- [13] I. Him, "Explainable Deep Learning Models in Medical Imaging," no. June, 2024.
- [14] K. S. Sunitha Krishnan and S. M. Thampi, "Deep Learning Approaches for IoT Security in the Big Data Era," *Adv. Sci. Technol. Secur. Appl.*, vol. 1, no. 1, pp. 105–135, 2020, doi: 10.1007/978-3-030-35642-2_6.
- [15] N. L. Rane, M. Paramesha, S. P. Choudhary, and J. Rane, "Partners Universal International Innovation Journal (PUIIJ) Machine Learning and Deep Learning for Big Data Analytics : A Review of Methods and Applications Partners Universal International Innovation Journal (PUIIJ)," no. June, pp. 172–197, 2024, doi: 10.5281/zenodo.12271006.
- [16] P. Vaibhav Potnurwar, A. Ainchwar, R. Neware, and V. Bongirwar, "Intrusion Detection System for Big Data Environment Using Deep Learning," 2024, doi: 10.20944/preprints202401.0912.v2.
- [17] L. Frank and D. Stilinski, "Deep Learning for Psychometric Assessments Abstract," no. July, 2024.
- [18] J. Xiao, J. Wang, S. Cao, and B. Li, "Application of a Novel and Improved VGG-19 Network in the Detection of Workers Wearing Masks," *J. Phys. Conf. Ser.*, vol. 1518, no. 1, 2020, doi: 10.1088/1742-6596/1518/1/012041.
- [19] I. A. Kandhro *et al.*, "Performance evaluation of E-VGG19 model: Enhancing real-time skin cancer detection and classification," *Heliyon*, vol. 10, no. 10, p. e31488, 2024, doi:

- 10.1016/j.heliyon.2024.e31488.
- [20] R. Vaghela, D. Labana, and K. Modi, "Efficient I3D-VGG19-based architecture for human activity recognition," *Sci. Temper*, vol. 14, no. 04, pp. 1185–1191, 2023, doi: 10.58414/scientifictemper.2023.14.4.19.
- [21] D. Hindarto, N. Afarini, and E. T. Esthi H, "Comparison Efficacy of VGG16 and VGG19 Insect Classification Models," *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 3, pp. 189–195, 2023, doi: 10.33387/jiko.v6i3.7008.
- [22] Y. Xu, "CNN-based image style transformation--Using VGG19," *Appl. Comput. Eng.*, vol. 39, no. 1, pp. 130–136, 2024, doi: 10.54254/2755-2721/39/20230589.
- [23] V. W. Handayani, A. Yudianto, M. S. M A R, R. Rulaningtyas, and M. Rasyad Caesarardhi, "Classification of Indonesian adult forensic gender using cephalometric radiography with VGG16 and VGG19: a Preliminary research," *Acta Odontol. Scand.*, vol. 83, no. 47, pp. 308–316, 2024, doi: 10.2340/aos.v83.40476.
- [24] F. Esmeray and A. Gülten, "WITHDRAWN: Breast Cancer Detection by Using VGG19 Deep Learning Network with Image Filtering and Histogram Equalization Methods BREAST CANCER DETECTION BY USING VGG19 DEEP LEARNING NETWORK WITH IMAGE FILTERING AND HISTOGRAM EQUALIZATION METHODS," 2023.
- [25] Kamal and H. Ez-zahraouy, "A comparison between the VGG16 , VGG19 and ResNet50 architecture frameworks for classification of normal and CLAHE processed medical images," *Res. Sq.*, pp. 0–16, 2023.
- [26] W. Xu, "A comparative analysis of VGG19 and Magenta models for Neural Style Transfer," *Appl. Comput. Eng.*, vol. 49, no. 1, pp. 236–241, 2024, doi: 10.54254/2755-2721/49/20241238.
- [27] K. Kalaiselvi and M. Kasthuri, "Tuning VGG19 hyperparameters for improved pneumonia classification," vol. 15, pp. 2231–2237, 2024, doi: 10.58414/SCIENTIFICTEMPER.2024.15.2.36.

