

Deteksi Jenis Kulit Wajah Menggunakan *Convolutional Neural Network* Arsitektur Mobilenet

Detection Of Facial Skin Type Classification Using Convolutional Neural Network With Mobilenet Architecture

1st Fiera Meiristika Utami
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
fierameiristika@student.telko
muniversity.ac.id

2nd Rita Magdalena
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ritamagdalenat@telkomuniver
sity.co.id

3rd Sofia Saidah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
sofiasaidahsfi@telkomuniver
sity.ac.id

Abstrak—Kulit wajah merupakan bagian tubuh yang sering mendapat perhatian ekstra karena mempengaruhi penampilan seseorang. Deteksi jenis kulit wajah sangat dibutuhkan untuk mengetahui jenis perawatan wajah yang harus dilekukan. Perawatan kulit pada wajah yang sesuai dengan jenis kulit yang dimiliki seseorang juga sangat penting agar kulit wajah tetap sehat. Dalam Tugas Akhir ini akan dibahas tentang bagaimana cara mendeteksi jenis kulit wajah pada manusia dengan metode *Convolutional Neural Network* arsitektur *MobileNet*. Pada metode ini, pengujian data akan dilakukan setelah melalui proses *training*. Setelah dilakukan ekstraksi fitur, jenis kulit akan diklasifikasikan berdasarkan jenis kulit wajah tipe normal, kering, berminyak, dan kombinasi. Penelitian deteksi jenis kulit wajah ini diuji oleh enam parameter sebagai tolak ukur hasil dari keempat tipe jenis kulit, yaitu normal, berminyak, kering, dan kombinasi. Hasil pengujian terbaik didapatkan saat ukuran citra 224x224, optimizer Adamax, learning rate 0,0001; epoch 100, batch size 16, dan n-fold 3 menghasilkan akurasi 93,14%; loss 0,2565; precision 93,25%; recall 93,25%; dan F1-Score 93%.

Kata kunci—CNN, *Convolutional Neural Network*, *MobileNet*, Deteksi Kulit Wajah, Jenis Kulit Wajah

Abstract—*Facial skin is a part of the body that often gets extra attention because it affects a*

person's appearance. Detection of facial skin type is needed to know the type of facial treatment that should be done. Skin care on the face that suits a person's skin type is also very important so that facial skin remains healthy. In this final project, we will discuss how to detect facial skin types in humans using the Convolutional Neural Network method of MobileNet architecture. In this method, data testing will be carried out after going through the training process. After feature extraction, skin types will be classified based on normal, dry, oily, and combination facial skin types. This facial skin type detection study was tested by six parameters as a benchmark for the results of the four skin types, namely normal, oily, dry, and combination. The best test results are obtained when the image size is 224x224, the Adamax optimizer, the learning rate is 0.0001; epoch 100, batch size 16, and n-fold 3 resulted in 93.14% accuracy; loss 0.2565; precision 93.25%; recall 93.25%; and F1-Score 93%.

Keywords— CNN, *Convolutional Neural Network*, *MobileNet*, *Facial Skin Detection*, *Facial Skin Type*

I. PENDAHULUAN

Kulit wajah pada manusia dibagi menjadi empat tipe jenis kulit, yaitu normal, kombinasi, kering, dan berminyak. Dengan perbedaan jenis kulit wajah ini, perawatan yang sesuai dengan tipe jenis kulit diperlukan agar tidak terjadi kerusakan pada kulit wajah.

Maka dari itu, deteksi awal diperlukan untuk dapat mengetahui jenis kulit wajah [1]. Berdasarkan masalah yang ada, penelitian deteksi jenis kulit wajah ini dilakukan menggunakan Convolutuional Neural Network arsitektur *MobileNet*.

Terdapat beberapa penelitian sebelumnya yang melakukan deteksi jenis kulit wajah dengan beberapa metode, yaitu dengan *Gray Level Co-Occurrence Matrix* (GLCM) dengan klasifikasi menggunakan *Support Vector Machine* (SVM) menghasilkan akurasi sebesar 88,89% [2]. Penelitian lainnya menggunakan *Gabor Wavelet* dan *Naïve Bayes* berbasis Android dengan akurasi sebesar 92% [3].

Penelitian pada Tugas Akhir ini menggunakan metode *Convolutional Neural Network* arsitektur *MobileNet*. Arsitektur *MobileNet* memiliki kelebihan yaitu *low consumption energy* dan mengurangi kompleksitas [4].

II. KAJIAN TEORI

A. Kulit

Kulit merupakan organ tubuh manusia yang paling luar yang vital dan esensial karena berfungsi untuk melindungi otot, sendi, dan bagian penting lainnya pada manusia. Setiap manusia memiliki jenis kulit yang bervariasi karena faktor umur, jenis kelamin, ras, iklim, dan bergantung pada lokasi kulit yang ada di tubuh [5].

B. Wajah

Wajah adalah salah satu bagian tubuh manusia yang mempunyai daya tarik tersendiri. Wajah seseorang dapat disebut sebagai tanda pengenal dari satu manusia ke manusia lain. Wajah yang bersih dan terawat dapat membuat rasa percaya diri seseorang

meningkat. Menjaga kesehatan kulit wajah dapat dilakukan dengan perawatan yang sesuai dengan jenis kulit yang dimiliki. Manusia memiliki empat tipe jenis kulit, yaitu kulit kering, kombinasi, normal, dan berminyak [6].

C. Neural Network


Neural network merupakan pemodelan yang meniru cara kerja syaraf otak manusia. Hasil dari *neural network* adalah menentukan produk dari interaksi ribuan sinyal pada tiap elemen jaringan. *Neural network* terdiri dari 3 layer, yaitu *input layer*, *hidden layer*, dan *output layer*. *Neural network* yang terdiri dari 2 *hidden layer* disebut dengan *recurrent* atau *feed-forward neural networks*, sedangkan yang terdiri lebih dari 2 *hidden layer* disebut *deep neural network* [7].

D. Deep Learning

Deep learning adalah bagian dari metode *machine learning* yang mempelajari tentang informasi algoritma abstraksi tingkat tinggi untuk mendapatkan ekstraksi berupa karakteristik klasifikasi dan analisis dari *non-linear* ayer. *Deep learning* merupakan teknik yang diterapkan pada komputer agar memiliki kemampuan akurasi ketepatan tingkat tinggi yang menyerupai manusia [7].

E. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu metode dalam pengolahan citra dua deimensi yang dikhususkan untuk pengolahan data dengan dimensi tingkat tinggi seperti gambar dan video. Metode yang digunakan pada CNN adalah operasi matematika dari sebuah operasi *linear* atau yang biasa disebut dengan konvolusi [8].

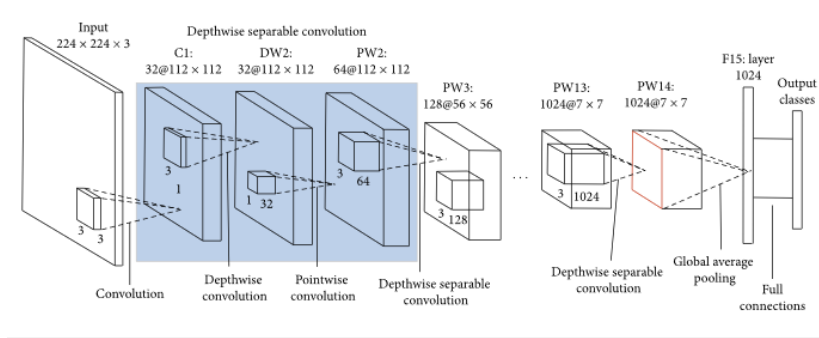


Gambar 2.1 Convolutional Neural Network [9]

F. MobileNet Architecture

MobileNet adalah arsitektur *Convolutional Neural Network* (CNN) yang digunakan untuk mengatasi *computing*

resource yang berlebih. Konvolusi pada *MobileNet* dibagi menjadi dua konvolusi, yaitu *depthwise convolution* dan *pointwise convolution* [10].




Gambar 2.2 Arsitektur MobileNet [10]

III. METODE

wajah. Metode yang digunakan adalah Convolutional Neural Network arsitektur MobileNet. Tahapan proses deteksi tersebut dapat dilihat pada gambar 3.1

A. Desain Sistem

Pada tugas akhir ini, sistem didesain untuk mendeteksi data objek citra digital kulit



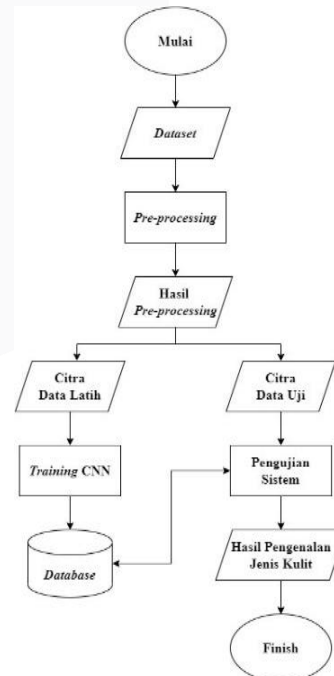
Gambar 3.1 Diagram Alur Sistem

B. Pre-processing

Pre-processing adalah sebagai proses awal sebelum masuk ke dalam proses utama. Tahapan pre-processing yang dilakukan pada penelitian ini adalah proses resizing. Tahapan ini bertujuan untuk menyeragamkan ukuran citra.

C. Pelatihan Model

Sistem pelatihan model dalam penelitian dirancang menggunakan model mobilenet. Penelitian pada pelatihan model ini melalui dua proses yaitu proses uji dan proses latih. Tahapan awal adalah input citra mikroskopik kulit wajah dan dilanjutkan dengan ekstraksi ciri. Hasil dari ekstraksi ciri digunakan untuk mengklasifikasikan jenis kulit wajah kedalam empat kelas yaitu kering, normal, berminyak, dan kombinasi.



Gambar 3.1 Diagram Alur Sistem

D. Parameter Performansi

Parameter performansi adalah tahap untuk mendapatkan model sistem terbaik dari sistem yang telah dirancang. Ada lima parameter yang digunakan pada penelitian ini, yaitu akurasi, *loss*, *presisi*, *recall*, dan *F1-score*. Berikut ini merupakan persamaan dari setiap performansi:

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$\text{Loss} = \sum_{i=1}^n p(x_i) \log q(x_i) \quad (2)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{F1 Score} = 2 \times \frac{(\text{Recall} \times \text{Presisi})}{(\text{Recall} + \text{Presisi})} \times 100 \quad (5)$$

E. Confusion Matrix

Confusion matrix adalah metode untuk melakukan prediksi pada kategori yang berbeda pada suatu classifier. Terdapat empat istilah yang merupakan representasi hasil proses klasifikasi, yaitu TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*).

IV. HASIL DAN PEMBAHASAN

A. Hasil

Pada penelitian ini, dilakukan enam pengujian skenario. Skenario pertama pengujian terhadap pengaruh perubahan ukuran citra. Skenario kedua pengujian terhadap pengaruh jenis *optimizer*. Skenario ketiga pengujian terhadap perubahan nilai *learning rate*. Skenario keempat pengujian terhadap perubahan nilai *epoch*. Skenario kelima pengujian terhadap perubahan *batch size*, dan skenario keenam pengujian terhadap pengaruh nilai *n-fold*.

1. Pengujian *Resize*

Tabel 1. Hasil Pengujian *Resize*

<i>Resize</i>	<i>Akurasi</i>	<i>Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
64x64	85,08%	0,5750	83,75%	83,75%	83,75%
128x128	89,22%	0,4316	86,75%	86,25%	86,25%
224x224	93,15%	0,2565	93%	93%	93%

Dari data pada tabel di atas, dapat disimpulkan bahwa nilai *resize* 224x224 menghasilkan akurasi terbaik yaitu sebesar 93,15% dan *loss* terkecil sebesar 0,2565.

2. Pengujian *Optimizer*

Tabel 2. Hasil Pengujian *Optimizer*

<i>Optimizer</i>	<i>Akurasi</i>	<i>Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Adam	76,83%	1,2627	95%	95%	95,25%
Nadam	95,97%	0,0943	96,25%	96%	96%
Adamax	85,92%	0,4336	89,75%	88,5%	88,5%
RMSProp	87,10%	0,7183	93,75%	92,25%	92,5%
SGD	69,35%	0,7628	79,45%	77,5%	92,5%
Adadelata	31,85%	1,3794	39,75%	44,25%	36%
Adagrad	56,85%	1,0734	67,25%	65%	64,75%

Dari data pada tabel di atas, dapat disimpulkan bahwa *optimizer* terbaik adalah Nadam yang menghasilkan akurasi 95,97% dan *loss* 0,0943 namun pada grafik mengalami *overfitting*. *Hyperparameter* awal

menggunakan *optimizer* Adamax, dan berdasarkan tabel, Adamax menghasilkan akurasi tertinggi ketiga dan tidak *overfitting*.

3. Pengujian *Learning Rate*

Tabel 3. Hasil Pengujian *Learning Rate*

<i>Learning Rate</i>	<i>Akurasi</i>	<i>Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
0,1	81,45%	0,6653	98,75%	98,75%	98,75%
0.01	77,2%	1,1488	99%	97,75%	97,5%
0,001	80,65%	0,7805	96,75%	96,25%	96,25%
0,0001	85,48%	0,4387	93,5%	93%	93%

Dari data pada tabel di atas, dapat disimpulkan bahwa nilai *learning rate* 0,0001 menghasilkan akurasi terbaik yaitu sebesar 85,48% dan *loss* sebesar 0,4387.

4. Pengujian *Epoch*

Tabel 4. Hasil Pengujian *Epoch*

<i>Epoch</i>	<i>Akurasi</i>	<i>Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
10	27,02%	1,5304	57,25%	41,25%	32%
20	83,06%	0,5378	90,5%	90,25%	90,25%
30	85,70%	0,2823	93,25%	92,25%	92,5%
40	92,34%	0,2343	92,25%	92%	91,75%
50	85,48%	0,5573	90,25%	88,5%	88,75%
60	90,32%	0,3851	88,5%	87,75%	87,75%
70	90,32%	0,3083	93%	92,25%	92,5%
80	89,52%	0,3398	92%	92%	91,75%
90	93,15%	0,1917	91%	89,75%	90%
100	91,94%	0,2854	91,75%	91%	91%
110	91,33%	0,3290	91,25%	90,25%	90,5%
120	90,32%	0,4221	91,75%	91,75%	91,75%

Dari data pada tabel di atas, dapat disimpulkan bahwa nilai *epoch* 90 menghasilkan akurasi terbaik yaitu sebesar 93,15% dan *loss* sebesar 0,1917. *Hyperparameter* awal menggunakan *epoch* 100 dengan menghasilkan akurasi 91,94%

dan *loss* 0,2854. Pengujian akan digunakan nilai *epoch* 100 karena nilai akurasi dan *loss* bagus dan grafik tidak mengalami *overfitting*.

5. Pengujian *Batch Size*

Tabel 5. Hasil Pengujian *Batch Size*

<i>Batch Size</i>	<i>Akurasi</i>	<i>Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
8	85,08%	0,4741	92%	92%	92%
16	91,94%	0,3023	93,75%	93,25%	93,25%
32	87,90%	0,3533	90,25%	89,75%	90%
64	87,90%	0,3819	91,5%	91,25%	91,25%

Dari data pada tabel di atas, dapat disimpulkan bahwa *batch size* 16 menghasilkan akurasi terbaik yaitu sebesar 91,94% dan *loss* 0,3023.

6. Pengujian *N-fold*


Tabel 5. Hasil Pengujian *N-fold*

<i>N-fold</i>	Akurasi	Loss	Precision	Recall	F1-Score
2	91,94%	0,2448	93,75%	93,75%	94%
3	89,92%	0,5227	93,25%	93,25%	93%
4	83,87%	0,6258	92,75%	92,75%	92,75%
5	88,71%	0,4019	94,75%	94,75%	94,75%

Dari data pada tabel di atas, dapat disimpulkan bahwa *n-fold* 2 menghasilkan akurasi terbaik yaitu sebesar 91,94% dan *loss* 0,2448.

7. Hasil Terbaik

Dari keenam skenario yang dilakukan, didapatkan skenario terbaik dari setiap parameter yang telah diuji. Parameter yang didapatkan yaitu menggunakan citra 224x224, dengan menggunakan *optimizer* Adamax, *learning rate* 0,0001; *epoch* 100, *batch size* 16, dan *n-fold* 3.



Gambar 4.1
Confusion Matrix Pengujian Terbaik

V. KESIMPULAN

Sistem deteksi kulit wajah dibagi menjadi empat tipe kelas yaitu normal, berminyak, kering, dan kombinasi menggunakan metode *convolutional neural network* arsitektur *mobilenet*. Hasil pengujian terbaik didapatkan saat ukuran citra 224x224 dengan akurasi 91,94% dan *loss* 0,2448; *learning rate* 0,0001 dengan akurasi 85,58% dan *loss* 0,4387; *optimizer* Nadam dengan akurasi 95,97% dan *loss* 0,0943; *batch size* dengan akurasi 91,94% dan *loss* 0,3023; *epoch* di angka 90 dengan akurasi 93,15% dan *loss* 0,1917; *batch size* 16 dengan akurasi 91,94% dan *loss* 0,3023; dan *n-fold* 2 dengan akurasi 91,94% dan *loss* 0,2448.

REFERENSI

- [1] D. Apriyani and Marwiyah, Journal of Beauty and Beauty Health Education, 2014, pp. 1-7.
- [2] T. F. B. Nusantara, Klasifikasi Jenis Kulit Wajah Pria Berdasarkan Tekstur Menggunakan Metode Gray Level Co-Occurance Matrix (GLCM) dan Support Vector Machine (SVM), 2018.
- [3] N. P. Safira, Klasifikasi Jenis Kulit Wajah Manusia Menggunakan Metode Gabor Wavelet Basis Android, 2020, pp. 436-444.
- [4] B. Chongke, J. Wang, D. Yulin, F. Baofeng, K. Jia-Rong and S. Yun, "MobileNet Based Apple Leaf Disease Identification," pp. 1-2, 2020.

- [5] S. J. Kalangi, "Histofisiologi Kulit," vol. 5, pp. 12-20, 2013.
- [6] N. N. Wardah, A. Sugiarto and A. H. Wibowo, "Sistem Pakar Identifikasi Kerusakan Kulit Wajah untuk Proses Aesthetic and Anti Aging," vol. III, p. 38, 2019.
- [7] J. Keller, D. Liu and D. Fogel, "Multilayer Neural Networks and Backpropagation," pp. 35-60, 2016.
- [8] S. Khan, H. Rahmani, S. A. A. Shah, M. Bennamoun, G. Medioni and S. Dickinson, "A Guide to Convolutional Neural Networks for Computer Vision," Morgan & Claypool, 2018. [Online]. Available: <https://ieeexplore.ieee.org/document/8295029>. [Accessed 6 May 2022].
- [9] S. Saha, "A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way," 16 December 2018. [Online]. Available: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. [Accessed 20 May 2022].
- [10] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," p. 2, 2017.