

OPTIMALISASI ARSITEKTUR MOBILENET UNTUK PENGKLASIFIKASIAN CUACA

MOBILENET ARCHITECTURE OPTIMALIZATION FOR WEATHER CLASSIFICATION

I Dewa Agung Aditya S.B^{*1}, Sofia Saidah^{*2}, Koredianto Usman^{*3}

^{1,2,3}Prodi S1 Teknik Telekomunikasi Fakultas Teknik Elektro, Universitas Telkom

¹ idewaagungaditya@student.telkomuniversity.ac.id,

²korediantousman@telkomuniversity.co.id, ³sofiasaidahsfi@telkomuniversity.ac.id

Abstrak

Cuaca adalah kondisi atmosfer dengan periode waktu yang singkat. Diketahui ada beberapa jenis cuaca yaitu cuaca cerah, berawan, hujan, dan panas. Kondisi cuaca juga berpengaruh terhadap aktifitas manusia sehari-hari. Adapun beberapa sektor yang dipengaruhi oleh kondisi cuaca yaitu sektor pertanian, peternakan, akuakultur, penerbangan, dan lain-lain. Perubahan cuaca yang ekstrim dengan waktu cepat, membutuhkan analisis klasifikasi cuaca yang cepat juga. Pada penelitian ini diusulkan desain sistem klasifikasi cuaca menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur MobileNet. Selain itu, penelitian ini memanfaatkan citra digital yang berasal dari data sekunder yaitu platform Kaggle. Dengan penelitian ini dilakukan proses akuisisi citra dengan dataset yang terdiri dari 4 kelas. Kelas tersebut terdiri dari 300 citra berawan, 215 citra hujan, 253 citra cerah, dan 357 citra cerah berawan. Dari dataset keseluruhan dibagi menjadi 80% data latih, 20% data uji. Dalam Penelitian ini dilakukan pengujian beberapa parameter yang mempengaruhi peformansi sistem antara lain image size, optimizer, learning rate, nilai epoch, dan batch size. Dari kelima parameter tersebut diuji menjadi 5 skenario. Masing-masing skenario dipilih hasil yang paling baik. Sehingga diperoleh parameter yang optimal yaitu resize citra 224×224 pixel, optimizer Adamax, epoch 50, batch size 16 dan learning rate 0,0001. Dengan nilai akurasi sebesar 95,56% dan nilai loss 0,194.

Kata kunci : *citra, convolutional neural network (CNN), MobileNet*

Abstract

Weather describes the condition of the atmosphere over a short period of time. It is known that there are several types of weather, namely sunny, cloudy, and rainy. Weather conditions also affect people's daily activities. Several sectors that are affected by weather conditions are agriculture, animal husbandry, aquaculture, aviation, and others. In this research, it is proposed to design a weather classification system using the Convolutional Neural Network (CNN) method with the MobileNet architecture. It can classify into 4 class namely, Rainy, Sunrise, Cloudy, and Shine. The class consists of 300 Cloudy images, 215 Rain images, 253 Shine images, and 357 Sunrise images. The overall dataset is divided into 60% training data, 20% test data, and 20% validation data. The design of this system is made by analyzing parameters that affect system performance based on the influence of image size, optimizer type, learning rate, and batch size. So that the optimal parameters are obtained, namely resize image to 224×224 pixel, Adamax optimizer, epoch 50, batch size 16 and learning rate 0.0001. With an accuracy value of 95.56% and a loss value of 0.194.

Keywords: *convolutional neural network (CNN), deep learning, MobileNet, weather classification*

1. Pendahuluan

Cuaca adalah kondisi atmosfer dengan periode waktu yang singkat. Diketahui ada beberapa jenis cuaca yaitu cuaca cerah, berawan, hujan, dan panas. Kondisi cuaca juga berpengaruh terhadap aktifitas manusia sehari-hari. Adapun beberapa sektor yang dipengaruhi oleh kondisi cuaca yaitu sektor pertanian, peternakan, akuakultur, penerbangan, dan lain-lain [1]. Salah satu contoh pada sektor pertanian yaitu perubahan cuaca yang ekstrim mempengaruhi tingkat produktifitas tanaman, pola tanam, dan hasil panen. Perubahan cuaca yang ekstrim dengan waktu cepat, membutuhkan analisis klasifikasi cuaca yang cepat juga.

Di Indonesia terdapat institusi yang bertugas mengamati kondisi meteorologi yaitu BMKG, dengan menggunakan sensor cuaca. Namun, sensor cuaca memiliki harga yang mahal. Maka dari itu, barang tersebut menjadi tidak populer dikalangan masyarakat menengah kebawah. Sebagai contoh didalam sektor pertanian, petani membutuhkan pengklasifikasian jenis cuaca yang cepat dan akurat. Oleh karena itu dibutuhkan alat atau sistem yang dapat memberikan informasi cuaca.

Saat ini klasifikasi citra atau gambar menggunakan metode deep learning sangat populer digunakan. Metode tersebut banyak digunakan untuk klasifikasi sampah, pengenalan rambu lalu lintas, dan pengenalan wajah [2]. Selain itu juga sudah ada beberapa penelitian tentang pengklasifikasian cuaca menggunakan metode deep learning.

Pada penelitian [2] menjelaskan tentang pengklasifikasian cuaca dengan metode ResNet dan DenseNet. Terdapat 12000 citra gambar dengan 400 gambar sebagai data uji dan 8000 gambar sebagai data latih. Didalam dataset tersebut ada 9 fenomena cuaca yaitu rain, dew, snow, frost, fog, ice, rain, haze. Dengan menggunakan 3 model dasar yaitu ResNet50, ResNet101, dan DenseNet121 diperoleh hasil akurasi klasifikasi model secara berurutan sebagai berikut 68,25% ,72,25%, 72,75%.

Pada penelitian [3] menjelaskan tentang pengklasifikasian citra cuaca yang datasetnya diperoleh dari data sekunder yaitu pengumpulan dari website dan requirement. Metode pengklasifikasian cuaca menggunakan Convolutional Neural Network (CNN) dengan arsitektur AlexNet dan GoogleNet. Jumlah dataset yang digunakan yaitu 16.635 gambar, dengan pembagian 4 kelas antara lain Sunny, Blizzard, Rainstorm, Fog. Adapun hasil pengujian sistem dari penelitian ini tanpa fine-tuning yaitu AlexNet 89,7% , Modified AlexNet 90,6% dan GoogleNet 90,1%.

Berdasarkan pada penelitian-penelitian sebelumnya cuaca dapat diklasifikasikan dengan beberapa metode deep learning. Namun, hasil akurasi sistem pada penelitian sebelumnya belum baik. Maka dari itu penulis membuat penelitian tentang klasifikasi cuaca dengan menggunakan metode CNN dan arsitektur yang dipilih yaitu MobileNet. Sehingga, dengan arsitektur tersebut dapat memperoleh akurasi lebih baik dari sistem klasifikasi cuaca pada penelitian sebelumnya. Dataset yang digunakan pada penelitian ini bersumber dari data sekunder yaitu Kaggle

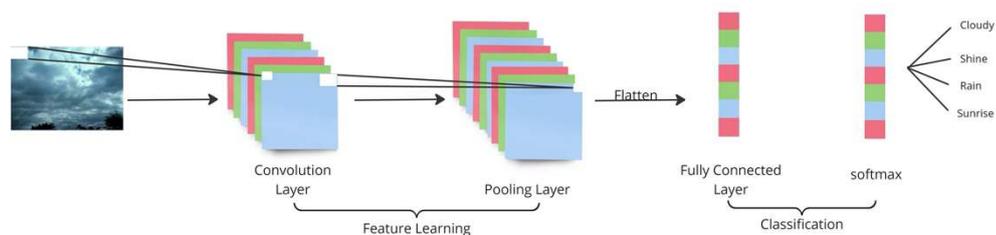
2. Dasar Teori /Material dan Metodologi/perancangan

2.1 Cuaca

Meteorologi adalah ilmu yang membahas tentang cuaca. Cuaca merupakan kondisi yang terjadi pada atmosfer dengan waktu yang relatif singkat. Perubahan cuaca dipengaruhi oleh temperatur udara, tekanan udara, kecepatan udara, sinar matahari dan lain-lain. Cuaca sangat penting diketahui dalam menjalankan aktivitas sehari-hari [1]. Adapun beberapa sektor yang dipengaruhi oleh kondisi cuaca yaitu sektor pertanian, peternakan, akuakultur, penerbangan, dan lain-lain. Berikut jenis-jenis cuaca yaitu cuaca cerah, cuaca panas, cuaca berawan, cuaca hujan, dan lain-lain.

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang biasanya digunakan dalam pengenalan atau pengolahan citra. CNN memiliki beberapa layer atau lapisan utama yaitu *input layer*, *convolution layer*, *pooling layer*, *fully-connected layer* dan *output layer*. Pada algoritma CNN menggunakan proses konvolusi, dimana kernel konvolusi atau filter digerakkan dengan ukuran tertentu.

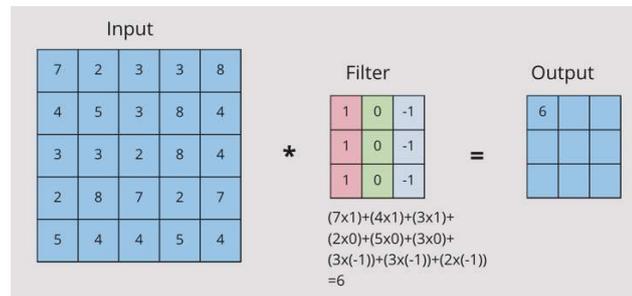


Gambar 1. Convolutional Neural Network (CNN)

2.2.1 Convolutional Layer

Convolutional layer merupakan lapisan pertama pada CNN yang berfungsi untuk mengekstrak informasi lengkap citra dari data *input layer*. Dalam Convolutional layer terjadi operasi

konvolusi pada output dari layer sebelumnya. Secara matematis, konvolusi adalah mengaplikasikan dua buah fungsi sehingga memperoleh fungsi baru. Tujuan dilakukannya konvolusi pada lapisan ini yaitu untuk memperoleh feature map dari pergeseran kernel (filter) ke seluruh permukaan citra. Berikut contoh yang terjadi pada lapisan konvolusi [4]:



Gambar 2. Contoh operasi konvolusi

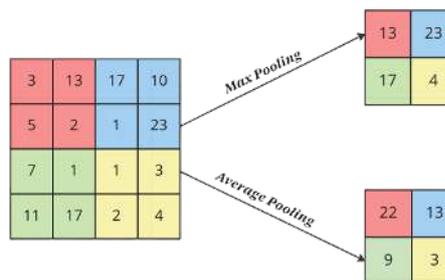
2.2.2 Rectified Linear Unit (ReLU) Activation Layer

Pada arsitektur CNN fungsi aktivasi biasanya terletak setelah hasil keluaran yang berupa feature map atau setelah proses perhitungan konvolusi atau pooling. ReLU berguna untuk menghasilkan suatu pola fitur, meminimalisir *error* dan menjadikan nol input *negative* serta memasukkan nilai *positive*. Fungsi aktivasi ReLU didefinisikan pada persamaan berikut [5]:

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

2.2.3 Pooling Layer

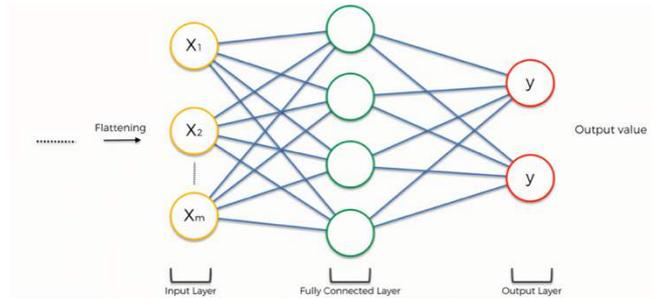
Pooling layer merupakan proses untuk mengurangi ukuran spasial data dan jumlah parameter serta mempercepat komputasi. Lapisan ini juga dapat mengontrol terjadinya *overfitting*. *Pooling layer* memiliki beberapa jenis yaitu *max pooling*, *average pooling*, dan *Lp pooling*. *Max pooling* membagi *output* dari *convolutional layer* menjadi beberapa grid kecil sesuai dengan ukurannya, selanjutnya mengambil nilai maksimal dari setiap grid. Sedangkan, dalam *average pooling* nilai yang diambil yaitu nilai rata-rata pada dari setiap grid [4]. Berikut contoh operasi *max pooling* dan *average pooling* [6]:



Gambar 3. Max Pooling dan Average Pooling

2.2.4 Fully Connected Layer

Fully Connected Layer merupakan lapisan yang sepenuhnya terhubung dan berfungsi untuk melakukan transformasi pada dimensi data, sehingga data dapat diklasifikasikan secara *linear*. Sebelum masuk ke lapisan *fully connected*, ada proses *flatten* yang berfungsi untuk mengkonversi *feature map* dari array multidimensi menjadi satu dimensi. Pada Gambar 4 ditunjukkan proses dalam *fully connected layer* [7].



Gambar 4. Fully Connected Layer

2.2.5 Softmax

Softmax merupakan algoritma regresi yang dapat mengklasifikasikan lebih dari dua kelas. Fungsi ini untuk memetakan output dari beberapa neuron dengan interval (0,1). Proses softmax digunakan sebagai fungsi aktivasi untuk mengetahui probabilitas pada multi-kelas yang diprediksi. Berikut persamaan yang menunjukkan fungsi softmax secara matematis [8].

$$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \tag{2}$$

2.3 Arsitektur MobileNet

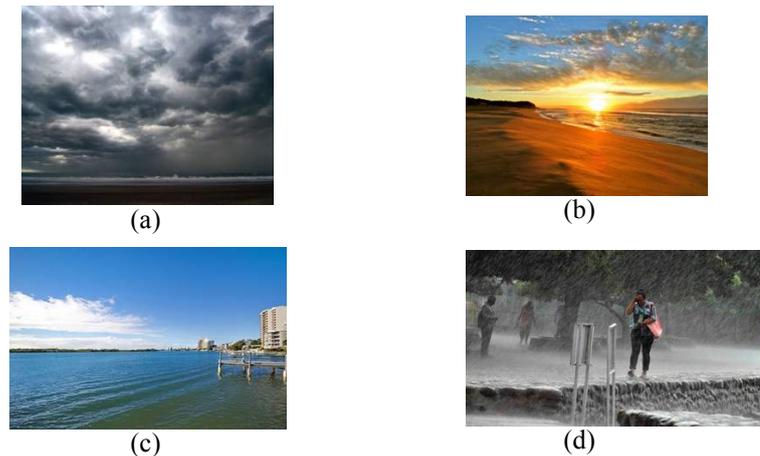
MobileNet merupakan salah satu arsitektur pada convolutional neural network (CNN). Arsitektur MobileNet di desain efisien untuk membangun model yang sangat kecil dengan latensi rendah yang akan mudah diimplementasikan sesuai kebutuhan mobile dan embedded applications. MobileNet memiliki dua lapisan utama yaitu convolution layer dan depthwise separable convolution. Di dalam depthwise separable convolution terdapat dua lapisan inti yaitu depthwise convolutions dan pointwise convolutions. Depthwise Convolution proses konvolusinya menggunakan filter tunggal pada setiap input filter, sedangkan pada Pointwise convolution proses konvolusinya menggunakan konvolusi 1x1 untuk membuat kombinasi linear output yang berasal dari Depthwise Convolution [9]. Pada Tabel berikut mempresentasikan arsitektur MobileNet.

Tabel 1. Arsitektur MobileNet

Arsitektur MobileNet
Input Layer
Convolutional Layer
Depthwise <i>n</i> Convolution layer Batch Normalization ReLU +
Pointwise <i>n</i> Convolution layer Batch Normalization ReLU (<i>n</i> = 1, 2, 3, ..., 13 layers)
Global Average Pooling Layer
Softmax
Output Layer

3. Pembahasan

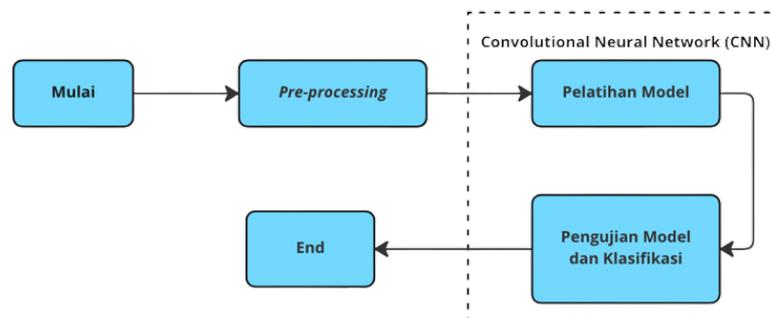
Pada penelitian ini menggunakan dataset yang berasal dari data sekunder yaitu pada platform Kaggle. Dataset yang digunakan ada 4 kelas yaitu 300 citra Berawan, 215 citra Hujan, 253 citra Cerah, dan 357 citra Cerah Berawan. Total keseluruhan jumlah data yaitu 1125 citra. Selanjutnya, dataset secara keseluruhan dibagi menjadi 80% data latih, dan 20% data uji. Berikut contoh jenis dataset



Gambar 5. Contoh Dataset jenis cuaca: (a) berawan, (b) cerah berawan, (c) cerah, (d) hujan

3.1 Desain Sistem

Pada penelitian ini dirancang sistem klasifikasi jenis cuaca menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet*. Berikut Gambar 5 mengilustrasikan desain sistem pada penelitian ini:



Gambar 5. Desain sistem klasifikasi cuaca

Pada tahapan pre-processing yaitu mengubah ukuran citra menjadi 64×64 pixel, 128×128 pixel, dan 224×224 pixel. Selanjutnya pada pelatihan model dan pengujian model menggunakan CNN. Hasil klasifikasi berupa 4 kelas jenis cuaca. Adapun parameter yang digunakan untuk mengetahui pengaruh terhadap performa sistem antara lain:

- Parameter resize citra dengan nilai 64×64 pixel, 128×128 pixel, dan 224×224 pixel
- Parameter jenis *Optimizer* yaitu Adam, Nadam, Adamax, SGD, RMSprop
- Parameter *learning rate* dengan nilai 0,1; 0,01; 0,001; 0,0001
- Parameter *epoch* 20, 30, 40, 50, 60, 60, 70, 80, 90, 100, 110, 120
- Parameter *batch size* dengan nilai 16, 32, 64

3.2 Peformansi Sistem

Peformansi sistem adalah tahap pengujian dan perhitungan untuk mengevaluasi keakuratan sistem. Parameter untuk menguji peformansi sistem terdiri dari *confusion matrix*, akurasi, presisi, *recall*, *F1-score*, dan *loss*. *Confusion Matrix* merupakan visualisasi data yang membantu untuk menghitung tingkat kebenaran dari sistem klasifikasi yang dirancang. *Confusion matrix* juga dapat menganalisis kelas-kelas yang berbeda pada tingkat klasifikasinya.

Tabel 2. *Confusion Matrix*

		Prediksi	
		Positif	Negatif
Data Uji	Positif	TP	FN
	Negatif	FP	TN

Keterangan:

- True Positive* (TP) adalah data positif yang diprediksi benar

- b. *True Negative* (TN) adalah data negatif yang diprediksi benar
- c. *False Positive* (FP) adalah data negative namun diprediksi sebagai data positif
- d. *False Negative* (FN) adalah data positif namun diprediksi sebagai data negative

Akurasi menjelaskan sebuah persentasi yang diprediksi benar oleh sistem, baik secara positif maupun negatif berdasarkan dengan keseluruhan data yang ada. Berikut rumus dari perhitungan akurasi:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (3)$$

Presisi merupakan rasio yang menggabarkan ketepatan sebuah model dalam memprediksi kejadian positif atau data positif. Berikut rumus dari perhitungan presisi:

$$Presisi = \frac{TP}{TP + FP} \quad (4)$$

Recall digunakan untuk mengevaluasi keberhasilan jenis citra mikroskopis saat melakukan identifikasi. Berikut menunjukkan persamaan *recall*:

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

F1-Score menunjukkan perbandingan antara nilai *recall* dan presisi. Pada *F1-Score* memiliki kecenderungan ketika nilai *recall* rendah, maka nilai presisi tinggi dan ini berlaku sebaliknya. Secara matematis *F1-Score* dituliskan sebagai berikut:

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (6)$$

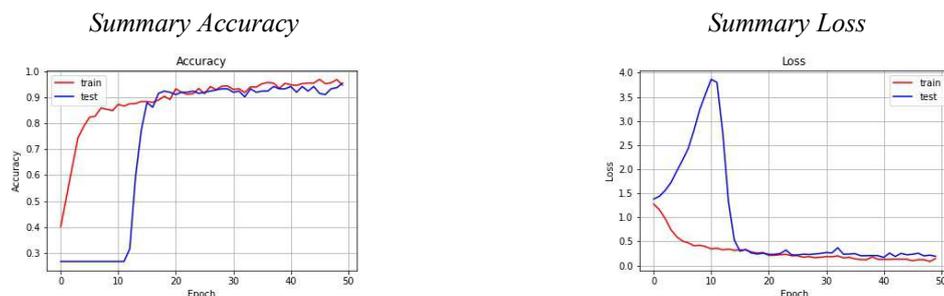
Loss merupakan parameter pengujian untuk mengetahui ketidaksesuaian sistem dalam mengenali atau mempelajari objek. Pada penelitian ini menggunakan jenis *Categorical Loss Entrophy*, dimana jenis ini membandingkan antara dua vektor probabilitas atau *multiclass*. Adapun rumus dari *loss* ini yaitu sebagai berikut:

$$Loss = - \sum_{i=1}^n P(x_i) \log Q(x_i) \quad (7)$$

4. Hasil dan Analisis

Pengujian sistem pada penelitian ini dilakukan berdasarkan beberapa parameter. Parameter tersebut antara lain pengujian ukuran citra, jenis optimizer, nilai epoch, nilai learning rate, dan nilai batch size. Maka dari itu pada penelitian ini dibuat 5 skenario pengujian, selanjutnya pada setiap skenario dipilih parameter paling baik berdasarkan akurasi dan loss terbaik.

Dalam 5 skenario diperoleh parameter yang optimal untuk dikombinasikan antara lain ukuran citra 224×224 *pixel*, *optimizer* Adamax, *epoch* 50, *batch size* 16 dan *learning rate* dengan nilai 0,0001. Adapun hasil pengujian sistem memperoleh akurasi sistem sebesar 95,56% dan nilai loss 0,194 dan terdapat hasil dalam grafik sebagai berikut:



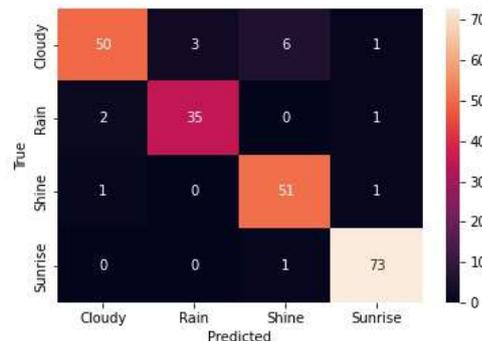
Gambar 6. Grafik Hasil Terbaik Akurasi dan Loss

Berdasarkan gambar diatas dapat dianalisis bahwa pada grafik akurasi dan *loss* tergolong stabil, stabil yang dimaksud yaitu tidak terjadi overfitting maupun underfitting. Hal itu ditandai dengan garis antara data latih dan data uji yang berhimpitan. Selanjutnya terdapat hasil perhitungan peformansi sistem sebagai berikut:

	precision	recall	f1-score	support
Cloudy	0.94	0.83	0.88	60
Rain	0.92	0.92	0.92	38
Shine	0.88	0.96	0.92	53
Sunrise	0.96	0.99	0.97	74
accuracy			0.93	225
macro avg	0.93	0.93	0.92	225
weighted avg	0.93	0.93	0.93	225

Gambar 7. Hasil perhitungan peforma sistem

Pada Gambar 7 menunjukkan bahwa hasil klasifikasi dari parameter terbaik yaitu hasil *weighted average* dengan presisi 93%, *recall* 93%, dan *F1-score* 93%. *Weighted average* merupakan hasil perhitungan rata-rata dengan mempertimbangkan bobot disetiap datanya, sedangkan *Macro Average* hasil perhitungan setiap kelas lalu mengambil rata-ratanya. Selain hasil tersebut dapat dilihat tingkat kebenaran sistem melalui *confusion matrix*.



Gambar 8. *Confusion matrix* sistem klasifikasi

Confusion matrix juga menunjukkan hasil terbaik dengan terlihat nilai terbanyak pada diagonal, yang artinya sebagian besar sistem mengklasifikasikan sesuai dengan jenis kelasnya yang benar. Dari *confusion matrix* juga dapat mengetahui seberapa banyak jumlah data yang diprediksi benar serta jumlah data yang diprediksi salah.

5. Kesimpulan

Sistem yang digunakan ini sudah mampu mengklasifikasikan jenis cuaca menggunakan metode *Convolutional Neural Network* dengan arsitektur *MobileNet*. Jenis cuaca yang dapat diklasifikasikan dalam 4 kelas yaitu Berawan, Hujan, Cerah, Cerah Berawan. Setelah dilakukan 5 skenario yaitu untuk mengetahui parameter yang mempengaruhi peforma sistem. Maka dari itu, parameter uji tersebut antara lain *image size*, jenis *optimizer*, *learning rate*, nilai *epoch*, dan *batch size*. Akurasi tertinggi diperoleh saat sistem menggunakan kombinasi parameter sebagai berikut, resize citra 224×224 pixel, *optimizer Adamax*, *epoch* 50, *batch size* 16 dan *learning rate* 0,0001. Maka dari itu, pengujian tersebut memperoleh hasil akurasi sistem sebesar 95,56% dan nilai *loss* 0,194

Daftar Pustaka

- [1] C. Lu, D. Lin, J. Jia, and C. K. Tang, "Two-Class Weather Classification," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 12, pp. 2510–2524, 2017, doi: 10.1109/TPAMI.2016.2640295.
- [2] Y. Wang and Y. X. Li, "Research on Multi-class Weather Classification Algorithm Based on Multi-model Fusion," *Proc. 2020 IEEE 4th Inf. Technol. Networking, Electron. Autom. Control Conf. ITNEC 2020*, no. Itnec, pp. 2251–2255, 2020, doi: 10.1109/ITNEC48623.2020.9084786.
- [3] Z. Zhu, L. Zhuo, P. Qu, K. Zhou, and J. Zhang, "Extreme weather recognition using convolutional neural networks," *Proc. - 2016 IEEE Int. Symp. Multimedia, ISM 2016*, pp. 621–

- 625, 2017, doi: 10.1109/ISM.2016.81.
- [4] S. R. Suartika E. P, I Wayan, Wijaya Arya Yudhi, "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>
- [5] B. Pradhan and M. I. Sameen, "Manifestation of SVM-Based Rectified Linear Unit (ReLU) Kernel Function in Landslide Modelling," *Sp. Sci. Commun. Sustain.*, pp. 185–195, 2018, doi: 10.1007/978-981-10-6574-3_16.
- [6] Z. Wang and Z. Qu, "Research on Web text classification algorithm based on improved CNN and SVM," *Int. Conf. Commun. Technol. Proceedings, ICCT*, vol. 2017-October, pp. 1958–1961, 2018, doi: 10.1109/ICCT.2017.8359971.
- [7] M. A. Khayer, M. S. Hasan, and A. Sattar, "Arabian date classification using CNN algorithm with various pre-trained models," *Proc. 3rd Int. Conf. Intell. Commun. Technol. Virtual Mob. Networks, ICICV 2021*, no. Iciev, pp. 1431–1436, 2021, doi: 10.1109/ICICV50876.2021.9388413.
- [8] C. Zhang, Z. Zhou, and L. Lin, "Handwritten Digit Recognition Based on Convolutional Neural Network," *Proc. - 2020 Chinese Autom. Congr. CAC 2020*, pp. 7384–7388, 2020, doi: 10.1109/CAC51589.2020.9326781.
- [9] W. Sae-Lim, W. Wettayaprasit, and P. Aiyarak, "Convolutional Neural Networks Using MobileNet for Skin Lesion Classification," *JCSSE 2019 - 16th Int. Jt. Conf. Comput. Sci. Softw. Eng. Knowl. Evol. Towar. Singul. Man-Machine Intell.*, pp. 242–247, 2019, doi: 10.1109/JCSSE.2019.8864155.