

SISTEM PENGENALAN WAJAH UNTUK KENDALI BERBASIS PERILAKU PENGGUNA PADA SMART HOME DENGAN ALGORITMA FASTER R-CNN

FACE RECOGNITION SYSTEM FOR CONTROL USER BEHAVIOR-BASED ON SMART HOME WITH FASTER R-CNN ALGORITHM

Muhammad Nando¹, Casi Setianingsih², Faisal Candrasyah Hasibuan³

^{1,2,3} Universitas Telkom, Bandung

muhammadnando@student.telkomuniversity.ac.id¹, setiacasie@telkomuniveristy.ac.id²,

faicanhasfcb@telkomuniversity.ac.id³

Abstrak

Smart Home merupakan salah satu teknologi yang sangat terkenal saat ini dan sering kali terdengar oleh kita. Penggunaan sistem rumah pintar ini sangat membantu pengguna dalam mengurangi pemborosan energi listrik dan memberikan kemudahan dalam melakukan kendali. Namun sistem rumah pintar saat ini perlu dilakukan pengembangan agar lebih baik, misalnya dengan penambahan fitur pengenalan wajah atau *face recognition*.

Berdasarkan proses pengujian yang dilakukan dari tahap pembuatan model, *training*, hingga proses pengenalan wajah, model yang dihasilkan memiliki keluaran yang dapat melakukan identifikasi dan klasifikasi wajah pengguna berdasarkan nilai *confidence* pada *bounding box*. Setelah melalui tahap pembuatan model, *training* dan pengenalan objek, yang menggunakan parameter Distribusi *Dataset* dan parameter *Learning Rate* dalam pengujiannya. Untuk pengujian dengan parameter distribusi *dataset* diperoleh nilai performansi sistem sebesar 99%, 92% untuk presisi dan 89% untuk nilai *recall*. Sedangkan untuk pengujian dengan parameter *learning rate* memiliki hasil untuk performansi sistem sebesar 90%, 80% nilai presisi dan 79% nilai *recall*. Dengan demikian sistem ini dapat mencapai performa yang maksimal.

Kata kunci : *Computer Vision, Face Recognition, Faster R-CNN, Object Detection, Smart Home.*

Abstract

Smart Home is one of the most famous technologies today and is often heard by us. The use of this smart home system is very helpful for users in reducing the waste of electrical energy and provide ease in controlling. But today's smart home system needs to be developed to be better, for example with the addition of facial recognition features or face recognition. This facial recognition will then perform the user's facial recognition. Then this feature will be integrated with the smart home system to control automatically so as to make the use of electrical energy more efficient and also provide convenience to the user in the operation of electronic devices, because the system will adjust the use of electronic devices in accordance with the user's habits and room conditions.

Based on the testing process carried out from the stage of model making, training, to the facial recognition process, the resulting model has an output that can identify and classify the user's face based on confidence values in the bounding box. After going through the stage of model creation, training and object recognition, which uses dataset distribution parameters and Learning Rate parameters in its testing. For testing with dataset distribution parameters obtained system performance values of 99%, 92% for precision and 89% for recall values. As for testing with learning rate parameters have results for system performance of 90%, 80% precision value and 79% recall value. Thus this system can achieve maximum performance.

Keywords: *Computer Vision, Face Recognition, Faster R-CNN, Object Detection, Smart Home.*

1. Pendahuluan

Sistem rumah pintar atau yang sering kita dengar sebagai *Smart Home* merupakan suatu sistem pintar yang terintegrasi, dan memungkinkan pengguna untuk menggunakan energi listrik dengan efisien. Selain itu, sistem ini juga memberikan kenyamanan dan kemudahan kepada pengguna karena pengguna dapat melakukan kendali jarak jauh pada perangkat elektronik tanpa harus berpindah dari tempat duduknya [1]. Namun sistem rumah pintar ini juga butuh perkembangan agar sistem ini jadi lebih baik, yaitu dengan menambahkan *face recognition* atau pengenalan wajah.

Penambahan fitur pengenalan wajah pada smart home dapat memberikan kemudahan kepada pengguna karena kendali perangkat elektronik jadi lebih mudah karena adanya cara baru dalam penggunaan perangkat elektronik. Selain itu, pengenalan wajah dipilih karena wajah setiap orang memiliki ciri yang berbeda-beda dan menjadi identitas individu.

Tujuan dari tugas akhir ini adalah merancang solusi sistem tersebut, dengan menggunakan kamera dan mikrokomputer. Pengembangan sistem ini berfungsi untuk mendeteksi dan mengenali wajah pengguna yang melakukan pengoperasian perangkat yang ada disuatu ruangan menggunakan kamera. Sistem pengenalan wajah ini

menggunakan algoritma *Deep Learning Faster R-CNN* untuk melakukan pengenalan, klasifikasi, dan training agar dapat dikenali oleh komputer. Setelah pengolahan data sudah selesai, maka perangkat elektronik yang sudah terintegrasi dengan sistem rumah pintar akan dikendalikan secara otomatis berdasarkan kebiasaan dari pengguna sehingga memberikan kemudahan dalam pengoperasian perangkat dan efisiensi dalam penggunaan energi listrik.

2. Dasar Teori

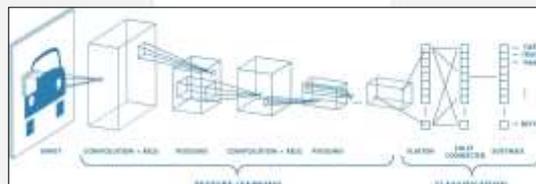
2.1 Face Recognition

Face Recognition adalah salah satu teknologi pengenalan yang paling populer pada bidang biometrik. Teknologi pengenalan wajah ini dianggap unik karena menggunakan wajah pengguna sebagai identitas yang sifatnya berbeda-beda setiap individu [2]. Dengan mengarahkan wajah ke modul kamera, maka wajah pengguna digunakan sebagai objek untuk melakukan identifikasi dan verifikasi akan dibandingkan terhadap informasi yang diperoleh sistem dengan semua pengguna dalam *dataset* [3].

2.2 Convolutional Neural Network (CNN)

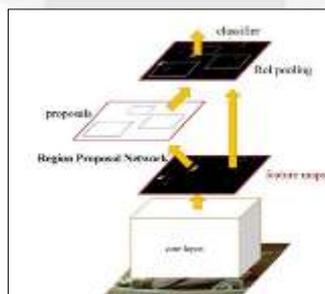
Melakukan pengolahan data dalam bentuk dua dimensi, melakukan klasifikasi data, proses *training* data dan bertujuan untuk mengelompokkan suatu data ke data sebelumnya merupakan fungsi dari algoritma *Convolutional Neural Network* (CNN). Pada algoritma ini terdiri dari dari neuron 3 dimensi (lebar, tinggi, kedalaman). Untuk ukuran lapisan menggunakan parameter lebar dan tinggi, sedang untuk jumlah lapisan menggunakan parameter kedalaman. Pengolah citra memiliki nilai keluaran dari gambar yang diolah dan digunakan sebagai nilai masuk pada lapisan berikutnya [4], [5]. Pada umumnya, klasifikasi CNN dibagi menjadi dua, diantaranya:

1. Tahap Ekstraksi Fitur (*feature extraction layer*), terdiri atas beberapa lapisan yang tersusun dari neuron yang saling terhubung pada awal arsitektur. Beberapa lapisan tersebut yaitu lapisan *convolutional layer* dan yang kedua adalah *pooling layer*. Pada setiap lapisan juga terdapat fungsi aktivasi dengan posisi yang bergantian. Tahap ini akan menerima nilai masukan gambar dan memprosesnya sehingga menghasilkan nilai keluaran berupa vector yang akan diolah pada lapisan berikutnya. Fungsi aktivasi *Rectified Linear Unit* (ReLU) akan menghasilkan nol apabila $x < 0$ dan linier dengan kemiringan satu ketika $x > 0$ [4], [5].
2. Tahap Klasifikasi, terdiri dari beberapa lapisan yang tersusun atas neuron yang saling terkoneksi secara penuh (*fully connected*). Pada tahap ini akan menerima nilai masukan dari hasil keluaran lapisan ekstraksi fitur berupa konvolusi dan *pooling layer*, serta gambar vector yang diolah atau ditransformasikan dengan penambahan *hidden layer*. Akurasi kelas untuk klasifikasi merupakan hasil keluarannya [4], [5].



Gambar 1. Ilustrasi CNN [6]

2.3 Faster R-CNN



Gambar 2. Arsitektur Umum Pada Faster R-CNN [7]

Algoritma *Faster R-CNN* adalah algoritma untuk melakukan pelatihan dalam deteksi dan pengenalan objek yang menggunakan *Fast R-CNN* dan *Region Proposal Network* (RPN) sebagai arsitektur utamanya. Algoritma ini juga merupakan hasil pengembangan dari algoritma *Fast R-CNN* untuk mengurangi terjadinya *bottleneck* dan mengganti peran *selective search* dengan *Region Proposal Network* (RPN). Selain itu, *Faster R-CNN* menjadi salah satu opsi yang banyak dipilih untuk deteksi dan pengenalan objek berbasis *deep learning* [7].

a. Regional Proposal Network (RPN)

Region Proposal Network merupakan suatu proses untuk menemukan kemungkinan lokasi objek pada gambar dengan memasukkan yang cepat. Untuk mengganti penggunaan *selective search*, digunakanlah RPN yang bertujuan dapat mengurangi kebutuhan komputasi yang berlebihan secara signifikan dan membuat keseluruhan objek dapat dilatih *end-to-end*. Adanya kemungkinan batasan lokasi objek pada gambar dari wilayah yang diketahui disebut

dengan *Region of Interest* (RoI). Pada tahapan awal RPN, citra input diproses pada jaringan saraf konvolusi agar menghasilkan *feature map* [7], [8].

b. *Region Of Interest* (ROI)

Region of Interest merupakan suatu teknik mempersempit area tangkap pada pengolahan citra untuk mempermudah dalam pengambilan citra digital. Pada area tertentu dari citra digital, ROI memungkinkan untuk dilakukan pengkodean berbeda, sehingga memiliki hasil kualitas yang lebih baik dibandingkan dengan area sekitarnya. Fitur ini dianggap penting karena bagian penting dari suatu citra dapat dijadikan prioritas [9].

2.4. *Confusion Matrix*

Confusion matrix merupakan suatu informasi yang berkaitan dengan prediksi dan aktualisasi dari sistem klasifikasi yang memiliki data nilai kebenaran (*supervise*) serta menggunakan bentuk matriks untuk datanya. Data yang ada pada matriks akan digunakan untuk memperoleh beberapa nilai berdasarkan data yang diklasifikasi dan diprediksi, diantaranya yaitu *Accuracy*, *Precision*, dan *Recall*. Pada klasifikasi objek seperti *Faster R-CNN* pengukuran dengan menggunakan *Average Precision* (AP) merupakan pengukuran yang populer dibidang ini. Nilai yang digunakan untuk melakukan perhitungan nilai yaitu dari 0 hingga 1. Nilai AP biasanya digunakan sebagai titik ukur tingkat akurasi pada suatu model yang nantinya nilai tersebut akan memperoleh nilai *Mean Average Precision* (mAP)[10].

1. Akurasi

Akurasi merupakan nilai yang menggambarkan hasil pengukuran, perhitungan dan pengamatan dari rasio benar (positif dan negatif) dari keseluruhan data yang digunakan.

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

2. Presisi

Presisi merupakan nilai yang menggambarkan hasil pengukuran dan perbandingan data yang diprediksi dengan benar dari seluruh data yang diprediksi positif.

$$precision = \frac{TP}{TP+FP} \quad (2)$$

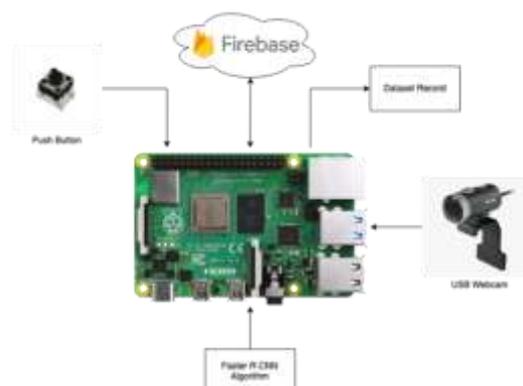
3. *Recall*

Recall merupakan nilai yang menggambarkan hasil pengukuran data dengan klasifikasi positif benar.

$$recall = \frac{TP}{TP+FN} \quad (3)$$

3. Pembahasan

3.1. Gambaran Umum Sistem



Gambar 3. Gambaran Umum Sistem

Pada tugas akhir ini dibuat sebuah sistem yang akan melakukan pengenalan wajah untuk diimplementasikan pada sistem *Smart Home* yang terintegrasi agar sistem ini dapat melakukan kendali otomatis berdasarkan kebiasaan pengguna dengan menggunakan modul kamera dan juga mikrokomputer Raspberry Pi. Modul kamera akan melakukan *face recognition* untuk dijadikan tahap awal pada proses perekaman data kegiatan pengguna, nilai masukan atau *dataset* berdasarkan data yang sudah didaftarkan dan dilatih menggunakan algoritma *Faster R CNN* sebelumnya. Perekaman data kegiatan pengguna akan dilakukan dengan menekan tombol yang sudah disesuaikan dengan ID pengguna, tombol juga berfungsi untuk memberikan perintah kepada program untuk melakukan identifikasi pengguna. Jika pengguna dikenali dan sesuai dengan ID tombol yang digunakan, maka data akan

direkam. Namun jika pengguna tidak dikenali, maka perekaman data tidak dilakukan.

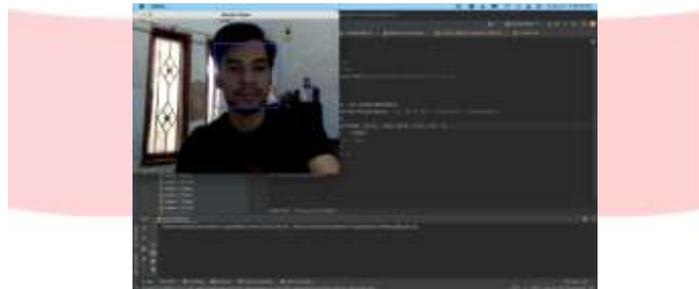
Mikrokomputer *Raspberry Pi* berfungsi untuk melakukan pengolahan citra dan juga melakukan pertukaran data dengan *firebase (cloud database)*. Pada pengerjaan sistem ini, penggunaan *Tensorflow* berperan sebagai *library* untuk melakukan pembelajaran mesin, *OpenCV* sebagai *detector* dan sistem dibangun menggunakan bahasa pemrograman *Python*.

3.2. Analisis Kebutuhan Dataset Pada Faster R-CNN

Pada tugas akhir ini menggunakan dataset sebanyak 400 gambar wajah manusia yang diperoleh dari 4 wajah pengguna dan dibagi kedalam 4 kelas berisikan 100 gambar dari wajah pengguna untuk dilakukan proses *training* model klasifikasi. Kemudian menggunakan 90 gambar untuk kelas yang tidak dikenali dan sebagai nilai negatif pada *testing*.

3.3. Pengumpulan Dataset

Pengumpulan dataset dilakukan dengan menggunakan program yang dibuat untuk mengambil *frame* gambar dari *live feed camera*. Sebelum melakukan pengambilan gambar, terdapat masukan yang akan menjadi ID pengguna. Kemudian, dari program yang digunakan akan mengaktifkan kamera dan dilakukan pengambilan gambar sebanyak 100 *frame* setiap 1 kelas. Kelas yang digunakan sebanyak 4 kelas pengguna sehingga jumlah seluruh dataset pengguna sebanyak 400 gambar. Penggunaan data wajah lainnya juga digunakan pada penelitian ini sebanyak 90 gambar untuk pengguna yang tidak dikenali.



Gambar 4. Pengambilan Dataset Melalui Live Feed Webcam

3.4. Pelabelan Gambar

Pemberian label atau anotasi pada gambar merupakan suatu proses pemilihan fitur pada setiap gambar yang berisikan informasi penting. Berkas gambar yang sudah diberikan label nantinya akan disimpan dalam format XML. Untuk melakukan labeling akan dilakukan secara manual dengan menggunakan aplikasi *LabelImg*.

Berkas XML yang telah dibuat memuat beberapa informasi diantaranya nama kelas, resolusi gambar, dan nilai pada setiap bounding box. Nilai bounding box memiliki koordinat, yaitu *Ymin*, *Xmin*, *Ymax* dan *Xmax*.



Gambar 5. Proses Pelabelan Dataset

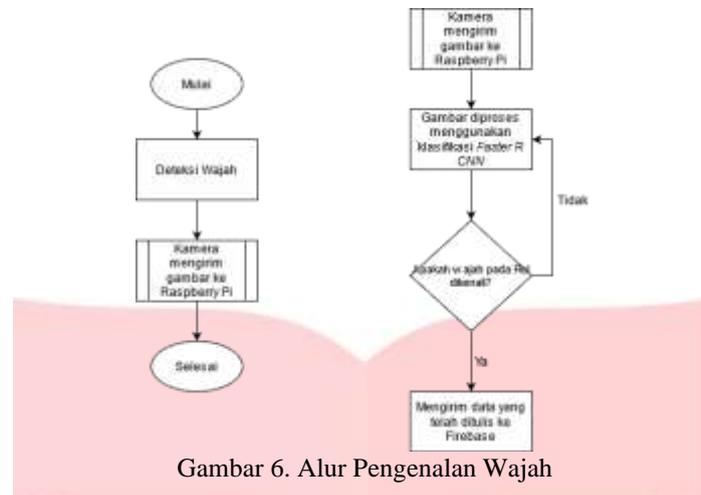
3.5. Proses Training

Setelah melakukan tahapan-tahapan sebelum *training* sampai tahap konfigurasi *pipeline*, saatnya dilakukan proses *training*. Proses bertujuan untuk membuat model baru menggunakan dataset yang sudah diberikan anotasi, dan *pipeline* yang sudah dikonfigurasi dengan parameter-parameter yang tersedia. Proses ini akan dilakukan berulang kali hingga mendapatkan hasil yang terbaik dengan nilai *error loss* yang kecil. Setelah proses *training* selesai, akan dihasilkan model klasifikasi untuk melakukan pengenalan pada objek yang sesuai dengan model pada *dataset* yang diolah.

3.6. Pengenalan Wajah

Proses pengenalan wajah dimulai dari penangkapan gambar yang diambil melalui *live* kamera dan diproses menggunakan model *Faster R-CNN* yang sudah diolah sebelumnya, sehingga sistem dapat melakukan identifikasi dan klasifikasi objek yang dideteksi berupa wajah pengguna. Klasifikasi objek ini menggunakan 4 kelas yang berarti setiap pengguna mempunyai 1 kelasnya sendiri. Sistem ini akan melakukan klasifikasi secara *real time*.

Jika wajah yang dideteksi dikenali, maka akan muncul *bounding box* sesuai dengan sesuai beserta nilai *confidence*-nya. Kemudian data wajah yang dikenali tersebut akan dikirimkan ke *firebase cloud*. Jika wajah tidak dikenali, maka data tidak akan dikirimkan ke *firebase cloud*.



4. Implementasi dan Pengujian Sistem

4.1. Tahapan Pengujian

Setelah perancangan sistem selesai, langkah selanjutnya yaitu melakukan pengujian sistem. Pengujian ini memiliki tujuan untuk:

1. Mencari parameter dengan hasil terbaik agar sistem dapat berjalan dengan maksimal.
2. Mencari nilai akurasi pada identifikasi dan klasifikasi oleh sistem.
3. Mengetahui apakah sistem dapat melakukan identifikasi dan klasifikasi wajah pengguna.
4. Melakukan analisis performa sistem.

4.2. Skenario Pengujian

Pengujian sistem akan menggunakan model yang telah dilatih menggunakan dataset yang telah diproses sebelumnya. Adapun perangkat keras yang digunakan yaitu laptop, mikrokomputer *Raspberry Pi*, dan kamera *webcam*. Pada perancangan tugas akhir ini terdapat beberapa skenario pengujian, diantaranya:

- Akurasi pada pengenalan wajah.
- Presisi dan juga *recall*

Nilai akurasi merupakan parameter yang dapat digunakan untuk menguji apakah suatu model dapat bekerja optimal atau tidak. Hal ini juga menentukan bisa atau tidaknya sistem dalam mengenali suatu objek yang telah dilatih. Untuk mendapat nilai akurasi yang terbaik, maka dibutuhkan parameter optimal yang sangat mempengaruhi nilai akurasi. Berikut beberapa parameter yang dapat mempengaruhi nilai akurasi pada model, yaitu Distribusi Data, Learning Rate, Epoch dan Global Steps.

4.3. Hasil Pengujian dan Analisis Sistem

Sebelum dilakukan pengenalan wajah, dibutuhkan model klasifikasi yang dapat bekerja dengan baik dari akurasi maupun performa agar dapat mengenali objek secara *real time* pada setiap pengguna. Pengujian ini dilakukan dengan model-model yang sudah dilatih menggunakan parameter distribusi *dataset*.

Dalam mempelajari suatu data, distribusi *dataset* merupakan salah satu parameter yang memiliki pengaruh. Jika suatu model memiliki data *training* yang banyak, maka akan semakin dalam pembelajaran yang dilakukan pada model, sehingga memberikan hasil yang lebih baik dalam pengenalan objek.

a. Pengujian Distribusi Dataset

Pada pengujian distribusi dataset, akan digunakan 5 tahapan dalam mendistribusikan dataset. Dimulai dari 50% data *training* dan 50% data *test*. Hingga akhirnya didistribusikan data sebanyak 90% data *train* dan 10% data *test*. Hasil dari pendistribusian dataset tadi akan dilakukan evaluasi untuk menentukan nilai akurasi yang paling baik. Konfigurasi lainnya pada pipeline yaitu *learning rate* dengan nilai 0.002, *num_epochs* sebesar 35, *batch_size* dengan nilai 1 dan proses ini menggunakan *global steps* sebanyak 10000 langkah. Konfigurasi ini merupakan pengaturan *default* saat melakukan pengujian ini dengan pendistribusian *dataset*.

Tabel 1. Pengujian Distribusi Dataset

No.	Pengujian Distribusi Dataset			
	Distribusi Dataset	Precision	Recall	Accuracy

1.	50%-50%	87%	81%	95%
2.	60%-40%	81%	96%	99%
3.	70%-30%	92%	92%	98%
4.	80%-20%	80%	97%	99%
5.	90%-10%	92%	89%	99%

b. Pengujian Learning Rate

Pengujian ini akan menggunakan sebanyak 6 nilai *learning rate* dari 2×10^{-2} hingga 2×10^{-7} . Konfigurasi lainnya pada pipeline yaitu *num_epochs* sebesar 35, *batch_size* dengan nilai 1 dan proses ini menggunakan *global_steps* sebanyak 10000 langkah. Berikut tabel hasil perhitungan dengan parameter *learning rate*.

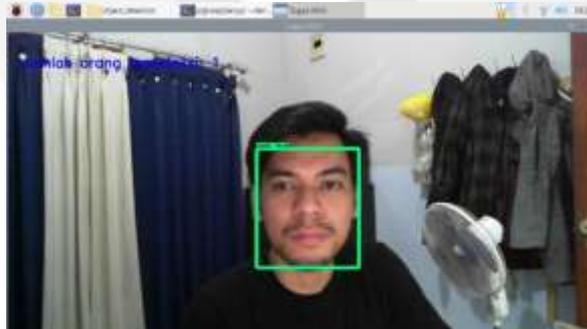
Tabel 2. Hasil Pengujian Learning Rate

No.	Pengujian Learning Rate			
	Learning Rate	Precision	Recall	Accuracy
1.	2×10^{-2}	3%	20%	82%
2.	2×10^{-3}	61%	79%	88%
3.	2×10^{-4}	80%	79%	90%
4.	2×10^{-5}	76%	80%	90%
5.	2×10^{-6}	78%	83%	89%
6.	2×10^{-7}	42%	35%	73%

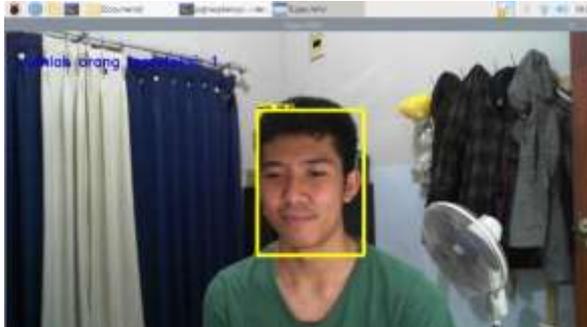
Dari 6 kali pengujian, hasil yang memperoleh akurasi tertinggi dibanding percobaan lainnya yaitu pada *learning rate* 2×10^{-4} dengan nilai presisi 80%, nilai recall sebesar 79% dan nilai akurasi sebesar 90%. Sedangkan hasil percobaan pada *learning rate* 2×10^{-2} menghasilkan nilai yang kurang baik karena perubahan beban yang diberikan pada model terlalu besar, sehingga proses *training* tidak stabil.

c. Pengujian Identifikasi dan Klasifikasi Wajah

Setelah melakukan proses *training* untuk mendapatkan model dengan hasil yang terbaik, selanjutnya dilakukan pengujian identifikasi dan klasifikasi model yang digunakan pada objek. Citra objek akan ditangkap secara *live* melalui *webcam* dan diproses secara *real-time* untuk melakukan identifikasi dan klasifikasi pada *frame*. Pengujian ini bertujuan untuk melihat secara langsung hasil pengolahan model yang dilatih. Pengujian ini menggunakan model *inference_graph* dengan nilai terbaik dari pengujian parameter Distribusi *Dataset* dan parameter *Learning Rate*.



Gambar 7. Penggunaan Model Parameter Distribusi Dataset



Gambar 8. Penggunaan Model Parameter Learning Rate

Pada pengujian ini didapatkan sistem dapat melakukan identifikasi dan klasifikasi wajah pengguna. Pada Gambar 7 pengguna berhasil diidentifikasi dengan nilai confidence 99% dan diklasifikasikan pada kelas "nando". Pada Gambar 8 pengguna berhasil diidentifikasi dengan nilai confidence 100% dan diklasifikasikan pada kelas "narta".

5. Kesimpulan

Berdasarkan hasil Tugas Akhir ini maka dapat diambil beberapa kesimpulan diantaranya :

1. Pada pengujian ini menggunakan sebanyak 400 data gambar dan menggunakan 4 kelas. Sistem ini dapat melakukan identifikasi dan klasifikasi pada objek berupa wajah. Berdasarkan proses pengujian yang dilakukan dari tahap pembuatan model, training , hingga proses pengenalan wajah, model yang dihasilkan memiliki keluaran yang dapat melakukan identifikasi dan klasifikasi wajah pengguna berdasarkan nilai confidence pada bounding box.
2. Untuk melakukan analisis performansi, pengujian ini menggunakan parameter distribusi dataset dan juga learning rate untuk mendapatkan nilai yang baik pada setiap pembelajaran mesin. Berdasarkan pengujian distribusi dataset, hasil terbaik yang diperoleh untuk performansi sistem ini memperoleh angka sebesar 99% untuk akurasi, 92% untuk presisi dan 89% untuk nilai recall. Sedangkan untuk pengujian dengan parameter learning rate memiliki hasil untuk performansi sistem sebesar 90% nilai akurasi, 80% nilai presisi dan 79% nilai recall. Dengan demikian sistem ini dapat mencapai performa yang maksimal.

REFERENSI

- [1] T. F. Yurnama and N. Azman, "Perancangan Software Aplikasi Pervasive Smart Home," *Snati*, vol. 2009, no. Snati, pp. E2–E5, 2009, [Online]. Available: <https://www.neliti.com/id/publications/116718/perancangan-software-aplikasi-pervasive-smart-home>.
- [2] I. T. Nugraha, R. Patmasari, and A. I. Irawan, "MENGUNAKAN FACE RECOGNITION PADA RASPBERRY PI," pp. 4–12.
- [3] M. N. Amirullah *et al.*, "FACE RECOGNITION PADA SMART MIRROR DENGAN METODE ALGORITMA PRINCIPAL COMPONENT ANALYSIS (PCA) FACE RECOGNITION ON SMART MIRROR WITH ALGORITHMS PRINCIPAL COMPONENT ANALYSIS (PCA)," pp. 1–7.
- [4] B. A. Budiman, I. I. Tritasmoro, R. Rahmania, F. T. Elektro, and U. Telkom, "ANALISI PERFORMANSI DETEKSI PELANGGARAN STOP MENGGUNAKAN FASTER R-CNN PERFORMANCE ANALYSIS STOP VIOLATION DETECTION USING FASTER R-."
- [5] M. Zufar and B. Setiyono, "Convolutional Neural Networks Untuk Pengenalan Wajah Secara Real-Time," *J. Sains dan Seni ITS*, vol. 5, no. 2, p. 128862, 2016, doi: 10.12962/j23373520.v5i2.18854.
- [6] P. Navia R, "PENERAPAN METODE CONVOLUTIONAL NEURAL," Jakarta.
- [7] Sunario Megawan and Wulan Sri Lestari, "Deteksi Spoofing Wajah Menggunakan Faster R-CNN dengan Arsitektur Resnet50 pada Video," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 3, pp. 261–267, 2020, doi: 10.22146/v9i3.231.
- [8] S. M. Abbas and S. N. Singh, "Region-based Object Detection and Classification using Faster R-CNN," *Int. Conf. "Computational Intell. Commun. Technol. CICT 2018*, no. Cict, pp. 1–6, 2018, doi: 10.1109/CICT.2018.8480413.
- [9] E. Angelina, I. Iwut T, and K. Usman, "KOMPRESI ADAPTIF UNTUK CITRA WAJAH DENGAN METODE AUTOMATIC REGION of INTEREST (ROI) PADA JPEG 2000," 2009.
- [10] J. Adiwibowo, "Deteksi Alat Pelindung Diri Menggunakan Metode YOLO dan Faster R-CNN."