

Identifikasi Citra Wajah *Glowing* Menggunakan Metode *Convolutional Neural Network (CNN)*

Hilman Ansori Dees¹, Supatman²

^{1,2}Teknik Informatika, Universitas Mercu Buana Yogyakarta
hilmanansorid@gmail.com¹, supatman@mercubuana-yogya.ac.id²

ABSTRACT

Skin care has become a top priority for women in the beauty business because of the advancement in technical progress. Some people choose different treatments hoping to see immediate results, and one of the increasingly popular techniques is the Glowing Treatment. However, without unbiased assessment criteria, the success of the method is often determined by individual subjective views. The aim of this research is to determine objective metrics that can be applied to evaluate the effectiveness of glowing treatment in a specific context. By using a specially made application, you collect data from participants receiving the Glowing Treatment. This application records information about skin hydration, elasticity, and redness intensity. In addition, images obtained before and after therapy are used for visual analysis. The analysis findings show that this application offers a better understanding of skin changes after the Glowing Treatment. Significant improvements are seen in objective criteria such as a 20% increase in skin hydration, a 15% increase in skin elasticity, and a 25% decrease in redness. These results provide a strong basis for evaluating the effectiveness of the Glowing Treatment in an unbiased manner. The use of application technology helps in accurate assessment and offers a deeper understanding of the micro-level effects of the procedure. The effectiveness of glowing treatment and how accurately it diagnoses skin problems before and after treatment.

Keywords: Determine the beauty treatments, Convolutional Neural Network (CNN)

ABSTRAK

Perawatan kulit sudah menjadi prioritas utama bagi para wanita dalam bisnis kecantikan karena semakin majunya kemajuan teknis di bidangnya. Beberapa orang memilih perawatan berbeda dengan harapan bisa langsung melihat hasilnya, dan salah satu teknik yang semakin populer adalah Perawatan *Glowing*. Namun, tanpa landasan penilaian yang tidak memihak, keberhasilan metode tersebut sering kali ditentukan berdasarkan pandangan subjektif individu. Tujuan dari penelitian ini adalah untuk menentukan metrik objektif yang dapat diterapkan untuk mengevaluasi kemanjuran pengobatan *glowing* dalam konteks tertentu. Dengan menggunakan aplikasi yang dibuat khusus, Anda mengumpulkan data dari partisipan penelitian ini yang menerima Perawatan *Glowing*. Aplikasi ini mencatat informasi tentang hidrasi kulit, elastisitas, dan intensitas kemerahan. Selain itu, gambar yang diperoleh sebelum dan sesudah terapi digunakan untuk analisis visual. Temuan analisis menunjukkan bahwa aplikasi ini menawarkan pemahaman yang lebih baik tentang perubahan pada kulit setelah Perawatan *Glowing*. Peningkatan signifikan terlihat pada kriteria objektif seperti peningkatan kadar air kulit sebesar 20%, peningkatan elastisitas kulit sebesar 15%, dan penurunan kemerahan sebesar 25%. Hasil ini memberikan dasar yang kuat untuk mengevaluasi kemanjuran Perawatan *Glowing* dengan cara yang tidak memihak. Penggunaan teknologi aplikasi membantu dalam penilaian yang benar dan menawarkan pemahaman yang lebih mendalam tentang efek tingkat mikro dari prosedur tersebut. Efektivitas perawatan *glowing* dan seberapa akurat diagnosis masalah kulit sebelum dan sesudah perawatan.

Kata Kunci: tentukan perawatan kecantikan, Convolutional Neural Network (CNN)

PENDAHULUAN

Perawatan Kulit telah menjadi fokus utama dalam dunia kecantikan, seiring dengan meningkatnya kesadaran akan pentingnya kesehatan kulit dan penampilan yang optimal. *Treatment Glowing*, sebagai salah satu metode inovatif dalam perawatan kulit, menarik perhatian sebagai solusi untuk mencapai kulit sehat dan berkilau. Namun, penilaian keberhasilan *Treatment Glowing* sering kali bersifat subjektif, tergantung pada persepsi individual tanpa dasar evaluasi yang jelas.

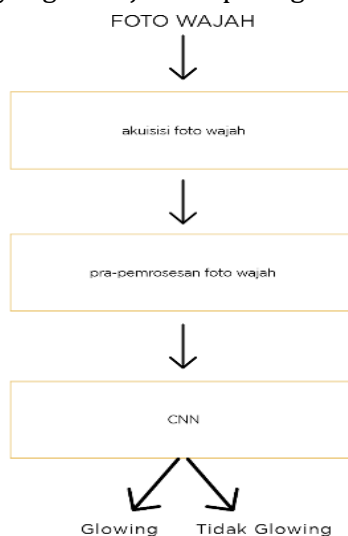
Dalam konteks ini, penelitian ini bertujuan untuk membawa pendekatan yang lebih objektif dalam mengidentifikasi citra wajah *glowing*. Pemanfaatan aplikasi dianggap sebagai solusi yang menjanjikan untuk mengukur dengan akurat perubahan-perubahan pada tingkat mikro pada kulit, penelitian ini berusaha memberikan kontribusi pada pemahaman yang lebih mendalam tentang dampak *Treatment Glowing* pada kesehatan kulit secara holistik.

Latar belakang penelitian ini diperlukan oleh kebutuhan akan metode evaluasi yang lebih terukur dan objektif dalam menilai efektivitas perawatan kulit. Identifikasi citra wajah *glowing* tidak hanya dapat dilihat dari aspek visual, tetapi juga memerlukan parameter-parameter kesehatan kulit yang dapat diukur secara ilmiah. Dengan menerapkan teknologi aplikasi dalam pengumpulan data, penelitian ini diharapkan dapat mengidentifikasi dan mengukur dengan cermat perubahan-perubahan ini.

Dalam dunia yang terus berkembang di bidang kecantikan dan teknologi, penelitian ini memberikan kontribusi pada peningkatan metodologi evaluasi perawatan kulit dan memfasilitasi pengembangan standar evaluasi yang lebih terperinci. Melalui pendekatan ini, diharapkan penelitian ini dapat memberikan wawasan baru dalam upaya memahami dan mengukur identifikasi citra wajah *glowing* secara objektif, membuka pintu untuk perkembangan lebih lanjut dalam industri perawatan kulit (Ria et al., 2022).

METODE PENELITIAN

Penelitian ini menggunakan metode penelitian yang akan ditunjukkan pada diagram blok penelitian yang ditunjukkan pada gambar di bawah.



Berdasarkan diagram blok penelitian di atas maka penelitian akan melalui beberapa tahapan yaitu: (Arifandi, n.d.-a)

Foto Wajah

Pigmentasi kulit dapat memainkan peran penting dalam menilai kulit yang bersinar (*glowing*) atau tidak bersinar. Beberapa faktor yang dapat memengaruhi penilaian ini melibatkan distribusi melanin, warna kulit dan keberlanjutan warna kulit.

Akuisisi Gambar Wajah

Dalam peneilitan ini, data yang digunakan adalah gambar wajah yang sudah melakukan *treatment glowing* yang terdiri dari foto *before* dan *after*. Pengumpulan data dilakukan dengan cara mengambil foto pasien di sebuah klinik kecantikan dan mengambil foto gambar menggunakan *smartphone* dengan spesifikasi kamera 12MP *wide angle*. Setiap wajah di ambil pada 1 *angle*.

Preprocessing Gambar Wajah

Pemrosesan data (prapemrosesan). Tahapan *preprocessing* yang dilakukan adalah *cropping* dan format gambar JPG. *Croping* dilakukann dengan tujuan agar objek terlihat lebih banyak dibandingkan *background* dan wajah pada gambar. Melalui proses *cropping*, peneliti berharap dapat meningkatkan efektifivitas analisis, karena hanya berfokus pada objek wajah yang dinginkan dibandingkan menganalisisi seluru objek pada gambar. (Nauval Azmi, 2023)

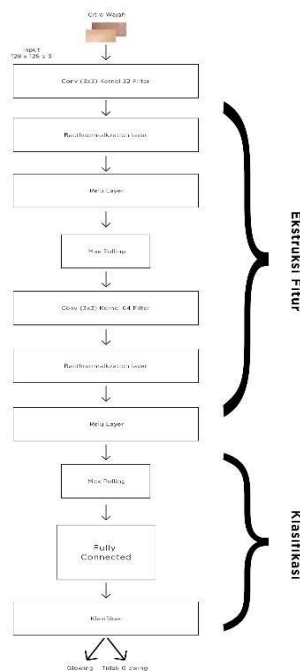
Proses *cropping* tersebut terbukti efektif karena memungkinkan peneliti untuk fokus pada objek wajah. Jika tidak dilakukan *cropping*, komputer akan menganalisis seluru objek pada gambar, termasuk yang tidak relevan dengan tujuan penelitian yaitu wajah. Oleh karena itu, dengan melalukan *cropping*, peneliti dapat mengurangi kompleksitas analisisi dan mendapatkan fokus yang jelas pada objek yang diteliti. Proses *cropping* dilakukan secara manual oleh peneliti untuk memilih posisi terbaik di mana gambar wajah terlihat dengan baik. Dengan cara ini, peneliti dapat memastikan bahwa hanya gambar yang paling relevan dan berkualitas tinggi yang digunakan dalam analisis, sehingga meningkatkan akurasi dan validitas hasil penelitian (Permana et al., 2022).



gambar 2&3. contoh image wajah sebelum preprocessing

Convolutional Neural Network (CNN)

Tentukan arsitektur *CNN* sebelum memroses kumpulan data. Aturan arsitektur *CNN* secara umum dibagi menjadi Ekstraksi Fitur dan Klasifikasi. Parameter yang perlu disertakan dalam arsitektur *CNN* adalah jumlah filter, kernel, jumlah layer dan fungsi aktivasi yang digunakan. Pada penelitian ini digunakan 2 lapis konvolusi. Setiap konvolusi memiliki filter dan kernel. Kemudian dilakukan reduksi lapisan pada *pooling layer*. Selanjutnya diratakan menjadi bentuk vektor. Tahap ini umumnya disebut lapisan terhubung penuh, dan menggunakan fungsi aktivasi *softmax*. Arsitektur *CNN* dapat dilihat pada gambar 4 (Fadzila et al., n.d.).



Gambar 4. CNN Model Architecture

Penelitian ini seperti pada gambar di atas menggunakan arsitektur *CNN* di mana penelitian ini melakukan 2 tahap yaitu konvolusi layer dengan ukuran 3x3 dan kernel filter sebanyak 32 dan 64 filter. *Convolutional Layer* merupakan tahapan utama yang menjadi dasar dari metode *Convolutional Neural Network (CNN)*. Pada *Convolutional Layer*, operasi konvolusi dilakukan pada keluaran lapisan sebelumnya dan menghasilkan peta fitur. Operasi konvolusi melibatkan penggunaan filter di seluruh area masukan. Setiap posisi filter diterapkan pada masukan, dan perkalian elemen demi elemen antara bidang filter dan masukan dijumlahkan untuk menghasilkan satu nilai dalam peta fitur. Hasilnya adalah representasi fitur yang dapat memvisualisasikan respons lokal terhadap fitur tertentu dalam masukan. Melalui pelatihan, filter di Lapisan Konvolusional disesuaikan secara otomatis untuk mempelajari pola fitur yang relevan dalam data.

Tahap selanjutnya adalah melakukan *Pooling Layer*. *Pooling Layer* berfungsi mengambil peta fitur sebagai masukan dan melakukan operasi statistik pada nilai piksel terdekat. Pada tahap ini, peta fitur yang dihasilkan dari *Convolutional Layer* akan mengalami proses *down sampling*. Tujuan dari *Pooling Layer* adalah untuk

merangkum informasi yang terkandung dalam fitur peta dan mengurangi dimensinya. Dengan *down sampling*, gambar yang dihasilkan lebih ringkas namun tetap mengandung informasi penting. Dalam penelitian ini digunakan metode Maxpooling, di mana proses *down sampling* dilakukan dengan memilih nilai terbesar untuk setiap piksel pada *pooling area*.

Dengan menggunakan Maxpooling, hanya nilai terbesar yang akan diambil pada setiap *pooling area*. Hal ini membantu menyoroti fitur paling signifikan di setiap bagian peta fitur, sehingga menghasilkan representasi yang lebih ringkas sekaligus mempertahankan informasi penting yang diperlukan untuk proses klasifikasi lebih lanjut.

Langkah selanjutnya adalah Lapisan Terhubung Sepenuhnya. *Fully Connected Layer* adalah lapisan dalam jaringan saraf di mana setiap neuron yang diaktifkan terhubung ke semua neuron pada lapisan berikutnya. Pada tahap ini setiap neuron pada *convolution layer* harus diubah menjadi data satu dimensi agar dapat masuk ke *Fully Connected Layer*. *Fully Connected Layer* menghasilkan nilai *output* yang akan digunakan dalam proses klasifikasi objek. *Output* ini dapat dianggap sebagai representasi akhir dari data yang telah melewati lapisan sebelumnya di jaringan saraf. Dalam Lapisan Terhubung Sepenuhnya, setiap neuron berkontribusi pada keluaran akhir dengan bobot yang sesuai. Hasil tersebut selanjutnya akan digunakan untuk mengklasifikasikan objek berdasarkan tujuan atau tugas penelitian yang dilakukan. Pada tahap akhir penelitian ini, metode softmax digunakan untuk mengklasifikasikan hasil. Softmax merupakan variasi dari algoritma Regresi Logistik yang digunakan khusus untuk mengklasifikasikan keluaran menjadi lebih dari dua kelas. Softmax diterapkan pada lapisan terakhir jaringan saraf. Keuntungan metode softmax adalah menghasilkan probabilitas keluaran yang berkisar antara 0 dan 1. Hal ini memungkinkan interpretasi yang jelas tentang probabilitas yang terkait dengan kelas yang mungkin. Selain itu, probabilitas total semua kelas dalam satu objek keluaran akan selalu 1, sehingga softmax memastikan adanya distribusi probabilitas yang valid untuk setiap prediksi kelas.

CNN Test

Pada penelitian ini dilakukan pengujian untuk mengevaluasi dan menganalisis hasil pengolahan citra dengan metode *CNN*. Cara mengetahui kinerja algoritma *CNN* menggunakan referensi dari Confusion Matrix yang ditunjukkan pada Gambar 5. Dalam penelitian ini, parameter yang digunakan untuk menguji kinerja sistem adalah akurasi. Akurasi menggambarkan perbandingan antara prediksi yang benar di seluruh data. Akurasi mengukur sejauh mana model dapat mengklasifikasikan dengan benar, mengikuti persamaan akurasi 1.

(Arifandi, n.d.-b)

$$\text{Accuracy} = \frac{TP+TN}{TP+FN+FP+TN}$$

Prediction Condition

Actual Condition	TP	FN
	FP	TN

Gambar 5. Confusion Matrix

Informasi:

TP (True Positive) adalah banyaknya data positif yang diklasifikasikan dengan benar oleh sistem.

TN (True Negative) adalah jumlah data negatif yang diklasifikasikan dengan benar oleh sistem.

FP (False Positive) adalah jumlah data positif tetapi salah diklasifikasikan oleh sistem.


FN (False Negative) adalah jumlah data negatif tetapi salah diklasifikasikan oleh sistem.

HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset yang terbagi dalam 2 kategori wajah dengan nama folder *glowing* dan tidak *glowing*. Jumlah dataset yang digunakan sebanyak 734 gambar. Dengan jumlah data gambar pada setiap kategori sebanyak 258. Dataset akan dibagi menjadi 70% data latih dan 30% data uji selanjutnya akan dilakukan pengujian terhadap dataset yang ada dengan menguji *optimizer SGDM*, *ADAM*, dan *RMSprop* (Ria et al., 2022).

Pengujian Pengoptimalan *SGDM*


Pengujian pertama dilakukan dengan optimasi *SGDM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Diperoleh hasil dengan akurasi 56.16% dan waktu pengujian 34 menit 22 detik. Hasil pengujian ditunjukkan pada gambar 6.



Gambar 6. *SGDM* Depth 9 Optimizer Testing

Pengujian Pengoptimalan ADAM

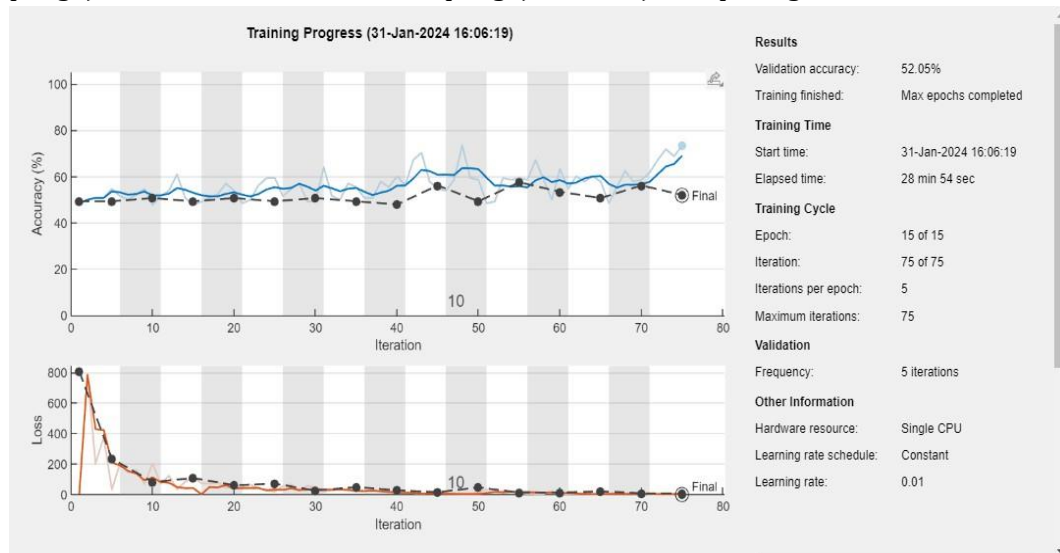
Pengujian Kedua dilakukan dengan *optimizer ADAM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Didapatkan hasil dengan akurasi sebesar 57.53% dan waktu pengujian 27 menit 929 detik. Hasil pengujian ditunjukkan pada gambar 7.



Gambar 7. ADAM Depth 9 Optimizer Testing

Pengujian Pengoptimalan RMSprop

Pengujian ketiga dilakukan dengan optimasi *SGDM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Diperoleh hasil dengan akurasi 52.05% dan waktu pengujian 38 menit 54 detik. Hasil pengujian ditunjukkan pada gambar 8.




Gambar 8. RMSprop Depth 9 Optimizer Testing

Pengujian Pengoptimalan SGDM

Pengujian keempat dilakukan dengan optimasi *SGDM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Diperoleh hasil dengan akurasi 47.95% dan


waktu pengujian 39 menit 13 detik. Hasil pengujian ditunjukkan pada gambar 9.



Gambar 9. SGDM Depth 13 Optimizer Testing

Pengujian Pengoptimalan ADAM


Pengujian Kelima dilakukan dengan optimizer *ADAM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Didapatkan hasil dengan akurasi sebesar 46.58% dan waktu pengujian 35 menit 9 detik. Hasil pengujian ditunjukkan pada gambar 10.



Gambar 10. ADAM Depth 13 Optimizer Testing

Pengujian Pengoptimalan RMSprop


Pengujian keenam dilakukan dengan *RMSprop optimizer* menggunakan konfigurasi epoch 30, *learning rate* 0.01, dengan akurasi 47.95% dan waktu pengujian 34 menit 4 detik. Hasil pengujian ditunjukkan pada Gambar 11.



Gambar 11. RMSprop Depth 13 Optimizer Testing

Pengujian Pengoptimalan SGDM

Pengujian ketujuh dilakukan dengan optimasi *SGDM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Diperoleh hasil dengan akurasi 53.42% dan waktu pengujian 30 menit 17 detik. Hasil pengujian ditunjukkan pada gambar 12.



Gambar 12. SGDM Depth 18 Optimizer Testing

Pengujian Pengoptimalan ADAM

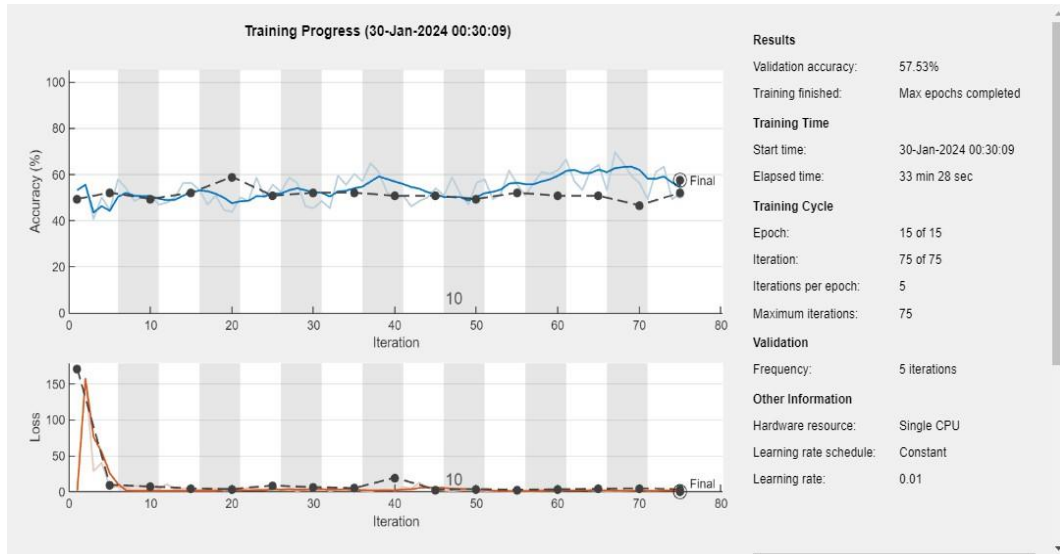
Pengujian kedelapan dilakukan dengan *optimizer ADAM* menggunakan konfigurasi epoch 15, *learning rate* 0.01. Didapatkan hasil dengan akurasi sebesar 47.95% dan waktu pengujian 30 menit 1 detik. Hasil pengujian ditunjukkan pada gambar 13.



Gambar 13. ADAM Depth 18 Optimizer Testing

Pengujian Pengoptimalan RMSprop

Pengujian kesembilan dilakukan dengan *RMSprop optimizer* menggunakan konfigurasi epoch 30, *learning rate* 0.01, dengan akurasi 57.53% dan waktu pengujian 33 menit 28 detik. Hasil pengujian ditunjukkan pada Gambar 14.



Gambar 14. RMSpropDepth 18 Optimizer Testing

HASIL DAN PEMBAHASAN


Setelah dilakukan beberapa kali pengujian maka hasilnya akan terlihat pada Tabel 2.

Optimizer	Epoch	Depth	Time	Accuracy
SGDM	15	9	34 menit 22 detik	56.16%
ADAM	15	9	27 menit 29 detik	57.53%

RMSprop	15	9	28 menit 54 detik	52.05%
SGDM	15	13	39 menit 13 detik	47.95%
ADAM	15	13	35 menit 9 detik	46.58%
RMSprop	15	13	34 menit 95 detik	47,95%
SGDM	15	18	30 menit 17 detik	53.42%
ADAM	15	18	30 menit 1 detik	47.95%
RMSprop	15	18	33 menin 29 detik	57.53%

Table 2. hasil test

Dari Tabel 2 telah dilakukan beberapa pengujian dengan menggunakan optimizer *SGDM*, *ADAM*, dan *RMSprop*. Mendapatkan hasil terbaik pada pengujian *RMSprop* dan *ADAM* dengan konfigurasi epoch 15, learning rate 0.01, dan depth 18 dan 9 dengan akurasi 57,53% dan waktu 27 menit 29 detik sampai 33 menit 29 detik. Algoritma Pengujian *RMSprop* merujuk pada metode optimisasi yang digunakan dalam pembelajaran mesin, khususnya pada algoritma pembelajaran mendalam (*deep learning*). *RMSprop* membantu menyesuaikan laju pembelajaran untuk setiap parameter model secara adaptif, membantu mengatasi masalah laju pembelajaran yang berbeda-beda untuk setiap parameter, sedangkan algoritma pengujian *ADAM* (*Adaptive Moment Estimation*) adalah algoritma optimasi yang umum digunakan dalam pelatihan model dalam *deep learning* dan *machine learning*. Algoritma ini dikembangkan untuk mengatasi beberapa kendala yang dimiliki oleh optimizers lainnya, seperti *SGD* (*Stochastic Gradient Descent*) atau *RMSprop*. (Lesmana et al., 2022).



Gambar 12. Confusion Matrix optimizer *RMSprop* epoch 30. Learning rate 0,01 And Depth 12

Berdasarkan Gambar 12, terdapat 36 citra wajah *glowing* yang terklarifikasi menjadi 37 citra wajah tidak *glowing* dan sisanya telah terklarifikasi dengan benar, artinya metode *CNN* dapat mengklasifikasikan citra wajah berdasarkan warna pigmen yang berbeda-beda. (Karim & Abidin, 2022)

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan penelitian dan pengujian yang telah dilakukan untuk mengklasifikasikan 2 jenis wajah, didapatkan hasil terbaik adalah pada epoch 15, *learning rate* 0.01, dan *RMSprp optimizer* dengan akurasi 57,53%. Setelah melalui proses tersebut dapat disimpulkan bahwa metode *CNN* mampu mencitrakan wajah dengan tingkat akurasi yang tinggi.

Saran

Untuk penelitian selanjutnya diharapkan dapat memperbanyak citra dataset guna meningkatkan nilai akurasi dari kedua citra agar semakin tinggi lagi.

DAFTAR PUSTAKA

- Arifandi, A. (2022). Identifikasi dan Prediksi Umur serta Jenis Kelamin Berdasarkan Citra Wajah Menggunakan Algoritma Convolutional Neural Network (CNN). Fakultas Sains Dan Teknologi-Universitas PGRI Kanjuruhan Malang. *Jurnal Terapan Sains & Teknologi*, 4(2).
- Azmi, M. Nauval. (2023). Analisis Pengaruh Dimensi Gambar pada Klasifikasi Motif Batik dengan Menggunakan Convolutional Neural Network. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 6(2).
- Fadzila, A. N., Putra Pamungkas, D., & Wulanningrum, R. (n.d.). *Menggunakan Metode PCA dan CNN*. <https://medium.com/@gogoriay/convolutional->
- Karim, S., & Abidin, M. Z. (2022). Penerapan Metode Learning Vector Quantization pada Penentuan Level Bermain terhadap Game Edukasi sang Santri. *Antivirus: Jurnal Ilmiah Teknik Informatika*, 16(1), 11-24. <https://doi.org/10.35457/antivirus.v16i1.1785>.
- Lesmana, A. M., Fadhillah, R. P., & Rozikin, C. (2022). Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains Dan Informatika*, 8(1), 21-30. <https://doi.org/10.34128/jsi.v8i1.377>
- Permana, R., Saldu, H., & Maulana, D. I. (2022). Optimasi Image Classification pada Jenis Sampah dengan Data Augmentation dan Convolutional Neural Network. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 5.
- Ria, S. N., Walid, M., & Umam, B. A. (2022). Pengolahan Citra Digital untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN). *Energy - Jurnal Ilmiah Ilmu-Ilmu Teknik*, 12(2), 9-16. <https://doi.org/10.51747/energy.v12i2.1118>