



Klasifikasi Jenis Jerawat pada Data Citra Jerawat Wajah Menggunakan Convolutional Neural Network

Chatarina Natassya Putri, Wafi Dzul Qornain, Fakhirah Bamahri, Gusti Eka Yuliasuti*, Muchamad Kurniawan

Program Studi Teknik Informatika, Fakultas Teknik Elektro dan Teknologi Informasi, Institut Teknologi Adhi Tama Surabaya, Surabaya, Indonesia

Email: ¹chatarinanatassya@email.com, ²wafidzul@gmail.com, ³fakhirahBama@gmail.com, ^{4*}gustiekay@itats.ac.id, ⁵muchamad.kurniawan@itats.ac.id

Email Penulis Korespondensi: gustiekay@itats.ac.id

Abstrak—Jerawat merupakan kondisi yang disebabkan oleh inflamasi pilosebaceous yang mempengaruhi 85% kondisi kulit remaja hingga dewasa. Jerawat memiliki dampak pada kesehatan psikologis maupun sosial penderitanya. Untuk mengobati pada jerawat, perlu nya mengetahui jenis jerawat yang tepat agar penderita dapat menangani jenis jerawat sesuai dengan cara penanganannya. Pada penelitian ini dilakukan untuk mengklasifikasi jenis jerawat pada citra jerawat wajah dengan menggunakan metode Convolutional Neural Network (CNN). Berdasarkan penelitian sebelumnya, menunjukan bahwa penggunaan CNN di nilai efektif dan tepat dalam meningkatkan akurasi klasifikasi. Penelitian ini, menggunakan dataset jenis-jenis jerawat dari kaggle dengan total 351 data, terbagi menjadi 5 kelas yaitu acne fulminans, acne nodules, fungal acne, papula, dan pustula yang akan di uji dengan menggunakan 2 optimizer yang berbeda, yaitu Adam dan RMS-prop. Dari hasil pengujian ini menghasilkan akurasi tertinggi adalah 100% menggunakan optimizer Adam dan pengujian optimizer RMS-prop mendapatkan nilai akurasi tertinggi 80%.

Kata Kunci: Jerawat; Klasifikasi; CNN; Adam; RMS-prop

Abstract—Acne is a condition caused by pilosebaceous inflammation which affects 85% of skin conditions in adolescents and adults. Acne has an impact on the psychological and social health of sufferers. To treat acne, it is necessary to know the right type of acne so that sufferers can treat the type of acne according to how they are treated. This research was carried out to classify the types of acne in facial acne images using the Convolutional Neural Network (CNN) method. Based on previous research, it shows that the use of CNN is considered effective and appropriate in increasing classification accuracy. This research uses a dataset of acne types from Kaggle with a total of 351 data, divided into 5 classes, namely acne fulminans, acne nodules, fungal acne, papules and pustules which will be tested using 2 different optimizers, namely Adam and RMS-prop. From the results of this test, the highest accuracy was 100% using the Adam optimizer and the RMS-prop optimizer test obtained the highest accuracy value of 80%.

Keywords: Acne; Classification; CNN; Adam; RMS-prop

1. PENDAHULUAN

Jerawat merupakan salah satu permasalahan kulit yang sering terjadi pada manusia di berbagai jenis tipe kulit. Jerawat biasanya sering muncul pada wajah, leher, punggung, dan juga dada (Kayiran et al., 2022). Hal ini di tandai dengan munculnya bintik-bintik kecil (papula), papula besar (nodul), bekas luka, komedo hitam dan putih, pembengkakan yang keras di bawah kulit, maupun ruam merah pada permukaan kulit (Hasan et al., n.d.). Jerawat adalah penyakit yang di akibatkan penyumbatan minyak serta sel-sel kulit mati pada pori-pori akibat perubahan hormon maupun infeksi bakteri. Jerawat merupakan kondisi inflamasi pilosebaceous yang umum terjadi pada 85% kondisi kulit remaja dan sering berlanjut hingga dewasa (Rianto & Risdho Listianto, 2023). Jerawat mempengaruhi pasien dewasa khususnya perempuan dalam dua bentuk : jerawat akhir (persisten) yang muncul pada masa remaja hingga dewasa. Pada kasus ini, perempuan menjadi penyumbang 80% dari kasus tersebut. Lalu onset akhir yang muncul pada saat dewasa.

Jerawat ini dipengaruhi oleh faktor genetik serta hormonal (Quattrini et al., 2022). Fluktuasi hormon tersebut dapat dari siklus menstruasi, kehamilan, menopause, atau saat memulai/menghentikan penggunaan kontrasepsi pil (Latter et al., 2019). Kondisi-kondisi khusus ini, terutama pada wajah, memiliki dampak besar pada kesehatan emosional, sosial, psikologis penderitanya, serta kualitas hidup seseorang. Konsekuensi signifikan termasuk perasaan ketidaknyamanan dan ketidakpercayaan diri, tekanan emosional dan psikososial, termasuk depresi dan bunuh diri (Riahi & Jung, 2020).

Penelitian mengenai kecemasan pada penderita jerawat yang dilakukan oleh Pinar Duru dan Özlem Örsal menyatakan 7 dari 10 mahasiswa merasa cemas akibat jerawat. Individu dengan jerawat cenderung menghindari dalam berpartisipasi pertemuan sosial, difoto atau menutupi jerawat menggunakan riasan (Duru & Örsal, 2021). Kecemasan ini membuat penderita mencari pengobatan atau penanganan alternatif yang mampu bekerja secara instan. Pengobatan ini menggabungkan atau mengintegrasikan pengobatan konvensional dengan menggunakan vitamin, jamu, meditasi, dan hal-hal berbau herbal dan spritual (Windiramadhan & Carsita, 2022). Penggunaan pengobatan ini cukup rentan berbahaya untuk beberapa tipe jenis kulit serta jerawat. Ini dikarenakan efek samping yang diakibatkan dapat berbeda-beda.

Beberapa jenis jerawat dapat muncul secara bersamaan pada wajah maupun daerah yang rentan terkena jerawat. Pentingnya pemahaman serta penanganan yang akurat dalam berbagai jenis jerawat yang muncul sangat membantu dalam menetapkan jenis obat serta perawatannya (Kayiran et al., 2022).

Oleh karena itu, klasifikasi pada berbagai jenis jerawat telah menjadi fokus oleh beberapa penelitian, agar masyarakat teredukasi dalam menangani permasalahan tersebut. Untuk mengatasi permasalahan ini, pemanfaatan

teknologi dapat menjadi solusi yang efektif. Salah satunya dengan menerapkan metode deep learning. Deep learning memiliki keunggulan dalam hal akurasi klasifikasi maupun bidang lainnya. Salah satu metode dalam deep learning yakni Convolutional Neural Network (CNN) (Dhande & Shaikh, 2019).

CNN saat ini menjadi pilihan para peneliti untuk digunakan dalam mendeteksi dan juga klasifikasi citra karena keunggulan strukturnya, yaitu: rangkaian-rangkaian lapisan konvolusi, lapisan pooling dan lapisan full – connected yang terhubung satu sama lain (Alzubaidi et al., 2021). CNN memiliki kemampuan generalisasi yang baik dan dapat mempelajari fitur-fitur yang abstrak dari objek data spasial serta dapat melakukan identifikasi lebih efisien. CNN ini terdiri dari neuron yang memiliki bobot atau parameter (sharing weight) (Wicaksono et al., 2023).

Penggunaan atau penerapan beberapa metode dalam klasifikasi jerawat sudah banyak dilakukan sebelumnya. Beberapa di antaranya antara lain menggunakan metode GLCM (Grey Level Co-ocurance Matrix) dan ELM (Extreme Learning Machine) yang digunakan untuk mengekstraksi fitur serta mengklasifikasi jenis jerawat berdasarkan citra jerawat. Dengan menggunakan 100 data gambar yang dikategorikan menjadi: Nodul, Papula, dan Pustula. Penelitian dilakukan dengan mengevaluasi tingkat akurasi metode ELM dalam mengklasifikasi jenis-jenis jerawat dalam dua tahapan. Tahapan pertama menguji kelas Nodul dan Papula menghasilkan akurasi tertinggi 95,24% dan tahap kedua menghasilkan 80% (Hasanah et al., 2022).

Penelitian lain juga memanfaatkan metode GLCM dengan mengkombinasikan pada metode SVM (Support Vector Machine) untuk mengklasifikasi jenis jerawat. Yang mana metode GLCM digunakan untuk menganalisis tekstur dan metode SVM digunakan untuk mengklasifikasi. Dengan melalui 3 tahapan kerja, yaitu: preprocessing, ekstraksi fitur GLCM, dan klasifikasi SVM untuk menguji 100 data citra jerawat untuk proses pelatihan serta 30 data citra jerawat untuk proses pengujian. Penelitian ini menghasilkan akurasi 86% dari kombinasi kedua metode ini (Wulan & Musdholifah, 2020).


Penelitian sebelumnya yang dilakukan Doni Anggara, Nana Suarna, dan Yudhistira Arie Wijaya, pada tahun 2023 berjudul “Analisa Perbandingan Performa Optimizer Adam, SGD, dan RMS-prop Pada Model H5”. Dengan menggunakan 71.774 data ekspresi wajah, dengan 7 label ekspresi wajah, diantaranya senang, sedih, terkejut, marah, takut, jijik, dan netral. Penelitian ini menghasilkan akurasi tinggi pada optimizer Adam dengan nilai 68,61% disusul oleh SGD sebesar 57,68% dan RMS-prop sebesar 54,83% (Anggara et al., 2023).

Pada penelitian lain, yang di lakukan oleh D. Diffran Nur Cahyo, Muhammad Anwar Fauzi, Jangkung Tri Nugroho, dan Kusri dengan judul “Analisis Perbandingan Optimizer pada Arsitektur NASNetMobile Convolutional Neural Network untuk Klasifikasi Ras Kucing”. Penelitian tersebut bertujuan untuk membandingkan optimizer RMS-prop dan SGD untuk menentukan optimizer yang optimal pada klasifikasi jenis ras kucing. Penelitian ini menghasilkan akurasi RMS-prop sebanyak 89,88%, SGD mendapat akurasi 78,57% (Nur Cahyo et al., 2023).

Berdasarkan penelitian-penelitian yang telah di lakukan sebelumnya, menunjukkan bahwa penggunaan Convolutional Neural Network (CNN) dalam klasifikasi sangat efektif. Oleh karena itu, pada penelitian ini penulis mencoba menerapkan metode Convolutional Neural Network (CNN) untuk mengklasifikasi jenis jerawat berdasarkan citra jerawat wajah dengan bantuan optimizer berupa Adam dan RMS-prop. Penggunaan optimizer bertujuan untuk mengetahui jenis optimizer mana yang optimal dalam meningkatkan akurasi untuk klasifikasi jenis jerawat pada wajah.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian



Gambar 1. Tahapan Penelitian


Adapun tahapan kerja seperti ditunjukkan pada Gambar 1 yaitu tahapan penelitian dimulai dari pengumpulan data semua jenis jerawat. Dari data yang didapatkan akan dilanjutkan proses pre-processing. Tujuan dari pre-processing data yakni menyelesaikan permasalahan ketidakseimbangan data, yang jika dihiraukan dapat mempengaruhi pemrosesan data berikutnya. Data yang sudah dilakukan pre-processing tersebut dibagi menjadi dua bagian yakni data untuk pelatihan (training data) dan data untuk pengujian (testing data). Kedua bagian data tersebut diimplementasi dengan menggunakan metode CNN. Sejumlah data dilakukan sebagai proses pembelajaran (training data), kemudian dilanjutkan dengan pengujian beberapa data lainnya (testing data). Hasil implementasi tersebut dilanjutkan untuk melakukan pengujian model dari CNN. Hasil pengujian model CNN ini dapat dihitung seberapa besar nilai akurasi.

2.2 Tahapan Penelitian

2.2.1 Dataset

Pada penelitian ini dataset yang di gunakan adalah dataset citra jenis-jenis jerawat, yang didapatkan atau di akses dari kaggle pada link berikut ini, <https://www.kaggle.com/dinartas/skin90?resource=download>. Dengan gambar berjumlah 351 sampel dan di bagi menjadi beberapa kelas, yakni kelas Pustula dengan 60 gambar, 66 gambar Papula, 64 gambar Acne Fulminans, 63 gambar Acne Nodules dan 63 gambar Fungal Acne. Berikut data gambar jenis-jenis jerawat yang di gunakan dalam penelitian ini. Jerawat pustula adalah salah satu jenis jerawat yang ditandai dengan benjolan kecil yang berisi nanah. Lesi ini berwarna merah di dasar dan memiliki puncak putih atau kuning yang menandakan adanya nanah di dalamnya. Pustula terbentuk ketika folikel rambut tersumbat oleh minyak dan sel kulit mati, yang kemudian mengalami infeksi bakteri sehingga menyebabkan peradangan. Proses ini memicu respon imun tubuh, yang akhirnya menghasilkan nanah. Pustula sering kali terasa nyeri dan bisa meninggalkan bekas luka jika dipencet atau ditangani dengan tidak tepat, contoh jerawat jenis ini dapat dilihat pada Gambar 2. Gambar 3 merupakan contoh dari jenis jerawat kelas Papula.

Jerawat Papula adalah jenis jerawat yang muncul sebagai benjolan kecil berwarna merah atau merah muda pada kulit. Papula tidak berisi nanah, tetapi merupakan hasil dari peradangan di dalam folikel rambut yang tersumbat. Karena tidak adanya nanah, Papula biasanya tidak memiliki puncak putih seperti Pustula. Meskipun ukurannya kecil, papula dapat terasa nyeri jika disentuh. Jika papula meradang lebih lanjut, mereka bisa berkembang menjadi Pustula atau nodul yang lebih parah. Papula sering dianggap sebagai tanda awal dari jerawat yang meradang. Acne fulminans adalah bentuk jerawat yang sangat langka dan parah, yang terutama menyerang remaja laki-laki. Kondisi ini muncul secara tiba-tiba dan ditandai dengan lesi yang sangat meradang dan berukuran besar, yang dapat berisi nanah dan sering kali membentuk kerak. Acne fulminans sering disertai dengan gejala sistemik seperti demam, nyeri sendi, dan peningkatan jumlah sel darah putih. Penyebab pasti dari acne fulminans tidak sepenuhnya dipahami, tetapi diduga melibatkan faktor genetik dan imunologis. Pengobatan biasanya melibatkan penggunaan steroid untuk mengendalikan peradangan dan antibiotik untuk mengatasi infeksi bakteri. Contoh jenis jerawat ini dapat dilihat pada Gambar 4. Jerawat nodul adalah jenis jerawat yang parah dan menyakitkan, yang terbentuk jauh di dalam kulit. Nodul adalah benjolan besar dan keras yang terasa nyeri saat disentuh dan tidak memiliki puncak yang terlihat. Karena nodul terbentuk di bawah permukaan kulit, mereka sering kali sulit diobati dengan produk topikal biasa. Jerawat nodul sering meninggalkan bekas luka yang dalam dan permanen jika tidak ditangani dengan benar. Pengobatan jerawat nodul biasanya melibatkan penggunaan obat oral seperti antibiotik atau isotretinoin, yang dapat membantu mengurangi peradangan dan mencegah pembentukan nodul baru (Gambar 6). Gambar 7 adalah contoh jerawat Fungal Acne, atau lebih dikenal dengan istilah medis *Malassezia folliculitis*, adalah kondisi kulit yang menyerupai jerawat biasa tetapi disebabkan oleh pertumbuhan berlebihan dari jamur *Malassezia*. Lesi ini muncul sebagai benjolan kecil yang gatal, yang sering kali berkelompok dan muncul di area tubuh yang berminyak seperti dada, punggung, dan wajah. *Malassezia folliculitis* sering kali sulit dibedakan dari jerawat bakteri biasa, tetapi tidak merespons pengobatan jerawat konvensional. Pengobatan biasanya melibatkan penggunaan obat antijamur topikal atau oral untuk mengendalikan pertumbuhan jamur.



Gambar 2. Contoh beberapa gambar dari kelas Pustula



Gambar 3. Contoh beberapa gambar dari kelas Papula



Gambar 4. Contoh beberapa gambar dari kelas Acne Fulminans



Gambar 5. Contoh beberapa gambar dari kelas Acne Nodules



Gambar 6. Contoh beberapa gambar dari kelas Fungal Acne

2.2.2 Preprocessing

Preprocessing merupakan sebuah tahapan yang digunakan untuk mempermudah pengolahan data serta meningkatkan kualitas data. Preprocessing dapat dilakukan dengan berbagai cara, yaitu: mengubah ukuran data gambar, ukuran citra atau gambar, dan mengolah data menjadi berkualitas serta optimal. Hal ini penting karena preprocessing berperan dalam kecepatan pemrosesan data serta akurasi (Prabowo et al., 2021).

Pada tahapan ini, dilakukan cleaning data (pembersihan) pada data yang tidak relevan atau tidak valid. Dalam penelitian ini, dilakukan 2 tahapan cleaning yaitu:

a. Mengubah data ke bentuk JPG

Pada dataset, terdapat beberapa gambar yang berformat jfif dan png sehingga di perlu kan konversi gambar ke format jpg untuk menghindari permasalahan dalam penggunaan data.

b. Penghapusan data

Jumlah dalam dataset yang digunakan memiliki ketidakseimbangan atau skewness distribution. Dimana terdapat perbedaan jumlah data citra dari masing-masing kelas, yakni : kelas Pustula dengan 60 gambar, 66 gambar Papula, 64 gambar Acne Fulminans, 63 gambar Acne Nodules dan 63 gambar Fungal Acne. Hal ini sangat mempengaruhi hasil dalam penelitian ini. Seperti pada penelitian sebelumnya, yang di lakukan oleh Fransiscus Rian Pratikto yang berjudul "Oversampling Sintesis Berbasis Kopula untuk Model Klasifikasi dengan Data yang Tidak Seimbang: Studi Kasus Prediksi Kredit Macet Nasabah Kartu Kredit" menyatakan bahwa ketidakseimbangan data dapat menyebabkan model klasifikasi cenderung tidak akurat dan berdampak pada hasil (Pratikto, 2023). Ini di karenakan terdapat bias pada model, Dimana model lebih cenderung memprediksi kelas yang memiliki banyak data, karena telah lebih banyak mempelajari kelas tersebut. Oleh karena itu, data di bagi menjadi 60 data citra permasing-masing kelas.

2.2.3 Arsitektur Model

Pada penelitian ini, model arsitektur yang digunakan adalah Convolutional Neural Network (CNN) atau yang di kenal dengan sebutan ConvNets. CNN merupakan teknik yang di gunakan unruk pengolahan gambar dan pengenalan pola (Suharni et al., 2022). Dalam CNN, citra di input lalu di proses melalui serangkaian lapisan konvolusi yang bertugas mengekstrak fitur-fitur dengan menggunakan filter-filter yang telah di tentukan dan menghasilkan pola-pola yang mencerminkan karakteristik tertentu sehingga memudahkan proses klasifikasi oleh model CNN (Alzubaidi et al., 2021). Pada penelitian ini, model arsitektur CNN di gunakan secara custom dengan mengatur hidden layer dari arsitektur model yang di gunakan beserta perlengkapan-perengkapan lainnya seperti optimizer Adam dan RMS-prop serta pengaturan epoch sebanyak 20,30,50, dan 100.

Model arsitektural CNN menggunakan Pustaka keras Pyhton dengan disusun secara berurut menggunakan skuensial. Tahapan pertama yaitu konvolusi yang dilakukan dengan menggunakan kernel dengan ukuran tertentu dan menghasilkan output yang kemudian dikenakan fungsi aktivasi, yaitu Rectifier Linear Unit (ReLU). Lalu hasil tersebut di proses sampling atau pooling. Output dari proses pooling adalah citra yang telah berkurang ukurannya, sesuai dengan pooling masknya. Model yang dibuat pada penelitian ini terdiri dari 7 layer seperti pada Gambar 7. Layer pertama


adalah layer input, layer kedua dan ketiga merupakan layer convolution dengan pooling. Jenis pooling yang digunakan adalah max polling dengan kernel 2 x 2 dan stride 2. Layer keempat merupakan dense dengan 100 node, layer kelima merupakan dense dengan 10 node, dan layer terakhir merupakan layer output dengan 10 node.

3. HASIL DAN PEMBAHASAN


Pengujian dilakukan dengan beberapa parameter awal seperti pemilihan optimizer dan nilai epoch. Penggunaan parameter bertujuan untuk menghasilkan akurasi optimal dan meningkatkan kecepatan pelatihan model. Dengan menggunakan optimizer Adam serta RMS-prop dengan nilai parameter epoch 20,30,50 dan 100. Berikut hasil pengujian yang dapat dilihat pada Tabel 1. Berdasarkan Tabel 1, dapat dilihat hasil dari pengujian CNN dengan penggunaan 7 data citra pada masing masing kelas untuk data testing dan 60 data citra pada masing-masing kelas untuk data training. Hasil perbandingan dari masing-masing optimizer dan perbedaan epoch juga menjadi fokus dari penelitian ini.

Tabel 1. Hasil Pengujian Model CNN


Optimizer	Epoch	Training	Testing
Adam	20	0,7	0,2
Adam	30	0,5	0,2
Adam	50	0,6	0,2
Adam	100	1	0,2
RMS-prop	20	0,2	0,2
RMS-prop	30	0,8	0,08
RMS-prop	50	0,2	0,2
RMS-prop	100	0,2	0,2



Gambar 7. Arsitektur Model




(a)




(b)

Gambar 8. Training (a) Akurasi dan (b) loss Optimizer Adam, Epoch 20




(a)




(b)

Gambar 9. Training (a) Akurasi dan (b) loss Optimizer Adam, Epoch 30




(a)




(b)

Gambar 10. Training (a) Akurasi dan (b) loss Optimizer Adam, Epoch 50




(a)




(b)

Gambar 11. Training (a) Akurasi dan (b) loss Optimizer Adam, Epoch 100




(a)




(b)

Gambar 12. Training (a) Akurasi dan (b) loss Optimizer RMS-prop, Epoch 20




(a)




(b)

Gambar 13. Training (a) Akurasi dan (b) loss Optimizer RMS-prop, Epoch 30



Gambar 14. Training (a) Akurasi dan (b) loss Optimizer RMS-prop, Epoch 50




Gambar 15. Training (a) Akurasi dan (b) loss Optimizer RMS-prop, Epoch 100

Dari ilustrasi tersebut, terdapat delapan kali percobaan menggunakan dua optimizer berbeda, yakni: Adam dan RMS-prop dengan nilai epoch dari 20, 30, 50, dan 100. Gambar 8(a), Gambar 9(a), Gambar 10(a), dan Gambar 11(a) merupakan hasil training dengan optimizer Adam dengan semua nilai epoch. Gambar 8(b), Gambar 9(b), Gambar 10(b), dan Gambar 11(b) adalah hasil testing (menggunakan data testing) dengan optimizer Adam. Dari hasil akurasi yang ditampilkan epoch 20, 30, dan 50 masih belum mampu mencapai hasil maksimal (1 atau 100%), sedangkan pada epoch 100 baru didapatkan hasil akurasi data training mencapai nilai 1. Hasil tersebut berbanding terbalik dengan pengukuran hasil error training. Pada hasil tersebut semua nilai epoch dapat mencapai mendekati 0. Gambar 12(a), Gambar 13(a), Gambar 14(a), dan Gambar 15(a) merupakan hasil akurasi dengan optimizer RMS-prop. Epoch 20, 30, dan 50 memperoleh hasil akurasi yang optimal yaitu tidak mencapai 100%. Epoch 100 terdapat anomali hasil, dimana hasil akurasi sempat mendapatkan nilai maksimal tetapi tiba-tiba hasilnya turun ke angka 0.2 persen. Hasil error optimizer ini dapat dilihat pada Gambar 12(b), Gambar 13(b), Gambar 14(b), dan Gambar 15(b). Hasil error training dengan optimizer ini pada epoch 30, 50 dan 100 mengalami tidak konsisten. Tidak konsisten dilihat dari grafik error yang sudah optimal (nilai error mendekati 0) tetapi terjadi lonjakan-lonjakan error. Tetapi pada epoch paling kecil (20) hasilnya stabil.

Dari hasil-hasil yang telah dilaporkan terlihat hasil yang berbanding terbalik antara dua optimizer. Optimizer Adam lebih konsisten dengan hasil yang wajar, sedangkan RMS-prop tidak. Dapat diketahui bahwa pengujian dengan menggunakan optimizer Adam, dinilai lebih unggul dengan memiliki tingkat akurasi tertinggi 100% dibandingkan dengan tingkat akurasi tertinggi pada optimizer RMS-prop yakni sebesar 80%.

3.1 Pembahasan

Hasil penelitian pada dataset jenis-jenis jerawat, dengan perbedaan optimizer, dan jumlah epoch seperti ditunjukkan pada ilustrasi grafik Gambar 16.



Gambar 16. Grafik Hasil Pengujian

Pada Gambar 16, menunjukkan bahwa percobaan pertama dengan epoch sejumlah 20. Hasil yang didapatkan memiliki perbedaan yang signifikan. Optimizer Adam memiliki nilai akurasi 80% sedangkan RMS-prop hanya senilai 20%. Namun keduanya memiliki kesamaan pada nilai loss yakni 20%. Pada percobaan kedua, optimizer RMS-prop pada grafik memiliki pola yang meningkat menjadi 80% dibanding optimizer Adam yang memiliki pola menurun dari pola sebelumnya atau pada percobaan pertama, dengan nilai 50%. Pada grafik loss, pola RMS-prop memiliki penurunan dari hasil percobaan pertama. Pada percobaan ketiga dan keempat, optimizer Adam terus melakukan peningkatan akurasi menjadi 60% dan 100% sedangkan pada loss memiliki pola yang sama yaitu 20%. Begitu pula dengan Optimizer RMS-prop, pola yang di tunjukan pada grafik tidak memiliki perubahan, dengan nilai akurasi dan loss yang sama yaitu 20%.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah diuraikan sebelumnya, bisa dilihat bahwa penggunaan optimizer dan epoch sangat mempengaruhi hasil akurasi klasifikasi pada jenis-jenis jerawat. Optimizer Adam terbukti bekerja dengan baik dibandingkan dengan optimizer RMS-prop. Optimizer Adam memiliki nilai tertinggi dengan jumlah epoch 100 dengan menghasilkan akurasi 100% sedangkan optimizer RMS-prop memiliki nilai tertinggi 80% dengan jumlah epoch 30. Dari hasil pengujian ini, bisa di simpulkan bahwa perbandingan hasil dari dua optimizer pada CNN yakni Adam dan RMS-prop, Optimizer Adam memiliki nilai akurasi paling optimal yaitu sebesar 100% di bandingkan Optimizer RMS-prop. Sehingga optimizer Adam sangat efektif dalam klasifikasi jenis-jenis jerawat.

REFERENCES

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Anggara, D., Suarna, N., & Wijaya, Y. A. (2023). Analisa Perbandingan Performa Optimizer Adam, Sgd, Dan Rmsprop Pada Model H5. *Networking Engineering Research Operation*, 8(1), 1–12.
- Dhande, G., & Shaikh, Z. (2019). Analysis of Epochs in Environment based Neural Networks Speech Recognition System. *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, 605–608. <https://doi.org/10.1109/ICOEI.2019.8862728>
- Duru, P., & Örsal, Ö. (2021). The effect of acne on quality of life, social appearance anxiety, and use of conventional, complementary, and alternative treatments. *Complementary Therapies in Medicine*, 56, 102614. <https://doi.org/10.1016/j.ctim.2020.102614>
- Hasan, I., Suprayogi, H., & Bethaningtyas, D. (n.d.). Klasifikasi Jenis Jerawat Menggunakan Convolutional Neural Networks.
- Hasanah, R. L., Rianto, Y., & Riana, D. (2022). Identification of Acne Vulgaris Type in Facial Acne Images Using GLCM Feature Extraction and Extreme Learning Machine Algorithm. 15(2), 204–214. <https://doi.org/10.21107/rekayasa.v15i2.141580>
- Kayiran, M., Karadağ, A., Alyamaç, G., Cemil, B., Demirseren, D., Demircan, Y., Aksoy, H., Kılıç, S., Yüksel, E., Kalkan, G., Aksaç, S., Kutlu, Ö., Kakşı, S., Aktürk, A., Solak, S., Yazıcı, S., Özden, H., Koska, M., Uzunçakmak, T., ... Alpsöy, E. (2022). Use of complementary and alternative medicine among patients with acne vulgaris and factors perceived to trigger the disease: A multicentre cross-sectional study with 1571 patients. *Indian Journal of Dermatology*, 67(3), 311. https://doi.org/10.4103/ijdr.ijdr_745_21
- Latter, G., Grice, J. E., Mohammed, Y., Roberts, M. S., & Benson, H. A. E. (2019). Targeted topical delivery of retinoids in the management of acne vulgaris: Current formulations and novel delivery systems. In *Pharmaceutics* (Vol. 11, Issue 10). MDPI AG. <https://doi.org/10.3390/pharmaceutics11100490>



- Nur Cahyo, D. D., Anwar Fauzi, M., Tri Nugroho, J., & Kusrini, K. (2023). Analisis Perbandingan Optimizer pada Arsitektur NASNetMobile Convolutional Neural Network untuk Klasifikasi Ras Kucing. *Jurnal Teknologi*, 15(2), 171–177. <https://doi.org/10.34151/jurtek.v15i2.4025>
- Prabowo, R., Heningtyas, Y., Yusman, machudor, Iqbal, M., & Wulansari, O. D. E. (2021). Klasifikasi Image Tumbuhan Obat (Keji Beling) Menggunakan Artificial Neural Network. *Jurnal Komputasi*, 2541–0350, 88–92. <https://doi.org/10.23960/komputasi.v9i2.2868>
- Pratikto, F. R. (2023). Oversampling Sintetis Berbasis Kopula untuk Model Klasifikasi dengan Data yang Tidak Seimbang. *Jurnal Rekayasa Sistem Industri*, 12(1), 1–10. <https://doi.org/10.26593/jrsi.v12i1.6380.1-10>
- Quattrini, A., Boër, C., Leidi, T., & Paydar, R. (2022). A Deep Learning-Based Facial Acne Classification System. *Clinical, Cosmetic and Investigational Dermatology*, 15, 851–857. <https://doi.org/10.2147/CCID.S360450>
- Riahi, A., & Jung, D. (2020). *Acne:Advocating for holistic support*. 47(1), 1–3.
- Rianto, R., & Risdho Listianto, D. (2023). Convolutional Neural Network untuk mengklasifikasi tingkat keparahan jerawat. *AITI*, 20(2), 167–176. <https://doi.org/10.24246/aiti.v20i2.167-176>
- Suharni, Susilowati, E., & Hidayat, T. M. (2022). Implementasi Model Convolutional Neural Network (Cnn) Untuk Klasifikasi Penyakit Tbc Berbasis Dekstop. *UG Journal*, 16(4), 1–9.
- Wicaksono, R. N., Nugroho, H., & Yuliasuti, G. E. (2023). Pengenalan Pola Citra Ekspresi Wajah Manusia Menggunakan Masker Dengan Metode Convolutional Neural Network (CNN). *Prosiding Seminar Nasional Sains Dan Teknologi Terapan*, 1–6. <http://ejurnal.itats.ac.id/sntekpan/article/view/5157%0Ahttp://ejurnal.itats.ac.id/sntekpan/article/download/5157/3571>
- Windiramadhan, A. P., & Carsita, W. N. (2022). Penggunaan Complementary and Alternative Medicine (CAM) pada ODHA: Literatur Reveiw. *Bima Nursing Journal*, 3(2), 140. <https://doi.org/10.32807/bnj.v3i2.880>
- Wulan, P. I. D. C., & Musdholifah, A. (2020). Klasifikasi Jenis Jerawat Menggunakan Support Vector Machine Berdasarkan Hasil Ekstraksi Tekstur Gray-Level Co-Occurrence Matrix. Universitas Gadjah Mada.