

Klasifikasi Penyakit Pulpitis Pada Citra Radiografi Periapikal Menggunakan Metode Convolutional Neural Network (CNN)

Febby Lavenia¹, Cecep Muhamad Sidik Ramdani², Irani Hoeronis³

Program Studi Informatika, Universitas Siliwangi^{1,2,3}

177006007@student.unsil.ac.id¹, cecepmuhamad@unsil.ac.id², iranihoeronis@unsil.ac.id³

Abstract

Teeth are an important part of the human body. Lack of dental care can lead to various dental diseases, one of which is pulpitis. Pulpitis is an inflammation of the dental pulp (the innermost part of the tooth that contains nerves and blood vessels) and the tissue around the tooth root. It can also be caused by toothache or tooth loss, especially in young people. To diagnose pulpitis, dentists use the periapical radiography technique. This technique provides clear images of all layers of the tooth, allowing diagnosis of the condition of the tooth and surrounding tissues. However, these radiographs can only be interpreted by dental radiology specialists, who are limited in number. Therefore, to facilitate the detection of pulpitis, classification using image processing techniques is used to assist doctors in classifying pulpitis based on radiographic images. This study uses the Convolutional Neural Network (CNN) method to classify pulpitis disease based on radiographic images. CNN is a variation of Multi Layer Perceptron (MLP) that has few free parameters because it does not require pre-processing, segmentation, or feature extraction. This study used 1000 image data divided into two classes: pulpitis and normal. The test results show that hyperparameters such as epoch value and optimizer greatly affect the accuracy. The highest accuracy achieved was 98.75% using the RMSPROP optimizer and an epoch value of 50. This research shows that the use of Convolutional Neural Network (CNN) can help dentists in diagnosing pulpitis. This system can be used to simplify and assist doctors in determining the diagnosis of pulpitis based on radiographic images.

Keywords: Convolutional Neural Network, Pulpitis, Classification

Abstrak

Gigi adalah bagian penting dari tubuh manusia. Kurangnya perawatan gigi dapat menyebabkan berbagai penyakit gigi, salah satunya pulpitis. Pulpitis adalah peradangan pada pulpa gigi (bagian terdalam gigi yang berisi saraf dan pembuluh darah) dan jaringan di sekitar akar gigi. Penyakit ini juga bisa disebabkan oleh sakit gigi atau gigi tanggal, terutama pada orang muda. Untuk mendiagnosis pulpitis, dokter gigi menggunakan teknik radiografi periapikal. Teknik ini memberikan gambar jelas dari seluruh lapisan gigi, memungkinkan diagnosis kondisi gigi dan jaringan sekitarnya. Namun, hasil radiografi ini hanya dapat diinterpretasikan oleh dokter spesialis radiologi gigi, yang jumlahnya terbatas. Oleh karena itu, untuk memudahkan mendeteksi penyakit pulpitis, digunakan klasifikasi dengan teknik pengolahan citra (image processing) untuk membantu dokter dalam mengklasifikasikan penyakit pulpitis berdasarkan citra radiografi. Penelitian ini menggunakan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan penyakit pulpitis berdasarkan citra radiografi. CNN adalah variasi dari Multi Layer Perceptron (MLP) yang memiliki sedikit parameter bebas karena tidak memerlukan pra-pemrosesan, segmentasi, atau ekstraksi fitur. Penelitian ini menggunakan 1000 data citra yang dibagi menjadi dua kelas: pulpitis dan normal. Hasil pengujian menunjukkan bahwa hyperparameter seperti nilai epoch dan optimizer sangat mempengaruhi akurasi. Akurasi tertinggi yang dicapai adalah 98,75% dengan menggunakan optimizer RMSPROP dan nilai epoch 50. Penelitian ini menunjukkan bahwa penggunaan Convolutional Neural Network (CNN) dapat membantu dokter gigi dalam mendiagnosis penyakit pulpitis. Sistem ini dapat digunakan untuk mempermudah dan membantu dokter dalam menentukan diagnosis pulpitis berdasarkan citra radiografi.

Kata kunci: Convolutional Neural Network, Pulpitis, Klasifikasi

I. PENDAHULUAN

Gigi merupakan organ tubuh yang memiliki peranan penting dengan fungsi utama untuk merobek, memotong, dan mengunyah makanan, serta berpartisipasi dalam proses berbicara. Menjaga kesehatan gigi menjadi sangat esensial, mengingat potensi terjadinya berbagai jenis

penyakit gigi. Terdapat kurangnya kesadaran pada beberapa individu terkait kebersihan gigi, meskipun rongga mulut manusia menjadi tempat tinggal bagi beragam bakteri yang memiliki potensi menimbulkan berbagai penyakit pada pulpa gigi, salah satunya Pulpitis[1]. Pulpitis adalah suatu kondisi peradangan yang terjadi pada pulpa gigi, yaitu bagian terdalam dari gigi yang berisi saraf dan pembuluh darah, beserta jaringan

periradikular yang melingkupi akar gigi [2]. Pulpitis juga bisa disebabkan oleh sakit gigi dan gigi tanggal. Pemeriksaan juga dapat dilakukan melalui teknik radiograf periapikal, di mana seluruh lapisan gigi terlihat dengan jelas, memungkinkan dilakukannya diagnosis terhadap kondisi kesehatan gigi. Radiograf periapikal merupakan sebuah perangkat penunjang diagnostik yang digunakan oleh dokter gigi untuk memeriksa secara rinci keadaan gigi dan jaringan sekitarnya[3]. Teknik radiograf periapikal merupakan salah satu implementasi dari teknologi sinar-X. Oleh karena itu, kemampuan seorang dokter dalam mendiagnosa penyakit gigi sangat diperlukan[4]. Hasil radiograf hanya dapat diinterpretasikan oleh dokter spesialis radiologi gigi, yang sayangnya jumlahnya terbatas. Meski demikian, hasil yang diperoleh dari alat ini tidak selalu memberikan data atau gambaran yang jelas. Oleh karena itu, diperlukan sebuah alat yang dapat mendeteksi penyakit pulpitis dengan akurat dan efisien untuk mempermudah proses identifikasi hasil dari radiograf periapikal.

Perkembangan teknologi pada zaman ini sangat membantu manusia dalam melakukan berbagai aktifitas, manfaat dari perkembangan teknologi ini adalah mempermudah manusia dalam memecahkan beberapa masalah dengan cepat dan akurat. Penggunaan AI (Artificial Intelligence) pada pengolahan citra digital membantu pada proses diagnosa. Salah satu cabang pembelajaran dari ranah AI (Artificial Intelligence) adalah Machine Learning yang mengambil inspirasi dari kompleksitas jaringan syaraf manusia [5]. Machine Learning merupakan suatu paradigma pembelajaran mesin yang dirancang untuk memahami dan mengembangkan metode yang menggunakan data untuk meningkatkan kinerja, dan dikonfigurasi untuk memperoleh informasi secara otomatis [6]. Dengan demikian, para pengembang hanya perlu memprogramnya sekali dengan algoritma tertentu, dan selanjutnya mesin akan beroperasi sesuai dengan sistem algoritma yang telah ditanamkan. Keberhasilan model ini menjadi sebuah terobosan yang signifikan untuk mempermudah berbagai kegiatan. Konsep ini pun terus berkembang lebih lanjut dalam Deep Learning [7]. Saat ini, Deep Learning telah menjadi perhatian luas dalam ranah Machine Learning dikarenakan kemampuannya yang sangat signifikan dalam memodelkan data yang bersifat kompleks, seperti citra dan suara [8]. Deep Learning merupakan sub cabang dari Machine Learning yang menggunakan model komputasi dengan multiple processing layers, bertujuan untuk mewakili data dengan tingkat abstraksi yang beragam [9]. Melalui pendekatan ini, Deep Learning mampu menghasilkan prediksi atau klasifikasi dengan tingkat akurasi yang tinggi. Salah satu contoh dari implementasi Deep Learning adalah kemampuannya dalam mendeteksi objek dan mengklasifikasikannya melalui sebuah citra [10]. Keberhasilan Deep Learning dalam menangani data-data kompleks, seperti gambar dan suara, menjadikannya sebagai topik yang sangat diminati di dalam lingkup Machine Learning. Salah satu metode Deep Learning yang sedang mengalami perkembangan pesat saat ini adalah Convolutional Neural Network (CNN) [11]. Convolutional Neural Network (CNN) adalah teknik pembelajaran mendalam yang memiliki skor pengenalan

gambar terbaik saat ini [12]. Jaringan saraf ini, meskipun memiliki kesamaan dengan Multi Layer Perceptron (MLP) atau jaringan saraf biasa, memiliki perbedaan signifikan dalam representasi setiap neuron, yang diwujudkan dalam bentuk dua dimensi, berbeda dengan Multi Layer Perceptron (MLP) yang hanya memiliki satu dimensi. Convolutional Neural Network (CNN) memiliki lapisan khusus yang disebut lapisan konvolusi, dimana citra masukan diproses melalui filter yang telah ditentukan.

Banyak penelitian yang telah dilakukan untuk mengembangkan sistem deteksi pulpitis. Deteksi pada pulpitis dapat menjadi alat yang efektif untuk memudahkan dokter dalam mendiagnosa hasil radiografi.

Salah satu penelitian terdahulu yang dilakukan adalah tentang Deteksi Pulpitis Reversibel Melalui Sinyal Wicara Dengan Metode Wavelet Packet Dan Klasifikasi Self Organizing Maps (SOM) yang dilakukan oleh M. Amiriyanti, B.Hidayat, Y.M.Akbar pada tahun 2019. Penelitian ini bertujuan untuk mengembangkan sebuah sistem yang dapat mendeteksi sinyal suara pada penyelim dengan fenomena barodontalgia khususnya kasus perawatan pulpitis reversibel melalui metoda klasifikasi Wavelet Packet dan Self Organizing Maps (SOM). Hasil eksperimen menunjukkan bahwa metode Wavelet Packet dan Self Organizing Maps (SOM) yang dikembangkan berhasil mencapai akurasi sebesar 73.333% [13].

Selain itu, penelitian terdahulu yang dilakukan adalah Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN) yang dilakukan oleh A.Rasyid dan L.Heryawan pada tahun 2023. Penelitian ini bertujuan untuk merancang sebuah sistem untuk mengklasifikasi penyakit pada paru-paru menggunakan model CNN dengan arsitektur MobileNet. Hasil eksperimen menunjukkan bahwa metode CNN yang dikembangkan berhasil mencapai akurasi sebesar 96.837% [14].

Lalu penelitian terdahulu yang membahas tentang Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN) yang dilakukan oleh S.N.Ria, M.Walid, dan B.A.Umam pada tahun 2022. Penelitian bertujuan untuk merancang sebuah sistem untuk mengidentifikasi jenis penyakit pada kulit menggunakan model CNN. Hasil eksperimen menunjukkan bahwa metode CNN yang dikembangkan berhasil mencapai akurasi sebesar 98.00% [15].

Berdasarkan pada uraian latar belakang di atas, penelitian ini menggunakan metode Convolutional Neural Network (CNN) dengan fokus studi pada citra radiograf pulpitis. Tujuan utama dari penelitian ini adalah untuk mengevaluasi tingkat akurasi model yang dihasilkan serta menguji kemampuan model Convolutional Neural Network (CNN) dalam mengklasifikasi gambar radiograf pulpitis.

II. METODE PENELITIAN

Untuk metode penelitiannya akan digambarkan menggunakan Flowchart yang menjelaskan tentang alur cerita dari penelitian yang akan penulis kerjakan. Isi dari

Flowchart tersebut dapat diuraikan pada gambar 1 dibawah ini:



Gambar 1: Tahapan Penelitian

a. Identifikasi Masalah

Identifikasi Masalah, yang dilakukan dengan mencari jurnal-jurnal penelitian terkait. Pencarian ini mencakup literatur-literatur yang menggunakan metode Convolutional Neural Network (CNN) untuk memberikan gambaran terinci mengenai kerangka kerja yang akan digunakan dalam pelaksanaan penelitian ini.

b. Pengumpulan Data

Pencarian data citra radiografi gigi sebanyak mungkin dengan tujuan untuk menghasilkan dataset yang akan menjadi materi pra-pemrosesan pada tahap selanjutnya dari penelitian ini.

c. Pra Processing

Dilakukan dengan cara memberi label pada setiap data dan mengubah dimensi gambar agar gambar memiliki ukuran yang sama lalu data yang sudah diproses dikumpulkan menjadi dua bagian yaitu untuk data uji dan data latih. Data latih sendiri merupakan data yang digunakan untuk proses pelatihan data klasifikasi dan data uji merupakan data yang akan digunakan untuk proses pengujian pada klasifikasi CNN.

d. Perancangan Model CNN

Perancangan model Convolutional Neural Network (CNN) merupakan tahapan krusial dalam merancang sebuah model yang akan digunakan dalam proses klasifikasi. Proses pembuatan model ini melibatkan dua tahapan utama, yaitu konvolusi dan pooling, yang terjadi pada tahap feature learning. Setiap operasi konvolusi memanfaatkan sejumlah filter dengan ukuran kernel yang berbeda. Pada tahap selanjutnya dilakukan proses flatten, di mana feature


map yang dihasilkan dari lapisan pooling diubah menjadi vektor. Proses ini umumnya dikenal sebagai tahap Fully Connected layer.

e. Pengujian Model CNN

Pada tahap pengujian ini, dilakukan evaluasi terhadap model yang dihasilkan oleh Convolutional Neural Network (CNN). Pengujian ini terbagi menjadi dua tahap, yakni tahap latih dan tahap uji. Tahap latih merupakan proses dimana model CNN diuji menggunakan data yang telah disiapkan untuk pelatihan. Sementara itu, tahap uji adalah langkah pengujian terhadap model yang telah mengalami proses pelatihan sebelumnya.

f. Rancangan User Interface

Pengujian telah dilakukan secara berulang untuk mencapai tingkat akurasi tertinggi. Model terbaik yang dihasilkan akan diimplementasikan dalam sebuah sistem yang dirancang untuk menguji citra data test. Sistem ini dibangun dengan model optimal dan dilengkapi dengan antarmuka pengguna grafis (GUI) yang interaktif, sehingga memudahkan pengguna dalam menjalankan program. Untuk hasil user interface dapat digambarkan pada gambar 2 :



Gambar 2: User Interface Aplikasi

Pada user interface aplikasi ini, proses penginputan data citra dilakukan melalui tindakan menekan tombol "Input," yang membuka data citra yang tersimpan di folder data uji. Setelah citra ditampilkan, pengguna dapat menekan tombol "Klasifikasi" untuk memperoleh hasil akhir dari citra yang telah diinputkan. Hasil klasifikasi tersebut akan ditampilkan di bagian "Output." Tombol "Reset" berfungsi untuk menghapus seluruh data sebelumnya, memungkinkan pengguna untuk memulai kembali dengan data citra baru untuk penggunaan berikutnya.

III. HASIL PENELITIAN

a. Pengumpulan Bahan dan Data

Pengumpulan data dilakukan ini dilakukan melalui penelusuran data gambar pada situs-situs web resmi yaitu


kaggle. Data yang digunakan berasal dari foto radiografi gigi yang memiliki keluhan pulpitis.

b. Praproses Data

1. Pemotongan Area Citra

Pemotongan area citra untuk membentuk sebuah gambar persegi dari hasil radiograf yang sebelumnya memiliki bentuk persegi panjang. Sesuai dengan prinsip klasifikasi Convolutional Neural Network (CNN) yang menetapkan persyaratan agar gambar memiliki dimensi yang sama pada panjang dan lebar, maka hasil radiograf gigi yang pada awalnya berbentuk persegi panjang, menjalani proses pemotongan untuk menghasilkan gambar persegi.

Untuk penjabarannya seperti gambar 3 dibawah ini :



Gambar 3 : Paronamic Radiografi Gigi

Untuk proses pemotongan gambar untuk membentuk gambar kedua yang memiliki bentuk persegi, seperti contoh gambar 4 dibawah ini :



Gambar 4 : Radiografi Pulpitis

2. Merubah Ukuran Citra

Penyesuaian ukuran pada setiap elemen data set yang dikumpulkan secara individual, dengan dimensi gambar ditetapkan pada 128 x 128 piksel untuk setiap gambar. Pemilihan ukuran 128 x 128 piksel dilakukan sesuai dengan persyaratan metode Convolutional Neural Network (CNN), di mana ukuran piksel yang dapat diterima adalah 64 x 64, 128 x 128, 256 x 256, 512 x 512, dan seterusnya. Dalam kerangka penelitian ini, ukuran piksel yang digunakan adalah 128 x 128 untuk mendukung proses klasifikasi menggunakan CNN.

3. Pelabelan Data

Proses pelabelan data di sini bertujuan untuk memberikan identifikasi terhadap data yang terkumpul, sehingga dapat diakses dengan jelas. Untuk melaksanakan proses ini, peneliti membentuk dua folder utama, yaitu folder data latih dan folder data

uji. Bagian folder data latih berperan sebagai tempat penyimpanan data yang akan diproses dalam kerangka penelitian ini, sementara folder data uji berfungsi untuk memvalidasi data yang berasal dari proses data latih, dan nantinya akan digunakan dalam tahap pengujian penelitian ini. Setiap subfolder yang ada dalam kedua folder utama diberi nama "pulpitis" dan "normal," sesuai dengan contoh gambar 5 dibawah ini :



Gambar 5 : Data yang telah diberi label

4. Proses Convolutional Neural Network (CNN)

Pada tahap ini digunakan 2 tahapan yaitu tahapan *feature learning* dan *classification*.

a. Feature Learning

Paada tahapan Feature Learning terdiri dari dua komponen utama, yaitu Convolutional Layer dan Pooling Layer. Untuk memberikan gambaran implementasi pada tahapan Feature Learning ini, berikut adalah potongan source code yang digunakan pada gambar 6 :

```
% Layer 1
convolution2dLayer(3,16,'Padding',1)
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2,'Stride',2)

% Layer 2
convolution2dLayer(3,32,'Padding',1)
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2,'Stride',2)

% Layer 3
convolution2dLayer(3,64,'Padding',1)
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2,'Stride',2)

% Layer 4
convolution2dLayer(3,128,'Padding',1)
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2,'Stride',2)
```

Gambar 6 Source Code pada Feature Learning

b. Classification

Tahapan kedua setelah melalui proses Feature Learning adalah tahap Classification, di mana data citra akan diarahkan. Pada tahapan ini, aktivasi softmax berperan dalam mengklasifikasikan input sesuai dengan kategori yang ditentukan. Terdapat dua kategori dalam konteks ini, yaitu kategori pulpitis dan normal.


IV. PEMBAHASAN

a. Pengujian Model

Pada tahap ini, peneliti mengalokasikan masing-masing kategori normal 500, kategori pulpitis 500 dengan jumlah seluruh dataset sebanyak 1.000 citra, dan rasio distribusi data yang digunakan adalah 80%:20%. Setelah melalui serangkaian proses algoritma Convolutional Neural Network (CNN), diperoleh hasil dari proses training dan validasi. Pada tahap ini, dilakukan beberapa uji coba pada jumlah epoch dan optimizer untuk mengetahui jumlah akurasi terbaik. Pada uji coba epoch jumlah yang digunakan sebanyak 25, 50, 100, 200, 300. Optimizer yang digunakan yaitu Stochastic Gradient Descent with Momentum (SGDM), Root Mean Square Propagation (RMSPROP), dan Adaptive Moment Estimation (ADAM).

b. Perbandingan Epoch dengan Optimizer SGDM

Pengujian pertama akan dilakukan dengan menggunakan optimizer berupa SGDM. Pada pengujian ini juga dapat diketahui bahwa hasil nilai akurasi terus meningkat seiring dengan berkurangnya nilai epoch yang digunakan.



Gambar 7 : Grafik Perbandingan SGDM

Grafik di atas menggambarkan pengaruh jumlah epoch terhadap akurasi model saat menggunakan optimizer SGDM (Stochastic Gradient Descent with Momentum). Hasil penelitian menunjukkan bahwa akurasi tertinggi dicapai pada epoch ke-50, dengan akurasi 97.50%. Hal ini menunjukkan bahwa epoch ke-50 merupakan jumlah epoch yang optimal untuk melatih model dengan optimizer SGDM pada dataset dan arsitektur yang digunakan dalam penelitian ini.


Epoch	Validation Accuracy
25	93.75%
50	97.50%
100	93.75%
200	96.88%
300	91.25%

Tabel 1 Hasil Perbandingan Optimizer SGDM

Penurunan akurasi yang signifikan terlihat pada epoch ke-25 dan 300. Hal ini mengindikasikan bahwa melatih model terlalu sedikit (underfitting) atau terlalu banyak (overfitting) dapat berdampak negatif pada performa model.

c. Perbandingan Epoch dengan Optimizer ADAM

Pengujian kedua akan dilakukan menggunakan optimizer ADAM dengan menggunakan epoch yang sama seperti pada optimizer sebelumnya.



Gambar 8 : Grafik Perbandingan ADAM

Grafik di atas menggambarkan pengaruh jumlah epoch terhadap akurasi model saat menggunakan optimizer ADAM. Hasil penelitian menunjukkan bahwa akurasi tertinggi dicapai pada epoch ke-100 dan 300 dengan akurasi 96.25%. Hal ini menunjukkan bahwa epoch ke-100 dan 300 merupakan jumlah epoch yang optimal untuk melatih model dengan optimizer ADAM pada dataset dan arsitektur yang digunakan dalam penelitian ini.


Tabel 2 : Hasil Perbandingan Optimizer ADAM

Epoch	Validation Accuracy
25	95.62%
50	95.00%
100	96.25%
200	95.62%
300	96.25%

Penurunan akurasi yang terlihat pada epoch ke-50 dan 200 mengindikasikan bahwa pemilihan jumlah epoch yang tepat sangat penting untuk mencapai performa model yang optimal. Epoch ke-100 dan 300 menunjukkan hasil yang relatif sama, menandakan bahwa penambahan epoch lebih dari 100 tidak memberikan peningkatan akurasi yang signifikan.

d. Perbandingan Epoch dengan Optimizer RMSPROP

Untuk pengujian terakhir akan dilakukan pengujian menggunakan *optimizer* RMSPROP dengan Epoch yang sama sesuai dengan percobaan yang sebelumnya.



Gambar 9 : Grafik Perbandingan RMSPROP

Grafik di atas menunjukkan perbandingan akurasi model dengan *optimizer* RMSProp pada berbagai jumlah epoch. Terlihat bahwa akurasi tertinggi dicapai pada epoch 50, dengan nilai akurasi 98,75%.

Tabel 3 : Hasil Perbandingan *Optimizer* RMSPROP

<i>Epoch</i>	<i>Validation Accuracy</i>
25	95.00%
50	98.75%
100	95.00%
200	94.38%
300	98.12%

Seiring bertambahnya jumlah epoch hingga 300, akurasi model cenderung stabil di sekitar 98%, menunjukkan bahwa penambahan epoch lebih lanjut tidak memberikan peningkatan akurasi yang signifikan. Hasil ini mengindikasikan bahwa epoch 50 merupakan jumlah epoch optimal untuk mencapai akurasi tinggi dengan *optimizer* RMSProp pada model yang digunakan.

e. Hasil Klasifikasi *Optimizer* Terbaik

Pada tahap ini dilakukan perbandingan antara *optimizer* SGDM, Adam, RMSPPPOP untuk mendapatkan hasil terbaik dari keseluruhan *optimizer* yang sudah dicoba yang dimana menggunakan epoch yang sama yaitu epoch 25, epoch 50, epoch 100, epoch 200, dan epoch 300. Dibawah ini adalah tabel dari perbandingan *optimizer* dengan nilai epoch terbaik.

Tabel 4 : Hasil Nilai *Epoch* Terbaik

<i>Optimizer</i>	<i>Epoch</i>	<i>Validation Accuracy</i>
SGDM	50	97.50%
Adam	100 & 300	96.25%
RMSPROP	50	98.75%

Berdasarkan hasil dari tabel diatas dapat diketahui bahwa *optimizer* terbaik adalah *optimizer* RMSPROP. Karena dapat menghasilkan nilai akhir akurasi yang paling tinggi dari pada *optimizer* yang lain.

V. KESIMPULAN

Berdasarkan hasil dan pengujian penelitian yang telah dilakukan untuk mengklasifikasi penyakit pulpitis pada citra radiograf periapikal menggunakan metode CNN (Convolutional Neural Network) dapat ditarik kesimpulan bahwa setelah dilakukan beberapa uji coba menggunakan *optimizer* SGDM, ADAM, RMSPROP dan jumlah epoch 25, 50, 100, 200, 300 menunjukkan pengujian bahwa hasil akurasi terbaik terdapat pada *optimizer* RMSPROP dengan jumlah epoch 50 memiliki akurasi tertinggi sebesar 98.75%.

VI. REFERENSI

- [1] Arsad, A. S. Yasin, and Husaini Juwita, "Analisis Terjadinya Pulpitis Pada Gigi Pasien yang Berkunjung Di Wilayah Puskesmas Tomoni Timur Kabupaten Luwu Timur," *Media Kesehatan Gigi*, vol. 21, no. 2, 2022.
- [2] Hillary Sekar Pawestri, "Pulpitis," Hello Sehat. Accessed: Jun. 16, 2024. [Online]. Available: <https://hellosehat.com/gigi-mulut/gigi/pulpitis-adalah/>
- [3] Eric Whaites, *Radiography and Radiology for Dental Care Professionals*, 2nd ed. Churchill Livingstone, 2009.
- [4] drg. , M. Sp. R. Prof. Dr. H. Suhardjo Sitam, *Radiografi Periapikal*, Cetakan I. Jakarta : Penerbit Buku Kedokteran EGC, 2013.
- [5] L. Anggraini and Y. Yamasari, "Klasifikasi Citra Wajah Untuk Rentang Usia Menggunakan Metode Artificial Neural Network," *Journal of Informatics and Computer Science*, vol. 05, 2023.
- [6] M. Efisiensi et al., *Sistem Informasi Manajemen Terkini*. 2023.
- [7] A. Raup, W. Ridwan, Y. Khoeriyah, Q. Yulianti Zaqiah, and U. Islam Negeri Sunan Gunung Djati Bandung, "Deep Learning dan Penerapannya dalam Pembelajaran," 2022. [Online]. Available: <http://Jiip.stkipyapisdompnu.ac.id>
- [8] P. Adi Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Jurnal Algor*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/algor/index>

-
- [9] J.-P. Briot, G. Hadjeres, and F.-D. Pachet, "Deep Learning Techniques for Music Generation -- A Survey," Sep. 2017, [Online]. Available: <http://arxiv.org/abs/1709.01620>
- [10] A. Peryanto, A. Yudhana, and D. R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," 2019. [Online]. Available: <https://www.mathworks.com/discovery/convolutional-neural-network.html>
- [11] Y. B. A. C. Ian Goodfellow, *Deep Learning*. MIT Press, 2016.
- [12] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," May 2019, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [13] M. Amiriyanti, I. B. Hidayat, M. Yun, and S. O. Akbar, "Deteksi Pulpitis Reversibel Melalui Sinyal Wicara Dengan Metode Wavelet Packet Dan Klasifikasi Self Organizing Maps (Som) Detection Of Reversible Pulpitis Via Speech Signals Using Wavelet Packet Method And Self Organizing Maps (SOM) Classification," 2019.
- [14] A. Rasyid and L. Heryawan, "Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Manajemen Informasi Kesehatan Indonesia (JMIKI)*, vol. 11, no. 1, Mar. 2023, doi: 10.33560/jmiki.v11i1.484.
- [15] S. N. Ria, M. Walid, and B. A. Umam, "Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN)," *Energy - Jurnal Ilmiah Ilmu-Ilmu Teknik*, vol. 12, no. 2, pp. 9–16, Dec. 2022, doi: 10.51747/energy.v12i2.1118.