

Deteksi Pulpitis Menggunakan Machine Learning Convolutional Neural Network Berbasis CNN1D dan MFCC

1st Adrian Wibisono
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

adrianwib@student.telkomuniversity.ac.id

2nd Sofia Saidah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

sofiasaidahsfi@telkomuniversity.ac.id

3rd Fahmi Oscandar
Fakultas Kedokteran Gigi
Universitas Padjadjaran
Bandung, Indonesia

fahmi.oscandar@unpad.ac.id

Abstrak—Tulisan ini membahas isu krusial dalam upaya menjaga kesehatan gigi masyarakat, khususnya yang berkaitan dengan pulpitis, sebuah kondisi peradangan pada pulpa gigi yang dapat dipengaruhi oleh beberapa variabel seperti infeksi bakteri, trauma, atau kerusakan gigi. Penulis memperkenalkan sebuah solusi inovatif untuk mendeteksi dan membedakan gigi yang terkena pulpitis dari gigi yang sehat. Solusi ini diharapkan dapat membantu dokter gigi dalam proses diagnosis dan perawatan pulpitis agar lebih efektif dan juga efisien. Untuk mencapai tujuan tersebut, penulis mengembangkan sebuah sistem berbasis pembelajaran mesin yang menggunakan deteksi pulpitis melalui analisis sinyal audio. Dalam penelitian ini, model *Convolutional Neural Network 1D* (CNN1D) digunakan bersama dengan proses ekstraksi fitur Mel-Frequency Cepstral Coefficients (MFCC). Model CNN1D dioptimalkan menggunakan *optimizer* Adam dengan tingkat pembelajaran sebesar 0.001, ukuran batch 32, dan proporsi data uji sebesar 20%. Evaluasi model dilakukan dengan *confusion matrix* untuk menganalisis akurasi prediksi berdasarkan sinyal audio. Metode pembelajaran mesin yang diusulkan ini menunjukkan potensi besar dalam membantu tenaga kesehatan, terutama dokter gigi, untuk mendiagnosis pulpitis dengan tingkat akurasi yang tinggi, sehingga dapat meningkatkan kualitas perawatan dan hasil pengobatan bagi pasien.

Kata kunci—Data, gigi, machine learning, pulpitis, confusion matrix, CNN1D, MFCC, Ekstraksi Ciri

I. PENDAHULUAN

Gigi adalah salah satu struktur keras yang terletak di mulut yang bertujuan untuk menggigit, mengunyah, dan memotong makanan menjadi potongan kecil sehingga lebih mudah dicerna. Gigi juga berperan penting dalam proses berbicara, membantu pengucapan kata-kata, dan memberikan bentuk pada wajah. Gigi terdiri dari beberapa lapisan salah satu adalah pulpa [1].

Pulpa gigi adalah jaringan lunak yang berlokasi di Tengah gigi, yang terdiri dari saraf, pembuluh darah, dan jaringan ikat. Pulpa memainkan peran penting dalam menjaga kesehatan dan fungsi gigi, terutama karena memberikan nutrisi dan memberikan sensasi kepada saraf di dalamnya. Ketika pulpa rusak atau terinfeksi, terjadi proses peradangan, yang dapat menyebabkan rasa sakit dan memerlukan perawatan seperti terapi saluran akar [2].

Pulpitis merupakan peradangan pada jaringan pulpa gigi, yaitu jaringan lunak di dalam gigi yang terdiri dari saraf, pembuluh darah, dan jaringan ikat, terjadi ketika pulpa

teriritasi atau terinfeksi. Ini sering terjadi karena kerusakan gigi, seperti karies yang dalam atau trauma. Pulpitis dapat menyebabkan nyeri yang tajam dan berdenyut, terutama saat berada di bawah tekanan, panas, atau dingin [3]. Pulpitis terbagi menjadi 2 yaitu Reversibel: Kondisi ini terjadi ketika peradangan pulpa hanya sedikit dan sumber iritasi telah dihilangkan. Rasa sakit biasanya sementara dan hanya muncul ketika terstimulasi. Pulpitis irreversibel adalah kondisi yang lebih parah di mana peradangan telah merusak pulpa secara signifikan dan pulpa tidak dapat pulih sendiri. Kondisi ini biasanya menyebabkan nyeri spontan yang berkepanjangan dan sering kali memerlukan perawatan seperti terapi saluran akar atau pencabutan gigi [4].


Penelitian sebelumnya mencoba menggunakan machine learning untuk mendeteksi pulpitis dengan data suara ucapan manusia. Metode Kode *Prediction Linear* (LPC) digunakan untuk mengekstrak fitur, dan algoritma *K-Nearest Neighbor* (KNN) digunakan untuk mengklasifikasikan fitur [5]. Metode ini, bagaimanapun, menghadapi beberapa tantangan yang signifikan. Yang paling menonjol adalah bias yang terlibat dalam dataset yang digunakan. Misalnya, perbedaan suara antara orang yang bersuara berat dengan nyaring, serta antara orang yang belum baligh dan orang yang sudah dewasa, dapat memengaruhi hasil deteksi.

Temuan sebelumnya menunjukkan bahwa penelitian lebih lanjut diperlukan untuk meningkatkan akurasi deteksi pulpitis. Penulis penelitian ini memilih untuk mempelajari suara ketukan gigi karena setiap gigi dalam persepsi manusia menghasilkan suara yang serupa. Meskipun demikian, asumsi ini mungkin tidak berlaku untuk *machine learning*. Oleh karena itu, tujuan penelitian ini adalah untuk mendeteksi pulpitis dengan menggunakan model CNN1D dan target mencapai akurasi di atas 90%.

II. METODOLOGI

A. Machine Learning

Machine learning adalah salah satu lingkup jenis dari kecerdasan buatan (AI) yang berinovasi pada algoritma dan teknik canggih yang memungkinkan komputer untuk belajar secara mandiri dari data yang tersedia dan kemudian membuat prediksi atau keputusan berdasarkan pola-pola yang diidentifikasi dalam data tersebut [6]. Alih-alih diprogram secara eksplisit untuk melakukan tugas tertentu, mesin atau sistem berbasis *machine learning* dilatih melalui penggunaan sejumlah besar data untuk mempelajari lebih banyak tentang konsep tersebut.



GAMBAR 1.

Berbagai Macam Jenis *Machine Learning*

Machine learning melibatkan algoritma untuk dapat menemukan pola dan juga mengambil keputusan lalu mengeluarkan prediksi dari data yang masuk. *Machine Learning* diklasifikasikan menjadi berbagai jenis:

1. *Supervised Learning*

Dalam algoritma ini model akan dilatih dengan kumpulan data yang sudah diberi label, yang menyebabkan algoritma untuk dapat belajar dari contoh label yang sudah diberikan. Sebagai contoh, algoritma *Supervised Learning* dilatih pada set data audio yang dilabeli sebagai “suara sedih” dan “suara senang” untuk belajar mengklasifikasikan sinyal audio yang baru secara akurat berdasarkan hasil latih model tersebut.

2. *Unsupervised Learning*


Algoritma *Unsupervised Learning* memungkinkan dilatih pada data yang tidak diberi label, sehingga diharapkan algoritma ini dapat menemukan pola atau mencari fitur tersembunyi yang terletak pada data tertentu dengan cara mengelompokkan dengan data yang memiliki fitur yang sama. Seperti mengelompokkan rekomendasi tontonan berdasarkan analisa pada data tontonan sebelumnya.

3. *Reinforcement Learning*

Model ini merupakan model pelatihan melalui proses uji coba, model ini belajar membuat keputusan berdasarkan hadiah atau hukuman berdasarkan tindakan mereka atau keputusan yang diambil. Metode ini biasanya digunakan seperti menambah beban bobot saat salah mengambil keputusan dari latihan sehingga model akan memilih bobot yang ringan.

Algoritma *Machine learning* mempunyai bermacam kegunaan di berbagai sektor, pada bidang industri algoritma *machine learning* digunakan untuk untuk meningkatkan efisiensi operasional, kualitas produksi, dan prediksi perawatan. Pada sektor ini memungkinkan perusahaan untuk memproses data dari sensor di mesin dan fasilitas untuk memprediksi kapan peralatan mungkin mengalami kegagalan. Kemudian pada industri perbankan, *machine learning* digunakan untuk menganalisis riwayat transaksi dan perilaku pelanggan bertujuan mendeteksi aktivitas mencurigakan atau anomali yang bisa mengindikasikan penipuan. Pembelajaran *machine learning* juga sangat penting untuk mengembangkan mobil pintar, di mana sistem dapat belajar menavigasi dengan mengambil rute yang paling nyaman dan cepat.

B. *Convolutional Neural Network 1D (CNN1D)*




GAMBAR 2.

Arsitektur CNN1D

1D *Convolutional Neural Network* (Conv1D) adalah jenis jaringan saraf konvolusional yang dapat memproses data satu dimensi seperti deret waktu, teks, atau sinyal suara [7]. Berdasarkan gambar 2. Lapisan pertama merupakan proses penerimaan data input berupa sinyal audio. Selanjutnya, data tersebut diolah oleh lapisan Conv1D yang setiap lapisan memiliki filter dengan ukuran yang berbeda atau sama. Fungsi lapisan Conv1D adalah menemukan fitur lokal dalam data input. Ini membantu menemukan pola dasar yang ada dalam data [8]. Lapisan pertama *Convolution Layer 1* mengaplikasikan filter untuk mendapatkan fitur disetiap lapisan konvolusi, yang hasilnya diproses lebih lanjut oleh lapisan konvolusi berikutnya, *Convolution Layer 2* Fitur dari lapisan sebelumnya diambil dari lapisan ini dan diterapkan filter tambahan untuk menangkap fitur yang lebih kompleks. Ini membantu dalam mengekstraksi pola yang lebih rinci dari data.

Setelah melewati lapisan *convolution*, data akan dilanjutkan oleh lapisan *flatten* untuk merubah data menjadi vektor satu dimensi [9]. Selanjutnya data akan melalui proses lapisan berikutnya yaitu *dense layer* yang berfungsi menghubungkan semua neuron di lapisan sebelumnya ke setiap neuron di lapisan ini. Lapisan ini biasanya digunakan untuk klasifikasi akhir atau regresi berdasarkan fitur yang telah diekstraksi [10]. Pada tahap terakhir, lapisan *output* menghasilkan keluaran berupa peluang untuk setiap kelas target.

C. MFCC



GAMBAR 3.

Arsitektur Ekstraksi Ciri MFCC

Metode *Mel-Frequency Cepstral Coefficients* (MFCC) adalah salah satu teknik ekstraksi fitur yang efektif dalam pengolahan sinyal audio, terutama untuk klasifikasi suara dan ucapan. Proses MFCC melibatkan penggunaan transformasi Fourier untuk mengubah sinyal suara dari domain waktu ke domain frekuensi, kemudian menggunakan skala Mel, yang merupakan skala frekuensi yang dikenal sebagai Mel-Frequency [11]. Proses ini kemudian menghasilkan koefisien yang digunakan sebagai fitur dalam berbagai aplikasi pembelajaran mesin.

Proses *Mel-Frequency Cepstral Coefficients* (MFCC) terdiri dari beberapa proses vital yang dapat mengekstraksi

fitur relevan dari sinyal audio., berikut adalah proses langkah dalam MFCC:

4. Pre-Emphasis

Langkah pertama ini melibatkan penyaringan sinyal untuk meningkatkan amplitudo frekuensi tinggi. Tujuan dari pre-emphasis adalah untuk mengatasi hilangnya energi di bagian frekuensi tinggi yang sering terjadi selama perekaman suara [12].

$$y(t) = x(t) - \alpha \cdot x(t - 1) \quad (1)$$

5. Filtering

Dalam sinyal suara, *filtering* adalah proses yang digunakan untuk mengubah atau mengubah spektrum frekuensi sinyal suara. Tujuan utama dari *filtering* adalah untuk memperkuat atau melemahkan bagian frekuensi tertentu sesuai dengan kebutuhan aplikasi, atau untuk mengekstraksi fitur penting dari sinyal suara [13].

6. Framing

Karena sifat suara berubah-ubah dalam waktu yang singkat, sinyal suara dibagi menjadi beberapa segmen kecil yang disebut frame. Setiap frame dianggap stasioner dan dapat dianalisis secara mandiri [14].

7. Windowing

Windowing berguna mengurangi efek kebocoran spektral, setelah pembagian menjadi frame, setiap frame diberi jendela. Ini biasanya dilakukan dengan jendela *Hamming*. Jendela ini memastikan bahwa analisis frekuensi di sekitar batas frame tidak menghasilkan artefak [15].

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2)$$

8. Fast Fourier Transform (FFT)

FFT digunakan untuk mengubah sinyal dari domain waktu ke domain frekuensi. Ini memungkinkan analisis komponen frekuensi dari setiap frame suara [16].

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-j(2\pi/N)kn} \quad (3)$$

9. Mel-Scale Filter Bank

Setelah FFT, spektrum daya melewati bank filter Mel-scale, yang terdiri dari filter berbentuk segitiga yang diposisikan secara logaritmis di sepanjang sumbu frekuensi. Ini meniru cara manusia mendengar, di mana frekuensi rendah lebih sensitif dibandingkan frekuensi tinggi [17].

$$m = 2595 \cdot \log_{10} \left(1 + \frac{f}{700}\right) \quad (4)$$

10. Discrete Cosine Transform (DCT)

Langkah terakhir melibatkan penerapan DCT pada log filter bank untuk menghasilkan koefisien MFCC. DCT membantu mengompresi informasi dan mengurangi korelasi antar koefisien [18].

$$c(n) = \sum_{k=1}^K S(k) \cos\left[\frac{\pi n(k-0.5)}{K}\right] \quad (5)$$

D. Pembuatan Dataset

Penulis menggunakan dataset yang terdiri dari suara ketukan pada gigi untuk penelitian ini. Gigi yang diketuk termasuk gigi yang sehat dan gigi yang mengalami pulpitis.

Para ahli medis gigi telah memverifikasi proses pengetukan untuk memastikan keakuratannya. Semua data yang didapat diubah menjadi file wav.

Total yang data yang telah dikumpulkan berjumlah 180, termasuk sembilan puluh gigi sehat dan sembilan puluh gigi dengan pulpitis. Jumlah dataset ditambahkan menjadi 900 melalui proses augmentasi data untuk meningkatkan akurasi model. Dataset ini kemudian dibagi menjadi dua bagian, yaitu data pelatihan dan data validasi, sesuai dengan pembagian data sebagai berikut:

1. Data Pelatihan = 80% dari total dataset (720 file.wav)
2. Data Validasi = 20% dari total dataset (180 file.wav)

E. Pelatihan Model

Dalam mencapai model yang ideal, kita perlu melakukan berbagai proses. *Preprocessing*, *feature extraction*, dan *hyperparameter* adalah prosesnya.

1. Preprocessing

Tahap *preprocessing* merupakan tahap pertama sebelum proses penerapan algoritma yang akan digunakan. *Preprocessing* merupakan tindakan untuk menghilangkan beberapa masalah yang tidak relevan. Supaya data menjadi lebih efektif, *preprocessing* melalui beberapa proses, yaitu gaussian filter dan data augmentation. *Gaussian Filter* adalah filter yang bekerja dengan mencari persamaan *matrix* atau *kernel*. Proses ini dipilih karena sangat baik untuk menghilangkan *noise* yang tidak relevan. Augmentasi Data adalah cara yang digunakan bertujuan untuk menambah variasi data dengan cara mengubah data tersebut secara statistik. Augmentasi data sangat berguna ketika data yang didapat terbatas sehingga akurasi model akan meningkat.

2. Feature Extraction

Dalam 1D *Convolutional Neural Networks* (CNN1D), proses *feature extraction* adalah proses model secara otomatis mempelajari dan mengekstraksi fitur penting dari data satu dimensi, seperti deret waktu atau sinyal audio, tanpa memerlukan pengolahan manual yang rumit. Proses ini sangat penting untuk berbagai aplikasi, seperti pengenalan pola, klasifikasi sinyal, dan deteksi anomali [19].

3. Hyperparameter


Pengujian hyperparameter adalah proses yang bertujuan untuk menentukan kombinasi *hyperparameter* yang paling optimal untuk meningkatkan kinerja model. Dalam sistem ini, pengujian *hyperparameter* dilakukan dengan mempertimbangkan berbagai elemen seperti *optimizer*, *learning rate*, *epoch*, dan *batch size*, serta membandingkan berbagai konfigurasi untuk menemukan yang memberikan performa terbaik pada model. Oleh karena itu, dataset yang telah dipersiapkan akan dilatih menggunakan algoritma CNN1D dengan menggunakan hyperparameter yang telah ditentukan berikut ini:

- a. *Size of Batch* : 32
- b. *Rate of Learning* : 0.001
- c. *Epoch* : 300
- d. *Optimizer* : Adam

F. Evaluasi Model

Evaluasi model merupakan langkah penting untuk menilai kinerja model menggunakan berbagai metode penilaian. Salah satu metode utama yang digunakan adalah *confusion matrix*, yang berfungsi sebagai alat untuk mengukur akurasi prediksi dalam sistem klasifikasi.

Confusion matrix memberikan empat elemen penting seperti *False Positive (FP)*, *True Positive (TP)*, *False Negative (FN)*, dan *True Negative (TN)*, yang digunakan untuk menghitung metrik seperti *F1 score*, *recall*, dan *precision*. Keempat elemen ini membentuk dasar dalam mengevaluasi seberapa baik model dalam mengklasifikasikan data [20]. Keempat elemen hasil kategorisasi dalam *confusion matrix* ditunjukkan pada gambar berikut.



GAMBAR. 4.
Ilustrasi dari *Confusion Matrix*

Berdasarkan Gambar 4. menganalisa nilai yang diprediksi dengan nilai data sebenarnya, dengan empat komponen utama yang mengindikasikan hasil proses klasifikasi.

1. *True Positive (TP)*: Data yang diklasifikasikan secara benar ke dalam kategori yang sesuai dengan kondisi sebenarnya.
2. *True Negative (TN)*: Data yang benar-benar tidak termasuk dalam kategori tertentu dan dengan tepat tidak diklasifikasikan ke dalam kategori tersebut
3. *False Positive (FP)*: Data yang secara salah diklasifikasikan sebagai bagian dari kategori tertentu padahal sebenarnya tidak termasuk dalam kategori tersebut.
4. *False Negative (FN)*: Data yang seharusnya diklasifikasikan ke dalam kategori tertentu, namun tidak diklasifikasikan dengan benar ke dalam kategori tersebut.

Berdasarkan *confusion matrix*, kita dapat menghitung beberapa metrik evaluasi, seperti *F1-score*, *precision*, *accuracy*, dan *recall*. *Accuracy* adalah rasio antara jumlah prediksi yang benar, baik positif maupun negatif, terhadap total jumlah data. *Precision* mengukur seberapa banyak dari prediksi positif yang benar-benar sesuai dengan klasifikasi yang sebenarnya, yaitu rasio antara jumlah prediksi positif yang benar dengan total semua prediksi positif. Sementara itu, *recall* mengukur seberapa banyak dari data yang seharusnya diklasifikasikan sebagai positif yang berhasil dikenali dengan benar oleh model, atau rasio antara jumlah prediksi positif yang benar dengan total data positif yang ada.

$$Recall = \frac{TP}{(FN+TP)} \quad (6)$$

$$Precision = \frac{TP}{(FP+TP)} \quad (7)$$

$$F1-Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (8)$$


$$Accuracy = \frac{(TN+TP)}{(TN+FN+FP+TP)} \quad (9)$$

III. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan dan Pengujian

Model optimal dari algoritma CNN1D diperoleh melalui pengujian *hyperparameter* dan ukuran data uji. Untuk mengevaluasi model ini, analisis dilakukan menggunakan data uji untuk menilai kemampuan model dalam melakukan prediksi berdasarkan sinyal suara. *Confusion matrix* digunakan untuk mengukur kinerja model, menentukan parameter evaluasi untuk setiap kelas, serta menghitung rata-rata keseluruhan kinerja model.

Hasil optimal dari proses pengujian algoritma CNN1D yakni menggunakan *hyperparameter* Adam dengan *learning rate* 0.001, epoch 300, dan batch size 32. Model ini menggunakan *training test* 0.2 dari total jumlah dataset acak.



GAMBAR 5.
Confusion Matrix Terhadap Model


Berdasarkan Gambar 5. *confusion matrix* menunjukkan hasil evaluasi kinerja model klasifikasi dalam membedakan antara kelas "Sehat" dan "Pulpitis". Matriks ini menunjukkan bahwa model berhasil memprediksi 98 kasus "Sehat" dan 67 kasus "Pulpitis" dengan benar, namun juga melakukan kesalahan dengan memprediksi 4 kasus "Pulpitis" yang sebenarnya "Sehat" dan 11 kasus "Sehat" yang sebenarnya "Pulpitis". Matriks ini memberikan gambaran tentang akurasi model serta jenis kesalahan yang terjadi dalam prediksi, yang penting untuk analisis lebih lanjut.

Classification Report				
	precision	recall	f1-score	support
Sehat	0.90	0.96	0.93	102
Pulpitis	0.94	0.86	0.90	78
accuracy			0.92	180
macro avg	0.92	0.91	0.91	180
weighted avg	0.92	0.92	0.92	180

GAMBAR 6.
Classification Report Terhadap Model


Pada Gambar 6. menampilkan laporan klasifikasi yang merangkum kinerja model dalam mengklasifikasikan dua kelas, yaitu "Sehat" dan "Pulpitis". Pada kelas "Sehat", model

mencapai *precision* sebesar 0.90, *recall* sebesar 0.96, dan *F1-score* sebesar 0.93, dengan 102 data sebagai *support*. Sementara untuk kelas "Pulpitis", *precision* tercatat sebesar 0.94, *recall* sebesar 0.86, dan *F1-score* sebesar 0.90, dengan 78 data sebagai *support*. Secara keseluruhan, model memiliki akurasi 0.92, dengan *macro average* dari *precision*, *recall*, dan *F1-score* masing-masing 0.92, 0.91, dan 0.91, serta *weighted average* sebesar 0.92 untuk ketiga metrik tersebut. Laporan ini menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mengklasifikasikan kedua kelas, yaitu "Sehat" dan "Pulpitis" sehingga model ini dapat diandalkan.



GAMBAR 7.
Grafik Train Loss dan Validation Loss

Berdasarkan Gambar 7. menampilkan grafik yang menunjukkan perubahan nilai loss selama proses pelatihan model *Training Loss* dan validasi *Validation Loss* terhadap jumlah *epoch*. Pada awal pelatihan, baik *training loss* maupun *validation loss* menunjukkan penurunan yang tajam, yang menandakan bahwa model dengan cepat belajar dari data yang diberikan. Setelah sekitar 50 *epoch*, kedua kurva mulai mendatar, menunjukkan bahwa model telah mencapai titik stabil di mana perubahan nilai *loss* menjadi minimal. Kurva yang saling mendekati di sepanjang pelatihan juga menunjukkan bahwa model tidak mengalami *overfitting*, karena perbedaan antara *training loss* dan *validation loss* tetap kecil. Hal ini mengindikasikan bahwa model memiliki proses yang baik terhadap data yang belum pernah diproses sebelumnya. Sehingga dapat dinyatakan model telah dilatih dengan baik, menunjukkan kinerja yang stabil, dan mampu melakukan generalisasi secara efektif terhadap data baru.



GAMBAR 8.
Grafik Train Accuracy dan Validation Accuracy

Gambar 8. menampilkan grafik yang menunjukkan perubahan akurasi model selama proses pelatihan *Training Accuracy* dan validasi *Validation Accuracy* terhadap jumlah *epoch*. Pada tahap awal pelatihan, akurasi model meningkat tajam, menunjukkan bahwa model dengan cepat belajar dari data. Seiring bertambahnya jumlah *epoch*, baik akurasi

pelatihan maupun validasi terus meningkat dan mencapai nilai yang mendekati 0.9, menunjukkan kinerja yang konsisten. Fluktuasi kecil pada kurva validasi mengindikasikan adanya variabilitas kecil dalam performa model terhadap data validasi, tetapi secara keseluruhan, kurva akurasi validasi tetap tinggi dan mendekati kurva akurasi pelatihan. Didapat bahwa model menunjukkan kinerja yang baik dengan akurasi yang tinggi dan stabil, serta tidak mengalami *overfitting*, karena akurasi pada data pelatihan dan validasi tetap seimbang sepanjang pelatihan.

B. Pembahasan

Menurut penelitian sebelumnya, ada beberapa elemen yang perlu diperbaiki terkait dataset dan model pembelajaran mesin yang digunakan. Penggunaan dataset yang terdiri dari ucapan manusia merupakan salah satu keterbatasan dari penelitian sebelumnya. Jumlah data yang ada tidak homogen karena bias ucapan manusia, seperti perbedaan suara dengan suasana hati berbeda serta suara orang yang belum masuk baligh dengan orang dewasa.

Dalam penelitian sebelumnya, keterbatasan ini telah diatasi dan ditingkatkan. Sebagai upaya untuk mencapai homogenitas data, peneliti menggunakan dataset yang terdiri dari suara ketukan gigi manusia sehingga variabel pengganggu yang terjadi dalam penelitian sebelumnya bisa ditiadakan. Selain itu, algoritma yang digunakan adalah CNN1D, yang dikenal mampu memproses sinyal audio dengan baik, dan dilengkapi dengan fitur mfcc untuk meningkatkan ketepatan. Hasilnya, laporan klasifikasi menunjukkan bahwa akurasi model lebih dari 92 persen.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem untuk mendeteksi penyakit pulpitis menggunakan machine learning yang menggunakan *Convolutional Neural Network* berbasis CNN1D dan fitur ekstraksi mfcc. Hasil dan diskusi menunjukkan bahwa ini adalah hasil yang berhasil. Laporan klasifikasi menunjukkan kinerja yang cukup memuaskan dari model, yang mencapai akurasi 92% dengan *precision* dan *recall* yang cukup tinggi. Karena penelitian ini hanya menentukan pulpitis dengan sinyal audio, diharapkan penelitian selanjutnya dapat menemukan penyakit gigi lainnya dengan menggunakan sinyal audio dan dua dimensi.

REFERENSI

- [1] H. Jayakodi, S. Kailasam, K. Kumaravadivel, B. Thangavelu, and S. Mathew, "Clinical and pharmacological management of endodontic flare-up," *Journal of Pharmacy and Bioallied Sciences*, vol. 4, no. 6, p. 294, Jan. 2012, doi: 10.4103/0975-7406.100277.
- [2] I. a. E. Karim, P. R. Cooper, I. About, P. L. Tomson, F. T. Lundy, and H. F. Duncan, "Deciphering reparative processes in the inflamed dental pulp," *Frontiers in Dental Medicine*, vol. 2, Mar. 2021, doi: 10.3389/fdmed.2021.651219.
- [3] Y. -I. Ng, V. Mann, and K. Gulabivala, "A prospective study of the factors affecting outcomes of nonsurgical root canal treatment: part 1: periapical health," *International Endodontic Journal*, vol. 44, no. 7, pp. 583–609, Mar. 2011, doi: 10.1111/j.1365-2591.2011.01872.x.
- [4] F. Lorencetti-Silva *et al.*, "Effects of inflammation in dental pulp cell differentiation and reparative response,"

- Frontiers in Dental Medicine*, vol. 3, Aug. 2022, doi: 10.3389/fdmed.2022.942714.
- [5] M. F. Amanda, "Deteksi Pulpitis Reversibel Melalui Sinyal Wicara Dengan Metode Linear Predictive Coding (Lpc) Dan Klasifikasi K-Nearest Neighbor (K-Nn)," Repository, May 03, 2019. <https://repository.telkomuniversity.ac.id/home/catalog/id/149651/slug/deteksi-pulpitis-reversibel-melalui-sinyal-wicara-dengan-metode-linear-predictive-coding-lpc-dan-klasifikasi-k-nearest-neighbor-k-nn-.html>
- [6] K. Das and R. N. Behera, "A survey on Machine Learning: Concept, Algorithms and Applications," *International Journal of Innovative Research in Computer and Communication Engineering*, vol. 5, no. 2, Jan. 2017, [Online]. Available: <https://www.rroij.com/open-access/a-survey-on-machine-learning-conceptalgorithms-and-applications-.pdf>
- [7] S. Kiranyaz, T. Ince, and M. Gabbouj, "Real-Time Patient-Specific ECG classification by 1-D convolutional neural networks," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 3, pp. 664–675, Mar. 2016, doi: 10.1109/tbme.2015.2468589.
- [8] Z. Wang, W. Yan and T. Oates, "Time series classification from scratch with deep neural networks: A strong baseline," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 2017, pp. 1578-1585, doi: 10.1109/IJCNN.2017.7966039.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Neural Information Processing Systems*, vol. 25, pp. 1097–1105, Dec. 2012, [Online]. Available: http://books.nips.cc/papers/files/nips25/NIPS2012_0534.pdf
- [10] K. Simonyan and A. Zisserman, "Very deep convolutional networks for Large-Scale image recognition," *Computer Vision and Pattern Recognition*, Sep. 2014, [Online]. Available: <http://export.arxiv.org/pdf/1409.1556>
- [11] R. Gomez, K. Nakamura, T. Mizumoto and K. Nakadai, "Improved hands-free automatic speech recognition in reverberant environment condition," 2014 4th Joint Workshop on Hands-free Speech Communication and Microphone Arrays (HSCMA), Villers-les-Nancy, France, 2014, pp. 67-71, doi: 10.1109/HSCMA.2014.6843253. Al-Khowarizmi and H. Maulana, "The Utilization of Gaussian Filter Method on Voice Record Frequency Noise," 2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS), Manado, Indonesia, 2020, pp. 1-5, doi: 10.1109/ICORIS.2020.9443253.
- [12] C. Cowan, J. Arthur, J. Mavor and P. Denyer, "CCD based adaptive filters: Realization and analysis," in *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 29, no. 2, pp. 220-229, April 1981, doi: 10.1109/TASSP.1981.1163538. Y. Religia, A. Rusdi, I. Romli, and A. Mazid, "Feature Extraction Untuk Klasifikasi Pengenalan Wajah Menggunakan Support Vector Machine Dan K-Nearest Neighbor," *jurnal.pelitabangsa.ac.id*, Sep. 2019, doi: 10.37366/pelitakno.v14i2.233.
- [13] A. V. Oppenheim and R. W. Schaffer, *Discrete-Time signal Processing*. 1989. [Online]. Available: <http://ci.nii.ac.jp/ncid/BA06610540>.
- [14] L. Rabiner and B.-H. Juang, *Fundamentals of speech recognition*. 1993. [Online]. Available: <https://ci.nii.ac.jp/naid/10016946567/>
- [15] D. O'Shaughnessy, *Speech Communications: human and machine*. 2012. [Online]. Available: <https://cds.cern.ch/record/1480800>
- [16] J. W. Cooley, P. a. W. Lewis, and P. D. Welch, "The Fast Fourier Transform and its applications," *IEEE Transactions on Education*, vol. 12, no. 1, pp. 27–34, Jan. 1969, doi: 10.1109/te.1969.4320436.
- [17] S. S. Stevens, J. Volkman, and E. B. Newman, "A scale for the measurement of the psychological magnitude pitch," *The Journal of the Acoustical Society of America*, vol. 8, no. 3, pp. 185–190, Jan. 1937, doi: 10.1121/1.1915893.
- [18] N. Ahmed, T. Natarajan and K. R. Rao, "Discrete Cosine Transform," in *IEEE Transactions on Computers*, vol. C-23, no. 1, pp. 90-93, Jan. 1974, doi: 10.1109/T-C.1974.223784.
- [19] Z. Wang, W. Yan and T. Oates, "Time series classification from scratch with deep neural networks: A strong baseline," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 2017, pp. 1578-1585, doi: 10.1109/IJCNN.2017.7966039.
- [20] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, Jan. 2020, doi: 10.1186/s12864-019-6413-7.
- [21]