

PENERAPAN METODE DIMENSI FRAKTAL HIGUCHI DAN K-NEAREST NEIGHBOURS DALAM KLASIFIKASI EMOSI MANUSIA BERDASARKAN SUARA

Dimas Duzazagi Akbar

Program Studi Matematika, FMIPA, Universitas Negeri Surabaya, Surabaya, Indonesia

e-mail: dimas.21060@mhs.unesa.ac.id

Dwi Juniati

Program Studi Matematika, FMIPA, Universitas Negeri Surabaya, Surabaya, Indonesia

e-mail: dwijuniati@unesa.ac.id*

ABSTRAK

Pengenalan emosi melalui suara memiliki banyak manfaat, terutama dalam bidang psikologi, pendidikan, dan teknologi interaksi manusia. Penelitian ini bertujuan untuk mengklasifikasikan emosi manusia berdasarkan suara menggunakan metode Dimensi Fraktal *Higuchi* dan algoritma *K-Nearest Neighbours* (KNN). Data yang digunakan terdiri dari 120 sampel suara yang mewakili enam jenis emosi, yaitu marah, jijik, takut, bahagia, sedih, dan terkejut. Setelah melalui tahap *pre-processing*, fitur suara diekstraksi menggunakan *Discrete Wavelet Transform* (DWT), kemudian dihitung nilai dimensi fraktalnya dengan metode *Higuchi*. Nilai-nilai tersebut kemudian digunakan dalam proses klasifikasi menggunakan algoritma KNN. Berbagai pengujian dilakukan dengan variasi nilai K dan *K-max* untuk menemukan akurasi terbaik. Hasil penelitian menunjukkan bahwa metode yang digunakan mampu mengklasifikasikan emosi dengan akurasi tertinggi mencapai 91,67%. Temuan ini menunjukkan bahwa pendekatan ini cukup efektif dalam mengenali emosi manusia berdasarkan suara dan dapat menjadi dasar bagi pengembangan sistem pengenalan emosi berbasis suara di masa depan.

Kata kunci: Pengenalan emosi, suara, Dimensi Fraktal *Higuchi*, *K-Nearest Neighbours*, *Discrete Wavelet Transform*

ABSTRACT

Emotion recognition through speech plays an important role in various fields, including psychology, education, and human-computer interaction. This study aims to classify human emotions based on speech using the Higuchi Fractal Dimension method and the K-Nearest Neighbours (KNN) algorithm. The dataset consists of 120 speech samples representing six emotion categories: anger, disgust, fear, happiness, sadness, and surprise. After pre-processing, speech features were extracted using Discrete Wavelet Transform (DWT), and their fractal dimension values were calculated using the Higuchi method. These values were then used as input for classification with the KNN algorithm. Several tests were conducted with different K and K-max values to find the best accuracy. The results show that the proposed method successfully classified emotions with a highest accuracy of 91.67%. This indicates that the approach is effective in recognizing human emotions based on speech and could serve as a foundation for future speech-based emotion recognition systems.

Keywords: Emotion recognition, speech, Higuchi Fractal Dimension, K-Nearest Neighbours, Discrete Wavelet Transform

PENDAHULUAN

Manusia adalah makhluk sosial, yang berarti interaksi antara dua manusia atau lebih sangat sering terjadi, dimana dalam suatu interaksi terdapat berbagai emosi yang terlibat. Emosi merupakan perasaan kuat yang muncul sebagai respon terhadap seseorang atau suatu hal. Emosi juga bisa diartikan

sebagai reaksi yang terjadi akibat tindakan seseorang atau peristiwa tertentu (Prasetyo dkk., 2017). Jadi banyak sekali faktor dapat mempengaruhi emosi seseorang, seperti suasana hati yang buruk atau lingkungan sekitar yang terasa kurang mendukung, yang dapat memicu perubahan emosi pada manusia. Oleh karena itu emosi memiliki pengaruh besar

dalam kehidupan manusia, maka pengenalan emosi menjadi penting untuk membantu individu memahami emosi orang lain.

Pengenalan emosi merupakan sesuatu yang sangat penting, seperti dalam memahami perasaan orang lain, membangun empati, dan menciptakan hubungan sosial yang lebih harmonis. Pengenalan emosi juga berperan penting di dunia teknologi mengingat banyaknya penerapannya di berbagai bidang dengan berbagai tujuan. Dalam pendidikan, pengenalan emosi dapat diterapkan untuk mendeteksi kebosanan pada pelajar sehingga memungkinkan perubahan metode atau materi yang disajikan (H. Aouani, 2020), dan menurut Putri dkk. (2003) deteksi emosi juga bisa diterapkan pada proses interogasi dan tes kejujuran untuk memperoleh hasil yang maksimal. Pengenalan emosi memerlukan metode yang efektif dalam mendeteksi ciri emosi yang dapat diidentifikasi.

Banyak sekali cara untuk mengenali emosi, menurut H. Aouani (2020) emosi dapat dikenali melalui beberapa faktor seperti denyut nadi, tekanan darah, gelombang otak, ekspresi wajah, dan gerak tubuh. Faktor-faktor ini dapat dideteksi dengan peralatan medis, namun ekspresi wajah dan suara dapat dianalisis tanpa bantuan alat medis. Misalnya, perubahan nada suara, intensitas bicara, atau ekspresi wajah tertentu dapat menjadi petunjuk yang jelas tentang emosi yang dirasakan. Pendekatan ini menjadi penting karena memberikan cara yang lebih mudah dalam memahami dan mendeteksi emosi manusia untuk diterapkan pada kehidupan sehari-hari. Berbagai cara untuk mengenali emosi telah menjadi subjek penelitian sebelumnya, terutama dalam menganalisis suara sebagai indikator utama. Berbagai penelitian telah menemukan hubungan yang kuat antara indikator statistik dalam suara dengan emosi yang dirasakan oleh pembicara. Indikator yang paling sering digunakan mencakup atribut seperti *pitch*, intensitas suara, pola artikulasi, dan struktur spektral (Nogueiras, 2001).

Telah banyak penelitian terdahulu yang mengkaji seputar pengenalan emosi berdasarkan suara, seperti yang dilakukan oleh Putri dkk. (2003) yang memperoleh akurasi tertinggi yaitu 100%, dan penelitian yang dilakukan oleh Septria dkk. (2019) yang memperoleh akurasi tertinggi yaitu 92,5%.

Dalam bidang pengenalan emosi berdasarkan suara, penelitian menunjukkan adanya korelasi yang signifikan antara ukuran - ukuran statistik suara seperti nada, energi, artikulasi, dan bentuk spektral dengan emosi pembicara (Nogueiras, A., 2001). Dengan demikian, pengenalan emosi berdasarkan suara sangat mungkin dilakukan, dimana pada penelitian ini digunakan metode Higuchi untuk menghitung nilai dimensi fraktal dan *K-Nearest Neighbours* (KNN) untuk proses klasifikasi.

Dimensi fraktal adalah salah satu cara untuk menganalisis dan memahami karakteristik pola fraktal. Dimensi ini berfungsi sebagai alat ukur tingkat kompleksitas suatu pola dengan mengamati perubahan detailnya saat skala diperbesar atau diperkecil. Nilai dimensi fraktal dapat berupa bilangan pecahan atau tidak bulat (Juniati dkk., 2018). Dalam penelitian ini, nilai dimensi fraktal dihitung menggunakan metode Higuchi, yang dianggap sangat efisien dalam menghitung nilai kurva dan data deret waktu (Wintarti dkk., 2018). Sebelum menghitung dimensi fraktal, diperlukan metode lain untuk ekstraksi ciri suara, yaitu Discrete Wavelet Transform (DWT). DWT adalah metode yang menggambarkan perkembangan waktu dari sinyal digital menggunakan teknik filterisasi digital untuk memahami karakteristik setiap sinyal (Wulandari, 2017).

Untuk proses klasifikasi, hasil perhitungan dimensi fraktal digunakan sebagai input bagi metode KNN. KNN adalah algoritma klasifikasi yang sederhana dan efektif, yang bekerja dengan mengelompokkan data berdasarkan jarak terdekat (Safitri, 2017). KNN dikenal mudah diimplementasikan dan memiliki tingkat keefektifan tinggi (Widhyanti, 2020).

Penelitian sebelumnya telah menunjukkan keberhasilan klasifikasi sinyal suara menggunakan dimensi fraktal Higuchi dan KNN. Misalnya, Nan & Juniati (2022) berhasil mengklasifikasikan penyakit paru-paru berdasarkan suara pernapasan dengan akurasi 83%. Sofiani & Juniati (2022) mengklasifikasikan jenis emosi berdasarkan gelombang otak dengan akurasi 91,67%. Yulistina & Juniati (2024) mengklasifikasikan jenis monyet berdasarkan suara dengan akurasi 90,38%. Berdasarkan keberhasilan ini, penelitian ini diharapkan dapat mengklasifikasikan emosi berdasarkan suara ke dalam tujuh kategori menggunakan metode Higuchi dan KNN dengan akurasi yang tinggi. Dari uraian di atas, penelitian ini bertujuan untuk menguji keefektifan metode Higuchi dan KNN dalam mengklasifikasikan emosi berdasarkan suara. Hasil penelitian ini diharapkan

dapat berkontribusi pada pengembangan teknologi pengenalan emosi berbasis suara.

KAJIAN TEORI

A. Suara Manusia

Suara manusia dihasilkan oleh getaran pita suara di laring, yang terjadi saat udara dari paru-paru melewati pita suara yang terbuka. Ketegangan dan posisi pita suara menentukan frekuensi suara yang dihasilkan. Selain itu, gerakan organ artikulator seperti rahang, lidah, dan gigi sangat mempengaruhi pembentukan vokal dan konsonan yang membedakan satu suara dengan suara lainnya. Suara manusia bukan hanya alat untuk komunikasi verbal, tetapi juga membawa informasi non-verbal, seperti emosi, intonasi, dan maksud pembicara, yang memberikan konteks lebih dalam dalam percakapan (S. Helmiyah et al, 2020).

B. Emosi

Emosi adalah bagian dari pengalaman manusia yang mencakup perasaan, pemikiran, dan reaksi fisik terhadap stimulus eksternal maupun internal. Menurut B. Sarasati (2021), emosi tidak hanya berkaitan dengan jenis perasaan dan pikiran tertentu, tetapi juga mencakup kondisi biologis dan psikologis yang mempengaruhi individu. Paul Ekman (1972) membagi jenis emosi dasar menjadi enam: marah, jijik, takut, bahagia, sedih, dan kaget. Parameter suara dan hubungannya dengan pengenalan emosi merupakan salah satu topik yang paling banyak diteliti dalam bidang ini. Parameter seperti intensitas, nada (*pitch*), kecepatan berbicara, dan kualitas suara sering kali menjadi pertimbangan utama (Khalil et al., 2019). Berikut definisi emosi berdasarkan parameter – parameter suara beserta contoh frekuensi suara setiap kategori:

1. **Marah:** Emosi yang muncul akibat perasaan frustrasi atau ancaman, ditandai dengan nada tiba-tiba naik, intensitas suara sangat keras, kecepatan bicara sedikit lebih cepat, dan kualitas suara serak dengan suara dada (Khalil et al., 2019).




Gambar 2.1: Grafik frekuensi suara emosi marah

2. **Jijik:** Emosi yang timbul dari rasa ketidaknyamanan atau ketidaksukaan mendalam, biasanya ditandai dengan nada rendah menurun, intensitas suara lebih pelan, kecepatan bicara jauh lebih cepat, dengan kualitas suara bergetar dan berat (Khalil et al., 2019).



Gambar 2.2: Grafik frekuensi suara emosi jijik

3. **Takut:** Emosi yang dihasilkan dari rasa ancaman atau bahaya, dengan nada tinggi normal, intensitas lebih pelan, kecepatan bicara jauh lebih cepat, dan kualitas suara tidak stabil dengan suara gemetar (Khalil et al., 2019).



Gambar 2.3: Grafik frekuensi suara emosi takut

4. **Bahagia:** Emosi positif yang mencerminkan perasaan senang dan kepuasan, memiliki nada naik dan beragam, intensitas lebih keras, kecepatan bicara bisa lebih cepat atau lambat, dengan kualitas suara tinggi dan bernapas (Khalil et al., 2019).



Gambar 2.4: Grafik frekuensi suara emosi bahagia

5. **Sedih:** Emosi yang muncul akibat kehilangan atau kekecewaan, ditandai dengan nada lebih rendah dan monoton, intensitas lebih pelan, kecepatan bicara lebih lambat, dengan kualitas suara beresonansi dan mendalam (Khalil et al., 2019).



Gambar 2.5: Grafik frekuensi suara emosi sedih

6. **Kaget:** Emosi yang muncul secara tiba-tiba sebagai reaksi dari kejutan, dengan nada tiba-tiba naik tajam, intensitas keras, kecepatan bicara sangat cepat terputus, dan kualitas suara tiba-tiba terputus-putus (Khalil et al., 2019).



Gambar 2.6: Grafik frekuensi suara emosi kaget

C. Pre-Processing Sinyal Suara

Pre-Processing sinyal suara merupakan tahapan yang harus dilakukan agar data yang akan diolah menjadi seragam, bersih dan memiliki kualitas yang baik. Pada tahap ini dilakukan proses *filtering* untuk menghilangkan *noise* – *noise* yang tidak dibutuhkan sehingga sinyal suara yang digunakan menjadi bersih. Lalu selanjutnya dilakukan proses normalisasi yaitu agar sinyal suara menjadi seragam.

1. Filtering

Filter pada sinyal suara adalah salah satu metode seleksi frekuensi yang berfungsi untuk melewati atau menahan frekuensi tertentu. Dalam sinyal suara sering kali terdapat noise atau gangguan yang dapat mempengaruhi pengolahan sinyal suara. Oleh karena itu, diperlukan tahap *filtering* untuk mengurangi atau menghilangkan sinyal yang tidak diperlukan sehingga dapat meningkatkan kualitas data suara untuk proses pengolahan (AR & Andriani, 2019). Berikut contoh sinyal suara yang sebelum dan sesudah *filtering*:



Gambar 2.7: Grafik frekuensi suara sebelum di-*filtering*



Gambar 2.8: Grafik frekuensi suara setelah di-*filtering*

2. Normalisasi

Normalisasi merupakan proses untuk menyamaratakan amplitudo pada sinyal suara agar hasil pengolahan data tidak dipengaruhi oleh perubahan amplitudo. Menurut (Nan & Juniati, 2022) tahap normalisasi, di mana interval amplitudo data suara diubah menjadi -1 sampai 1 untuk memastikan bahwa masing-masing data memiliki interval amplitudo yang sama. Proses normalisasi dapat ditunjukkan seperti persamaan berikut (El-Ramsisi & Khalil, 2007):

$$x_{\text{normalisasi}}(t) = \frac{x(t)}{|(x(t))|}$$


Keterangan:

$x(t)$: nilai amplitudo pada sinyal asli,


$|x(t)|$: nilai amplitudo maksimum pada sinyal asli,

t : waktu, $0 \leq t \leq$ panjang durasi sinyal suara.

Sinyal suara manusia yang telah melalui proses *filtering* dan normalisasi akan dicari ciri dari masing masing data sinyal suara manusia melalui proses ekstraksi ciri. Berikut contoh sinyal suara yang telah dinormalisasi:



Gambar 2.9: Grafik frekuensi suara sebelum dinormalisasi




Gambar 2.10: Grafik frekuensi suara setelah dinormalisasi

D. Proses Ekstraksi Ciri

Proses ekstraksi ciri digunakan untuk mendapatkan informasi tentang ciri atau karakteristik pada setiap data sehingga bisa menjadi data yang relevan (Yulistina & Juniati, 2024)

1. Wavelet

Wave adalah sebuah fungsi yang secara periodik bergerak naik dan turun dalam ruang dan waktu. Namun, *Wavelet* adalah gelombang kecil yang memiliki energi terkonsentrasi dalam waktu dan memiliki ciri-ciri gelombang beresilasi. Mereka juga dapat memberikan informasi frekuensi dan waktu sekaligus, yang membuatnya ideal untuk sinyal non-stasioner (Wulandari & Juniati 2017).



Gambar 2.11: Bentuk *Wave* dan *Wavelet* (Burrus et al., 1998)

Wavelet terdiri dari banyak keluarga, yaitu Haar, Daubechies, Symlet, Coiflet, Meyer, Mexican Hat, B-spline, dan lain-lain. Wavelet daubechies, symlet, dan coiflet memiliki fungsi asimetris. Daubechies adalah yang paling umum di antara ketiga fungsi ini untuk pengenalan suara (Hidayat dkk, 2017).

2. Transformasi Wavelet

Transformasi wavelet pertama kali diperkenalkan sekitar tahun 1980 sebagai alternatif untuk Short Time Fourier Transform dalam menganalisis sinyal. Wavelet, yang dapat diartikan sebagai 'gelombang pendek', memiliki energi yang terkonsentrasi pada waktu tertentu. Teknik ini telah digunakan dalam berbagai aplikasi, seperti analisis sinyal dalam domain waktu-frekuensi, aproksimasi fungsi, penyelesaian persamaan diferensial parsial, dan lainnya (Kurniawan dkk, 2011).

Wavelet dikorelasikan dengan sinyal untuk memperoleh koefisien wavelet. Fungsi dasar wavelet dikenal sebagai *mother wavelet*, dan koefisien dihitung sepanjang seluruh interval sinyal melalui proses translasi (pergeseran) wavelet kontinu pada skala waktu. Selanjutnya, wavelet mengalami proses translasi dan dilatasi (perubahan skala) dengan berbagai lebar, yang kemudian diulang berkali-kali. Berdasarkan parameter dilatasi dan translasi, transformasi wavelet dibagi menjadi dua jenis

utama, yaitu *Continuous Wavelet Transform* (CWT) dan *Discrete Wavelet Transform* (DWT) (Wulandari & Juniati 2017).

a) *Continuous Wavelet Transform* (CWT)

Continuous Wavelet Transform (CWT) adalah proses konvolusi sinyal $f(t)$ dengan fungsi jendela (*window function*), yang dapat berubah sesuai dengan waktu dan skala tertentu. Fungsi jendela ini dikenal sebagai *mother wavelet*, yang berfungsi sebagai dasar dalam transformasi wavelet (Hakim dkk, 2012). Dalam transformasi wavelet kontinu, waktu t , serta parameter penskalaan(dilatasi) a dan pergeseran(translasi) b , mengalami perubahan secara kontinu (dengan $a \neq 0$) (Mustiadi dkk, 2015). Transformasi wavelet kontinu untuk fungsi $f(t)$ didefinisikan menggunakan rumus berikut:

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt.$$

Continuous Wavelet Transform (CWT) menghasilkan banyak koefisien wavelet yang menyebabkan data menjadi berlebihan (redundansi). Masalah redundansi data ini dapat diatasi melalui penggunaan *Discrete Wavelet Transform* (DWT) (Asfani dkk, 2014).

b) *Discrete Wavelet Transform* (DWT)

DWT merupakan teknik yang memungkinkan analisis aspek temporal dan spektral pada sinyal non-stasioner, seperti audio, dengan memanfaatkan kemampuan multi-resolusi waktu dan frekuensi yang dimiliki oleh transformasi wavelet (Kristomo & Nugroho, 2021). *Discrete Wavelet Transform* (DWT) adalah proses mengubah sinyal diskrit menjadi koefisien wavelet dengan memfilter sinyal menggunakan dua jenis filter yang saling melengkapi, yaitu *low-pass filter* dan *high-pass filter* (Gumilar, 2013).

Koefisien DWT umumnya diperoleh dari *Continuous Wavelet Transform* (CWT) dengan mengubah parameter translasi $a = 2^m$ dan skala $b = n2^m$ (Chaiwachiragompol & Suwannata, 2016). Persamaan DWT didefinisikan sebagai berikut:

$$DWT(a, b) = \frac{1}{\sqrt{|n2^m|}} \sum_{t=-\infty}^{\infty} \psi\left(\frac{t-2^m}{n2^m}\right) f(t).$$


Dengan:

ψ : mother wavelet,
 2^m : parameter translasi,
 $n2^m$: parameter dilatasi,
 $f(t)$: fungsi sinyal dengan domain waktu.

3. Dekomposisi Wavelet


Dalam dekomposisi wavelet, sinyal dipisahkan menjadi komponen aproksimasi dan komponen detail. Selanjutnya, komponen aproksimasi kembali didekomposisi menjadi komponen aproksimasi dan

detail, dan proses ini berlanjut hingga mencapai level yang diharapkan (Mustiadi dkk, 2015).




Gambar 2.12: Bentuk Wave dan Wavelet (Burrus et al., 1998)

Pada gambar dapat dilihat proses dekomposisi wavelet dengan X adalah sinyal awal yang akan didekomposisi menjadi komponen aproksimasi (cA) dan komponen detail (cD), selanjutnya dilakukan proses dekomposisi pada komponen aproksimasi. Proses ini dilakukan sampai level yang diinginkan. Untuk mendapatkan komponen aproksimasi (cA) melalui proses *low-pass filter* dan komponen detail (cD) melalui proses *high-pass filter* seperti pada gambar.



Gambar 2.13: Bentuk Wave dan Wavelet (Burrus et al., 1998)

Berikut contoh dekomposisi 5 level:



Setelah melalui proses ekstraksi ciri, sinyal suara manusia akan dihitung nilai dimensi fraktalnya menggunakan metode Higuchi. Berikut penjelasan mengenai geometri fraktal karena ada keterkaitan antara sinyal suara dengan geometri fraktal.

E. Geometri Fraktal

Istilah *fraktal* berasal dari bahasa Latin *fractus*, yang berarti pecahan atau bentuk yang tidak beraturan. Konsep ini pertama kali diperkenalkan oleh Benoit B. Mandelbrot pada tahun 1977 melalui bukunya yang berjudul *The Fractal Geometry of Nature*. Fraktal memiliki kemampuan untuk merepresentasikan dimensi pecahan (*fractional dimension*) dari suatu objek, berbeda dengan geometri Euclid yang hanya dapat menggambarkan dimensi dalam bilangan bulat. Misalnya, garis memiliki dimensi satu, bidang memiliki dimensi dua, dan balok memiliki dimensi tiga (Mulyadi dkk., 2013). Dimensi fraktal memiliki sifat *self-similarity*, yang mengacu pada karakteristik di mana setiap bagian kecil dari fraktal menyerupai keseluruhan struktur dalam skala yang berbeda. Dengan kata lain, bagian-bagian dari objek fraktal akan tampak mirip dengan bentuk aslinya jika diamati secara keseluruhan (Jaidan, 2009).

F. Dimensi Fraktal Higuchi

metode higuchi adalah metode yang memiliki efisiensi tinggi dalam menentukan nilai dimensi fraktal suatu kurva dan sangat sesuai untuk analisis data deret waktu (Wintarti, 2018). Misal diberikan sebuah deret $X(1), X(2), \dots, X(N)$. Berikut langkah – langkah dalam menghitung nilai dimensi fraktal dengan metode *higuchi* (Juniati dkk., 2018).

1. Bentuk k deret waktu yang baru X_n^k sebagai berikut:

$$X_n^k = \left\{ X[n], X[n+k], \dots, X \left[n + \text{int} \left(\frac{N-n}{k} \right) \cdot k \right] \right\}.$$

dengan m dan $k \in \mathbb{Z}$, dimana k menunjukkan interval waktu diskrit dan $n = 1, 2, 3, \dots, k$ yang menunjukkan nilai waktu awal

2. Menentukan panjang setiap deret waktu baru dapat didefinisikan sebagai berikut :

$$L(n, k) = \frac{\left(\sum_{i=1}^{\text{int} \left(\frac{N-n}{k} \right)} |x[n+ik] - x[n+(i-1) \cdot k]| \right) \frac{N-1}{\text{int} \left(\frac{N-n}{k} \right)}}{k}.$$

Dengan N adalah panjang dari deret waktu asli, $\text{int} \left(\frac{N-n}{k} \right) \cdot k$ menunjukkan faktor normalisasi dan $|x[n+ik] - x[n+(i-1) \cdot k]| = h_i$. Dengan demikian $L(n, k)$ adalah merupakan jumlah panjang segmen baru h_i . Setiap h_i menunjukkan nilai jarak yang berbeda pada koordinat pasangan titik sejauh n , dimulai pada sampel n , $X(N)$ dengan $n = 1, 2, 3, \dots, k$

3. Panjang kurva untuk interval waktu k diperoleh dengan membagi semua sub-deret $L(n, k)$ dengan k . untuk $n = 1, 2, 3, \dots, k$ diperoleh persamaan berikut:

$$L(k) = \frac{\sum_{n=1}^k L(n, k)}{k}$$

4. Dengan demikian, dimensi fraktal higuchi dapat didefinisikan sebagai kemiringan garis

sesuai dengan $\left\{ \ln(L(k)), \ln \left(\frac{1}{k} \right) \right\}$ yang mana diestimasi dengan kuadrat linear yang paling sesuai, sehingga diperoleh hasil dimensi fraktal dengan persamaan sebagai berikut:

$$\begin{aligned} L(k) &= k^{-D}, \\ L(k) &= \frac{1}{k^D}, \\ D &= \frac{\ln(L(k))}{\ln \left(\frac{1}{k} \right)}. \end{aligned}$$

Selanjutnya hitung $\ln(L(k))$ dan $\ln \left(\frac{1}{k} \right)$ untuk setiap nilai k .

Kemiringan garis yang sesuai dengan $\left\{ \ln(L(k)), \ln \left(\frac{1}{k} \right) \right\}$ dapat dihitung dengan persamaan sebagai berikut:

$$\alpha = \frac{(\sum_{n=1}^k xy) - \frac{(\sum_{n=1}^k x)(\sum_{n=1}^k y)}{n}}{(\sum_{n=1}^k x^2) - \frac{(\sum_{n=1}^k x)^2}{n}}.$$

Dengan $x = \ln \left(\frac{1}{k} \right)$, $y = \ln(L(k))$, n adalah banyaknya iterasi yang digunakan, dan α adalah kemiringan.

G. K-Nearest Neighbour

Klasifikasi adalah proses pengelompokan yang bertujuan untuk mengumpulkan data dengan kesamaan tertentu dan memisahkan data yang memiliki perbedaan (Nan & Juniati, 2022). Algoritma KNN adalah metode klasifikasi yang mengelompokkan objek ke dalam salah satu dari k kategori berdasarkan kedekatan jarak dalam data pelatihan (Juniati dkk., 2018). Nilai k biasanya dipilih sebagai bilangan ganjil untuk mencegah terjadinya jumlah suara yang sama antar kelas dalam proses klasifikasi (Wulandari & Juniati, 2017). Jarak terdekat dihitung menggunakan *Euclidean distance*. *Euclidean distance* merupakan jarak yang paling umum digunakan untuk data numerik. Jarak ini didefinisikan sebagai berikut (Wintarti, 2018):

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}.$$

Dengan :

$d(x, y)$: jarak antara pada data latih dan pada data uji

x : data latih

y : data uji

n : jumlah atribut 1 sampai n

Langkah – langkah dalam menghitung algoritma KNN adalah sebagai berikut :

1. Menentukan parameter k .
2. Menghitung jarak antara data uji dan data latih.
3. Mengurutkan jarak yang terbentuk dan menentukan tetangga terdekat berdasarkan jarak minimum ke k .

4. Mengumpulkan kelas yang bersesuaian.
5. Mencari jumlah kelas dari tetangga yang terdekat dan menetapkan kelas tersebut sebagai kelas data yang akan dievaluasi.

H. Akurasi

Akurasi menggambarkan tingkat ketepatan suatu sistem dalam melakukan klasifikasi data (Damayanti & Juniati, 2023). Confusion matrix adalah salah satu metode yang digunakan untuk mengevaluasi kinerja suatu model klasifikasi. Secara umum, confusion matrix menyediakan informasi yang membandingkan hasil klasifikasi dari sistem dengan hasil klasifikasi yang seharusnya. Dalam evaluasi kinerja menggunakan confusion matrix, terdapat empat istilah yang digunakan untuk merepresentasikan hasil klasifikasi. Keempat istilah tersebut meliputi True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). True Negative (TN) mengacu pada jumlah data negatif yang berhasil teridentifikasi dengan tepat, sedangkan False Positive (FP) merujuk pada data negatif yang salah diklasifikasikan sebagai data positif (Karsito & Susanti, 2019).

		Actual class	
		True (1)	False (0)
Predicted class	True (1)	TP	FP
	False (0)	FN	TN

Tabel 2.1 Confusion matrix

Confusion matrix dapat membantu dalam mencari nilai matrik evaluasi dari accuracy, precision, dan recall untuk melihat seberapa bagus model klasifikasi, berikut rumus untuk menghitung accuracy, precision, dan recall (Subarkah dkk., 2021):

$$akurasi = \left(\frac{TP+TN}{TP+TN+FP+FN} \right) \times 100.$$

$$precision = \left(\frac{TP}{TP+FP} \right) \times 100.$$

$$recall = \left(\frac{TP}{TP+FN} \right) \times 100.$$

METODE

Data yang digunakan pada skripsi ini merupakan data sekunder. Data yang digunakan sebanyak 120 sampel yang terdiri dari 6 kondisi emosi berdasarkan suara yaitu marah, jijik, takut, bahagia, sedih, dan kaget yang diperoleh dari website

<https://www.kaggle.com/datasets/dmitrybabko/speech-emotion-recognition-en/data>. Setiap kondisi

emosi masing - masing memiliki 20 data suara dengan format wav. yang durasi setiap audio 2 detik.

A. Data Set

Data yang digunakan dalam penelitian ini ada sebanyak 120 data yang diperoleh dari website kaggle.com dengan format wav. yang kemudian data tersebut diproses dengan bantuan *software* MatlabR2024b.

B. Pre-Processing

Sinyal Suara pada tahap ini akan dilakukan proses *filtering* dan normalisasi. Proses *filtering* bertujuan untuk menghilangkan *noise - noise* yang tidak dibutuhkan sehingga dapat mengganggu kualitas suara. Kemudian proses normalisasi bertujuan untuk mengubah interval amplitudo menjadi -1 sampai 1 agar perubahan amplitudo yang acak tidak mempengaruhi pada proses ekstraksi ciri dan terbukti efektif untuk mencapai tujuan normalisasi dalam penelitian - penelitian sebelumnya. Untuk proses *filtering* dibantu dengan *software* Audacity dan proses normalisasi dibantu dengan MatlabR2024b.

C. Ekstraksi Ciri

Pada proses ekstraksi ciri pada penelitian ini menggunakan metode *Discrete Wavelet Transform* (DWT). Langkah penting dalam proses DWT adalah pemilihan jenis mother wavelet. Tingkat akurasi klasifikasi sangat bergantung pada jenis mother wavelet yang dipilih (Widhyanti & Juniati, 2021). Karena sifat dari sinyal suara emosi manusia yang asimetrik dan nonstasioner maka menurut (Karmila dkk., 2016) Wavelet Db4 dianggap lebih cocok untuk proses ekstraksi karena kemampuannya yang lebih handal dalam menangani sinyal asimetrik dan ortogonal. Selanjutnya dilakukan pemilihan level dalam proses dekomposisi *wavelet*. Pada penelitian ini dilakukan dekomposisi level 5, karena level dekomposisi yang terlalu rendah menghasilkan jumlah vektor ciri yang sedikit, sehingga sulit membedakan antara suara yang berbeda. Sebaliknya, jika level dekomposisi terlalu tinggi, jumlah vektor ciri yang dihasilkan menjadi berlebihan, yang dapat menyebabkan kesalahan dalam klasifikasi. Dari penelitian yang dilakukan oleh (Putri dkk., 2023) dalam mengklasifikasikan emosi dengan mencoba dekomposisi level 4 - 6, memperoleh akurasi terbaik pada dekomposisi level 5. Proses ekstraksi ciri akan dilakukan dengan bantuan *software* MatlabR2024b.

D. Menghitung nilai dimensi fraktal

Dalam proses ini, setelah melakukan proses ekstraksi ciri selanjutnya menghitung nilai dimensi fraktal menggunakan metode *higuchi*. Dalam proses menghitung nilai fraktal menggunakan metode *higuchi* harus menentukan nilai k-max, pada penelitian ini dipilih nilai k-max 50 dan 60 karena didasarkan oleh penelitian sebelumnya oleh (Yulistina & Juniati, 2024) dan memperoleh hasil yang cukup baik.

E. Klasifikasi

Pada proses klasifikasi akan menggunakan metode *K-Nearest Neighbour* dengan data yang akan dibagi menjadi data uji dan data latih. Dalam penelitian ini dipilih nilai K yang ganjil dari 1 - 9 karena menurut (Khairi dkk., 2021) pada proses klasifikasi harus dipilih nilai K yang ganjil pada KNN.

F. Akurasi

Setelah didapatkan hasil dari klasifikasi, kemudian akan dilakukan pengecekan akurasi untuk mengetahui tingkat keefektifan dari metode. Berdasarkan penelitian terdahulu yang menggunakan metode dimensi fraktal *higuchi* dan *K-Nearest Neighbour* dengan akurasi diatas 80%. Maka diharapkan pada penelitian dengan metode yang sama akan memperoleh akurasi diatas 80%. Berikut persamaan yang digunakan untuk menghitung akurasi:

$$akurasi = \left(\frac{TP+TN}{TP+TN+FP+FN} \right) \times 100.$$

HASIL DAN PEMBAHASAN

A. Pre-Processing Sinyal Suara

Pada Proses ini terdapat 2 tahapan yang harus dilakukan, yaitu proses *filtering* dan proses normalisasi. Dibawah ini akan dijelaskan dari kedua proses tersebut.


1. Filtering

Pada proses ini bertujuan untuk menghilangkan atau mengurangi noise - noise pada sinyal suara sehingga dapat memperoleh suara yang jernih. Proses *filtering* dibantu menggunakan *software* Audacity.

2. Normalisasi

Pada proses ini bertujuan untuk menyamakan interval amplitudo setiap data yaitu menjadi -1 sampai dengan 1. Setiap data memiliki amplitudo


yang sangat bervariasi, oleh karena itu normalisasi berguna agar perubahan amplitudo tidak mempengaruhi proses ekstraksi ciri. Berikut contoh hasil normalisasi sinyal suara dengan bantuan *software* MatlabR2024b:




Gambar 4.1 Contoh sinyal suara yang telah melewati proses normalisasi

B. Proses Ekstraksi Ciri


Proses selanjutnya adalah proses ekstraksi ciri. Pada proses ini menggunakan *Discrete Wavelet Transform* (DWT) yang akan di-dekomposisi sebanyak 5 level dengan menggunakan Daubachies 4 sebagai *mother wavelet*. Pada setiap level dekomposisi sinyal suara akan melewati dua *filter* yang dimiliki oleh Daubachies, yaitu *lowpass filter* dan *highpass filter*. Pada *lowpass filter* menghasilkan komponen suara berfrekuensi rendah yang disebut koefisien aproksimasi, lalu pada *highpass filter* akan menghasilkan komponen suara berfrekuensi tinggi yang disebut koefisien detail. Pada penelitian ini menggunakan koefisien aproksimasi pada setiap level dekomposisi yaitu $A_1 - A_5$. Berikut contoh hasil ekstraksi ciri sinyal suara dengan bantuan *software* MatlabR2024b:




Gambar 4.2 Hasil dekomposisi emosi marah




Gambar 4.3 Hasil dekomposisi emosi jijik




Gambar 4.4 Hasil dekomposisi emosi takut



Gambar 4.5 Hasil dekomposisi emosi bahagia



Gambar 4.6 Hasil dekomposisi emosi sedih



Gambar 4.7 Hasil dekomposisi emosi terkejut

C. Metode Higuchi

Pada proses ini menghitung nilai dimensi fraktal dari hasil dekomposisi level 1 sampai 5 menggunakan dimensi fraktal *Higuchi* dengan memilih nilai K_{max} 50 dan 60. Pemilihan nilai K_{max} tersebut untuk mencari nilai hasil akurasi terbaik. Berikut contoh hasil perhitungan dimensi fraktal pada sinyal suara menggunakan metode *higuchi* dengan bantuan *software* MatlabR2024b:

Tabel 4.1 Perhitungan Dimensi Fraktal Higuchi dengan K_{max} 50

Level 1	Level 2	Level 3	Level 4	Level 5	Kelas
1.9293	1.9798	2.0009	1.9939	1.9821	A
1.8632	1.9587	1.9931	1.9981	1.9910	B
1.9271	1.9767	2.0016	1.9938	1.9724	C
1.9347	1.9939	2.0076	1.9975	1.9776	D
1.6740	1.8809	1.9794	1.9912	1.9916	E
1.9222	1.9878	2.0059	1.9886	1.9517	F


Tabel 4.2 Perhitungan Dimensi Fraktal Higuchi dengan K_{max} 60

Level 1	Level 2	Level 3	Level 4	Level 5	Kelas
1.9635	1.9876	1.9994	1.9872	1.9748	A
1.9066	1.9669	1.9923	1.9916	1.9840	B
1.9305	1.9850	1.9967	1.9853	1.9655	C
1.9554	1.9941	2.0035	1.9888	1.9689	D
1.7793	1.8966	1.9814	1.9996	1.9875	E
1.9489	1.9918	2.0012	1.9804	1.9409	F

D. Proses Klasifikasi

Setelah memperoleh nilai dimensi fraktal, selanjutnya akan dilakukan proses klasifikasi. Sebelumnya data dibagi menjadi dua yaitu data uji dan data latih dengan perbandingannya 4:6, 3:7, 2:8, dan 1:9, lalu pengklasifikasian dilakukan pada masing masing data dimensi fraktal dengan nilai K_{max} yang berbeda, yaitu $K_{max} = 50$ dan $K_{max} = 60$. Proses pengklasifikasian menggunakan algoritma KNN dengan bantuan *software* Rapidminer Studio sebagai berikut.

Gambar 4.8 Proses klasifikasi menggunakan *software* Rapidminer Studio



E. Hasil Penelitian

Dari hasil klasifikasi menggunakan KNN akan memperoleh confusion matrix untuk mengetahui akurasi model. Berikut adalah *confusion matrix* ketika memperoleh akurasi tertinggi:

Tabel 4.3 *Confusion matrix* pada akurasi tertinggi

	A	B	C	D	E	F
A	2	0	0	0	0	0
B	0	2	0	0	0	0
C	0	0	2	0	0	1
D	0	0	0	2	0	0
E	0	0	0	0	2	0
F	0	0	0	0	0	1

Dari confusion matrix diatas dapat dicari *precision* dan *recall* setiap kategori menggunakan rumus berikut

$$precision = \left(\frac{TP}{TP+FP} \right) \times 100.$$

$$recall = \left(\frac{TP}{TP+FN} \right) \times 100.$$

Tabel 4.4 Precision dan recall pada akurasi tertinggi

Precision	Recall	Kelas/Kategori
100%	100%	Marah (A)
100%	100%	Jijik (B)
66,67%	100%	Takut (C)
100%	100%	Bahagia (D)
100%	100%	Sedih (E)
100%	50%	Terkejut (F)

Berdasarkan analisis *precision* dan *recall*, performa model menunjukkan hasil yang bervariasi untuk setiap kategori. Pada kategori "Marah", *precision* dan *recall* mencapai 100%, yang berarti semua data yang diprediksi sebagai "Marah" benar-benar termasuk kategori tersebut, dan tidak ada data asli dari kategori ini yang terlewatkan atau salah diklasifikasikan. Hal yang sama berlaku untuk kategori "Jijik", di mana *precision* dan *recall* juga 100%, menunjukkan akurasi sempurna baik dalam prediksi maupun pengenalan data asli kategori tersebut. Kategori "Bahagia" dan "Sedih" juga memiliki *precision* dan *recall* 100%, menunjukkan bahwa semua prediksi untuk kategori ini benar, dan semua data asli berhasil dikenali tanpa ada yang terlewat atau salah diklasifikasikan. Namun, pada kategori "Takut", *precision* hanya mencapai 66,67%, yang berarti terdapat data dari kategori lain yang salah diklasifikasikan sebagai "Takut", meskipun *recall* tetap 100%, menunjukkan bahwa semua data asli dari kategori ini berhasil dikenali. Sebaliknya, pada kategori "Terkejut", *precision* mencapai 100%, yang berarti semua prediksi kategori ini benar-benar akurat tanpa kesalahan, tetapi *recall* hanya 50%, menunjukkan bahwa separuh data asli dari kategori ini tidak berhasil dikenali oleh model dan salah diklasifikasikan ke kategori lain.

Berikut adalah hasil klasifikasi emosi manusia berdasarkan suara menggunakan dimensi fraktal *higuchi* memperoleh akurasi tertinggi sebesar 91,67%. Akurasi tertinggi diperoleh ketika nilai $K_{max} = 50$ pada proses dimensi fraktal *higuchi*, lalu nilai $k = 9$ pada proses KNN dengan pembagian datanya yaitu 90% data latih dan 10% data uji. Berikut adalah *confusion matrix* yang diperoleh ketika mencapai akurasi tertinggi.

Tabel 4.5 Hasil akurasi KNN

K- max	Pembagian data		K				
	Latih	Uji	1	3	5	7	9
50	0.6	0.4	64,5 8%	68,7 5%	72,9 2%	70,8 3%	72,9 2%
	0.7	0.3	72,2 2%	75,0 0%	69,4 4%	72,2 2%	77,7 8%
	0.8	0.2	70,8 3%	75,0 0%	66,6 7%	70,8 3%	75,0 0%
	0.9	0.1	91,6 7%	91,6 7%	83,3 3%	91,6 7%	91,6 7%
60	0.6	0.4	70,8 3%	70,8 3%	72,9 2%	77,0 8%	70,8 3%
	0.7	0.3	77,7 8%	75,0 0%	80,5 6%	83,3 3%	77,7 8%
	0.8	0.2	70,8 3%	66,6 7%	70,8 3%	75,0 0%	79,1 7%
	0.9	0.1	83,3 3%	75,0 0%	75,0 0%	83,3 3%	83,3 3%

PENUTUP

SIMPULAN

Berdasarkan hasil dari penelitian yang telah dilakukan yaitu mengenai penerapan metode dimensi fraktal *higuchi* dan *K-Nearest Neighbours* dalam klasifikasi emosi manusia berdasarkan suara, dapat disimpulkan bahwa:

1. Penelitian ini diawali dengan proses *pre-processing*, pada proses ini terdapat dua tahap, yaitu *filtering* dan normalisasi. Pada tahap *filtering* bertujuan untuk mengurangi atau menghilangkan *noise* – *noise* pada sinyal suara, lalu pada tahap normalisasi berfungsi untuk menyamakan batas amplitudo setiap sinyal suara yaitu [-1,1] agar tidak mempengaruhi pada proses ekstraksi ciri. Selanjutnya dilakukan proses ekstraksi ciri untuk mendapatkan karakteristik atau informasi sinyal suara menggunakan *Discrete Wavelet Transform* (DWT) dengan dekomposisi 5 level. Selanjutnya akan dihitung dimensi fraktalnya menggunakan metode dimensi fraktal *higuchi* untuk setiap level dekomposisi. Setelah menghitung dimensi fraktalnya, selanjutnya nilai dimensi fraktal tersebut diklasifikasikan menggunakan metode *K-Nearest Neighbours* (KNN). Pada tahap terakhir dilakukan perhitungan akurasi untuk mengevaluasi model.
2. Hasil klasifikasi memperoleh akurasi tertinggi yaitu sebesar 91,67%. Akurasi terbaik diperoleh

ketika dipilih nilai $K_{max} = 50$ pada metode dimensi fraktal *higuchi*, dan ketika dipilih nilai $k = 1, 3$, dan 9 pada metode KNN dengan pembagian data uji dan data latihnya adalah 1:9. Jika dibandingkan dengan penelitian sebelumnya yang menggunakan metode dimensi fraktal *higuchi* dan *K-Nearest Neighbours* (KNN), akurasi yang diperoleh pada penelitian ini cukup tinggi. Sehingga dapat disimpulkan metode yang digunakan dalam mengklasifikasikan dimensi fraktal dari suara emosi memiliki efektivitas yang cukup tinggi dan sesuai dengan data yang digunakkan.

DAFTAR PUSTAKA

- Aouani, H., & Ayed, Y. B. (2020). Speech emotion recognition with deep learning. *Procedia Computer Science*, 176, 251-260.
- Putri, T. B., Saidah, S., Hidayat, B., Qothrunnada, F., & Darwindra, D. (2023). Deteksi Emosi Berdasarkan Sinyal Suara Manusia Menggunakan Discrete Wavelet Transform (DWT) Dengan Klasifikasi Support Vector Machine (SVM). *Jurnal Ilmu Komputer dan Informatika*, 3(1), 1-10.
- Nogueiras, A., Marino, J. B., Moreno, A., Bonafonte, A. Speech Emotion Recognition using Hidden Markov Model, In: Proc. European Conf. Speech Communication and Technology (Euro Speech 01). Denmark, 2001
- Wintarti, e. (2018). Classification of Gamelan Tones Based on Fractal Analysis. IOP Conf Series: Mater Sci Eng.
- Juniati, D., Khotimah, C., Wardani, D., & Budayasa, K. (2018). Fractal dimension to classify the heart sound recordings with KNN and fuzzy c-mean clustering methods. *Journal of Physics: Conf Series* 953 012202.
- Wulandari, I. N., & Juniati, D. (2017). Penerapan Dimensi Fraktal Untuk Klasifikasi Laras Pada Musik Gamelan. *Jurnal Ilmiah Matematika*, 3(6).
- El-Ramsisi, A. M., & Khalil, H. A. (2007). Diagnosis system based on wavelet transform, fractal dimension and neural network. *Journal of Applied Sciences*, 7(24), 3971-3976.
- Safitri, D. W., & Juniati, D. (2017, August). Classification of diabetic retinopathy using fractal dimension analysis of eye fundus image. In *AIP conference proceedings* (Vol. 1867, No. 1). AIP Publishing.
- Nan, A. N., & Juniati, D. (2022). Klasifikasi Jenis Jangkrik Berdasarkan Suara Menggunakan Dimensi Fraktal Metode Higuchi Dan K-Nearest Neighbor (Knn). *MATHunesa: Jurnal Ilmiah Matematika*, 10(1), 199-207.
- Sofiani, R. N., & Juniati, D. (2022). Klasifikasi Jenis Emosi Berdasarkan Gelombang Otak Menggunakan Dimensi Higuchi Dengan K-Nearest Neighbor. *MATHunesa: Jurnal Ilmiah Matematika*, 10(1), 150-160.
- Yulistina, F., & Juniati, D. (2024). PENERAPAN DIMENSI FRAKTAL HIGUCHI DALAM KLASIFIKASI JENIS MONYET BERDASARKAN SUARA DENGAN METODE K-NEAREST NEIGHBOR (K-NN). *MATHunesa: Jurnal Ilmiah Matematika*, 12(1), 110-120.
- Helmiyah, S., Riadi, I., Umar, R., Hanif, A., Yudhana, A., & Fadlil, A. (2020). Identifikasi Emosi Manusia Berdasarkan Ucapan Menggunakan Metode Ekstraksi Ciri LPC dan Metode Euclidean Distance. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 7(6), 1177-1186.
- Sarasati, B., & Nurvia, O. (2021). Emosi Dalam Tulisan. *Psibernetika*, 14(1).
- Burrus, C., Gopinath, R., & Guo, H. (1988). Introduction to Wavelets and Wavelet Transfrom-A Primer. *Recherche*, 67.
- Hidayat, S., Negara, H. R. P., & Kumoro, D. T. (2017). Penentuan Fungsi Basis Wavelet Terbaik Untuk Sinyal Suara. *Sntt Fgdt*, 3, 247-252.
- Kurniawan, A., Sudjadi, S., & Sumardi, S. (2011). *Reduksi Noise Pada Sinyal Suara dengan Menggunakan Transformasi Wavelet* (Doctoral dissertation, Jurusan Teknik Elektro Fakultas Teknik Undip).
- Hakim, L., Arifin, A., & Sardjono, T. A. (2012). Identifikasi Suara Serak Berbasis Transformasi Wavelet Dan Algoritma Jaringan Syaraf Tiruan. In *Seminar on Intelligent Technology and Its Applications*.
- Mustiadi, I., Widodo, T. S., & Soesanti, I. (2015, July). Analisis Ekstraksi Ciri Sinyal EMG Menggunakan Wavelet Discrete Transform. In *Seminar Nasional Informatika (SEMNASIF)* (Vol. 1, No. 3).
- Asfani, D. A., Negara, I. M. Y., & Rajavalens, M. (2014). Sensitive Detection for High Impedance Fault on Transmission Line using Wavelet and Naive Bayes. *JAVA Journal of Electrical and Electronics Engineering*, 12(2).
- Gumilar, G. (2013). Implementasi Transformasi Wavelet Daubechies pada Kompresi Citra Digital. *CAUCHY: Jurnal Matematika Murni dan Aplikasi*, 2(4), 211-215.
- Chaiwachiragompol, A., & Suwannata, N. (2016). The features extraction of infants cries by using discrete wavelet transform

- techniques. *Procedia Computer Science*, 86, 285-288.
- Kristomo, D., & Nugroho, F. H. (2021, December). Classification of Speech Signal based on Feature Fusion in Time and Frequency Domain. In *2021 4th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)* (pp. 560-564).
- Mulyadi, M. I., Isnanto, R. R., & Hidayatno, A. (2013). Sistem Identifikasi Telapak Tangan Menggunakan Ekstraksi Ciri Berbasis Dimensi Fraktal. *Transient: Jurnal Ilmiah Teknik Elektro*, 2(3), 751-756.
- Jaidan, J. (2009). Perangkat Lunak Pembangkit Geometri Fraktal Berbasis Fungsi Transenden. *MIPA dan Pembelajarannya*, 37(1), 220392.
- Mardiana, L. (2023). PENERAPAN DIMENSI FRAKTAL HIGUCHI DAN K-NEAREST NEIGHBOUR DAKAM KLASIFIKASI KONDISI KUCING BERDASARKAN SUARA [Skripsi]. Universitas Negeri Surabaya
- Widhyanti, D., & Juniati, D. (2021, February). Classification of baby cry sound using higuchi's fractal dimension with K-nearest neighbor and support vector machine. In *Journal of Physics: Conference Series* (Vol. 1747, No. 1, p. 012014). IOP Publishing.
- Karmila, R., Djamal, E. C., & Nursantika, D. (2016, August). Identifikasi Tingkat Konsentrasi Dari Sinyal EEG Dengan Wavelet dan Adaptive Backpropagation. In *Seminar Nasional Aplikasi Teknologi Informasi (SNATi)*.
- Chen, D., Wan, S., Xiang, J., & Bao, F. S. (2017). A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. *PloS one*, 12(3), e0173138.
- Khairi, A., Ghazali, A. F., & Hidayah, A. D. N. (2021). Implementasi K-Nearest Neighbor (KNN) untuk Klasifikasi Masyarakat Pra Sejahtera Desa Sapikerep Kecamatan Sukapura. *TRILOGI: Jurnal Ilmu Teknologi, Kesehatan, dan Humaniora*, 2(3), 319-323.
- Damayanti, M., & Juniati, D. (2023). Klasifikasi Jenis Anjing Laut Berdasarkan Suara Dengan Metode Higuchi Dan K-nearest Neighbor. *MATHunesa: Jurnal Ilmiah Matematika*, 11(2), 102-112.
- Karsito, K., & Susanti, S. (2019). Klasifikasi Kelayakan Peserta Pengajuan Kredit Rumah Dengan Algoritma Naïve Bayes Di Perumahan Azzura Residencia. *Jurnal SIGMA*, 9(3), 43-48.
- Azizah, N., Firdaus, M. R., Suyaningsih, R., & Indrayatna, F. (2023, August). Penerapan Algoritma Klasifikasi K-Nearest Neighbor pada Penyakit Diabetes. In *Prosiding Seminar Nasional Statistika Aktuaria* (Vol. 2, pp. 119-126).
- Subarkah, P., Abdallah, M. M., & Hidayah, S. O. N. (2021). Komparasi Akurasi Algoritme CART Dan Neural Network Untuk Diagnosis Penyakit Diabetes Retinopathy. *CogITo Smart Journal*, 7(1), 121-134.
- Khalil, R. A., Jones, E., Babar, M. I., Jan, T., Zafar, M. H., & Alhussain, T. (2019). Speech emotion recognition using deep learning techniques: A review. *IEEE access*, 7, 117327-117345.
- Hadiyono, J. E. (2000). Emosi dan ekspresinya dalam masyarakat. A. Supratiknya, Faturochman, & S. Haryanto, *Tantangan Psikologi Menghadapi Milenium Baru*, 33-55.
- Zaini, A. H., Hidayat, B., & Hartanto, R. (2019). Deteksi Infeksi Pada Rongga Mulut Berbasis Pemrosesan Sinyal Wicara Dengan Metoda Wavelet Packet Dan Klasifikasi Som: Infection Detection On Oral Cavity Based On Speech Processing With Wavelet Packet Method And Som Classification. *eProceedings of Engineering*, 6(1).