

penggunaan *back beat* yang pada bagian ritme dengan gitar bass dan drum, serta organ, piano atau *synthesizer*. Pada akhir tahun 60-an dan awal 70-an, musik rock berkembang menjadi beberapa jenis, yang bercampur dengan musik *folk* (musik daerah di amerika) menjadi *folk rock*, dengan blues menjadi blues-rock dan dengan jazz, menjadi jazz-rock *fusion*. Ciri khas dari genre ini adalah ritme yang tidak konvensional (bukan 4/4 atau sinkopasi), penguasaan alat musik yang mahir dengan permainan solo yang rumit dan lagu-lagu yang berdurasi panjang (Sulastianto, 2007 dikutip oleh Novianti, 2013).

2.1.4 Musik Jazz

Jazz adalah aliran musik yang berasal dari Amerika Serikat pada awal abad ke-20 dengan akar-akar dari musik Afrika dan Eropa. Elemen penting dalam jazz adalah *blue notes*, improvisasi, polyrhythms, sinkopasi dan shuffle note.

2.2 Format Audio

File suara (audio) memiliki beberapa format digital, seperti *Moving Picture Expert Group audio layer III* (MP3) serta beberapa format audio lainnya.


2.2.1 *Moving Picture Expert Audio Group Layer III* (MP3)

Moving Picture Expert Group audio layer III atau yang lebih dikenal dengan MP3, adalah salah satu dari pengkodean dalam digital audio dan juga merupakan format kompresi audio yang memiliki sifat menghilangkan. Istilah menghilangkan yang dimaksud adalah kompresi audio ke dalam format*mp3 menghilangkan aspek-aspek yang tidak signifikan pada pendengaran manusia untuk mengurangi besarnya *file* audio (Ardhyana & Juarna, 2008).

2.3 Ekstraksi Fitur

Dalam penelitian ini metode ekstraksi fitur yang digunakan adalah *Short Time Energy* (STE) dan *Zero Crossing Rate* (ZC) yang diturunkan dalam domain waktu yang merupakan salah satu komponen data audio. Domain waktu adalah pemaparan teknik sinyal audio dasar dimana sinyal digambarkan sebagai amplitudo dengan satuan waktu. Nilai dapat bernilai positif atau negatif tergantung pada tekanan suara (Setiawan & Handayani, 2012). Pada domain

waktu, sumbu horizontal menyatakan waktu (t) sedangkan sumbu vertikalnya menyatakan amplitudo (A). Adapun gambaran sinyal audio dengan domain waktu dapat dilihat pada gambar 2.1 berikut:



Gambar 2.1 sinyal audio domain waktu (Setiawan & Handayani, 2012)

Pada ekstraksi fitur *Short Time Energy* (STE) menandakan kekerasan suara pada waktu yang pendek. STE dapat dihitung dengan menggunakan persamaan 2.1 sebagai berikut:

$$STE = \frac{1}{N} \sum_{t=1}^N X(n)^2 \dots\dots\dots(2.1)$$

N : Jumlah Sampel

X(n) : Nilai Sinyal dari sampel

Sampel adalah banyaknya amplitudo pada suatu waktu

Nilai sinyal pada sampel didapatkan dari besarnya suara (amplitudo) pada suatu sampel.

Misalkan pada 1 *frame* terdapat 5 sampel dengan nilai amplitudo sebesar 0.2, -0.4, 0.03, 0.75 dan -0.1. Maka nilai STE pada 1 *frame* audio tersebut dapat dihitung sebagai berikut:

$$STE = \frac{1}{5} (0.2^2) + (-0.4^2) + (0.03^2) + (0.75^2) + (-0.1^2)$$

$$STE = \frac{1}{5} (0.7734)$$

$$STE = 0.15468$$

Untuk mendapatkan nilai STE pada suatu data audio, dapat dilakukan dengan menghitung rata-rata nilai STE yang didapatkan pada setiap detik audio.

Sedangkan ekstraksi fitur *Zero Crossing Rate (ZC)* adalah Sampel berurutan pada sebuah sinyal digital memiliki perbedaan tanda, ukuran dari noise sebuah sinyal pada fitur domain waktu:

$$ZC = \frac{\sum_{n=1}^N |sgn x(n) - sgn x(n-1)|}{2N} \dots\dots\dots(2.2)$$

$x(n)$: nilai dari $x(n)$, bernilai 1 jika $x(n)$ positif, -1 jika $x(n)$ negatif

N : Jumlah Sampel

2.4 Klasifikasi

Klasifikasi adalah salah satu tugas dari data *mining* yang bertujuan untuk memprediksi label kategori benda yang tidak diketahui sebelumnya, dalam membedakan antara objek yang satu dengan yang lainnya berdasarkan atribut atau fitur (Mutrofin dkk, 2014).

Didalam klasifikasi terdapat dua pekerjaan yang dilakukan, yaitu : (Prasetyo, 2012):

1. Pembangunan model sebagai *prototype* untuk disimpan sebagai memori.
2. Penggunaan model tersebut untuk melakukan pengenalan klasifikasi atau prediksi pada suatu objek data lain agar diketahui dikelas mana objek data tersebut dalam model yang sudah disimpannya.

Terdapat beberapa banyak algoritma klasifikasi yang sudah dikembangkan oleh para peneliti di antaranya adalah *K-Nearest Neighbor (KNN)*, *Modified K-Nearest Neighbor (MKNN)*, *Decision Tree Classifier*, *Rule-Based Classifier*, *Neural-Network*, *Artificial Neural Network (ANN)*, *Support Vector Machine*, dan *Naive Bayes Classifier*.

2.4.1 *K-Nearest Neighbor (KNN)*

Pada algoritma KNN, sebagian atau seluruh data latih disimpan, kemudian digunakan dalam proses prediksi. Algoritma *K-Nearest Neighbor (KNN)* adalah sebuah metode untuk melakukan klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut. Teknik dari algoritma *K-Nearest Neighbor (KNN)* yakni mengelompokkan suatu data baru

Hak Cipta Dilindungi Undang-Undang
 1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

berdasarkan jarak data baru tersenut ke beberapa data dengan jarak ketetanggaan terdekat.

Jarak antara dua titik yaitu titik pada data latih (x) dan titik pada data uji (y) dihitung berdasarkan persamaan *Euclidean Distance* berikut ini (Nasution, 2015):

$$d_i = \sqrt{\sum_{i=1}^p (x_{2i} - x_{1i})^2} \dots \dots \dots (2.3)$$

Keterangan:

- x= Data latih atau uji, i= Variabel data,
- d= Jarak, p= Dimensi data.

2.4.2 Modified K-Nearest Neighbor (MKNN)

Modified K-Nearest Neighbor (MKNN) merupakan algoritma pengembangan dari kelemahan algoritma *K-Nearest Neighbor* (KNN). Kelemahan *K-Nearest Neighbor* (KNN) terdapat pada penanganan data latih yang hanya berbasis jarak untuk menentukan ketetanggaan pada setiap data latih tanpa memperhitungkan nilai bobot pada setiap data latih.

Modified K-Nearest Neighbor (MKNN) bekerja dengan menempatkan kelas data sesuai dengan K (ketetanggaan) divalidasi poin data yang sudah ditetapkan dengan perhitungan *K-Nearest Neighbor* (KNN). Dalam proses algoritma *Modified K-Nearest Neighbor* (MKNN), terdapat beberapa tambahan proses dibandingkan dengan *K-Nearest Neighbor* (KNN) yaitu, menghitung validitas data latih dan *weight voting*.

2.4.3 Validitas Data Latih

Pada metode *Modified K-Nearest Neighbor* (MKNN) setiap data latih harus divalidasi terlebih dahulu. Validitas dari setiap data dihitung atau tergantung berdasarkan tetangganya. Perhitungan nilai validitas setiap data digunakan untuk informasi tambahan data latih. Validitas digunakan untuk menghitung jumlah titik dengan label yang sama untuk data latih.

Adapun persamaan yang digunakan untuk menghitung validitas dari setiap data latih adalah sebagai berikut ini (Parvin dkk, 2010):

$$Validitas(x) = \frac{1}{H} \sum_{i=1}^H S(label(x), label(N_i(x))) \dots\dots\dots(2.4)$$

Dimana :

- H = Jumlah titik terdekat.
- $label(x)$ = Kelasx.
- $labelNi(X)$ = Label kelas titik terdekat x.

Fungsi S digunakan untuk menghitung kesamaan antara titik x dan data ke-i dari tetangga terdekat. Berikut persamaan untuk memperoleh nilai S (Parvin dkk, 2010):

$$S(a, b) = \begin{cases} 1 & a=b \\ 0 & a \neq b \end{cases} \dots\dots\dots(2.5)$$

Dimana a merupakan kelas a pada data latih dan b adalah kelas lain selain a pada data latih.

2.4.4 Weight Voting

Didalam metode *Modified K-Nearest Neighbor* (MKNN), setiap masing-masing bobot tetangga dihitung dengan menggunakan rumus berikut ini (Parvin dkk, 2010):

$$\frac{1}{d_e + 0,5} \dots\dots\dots(2.6)$$

Dimana d_e merupakan nilai jarak *Euclidean* yang didapatkan pada persamaan 2.3.

Setelah itu, nilai validitas ada setiap data pada data latih dikalikan dengan nilai *weight voting* berdasarkan pada jarak *Euclidean*. Perhitungan nilai *weight voting* setiap tetangga pada metode *Modified K-Nearest Neighbor* (MKNN) dapat dilihat berdasarkan persamaan dibawah ini (Parvin dkk, 2010):

$$W(i) = Validitas(i) \times \frac{1}{d_e + 0,5} \dots\dots\dots(2.7)$$

Keterangan :

- $W(i)$ = Perhitungan *Weight Voting*
- Validitas (i) = Nilai Validitas

Setelah perhitungan *weight voting* dilakukan, kemudian akan diambil sebanyak kdari nilai *weight voting* terbesar. Dan kemudian kelas mayoritas dari k nilai *weight voting* yang terpilih tersebut akan menjadi kelas dari data uji.

2.5 Confussion Matrix

Untuk melihat akurasi pada pengujian klasifikasi, pada penelitian ini menggunakan *confussion matrix*. Menurut (Gurunescu, 2011), Jika data yang akan diuji memiliki *class* positif dan negatif, maka dapat dibuatkan seperti Tabel 2.1 berikut:

Tabel 2.1 Tabel Confussion Matrix 2 Class

Classification Observed Class	Predicted Class		
		Class = Yes	Class = No
	Class = Yes	(True Positive - TP)	(False Negative - FN)
	Class = No	(False Positive - FP)	(True Negative - TN)

Keterangan:

True Positive = Jumlah data kelas benaryang diklasifikasikan sebagai kelas benar

True Negative = Jumlah data kelas salah yang diklasifikasikan sebagai kelas salah

False Positive = Jumlah data kelas salah yang diklasifikasikan sebagai kelas benar

False Negative = Jumlah data kelas benar yang diklasifikasikan sebagai kelas salah

Berdasarkan Tabel 2.1 diatas, dapat dilakukan perhitungan akurasi seperti persamaan 2.8 berikut:

$$Akurasi = \frac{TP+TN}{TP+FN+FP+TN} \times 100\% \dots\dots\dots(2.8)$$

2.6 Penelitian Terkait

Adapun penelitian-penelitian yang terkait dengan penelitian yang akan dilakukan adalah sebagai berikut:

2.6.1 Metode Ekstraksi Fitur STE

Adapun beberapa penelitian mengenai metode ekstraksi fitur STE dapat dilihat pada Tabel 2.2 berikut:

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Tabel 2.2 Penelitian Terkait Ekstraksi Fitur STE dan ZC

No	Nama Peneliti	Judul Penelitian	Tahun Penelitian	Hasil yang Didapatkan
1	Arif Setiawan, Putri Kurnia Handayani	Klastering Suara Berdasarkan Gender Dengan Ekstraksi Ciri Berbasis Domain Waktu	2012	Pengklasifikasian suara berdasarkan jenis kelamin atau gender dapat dilakukan dengan ekstraksi ciri <i>Sort Time Energy</i> , <i>Zero Crossing Rate</i> , <i>Spectral Centroid</i> , dan <i>Spectral Flux</i> . Nilai rata-rata dari masing-masing ciri dihitung dengan standart deviasi, untuk memperoleh rata-ratanya, lalu diolah untuk pengklasifikasian.
2	Rocky Yefrenes Dillak, Dwi Murdaningsih Pangestuty, Martini Ganantowe Bintiri	Klasifikasi Jenis Musik Berdasarkan File Audio Menggunakan Jaringan Syaraf Tiruan <i>Learning Vector Quantization</i>	2012	Pada penelitian ini dilakukan klasifikasi jenis musik dari suatu lagu dengan menggunakan fitur data audio sebagai <i>input</i> sistem. Hasil pelatihan menggunakan Jaringan Syaraf Tiruan – <i>Lerning Vector Quantization</i> (LVQ) memiliki kinerja yang cukup baik karena mampu mengenali pola data dengan akurasi mencapai 80 %.
3	Ardiansyah dan Popy Meilina	Klasifikasi Genre Musik Menggunakan Metode <i>Support Vector Machine</i>	2015	Pada penelitian ini diklasifikasikan genre musik pop, rock, dangdut dan jazz dengan ekstraksi ciri STE, ZC, <i>spectral centroid</i> dan <i>spectral flux</i> dengan metode klasifikasi <i>Support Vector Machine</i> . Hasil yang didapat dari data testing secara keseluruhan yang diklasifikasikan secara benar ada 21 data dari 36 data sehingga persentase keberhasilan sebesar 58.33%.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.6.2 Metode Klasifikasi MKNN

Adapun beberapa penelitian mengenai metode klasifikasi *Modified K-Nearest Neighbor* (MKNN) dapat dilihat pada Tabel 2.3 berikut:

Tabel 2.3 Penelitian terkait klasifikasi MKNN

No	Nama Peneliti	Judul Penelitian	Tahun Penelitian	Hasil yang Didapatkan
1	Parvin, Alizadeh, Minati	<i>A Modification on K-Nearest Neighbor Classifier</i>	2010	Didalam penelitian ini, dilakukan pengujian untuk membandingkan <i>K-Nearest Neighbor</i> (KNN) dengan <i>Modified K-Nearest Neighbor</i> (MKNN) dengan data <i>set</i> dan nilai <i>k</i> yang berbeda. Hasil dari penelitian adalah hasil atau akurasi metode <i>Modified K-Nearest Neighbor</i> (MKNN) lebih baik dari <i>K-Nearest Neighbor</i> (KNN).
2	Siti Mutrofin, Abidatul Izzah, Arrie Kurniawardhani, Mukhamad Masrur	Optimasi Teknik Klasifikasi <i>Modified K-Nearest Neighbor</i> Menggunakan Algoritma Genetika	2014	Algoritma kNN, MKNN dan GMKNN memiliki kinerja yang sama baiknya, dalam melakukan klasifikasi data Iris dengan hasil akurasi 100%.