

# PENGENALAN SUARA PEMBICARA BERDASARKAN SINYAL SUARA BERBAHASA INDONESIA UNTUK Mendukung AKUSTIK FORENSIK

**Kanyadian Idananta<sup>1)</sup>, Ady Widjaja<sup>2)</sup>**

<sup>1</sup>Teknik Informatika, Fakultas Teknologi Informasi, Universitas Bina Nusantara  
Jl. KH. Syahdan No 9, Palmerah. Jakarta Barat  
Telp: (0231)5345830.

<sup>2</sup>Teknik Informatika, Fakultas Teknologi Informasi, Universitas Budi Luhur  
Jl. Raya Ciledug, Pertukangan Utara, Jakarta Selatan 12260  
Telp: (021)5853489  
E-mail: kidananta@binus.edu<sup>1)</sup>, ady\_w168@yahoo.co.id<sup>2)</sup>

## **Abstract**

*Nowadays, crime rate in Indonesia are increasing. People attempt crimes in many different various ways. One of the most frequent acts we met is by changing appearance, and changing their voice to trick the target. Therefore it is very important for us to know who we are talking to. Different emotions can be an obstacle for us to recognize the voice of the other person. This research is conducted to learn more about voiceprint recognition by processing emotional speech signals in Indonesian language using Mel Frequency Cepstral Coefficient (MFCC) for its features and Support Vector Machine (SVM) to classify the features. The result suggests that the recognition can achieve about 92% of the level of accuracy.*

**Keywords:** *Voiceprint Recognition, Feature Extraction, Classification, Language, Emotion, Accuracy*

## **Abstrak**

*Seperti yang kita ketahui bahwa tingkat kriminalitas di Indonesia semakin meningkat. Jenis-jenis tindakan kriminal yang dilakukanpun semakin bervariasi. Yang cukup sering dilakukan salah satunya adalah mengubah penampilan, dan berupaya untuk mengelabui lawan bicaranya dengan mengubah cara bicara. Untuk itu sangat penting bagi kita untuk mengetahui siapa lawan bicara kita. Emosi yang berbeda-beda dapat menjadi kendala bagi kita untuk mengenali suara lawan bicara kita. Riset ini dilakukan untuk mengenali siapa lawan bicara kita, yang menggunakan Bahasa Indonesia dan apapun emosi yang dimiliki sang pembicara dengan menggunakan metode ekstraksi fitur Mel Frequency Cepstral Coefficient (MFCC) dan metode klasifikasi Support Vector Machine (SVM). Hasil akhir yang terlihat menunjukkan bahwa pengamatan ini mencapai tingkat akurasi hingga 92%.*

**Kata Kunci:** *Pengenalan Suara, Ekstraksi Fitur, Klasifikasi, Bahasa, Emosi, Akurasi*

## **1. PENDAHULUAN**

Emosi adalah sebuah perasaan atau reaksi intens terhadap seseorang atau sebuah benda. Manusia mendemonstrasikannya ketika mereka senang, marah atau takut akan sesuatu [1]. Keadaan emosional tersebut terlihat dari cara bicara, gestur tubuh dan juga ekspresi wajah [2]. Sinyal suara merupakan sinyal kompleks yang mengandung informasi terkait pesan, pembicara, Bahasa dan juga emosi yang digunakan [3]. Pengenalan pembicara merupakan sebuah pengamatan tentang sifat-sifat pribadi seseorang dengan memperhatikan atau menganalisa kualitas suara yang dikeluarkannya [4].

Akustik Forensik biasanya meneliti pengenalan pembicara, pembuktian keaslian, pengembangan

audio dan verifikasi transkrip dengan menganalisa audio atau sinyal suara [5]. Secara umum, pengenalan pembicara biasa digunakan untuk mengenali seseorang berdasarkan suaranya. Namun ternyata perbedaan emosi yang digunakan saat berbicara dapat meningkatkan tingkat kesalahan dalam mengenali seseorang. Kontribusi dari riset ini adalah untuk mengenali sidik suara seseorang berdasarkan sinyal suara yang beremosi. Riset ini fokus lebih pada kebutuhan forensik. Dalam pengenalan pembicara, identitas pembicara dikenali dengan menganalisa dan membandingkan sinyal suara pembicara yang dikenal dengan yang tidak dikenal. Verifikasi pembicara merupakan proses penerimaan atau penolakan identitas pembicara dari

hasil analisa dan perbandingan [6]. Untuk kebutuhan ini, sinyal suara akan dianalisa menggunakan *Mel Frequency Cepstral Coefficient* (MFCC) untuk mendapatkan fiturnya dan *Support Vector Machine* untuk melakukan klasifikasi fitur-fitur yang didapat.

## 2. METODE

### 2.1. Ekstraksi Fitur

Dalam pembelajaran mesin, saat input data dalam sebuah algoritma terlalu besar untuk diproses dan diduga memiliki data yang redundan, maka data dapat diubah menjadi sebuah set fitur (biasa disebut juga dengan fitur vektor). Proses ini disebut ekstraksi fitur. Fitur yang diekstraksi diharapkan berisi informasi yang relevan dari data input, sehingga tugas yang diinginkan dapat dilakukan dengan menggunakan representasi ini daripada data awal yang lebih lengkap.

Beberapa macam fitur ekstraksi yang dapat dilakukan untuk mengidentifikasi sebuah emosi [7]. Salah satu fitur ekstraksi yang sering digunakan dalam mengidentifikasi sebuah percakapan adalah metode ekstraksi *Mel-Frequency Cepstral Coefficient* (MFCC).

MFCC sangat efektif dalam identifikasi audio dan dalam pemodelan nada dan frekuensi yang subjektif dari sinyal audio [8]. Metode ini digunakan untuk melakukan ekstraksi fitur, sebuah proses yang mengkonversikan sinyal suara menjadi beberapa parameter [9]. MFCC terdiri dari beberapa tahap seperti berikut [8] [10] [11]:

- a. Pra Proses
- b. Framing
- c. Windowing
- d. Fast Fourier Transform
- e. Mel Filter Bank Processing
- f. Discrete Cosine Transform

#### 2.1.1. Pra Proses

Dalam pra-proses gelombang tekanan suara akustik diubah menjadi sinyal digital, yang sesuai untuk pengolahan suara. Sebuah mikrofon dapat digunakan untuk mengubah gelombang akustik menjadi sebuah sinyal analog. Sinyal analog ini dilewatkan melalui filter antialiasing untuk mengkompensasi adanya gangguan [12]. Suara tersebut kemudian dibatasi lebih lanjut dengan memilih sebuah *frame size* dan melewatkan melalui *Hamming window*. Sebuah sampel kata yang sudah terisolasi dilewatkan melalui sebuah filter yang menekankan frekuensi yang lebih tinggi. Hal ini akan meningkatkan energi dari sinyal pada frekuensi yang lebih tinggi [13]. Tahap ini dilakukan dengan persamaan di bawah ini:

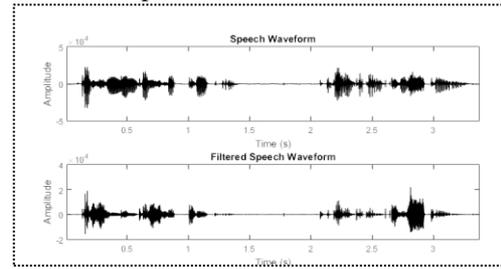
$$Y[n] = X[n] - 0.95 X[n - 1] \quad (1)$$

di mana:

$$Y[n] = \text{sinyal output pada waktu diskrit ke } n$$

$$X[n] = \text{sinyal input pada waktu diskrit ke } n$$

$n = \text{tahap ke-}$



Gambar 1 Sinyal Suara Sesudah dan Sebelum Difilter

#### 2.1.2. Framing

*Framing* diperlukan karena percakapan merupakan sinyal yang berubah-ubah seiring dengan jalannya waktu, tetapi ketika dilihat dalam waktu yang singkat, karakteristiknya cukup stasioner. Oleh karena itu dilakukanlah analisis spektral dalam jangka waktu yang singkat. Sinyal percakapan disegmentasi menjadi blok-blok dengan durasi kecil kisaran 20 - 30 ms yang juga dikenal dengan *frame*. Sinyal suara dibagi menjadi sampel  $N$  dan *frame* yang berdekatan dipisahkan oleh  $M$  di mana ( $M < N$ ) [14].

#### 2.1.3. Windowing

Dalam pemrosesan sinyal, fungsi *window* (juga dikenal sebagai fungsi apodisasi atau fungsi *tapering*) adalah fungsi matematika yang memiliki nilai nol di luar dari beberapa interval yang dipilih. Misalnya, sebuah fungsi yang konstan dalam interval dan nol di tempat lain disebut *rectangular window*, yang menggambarkan bentuk representasi grafis. Ketika fungsi lain atau gelombang / urutan-data dikalikan dengan fungsi *window*, hasilnya juga nilai-nol di luar interval; bagian yang tersisa adalah bagian di mana mereka tumpang tindih, "lihat melalui jendela" [15].

Setiap *frame* di atas dikalikan dengan *Hamming window* untuk menjaga kelangsungan sinyal. Jadi untuk mengurangi diskontinuitas ini kita menerapkan fungsi *window*. Pada dasarnya distorsi spektral diminimalkan dengan menggunakan *window* untuk mempertajam sampel suara ke nol pada bagian awal dan akhir setiap *frame* [10].

Jika jendela didefinisikan  $W(n)$ ,  $0 \leq n \leq (N - 1)$ , di mana  $N$  adalah banyaknya sampel yang diambil,  $Y(n)$  adalah sinyal *output*,  $X(n)$  adalah sinyal *input*,  $W(n)$  adalah *Hamming Window*, maka hasil sinyal yang telah di-*windowing*:

$$Y(n) = X(n) \otimes W(n) \quad (2)$$

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq (N-1) \quad (3)$$

Lambang  $\otimes$  adalah operator konvolusi.

#### 2.1.4. Fast Fourier Transform

*Fast Fourier Transform* (FFT) adalah algoritma yang menghitung *Discrete Fourier Transform* (DFT) dari urutan, atau kebalikannya. Analisis

*Fourier* mengubah sinyal dari *domain* aslinya (sering kali waktu atau ruang) ke *domain* frekuensi dan sebaliknya [16]. Tahap ini mengubah masing-masing *frame* dari  $N$  sampel, dari *domain* waktu menjadi *domain* frekuensi. *Fourier Transform* mengubah konvolusi dari *glottal pulse*  $U[n]$  dan respon *vocal tract impulse*  $H[n]$  dalam *domain* waktu [17] dengan persamaan seperti berikut:

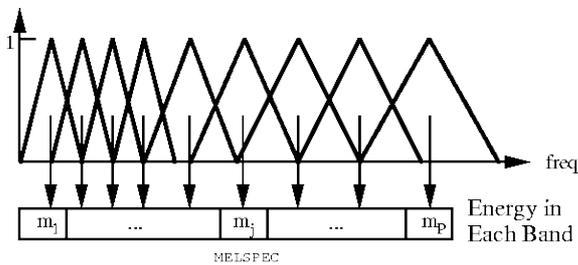
$$Y(\omega) = FFT[h(t)] * FFT[x(t)] = H(\omega) * X(\omega), \quad (4)$$

di mana  $\omega$ ,  $H(\omega)$  dan  $Y(\omega)$  adalah hasil dari *Fourier Transform* dari  $x(t)$ ,  $h(t)$  dan  $y(t)$  secara berurutan. Tahapan FFT ini menghasilkan sebuah spectrum yang akan diproses di tahap berikutnya.

### 2.1.5. Mel Filter Bank Processing

Telinga manusia menerima frekuensi non-linear [18]. Penelitian menunjukkan bahwa skala yang didapat linear sampai dengan 1 kHz dan logaritmik di atas itu. Skala Melodi (*Mel-Scale*) *filter bank* menggambarkan frekuensi yang dapat diterima oleh manusia. Hal ini digunakan sebagai filter *band pass* pada tahap identifikasi. Sinyal untuk setiap *frame* dilewatkan melalui *Mel-Scale filter band pass* untuk meniru telinga manusia [10].

Pada MFCC, *filter bank* diterapkan dalam *domain* frekuensi. *Filter bank* menggunakan representasi konvolusi dalam melakukan filter terhadap sinyal. Konvolusi dapat dilakukan dengan melakukan multiplikasi antara sinyal spektrum dengan koefisien *filter bank*. Jangkauan frekuensi di spektrum FFT sangat lebar dan sinyal suara tidak mengikuti skala linear. Besar masing-masing frekuensi filter berbentuk segitiga dan sama dengan frekuensi tengahnya dan menurun secara linear ke nol di frekuensi tengah dari filter-filter yang berdekatan. Lalu masing-masing keluaran dari filter merupakan jumlah dari komponen spektral yang difilternya dan menurun secara linear ke nol di frekuensi tengah dari filter-filter yang berdekatan. Lalu masing-masing keluaran dari filter merupakan jumlah dari komponen spektral yang difilter.



Gambar 2 Triangular Filter Bank [10].

Gambar 2 menunjukkan satu set filter segitiga yang digunakan untuk menghitung jumlah komponen spektral filter sehingga keluaran dari proses mendekati dengan skala Mel. Masing-masing keluaran filter adalah jumlah yang difilter komponen

spectral [10]. Persamaan yang digunakan adalah sebagai berikut:

$$F(\text{Mel}) = 2595 \times \log_{10} \left[ 1 + \frac{f}{700} \right] \quad (5)$$

### 2.1.6. Discrete Cosine Transform

Tahap ini merupakan proses untuk mengkonversi log Mel spektrum dalam *domain* waktu menggunakan *Discrete Cosine Transform* (DCT). Hasil konversi disebut *Mel Frequency Cepstrum Coefficient*. Set koefisien disebut vektor akustik. Oleh karena itu, setiap masukan ucapan berubah menjadi urutan vektor akustik [10] [17] [18].

### 2.2. Proses Pemilihan Fitur

Pada tahap ini penulis memilih 49 jenis fitur yang akan digunakan untuk mengklasifikasi data yaitu, nilai minimum, nilai maksimum, nilai standar deviasi dan nilai rata-rata yang dihitung dari masing-masing koefisien (total 12 koefisien) yang didapat dari hasil MFCC pada tahap sebelumnya.

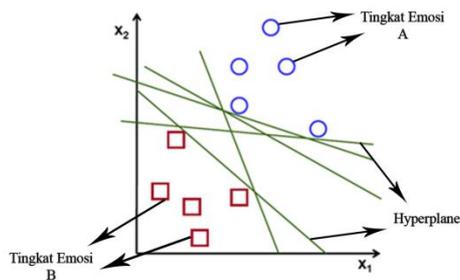
### 2.3. Klasifikasi

Sebuah *Support Vector Machine* (SVM) adalah suatu algoritma yang menggunakan pemetaan non-linear untuk mengubah data pelatihan sebenarnya ke dalam dimensi yang lebih tinggi. Dalam dimensi baru ini, ia mencari pemisah *hyperplane* optimal linear. Sebuah *hyperplane* adalah "batas keputusan" yang memisahkan tupel dari satu kelas dari yang lain. Dengan pemetaan non-linear yang tepat ke dimensi yang cukup tinggi, data dari dua kelas selalu dapat dipisahkan dengan *hyperplane*. SVM menemukan *hyperplane* ini menggunakan vektor pendukung ("penting" tupel pelatihan) dan margin (didefinisikan oleh vektor pendukung).

Walaupun waktu pelatihan SVM tercepat bisa saja sangat lambat, mereka sangat akurat, karena kemampuan mereka untuk memodelkan batas keputusan non-linear yang kompleks. Metode ini cenderung memiliki lebih sedikit data yang *over fitting* daripada metode lainnya [19].

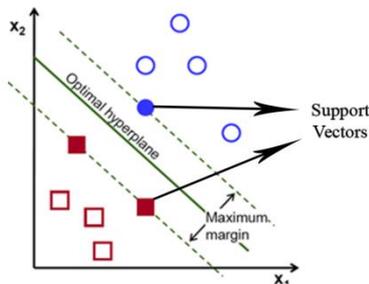
Pada tahap ini set data dibagi menjadi dua yaitu data pelatihan dan data pengujian. 66% fitur-fitur yang didapat, digunakan untuk melatih sistem. Sisa data digunakan untuk pengujian.

Set fitur yang telah diekstraksi sebelumnya digunakan pada tahap ini untuk mengenali pembicara. Yang pertama dilakukan adalah melatih *classifier* dengan beberapa *input file* percakapan beremosi disertai dengan proses pelabelan. Algoritma ini membuahkan *hyperplane* yang dapat mengkategorikan sampel baru.



Gambar 3 Set yang Sudah Dipisahkan Secara Linear oleh Hyperplane [20].

Gambar 3 menunjukkan bahwa ada beberapa *hyperplane* yang dibuat tetapi tidak semuanya memberikan *output* yang baik. Algoritma SVM mencari *hyperplane* yang memberikan jarak paling minimum terhadap sampel pelatihan. Jarak ini biasa disebut dengan margin. Pembatas *hyperplane* yang optimal memaksimalkan margin dari data pelatihan.



Gambar 4 Hyperplane Optimal [20].

Setelah tahap pelatihan, kita melanjutkan ke tahap berikutnya yaitu proses testing di mana terdapat proses pengidentifikasian pembicara dari rekaman percakapan beremosi yang dimasukkan.

#### 2.4. Akurasi

Pada tahap ini penulis menggunakan metode matriks konfusi untuk menghitung akurasi dari tahap sebelumnya. Tabel 3.2 menunjukkan bentuk matriks konfusi di mana TN adalah jumlah prediksi untuk sampel negatif yang diprediksikan benar, FN adalah jumlah prediksi untuk sampel negatif yang diprediksikan tidak benar, FP adalah jumlah prediksi untuk sampel positif yang diprediksikan tidak benar, dan TP adalah jumlah prediksi untuk sampel positif yang diprediksikan benar. Ada empat *output* yang bisa kita dapatkan dari matriks ini, yaitu *recall*, *precision*, *accuracy*, dan *error rate*. Berikut adalah persamaan yang dapat digunakan:

- a. *Recall* adalah proporsi sampel positif yang diidentifikasi dengan benar

$$\text{recall} = \frac{TP}{FP + TP} \quad (6)$$

- b. *Precision* adalah proporsi sampel dengan hasil positif yang benar

$$\text{precision} = \frac{TP}{FN + TP} \quad (7)$$

- c. *Accuracy* adalah perbandingan sampel yang diidentifikasi benar dengan jumlah semua sampel

$$\text{accuracy} = \frac{TN + FP}{TN + FN + FP + TP} \quad (8)$$

- d. *Error Rate* adalah perbandingan sampel yang diidentifikasi salah dengan jumlah semua sampel

$$\text{error rate} = \frac{FN + FP}{TN + FN + FP + TP} \quad (9)$$

### 3. HASIL DAN DISKUSI

Dengan total 291 basis data sinyal suara beremosi dan berbahasa Indonesia, penulis menggunakan metode MFCC dan mengekstraksi 48 fitur untuk masing-masing data, dengan mengambil, nilai minimum, nilai maksimum, nilai standar deviasi dan nilai rata-rata dari masing-masing koefisien yang telah didapat dari proses MFCC (total 12 koefisien). Masing-masing data akan memiliki fitur sebagai berikut: 12 nilai minimum, 12 nilai maksimum, 12 nilai standar deviasi, dan 12 nilai rata-rata. Fitur-fitur yang didapat kemudian diklasifikasi dengan menggunakan metode klasifikasi SVM untuk mendapatkan persentase akurasi identifikasi emosi. 66% data digunakan untuk pelatihan dan 34% data sisanya digunakan untuk melakukan testing. Kemudian tahapan ini diulang selama 10 kali dengan data set pelatihan dan *testing* yang berbeda-beda. Hasilnya seperti yang ditunjukkan pada tabel 1 di bawah ini:

Tabel 1 Hasil Klasifikasi dengan 10 Data Set Berbeda

Data Set	Accuracy
1 <sup>st</sup> Set	90.4
2 <sup>nd</sup> Set	91.0
3 <sup>rd</sup> Set	90.4
4 <sup>th</sup> Set	91.0
5 <sup>th</sup> Set	91.0
6 <sup>th</sup> Set	89.2
7 <sup>th</sup> Set	89.8
8 <sup>th</sup> Set	92.2
9 <sup>th</sup> Set	91.0
10 <sup>th</sup> Set	91.6

Dari hasil yang didapat dari Tabel 1, rata-rata tingkat akurasi pengenalan pembicara adalah 90.76%.

### 4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan pengenalan pembicara secara otomatis atas dasar sinyal suara yang berhubungan dengan emosi manusia dalam bahasa Indonesia. Dengan melakukan ekstraksi fitur menggunakan metode Mel Frequency Cepstral Coefficient (MFCC), tersedia 48 fitur sinyal suara yang siap untuk diklasifikasi menggunakan metode Support Vector Machine, dan tahapan ini diulang sebanyak 10 kali.

Berdasarkan percobaan tersebut, rata-rata tingkat akurasi pengenalan pembicara yang diperoleh adalah 90.76%.

Penelitian lebih lanjut berdasarkan bahasa, aksen dan penggunaan media perekam suara yang berbeda disarankan untuk meningkatkan kualitas pengakuan. Hasilnya bisa diaplikasikan dalam sebuah sistem untuk mengenali suara manusia yang bisa digunakan dalam analisis forensik dan industri penerbangan

## 5. DAFTAR PUSTAKA

- [1] N. Frieda, "Moods, Emotion Episodes and Emotions", New York: Guilford Press, 1993, pp. 381-403.
- [2] C. Chibelushi and F. Bourel, "Facial Expression Recognition: A Brief Tutorial Overview," 9 January 2003. [Online]. Available: [http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL\\_COPIES/CHIBELUSHI/CCC\\_FB\\_FacExprRecCVonline.pdf](http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/CHIBELUSHI/CCC_FB_FacExprRecCVonline.pdf).
- [3] S. Pahune and N. Mishra, "Emotion Recognition through Combination of Speech and Image Processing: A Review," *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 3, no. 2, pp. 134-137, February 2015.
- [4] J. S. Devi, S. Yarramalle and S. P. Nandyala, "Speaker Emotion Recognition based on Speech Features and Classification Techniques," *International Journal of Image, Graphics and Signal Processing (IJIGSP)*, vol. 6, no. No. 7, pp. 61-77, July 2014.
- [5] A. Yonovitz, H. Joe and J. Yonovitz, "Digital Signal Processing in Forensic Acoustics Cases," *The Journal of the Acoustical Society of America*, vol. 132, no. 3, p. 1971, September 2012.
- [6] P. Rose, Forensic Speaker Identification, J. Robertson, Ed., London and New York.
- [7] L. R. Rabiner, M. J. Cheng, A. E. Rosenberg and C. A. McGonegal, "A Comparative Performance Study of Several Pitch Detection Algorithms," 1976.
- [8] Y. D. Ling, T. C. Liang, J. C. S. X. Chang, Q. T. and X. M. , "HMM-Based Audio Keyword Generation," in *Advances in Multimedia Information Processing - PCM 2004*, K. Aizawa, Y. Nakamura and S. Satoh, Eds., Heng Mui Keng Terrace, Springer Berlin Heidelberg, 2004, pp. 566-574.
- [9] I. W. A. Resmawan, "Verifikasi Suara Menggunakan Metode MFCC dan DTW," Tugas Akhir Strata 1, Jimbaran, 2010.
- [10] L. Muda, M. Begam and I. Elamvazuthi, "Voice Recognition Algorithms using Mel Frequency Cepstral Coefficient (MFCC) and Dynamic Time Warping (DTW) Techniques," *Journal of Computing*, vol. 2, no. 3, pp. 138-143, March 2010.
- [11] K. J. Patil, P. H. Zope and S. R. Suralkar, "Emotion Detection From Speech Using MFCC & GMM," *International Journal of Engineering Research & Technology*, vol. 1, no. 9, pp. 1-7, November 2012.
- [12] E. Mower, M. J. Mataric and S. Narayanan, "A Framework for Automatic Human Emotion Classification Using Emotion Profiles," *IEEE Transactions On Audio, Speech and Language Processing*, vol. 19, no. 5, pp. 1057-1070, 5 July 2011.
- [13] A. B. Kandali, A. Routray and T. K. Basu, "Emotion Recognition from Assamese Speeches using MFCC Features and GMM Classifier," in *Proceedings of IEEE Region 10 Conference 19-21 November 2008*, Hyderabad, India, 2008.
- [14] P. P. Singh and P. Rani, "An Approach to Extract Feature Using MFCC," *IOSR Journal of Engineering*, vol. 4, no. 8, pp. 21-25, August 2014.
- [15] L. D. Enochson and R. K. Otnes, Programming and Analysis for Digital Time Series Data, vol. 3, United States: United States Dept. of Defense, Shock and Vibration Information Center, 1968, p. 142.
- [16] C. V. Loan, "The Radix-2 Framework," in *Computational Frameworks for the Fast Fourier Transform*, Ithaca, New York: Society for Industrial and Applied Mathematics, 1992, pp. 1-75.
- [17] J. Kaur and A. Sharma, "Emotion Detection Independent of User Using MFCC Feature Extraction," *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 4, no. 6, pp. 230-234, 6 June 2014.
- [18] S. Salsabila, R. Soelistijorini and M. Huda, "Aplikasi Pengenalan Suara Untuk Pemanggilan Aplikasi Komputer Berbasis MFCC dan DTW," *Journal Elektro PENS*, vol. 2, no. No 2, pp. 1-8, 2013.
- [19] R. E. Maleki, A. Rezaei and B. M. Bidgoli, "Comparison of Classification Methods Based on the Type of Attributes and Sample Size," *Journal of Cases in Information Technology*, vol. 4, no. 3, pp. 94-102, 2009.
- [20] "OpenCV," August 2015. [Online]. Available: [http://docs.opencv.org/2.4/doc/tutorials/ml/introduction\\_to\\_svm/introduction\\_to\\_svm.html](http://docs.opencv.org/2.4/doc/tutorials/ml/introduction_to_svm/introduction_to_svm.html). [Accessed August 2015].