

Deteksi Respon Konsentrasi Terhadap Rangsangan Suara Secara Real-Time Menggunakan Wavelet dan Support Vector Machine

Nendra Cahya Permana¹, Esmeralda C. Djamal, Agus Komarudin
Jurusan Informatika, Fakultas MIPA
Universitas Jenderal Achmad Yani
Cimahi, Indonesia
¹nendracahya@gmail.com

Abstrak—Konsentrasi merupakan penunjang untuk mencapai tujuan dalam melakukan kegiatan. Rangsangan suara dapat mempengaruhi konsentrasi dan dapat digunakan dalam terapi rehabilitasi medik. Oleh karena itu, peningkatan konsentrasi dapat dilakukan dengan pemberian rangsangan suara, namun perlu diukur efektivitasnya ditinjau dari jenis suara dan waktu pemberian. Namun, untuk mendeteksi respon tingkat konsentrasi terhadap rangsangan suara tersebut tidak mudah. EEG merupakan suatu alat yang dapat memberikan informasi kondisi pikiran berdasarkan aktivitas listrik di otak. Beberapa penelitian terdahulu telah melakukan analisis sinyal EEG untuk kondisi emosi, kondisi rileks, dan variabel pikiran lainnya. Analisis sinyal EEG tidak mudah, termasuk untuk mendeteksi respon konsentrasi sehingga diperlukan pemrosesan menggunakan metode yang tepat. Penelitian terdahulu menggunakan Absolute Power Spectrum, Wavelet dan Adaptive Backpropagation untuk identifikasi konsentrasi secara offline. Dalam evaluasi terapi, respon tingkat konsentrasi terhadap rangsangan suara perlu dideteksi setiap waktunya sehingga dibutuhkan perangkat yang dapat memonitor respon konsentrasi secara real-time. Penelitian ini telah menghasilkan sistem untuk mendeteksi respon tingkat konsentrasi seseorang terhadap rangsangan suara secara real-time setiap enam detik. Sistem dibangun menggunakan Wavelet untuk ekstraksi ciri dan Support Vector Machine untuk memisahkan tingkat konsentrasi dengan akurasi yang diperoleh sebesar 93,6% untuk data latih dan 85% untuk data uji.

Kata Kunci—sinyal EEG; deteksi konsentrasi; rangsangan suara; ekstraksi Wavelet; Support Vector Machine;

I. PENDAHULUAN

Berbagai kegiatan dalam kehidupan sehari-hari memerlukan konsentrasi yang baik untuk mencapai tujuan tertentu. Terdapat banyak faktor yang dapat mempengaruhi konsentrasi seseorang saat melakukan kegiatan, salah satunya adalah rangsangan suara. Dalam terapi rehabilitasi medik pun, rangsangan suara seperti musik tertentu dapat digunakan dalam upaya meningkatkan kemampuan fungsional pada pasien termasuk konsentrasi. Efek pemberian jenis rangsangan suara dan waktu pemberiannya perlu dievaluasi untuk mencapai terapi yang efektif. Pengukuran konsentrasi setiap waktu melalui pengamatan konvensional saat dilakukan terapi pun tidak mudah, di sisi lain pengamatan tersebut terdapat banyak kemungkinan informasi respon konsentrasi tidak sesuai dengan kondisi sebenarnya. Salah satu perangkat yang dapat dimanfaatkan untuk mengetahui kondisi pikiran di otak secara

real-time adalah Elektroensefalogram (EEG). Namun, pengolahan sinyal EEG menjadi informasi respon konsentrasi tidak mudah karena polanya yang tidak baku, bentuknya yang kompleks, mudah terpengaruh *noise*, dapat berubah setiap waktunya dan faktor lainnya sehingga diperlukan metode yang tepat.

Berkembangnya EEG menjadi *wireless* mendukung banyak penelitian dalam identifikasi kondisi pikiran. Penelitian lalu telah melakukan klasifikasi sinyal EEG terhadap rangsangan suara [1] [2] dan rangsangan video [3]. Beberapa penelitian terdahulu menganalisis sinyal EEG secara *offline* terhadap kondisi bahagian seseorang [4], tingkat perhatian [5], emosi [6] [7], kondisi rileks [8], kelelahan [9], dan konsentrasi [10], juga terdapat penelitian [11] yang mengidentifikasi dua level konsentrasi yaitu konsentrasi dan kurang konsentrasi secara *offline*. Padahal dalam terapi peningkatan konsentrasi, waktu pemberiannya perlu dievaluasi dan juga perlu diketahui respon setiap waktunya untuk dievaluasi sehingga dibutuhkan perangkat yang dapat melakukan deteksi respon tingkat konsentrasi secara *real-time*. Selain itu tingkat konsentrasi perlu dirincikan menjadi lebih dari dua kelas.

Penelitian ini telah menghasilkan sistem yang dapat mendeteksi respon tingkat konsentrasi secara *real-time* terhadap pemberian rangsangan suara berupa musik. Sinyal EEG yang berasal dari empat kanal diekstraksi ke dalam frekuensi Teta, Alfa, Beta dan Gamma menggunakan Wavelet, kemudian dilakukan deteksi respon tingkat konsentrasi menggunakan Support Vector Machine (SVM). Metode SVM telah digunakan pada penelitian sebelumnya dan terbukti SVM bekerja lebih cepat dibandingkan metode KNN dan memberikan akurasi mencapai 81% [12]. Penelitian terdahulu juga menggunakan metode SVM untuk deteksi migren dengan rata-rata akurasi 56% - 89% [13], dan deteksi epilepsi dengan akurasi 70% [14].

Sistem dibangun dengan 3.840 data latih yang diperoleh dari 12 naracoba sukarela dan terintegrasi dengan *wireless* EEG dalam bentuk perangkat lunak sehingga dapat memonitor pengaruh rangsangan suara dan waktu pemberian untuk peningkatan konsentrasi. Deteksi respon konsentrasi dilakukan setiap enam detik dengan pemberian rangsangan suara berupa musik selama tiga menit yang memberikan informasi respon pikiran seseorang yaitu konsentrasi, kurang konsentrasi, atau tidak konsentrasi. Sistem deteksi ini dapat dimanfaatkan untuk


monitoring peningkatan konsentrasi terhadap rangsangan suara seperti pada terapi Snoezelen di pelayanan rehabilitasi medik, juga dapat dimanfaatkan untuk lembaga pendidikan dalam bimbingan konsultasi.

II. PERANCANGAN SISTEM

A. Elektroensefalogram

Elektroensefalogram (EEG) adalah alat yang dapat menangkap aktivitas listrik di otak. Berdasarkan rentang frekuensi, sinyal EEG dapat dibagi ke dalam lima jenis gelombang yaitu Alfa berkisar antara frekuensi 8-13 Hz muncul dalam keadaan kesadaran, tenang, atau saat istirahat, Beta yang berkisar antara frekuensi 14-30 Hz muncul dalam keadaan sadar dan waspada, Teta yang berkisar antara frekuensi 4-7 Hz muncul ketika orang mengalami tekanan emosional, gangguan kesadaran, atau relaksasi fisik yang dalam, Delta yang berkisar antara frekuensi 0,5-3 Hz dan muncul ketika dalam tidur nyenyak, tidak sadar, dibius, atau kekurangan oksigen, Gamma yang berkisar antara frekuensi 31-50 Hz dan berhubungan dengan perhatian selektif, kognisi, dan aktivitas persepsi.

Sinyal EEG direkam dalam domain waktu, dan tidak mempunyai pola yang baku. Sinyal EEG diperoleh dengan meletakkan elektroda pada batok kepala manusia dengan urutan peletakan elektroda mengacu pada standar 10-20 berdasarkan International Federation of Societies of Electroencephalogram seperti pada Gambar 1.



Gambar 1. Standar 10-20

Set titik untuk penempatan elektroda terbagi menjadi empat bagian yang dijelaskan pada Tabel I.

TABEL I. TITIK PENGUKURAN SINYAL EEG

Bagian	Simbol	Fungsi
Frontal	F	Pengontrolan, kemampuan bicara, perencanaan gerakan, dan pengenalan
Parietal	P	Menerima informasi rangsangan sentuhan, temperature, posisi tubuh dan vibrasi
Occipital	O	Menerima rangsangan visual dan arti tulisan
Temporal	T	Menerima informasi rangsangan dari telinga dan berkaitan dengan memori.

B. Akuisisi Data

Data sinyal EEG diperoleh dari 12 naracoba sukarela berusia 21-25 tahun dengan menggunakan *Wireless EEG Emotiv Insight* empat kanal (AF3, T7, T8 dan AF4) dan *software Emotiv Xavier TestBench 3.1.21* untuk merekam data. Perekaman dilakukan terhadap naracoba dalam kondisi sehat, cukup tidur, makan teratur, tidak dalam keadaan lapar atau stress, tidak mengonsumsi obat-obatan dan sehari sebelum perekaman tidak

mengonsumsi kopi atau teh. Perekaman dilakukan dalam lima kali pengulangan. Naracoba ditempatkan pada ruangan yang hening dengan suhu dan cahaya yang cukup. Perekaman dilakukan di laboratorium Informatika Universitas Jenderal Achmad Yani. Setelah itu, naracoba memakai *wireless EEG* dan diberikan rangsangan suara melalui *headset* dengan volume yang disesuaikan. Rangsangan suara yang diberikan yaitu musik klasik yang dianggap dapat membangkitkan frekuensi Beta dan Gamma untuk kondisi konsentrasi, musik metal yang dianggap dapat membangkitkan frekuensi Beta untuk kondisi kurang konsentrasi, dan musik dangdut yang dianggap dapat membangkitkan frekuensi Alfa untuk kondisi tidak konsentrasi. Perekaman data sinyal EEG dari naracoba sukarela dapat dilihat pada Gambar 2.



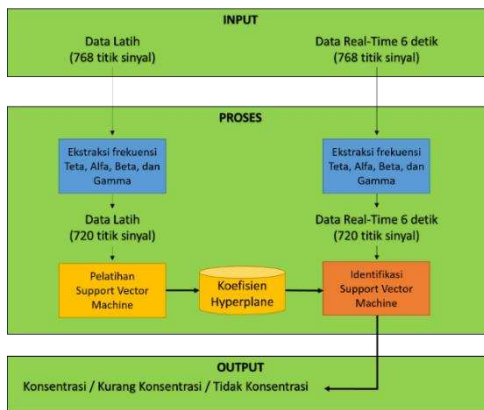
Gambar 2. Perekaman data sinyal EEG dari naracoba

Selama perekaman tersebut naracoba diberikan aplikasi Android bernama *Concentration* yang harus dimainkan untuk mengetahui indikator tingkat konsentrasi dari *score* yang didapatkan. Perekaman dilakukan selama tiga menit untuk masing-masing kondisi yaitu konsentrasi, kurang konsentrasi dan tidak konsentrasi pada setiap naracoba. Untuk data latihan konsentrasi diperoleh dari perekaman naracoba dengan *score* tinggi yaitu lebih dari 40 poin pada aplikasi yang dimainkan, pada saat perekaman tersebut naracoba diberikan target untuk mencapai *score* tersebut sehingga naracoba akan mencapai tingkat konsentrasi paling tinggi dan terjadi peningkatan pada frekuensi Beta dan Gamma. Data latihan kurang konsentrasi diperoleh dari perekaman naracoba dengan *score* rendah yaitu kurang dari 40 poin dan pada saat perekaman tersebut naracoba tidak diberikan target namun harus tetap dapat memusatkan pikirannya sehingga terjadi peningkatan pada frekuensi Beta namun naracoba berada pada tingkat konsentrasi yang kurang. Data latihan tidak konsentrasi diperoleh dari perekaman naracoba yang hanya diberikan rangsangan suara berupa musik saja, pada saat perekaman tersebut naracoba dikondisikan tenang sehingga akan terjadi peningkatan pada frekuensi Alfa. Selain itu, untuk memverifikasi kondisi tingkat konsentrasi, diberikan kuesioner setelah perekaman dilakukan. Penelitian terdahulu mengondisikan data latihan konsentrasi tinggi diperoleh dari perekaman naracoba saat memainkan *game* berhitung sedangkan untuk data latihan konsentrasi yang rendah dari naracoba dengan kondisi tenang [11]. Perekaman dari seluruh naracoba menghasilkan 4.500 set data latihan (12 naracoba x 3 kelas x 5 pengulangan x 25 segmen).

C. Sistem Deteksi

Sistem deteksi respon tingkat konsentrasi akan menghasilkan tiga kelas yaitu konsentrasi, kurang konsentrasi atau tidak konsentrasi. Untuk mendapatkan hasil tersebut dilakukan dengan merancang sistem untuk ekstraksi ciri menggunakan *Wavelet*, setelah itu membuat perancangan sistem

deteksi menggunakan SVM. Sebelum dideteksi, sinyal EEG akan diekstraksi ke dalam gelombang Teta, Alfa, Beta, dan Gamma. Perancangan sistem deteksi dapat dilihat pada Gambar 3.



Gambar 3. Sistem Deteksi Respon Konsentrasi

Data masukan diperoleh dari frekuensi sampling yang digunakan dikali dengan jumlah waktu deteksi sehingga diperoleh 128 x 6 detik atau 768 titik data sinyal untuk satu kanal. Proses pelatihan menggunakan SVM menghasilkan koefisien *hyperplane*. Setelah pelatihan, deteksi dilakukan dengan mengolah data sinyal EEG secara *real-time* setiap enam detik dan memasukkannya ke dalam fungsi *hyperplane* yang dibangun sehingga akan menghasilkan nilai dan dikonversi ke dalam kelas konsentrasi, kurang konsentrasi atau tidak konsentrasi. Namun, sebelum itu deteksi dilakukan dengan pengujian secara *offline* untuk mengukur akurasi sistem.

III. METODE

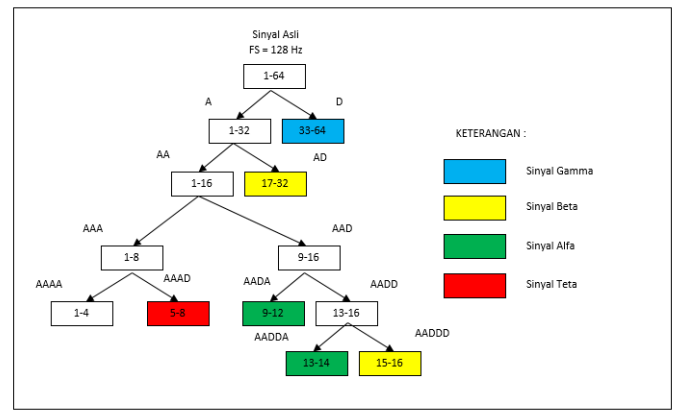
A. Wavelet

Wavelet dapat digunakan untuk transformasi sinyal atau citra dengan menggunakan fungsi penskalaan. Dalam transformasi sinyal, Wavelet merupakan analisis multi resolusi yang dapat merepresentasikan informasi waktu dan frekuensi suatu sinyal dengan baik sehingga dapat digunakan untuk menganalisis sinyal non-stasioner atau berubah terhadap waktu. Transformasi Wavelet diskrit terhadap sinyal berdasarkan [5] direpresentasikan dalam Persamaan (1).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

Dengan a adalah faktor skala dan b adalah pergeseran waktu.

Proses penskalaan dilakukan dengan dua cara yaitu dekomposisi dan rekonstruksi. Dekomposisi merupakan proses untuk ekstraksi pada frekuensi tertentu dengan konvolusi dan downsampling, sedangkan rekonstruksi adalah proses untuk mengembalikan menjadi sinyal semula. Proses dekomposisi sinyal dilakukan berdasarkan pohon dekomposisi multilevel Wavelet yang dibangun. Pada penelitian ini frekuensi *sampling* yang digunakan adalah 128Hz sehingga terkandung 1-64Hz untuk mendapatkan frekuensi Teta, Alfa, Beta dan Gamma seperti pada Gambar 4.



Gambar 4. Pohon dekomposisi multilevel Wavelet

Teknik konvolusi dilakukan dengan aproksimasi dan detail sesuai dengan proses dekomposisi yang telah ditentukan. Aproksimasi dilakukan dengan mengalikan dua fungsi dengan melewati koefisien pada Low-Pass Filter sedangkan detail melewati koefisien High-Pass Filter [7] seperti pada Persamaan (2) dan (3).

$$\text{Aproksimasi} = f(n) \cdot xg(n) \quad (2)$$

$$\text{Detail} = f(n) \cdot xh(n) \quad (3)$$

Keterangan :

$f(n)$ = sinyal asli

$g(n)$ = koefisien Low-Pass Filter

$h(n)$ = koefisien High-Pass Filter

Wavelet memiliki beberapa bentuk yaitu Haar, Coiflet, Symmet, Daubechies, dan Morlet. Wavelet Daubechies4 memiliki empat koefisien untuk Low-Pass Filter dan empat koefisien untuk High-Pass Filter seperti pada Persamaan (4) dan (5).

$$g_0 = 0.48296, g_1 = 0.83652, g_2 = 0.22414, g_3 = -0.12940 \quad (4)$$

$$h_0 = -0.12940, h_1 = -0.22412, h_2 = 0.83652, h_3 = -0.48296 \quad (5)$$

Masukan Wavelet pada penelitian ini adalah 768 titik data sinyal yang selanjutnya melalui tahapan :

- Ekstraksi pada frekuensi Teta (4-7Hz)
Ekstraksi data sinyal Teta dilakukan dengan langkah konvolusi aproksimasi sebanyak tiga kali kemudian detail sebanyak satu kali sehingga menghasilkan 48 titik data sinyal.
- Ekstraksi pada frekuensi Alfa (8-13Hz)
Ekstraksi data sinyal Alfa terbagi menjadi dua bagian. Bagian pertama ekstraksi sinyal dilakukan dengan langkah konvolusi aproksimasi sebanyak dua kali kemudian detail sebanyak satu kali dan aproksimasi sebanyak satu kali. Bagian kedua ekstraksi sinyal dilakukan dengan langkah konvolusi aproksimasi sebanyak dua kali, detail sebanyak dua kali dan aproksimasi sebanyak satu kali sehingga menghasilkan 48+24 = 72 titik data sinyal.
- Ekstraksi pada frekuensi Beta (14-30Hz)


Ekstraksi data sinyal Beta terbagi menjadi dua bagian. Bagian pertama ekstraksi sinyal dilakukan dengan langkah konvolusi aproksimasi sebanyak satu kali dan detil sebanyak satu kali. Bagian kedua ekstraksi sinyal dilakukan dengan langkah konvolusi aproksimasi sebanyak dua kali dan detil sebanyak tiga kali sehingga menghasilkan $192+24 = 216$ titik data sinyal.

- Ekstraksi pada frekuensi Gamma (31-50Hz)
Ekstraksi data sinyal Gamma dilakukan dengan langkah konvolusi detil sebanyak satu kali sehingga menghasilkan 384 titik data sinyal.

Keluaran ekstraksi Wavelet adalah gabungan dari titik data sinyal Teta, Alfa, Beta dan Gamma yaitu $48+72+216+384 = 720$ titik data sinyal untuk setiap kanal. Setelah itu dilakukan *filtering* yang merupakan proses mengurutkan data dari indeks terkecil sampai indeks terbesar. Setelah itu, dilakukan penggabungan data sinyal hasil ekstraksi dari empat kanal sehingga diperoleh 2.880 titik data sinyal yang menjadi data masukan Support Vector Machine atau dapat disebut juga dengan vektor fitur.


B. Support Vector Machine

Prinsip dasar Support Vector Machine adalah membangun fungsi *hyperplane* optimal dengan margin terbesar untuk memisahkan data antara dua kelas seperti +1 dan -1. Margin adalah jarak antara *hyperplane* tersebut dengan pola terdekat dari masing-masing kelas. Pola yang paling dekat ini disebut sebagai *support vector*. Proses untuk mencari fungsi *hyperplane* ini merupakan inti dari pembelajaran pada SVM. Arsitektur SVM dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur Support Vector Machine

Pada penelitian ini SVM yang digunakan adalah *hyperplane* non-linier. Dalam pencarian fungsi *hyperplane* tersebut data akan dikonversi ke dalam pemetaan dimensi yang lebih tinggi seperti pada Gambar 6.



Gambar 6. Pemetaan data input ke dimensi yang lebih tinggi

Fungsi optimisasi untuk pemisahan data non-linier adalah persamaan Lagrange Multiplier [15] seperti pada Persamaan (6).

$$L = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (6)$$

Kemudian karena penelitian ini menggunakan kernel Polynomial Ordo 2 maka Persamaan (7) digunakan untuk menggantikan operasi dot-product pada Persamaan (6).

$$K(x, x_i) = (\bar{x}_i \cdot \bar{x}_j + 1)^2 \quad (7)$$

Dengan \bar{x}_i adalah vektor fitur data latih dan \bar{x}_j adalah vektor fitur data uji sehingga koefisien fungsi *hyperplane* pemisah w berdasarkan [15] didapatkan menggunakan Persamaan (8) yang disebut dengan perhitungan *constraint*.

$$w = \sum_{i=1}^N \alpha_i y_i (\bar{x}_i \cdot \bar{x}_j + 1)^2 \quad (8)$$

Dengan N adalah jumlah data latih, α adalah koefisien alpha, y adalah nilai terhadap kelas, \bar{x}_i adalah vektor fitur data latih dan \bar{x}_j adalah vektor fitur data uji.

Setelah diperoleh koefisien fungsi *hyperplane* maka proses deteksi menggunakan SVM berdasarkan [15] dapat dilakukan dengan menggunakan Persamaan (9).

$$\text{Sign} \left(\sum_{i=1}^N \alpha_i y_i (\bar{x}_i \cdot \bar{x}_j + 1)^2 + b \right) \quad (9)$$

Keterangan :

N = jumlah fitur data latih (titik data sinyal)

α = koefisien alpha


y = nilai terhadap kelas

\bar{x}_i = vektor fitur data latih

x_j = vektor fitur data uji

b = koefisien bias

SVM dapat memisahkan dua kelas menggunakan fungsi *hyperplane*. Oleh karena itu, untuk memisahkan tiga kelas dalam penelitian ini dilakukan dua kali SVM yaitu SVM 1 dan SVM 2 seperti pada Gambar 7. Kondisi tidak konsentrasi memiliki karakteristik yaitu terjadi peningkatan pada frekuensi Alfa, sedangkan pada kurang konsentrasi terjadi peningkatan pada frekuensi Beta dan pada kondisi konsentrasi terjadi peningkatan pada frekuensi Beta dan Gamma.



Gambar 7 SVM memisahkan tiga kelas

SVM 1 bekerja untuk mendeteksi data masuk ke dalam kelas Tidak Konsentrasi atau kelas Lainnya. Jika data masuk ke dalam kelas Lainnya maka SVM 2 bekerja untuk mendeteksi data masuk ke dalam kelas Konsentrasi atau Kurang Konsentrasi.

IV. HASIL

Pelatihan dilakukan dengan menggunakan 3.840 data dari 4.500 data latih sedangkan pengujian dilakukan terhadap data yang tidak digunakan pada proses pelatihan sehingga diperoleh 660 data uji. Namun, sebelumnya dilakukan pengujian terhadap

data latih terlebih dahulu. Hasil pengujian terhadap data latih dapat dilihat pada Tabel II.

TABEL II. PENGUJIAN DATA LATIH

No	Naracoba	Jumlah Data	Data Tepat Dikenali	Akurasi (%)
1	Naracoba 1	384	384	100,0
2	Naracoba 2	384	381	99,2
3	Naracoba 3	384	383	99,7
4	Naracoba 4	384	380	98,9
5	Naracoba 5	384	384	100
6	Naracoba 6	384	376	97,9
7	Naracoba 7	384	384	100
8	Naracoba 8	384	384	100
9	Naracoba 9	384	379	98,7
10	Naracoba 10	384	160	41,7
Total		3.840	3.595	93,6

Setelah dilakukan pengujian terhadap data latih, maka dilakukan pengujian terhadap data uji. Data uji merupakan data baru yang tidak dilibatkan dalam proses pelatihan. Hasil pengujian terhadap data uji dapat dilihat pada Tabel III.

TABEL III. PENGUJIAN DATA UJI

No	Naracoba	Jumlah Data	Data Tepat Dikenali	Akurasi (%)
1	Naracoba 1	66	55	83,3
2	Naracoba 2	66	52	78,8
3	Naracoba 3	66	60	90,9
4	Naracoba 4	66	54	81,8
5	Naracoba 5	66	64	96,9
6	Naracoba 6	66	50	75,8
7	Naracoba 7	66	58	87,9
8	Naracoba 8	66	61	92,4
9	Naracoba 9	66	50	75,8
10	Naracoba 10	66	57	86,4
Total		660	561	85,0

Sebelum dilakukan pengujian atau identifikasi *real-time*, data sinyal EEG melalui tahapan ekstraksi terlebih dahulu. Namun untuk mengetahui pengaruh ekstraksi Wavelet terhadap akurasi sistem maka diperlukan pengujian tanpa ekstraksi yaitu dengan proses data sinyal EEG langsung menjadi data masukan SVM sehingga Wavelet tidak digunakan. Selain itu, terdapat pengujian dengan *filtering* Wavelet yaitu pengujian dengan data masukan SVM berupa data hasil ekstraksi berupa gabungan data frekuensi Teta, Alfa, Beta dan Gamma yang sudah diurutkan berdasarkan kemunculan seperti pada sinyal asli. Hasil pengujian dapat dilihat pada Tabel IV.

TABEL IV PERBANDINGAN JENIS EKSTRAKSI

Jumlah Data	Jenis Ekstraksi	Waktu Pelatihan	Rata-Rata Waktu Deteksi (detik)	Data Tepat Dikenali	Akurasi (%)
3840	Tanpa ekstraksi Wavelet	7 menit 19 detik	0,071	3.459	90,0
	Dengan ekstraksi Wavelet	15 menit 15 detik	0,068	3.595	93,6
	Dengan Filtering Wavelet	16 menit 3 detik	0,068	3.595	93,6

Pada penelitian ini dilakukan perbandingan hasil deteksi dari dua kanal simetrik yaitu AF3-AF4 dan T7-T8. Hasil pengujian dapat dilihat pada Tabel V.

TABEL V PERBANDINGAN HASIL DUA KANAL SIMETRIK

No.	Kanal	Jumlah Data	Jumlah Tepat Dikenali	Akurasi (%)
1	AF3-AF4	2880	2.701	93,8
	T7-T8	2880	2.597	90,2
2	AF3-AF4	3840	3.651	95,1
	T7-T8	3840	3.644	94,9

Proses deteksi respon konsentrasi terhadap rangsangan suara secara *real-time* dapat diimplementasikan seperti pada Gambar 8.



Gambar 8. Deteksi Respon Konsentrasi Secara Real Time

Gambar 8 menunjukkan seseorang memakai *wireless* EEG yang sedang belajar disertai dengan musik. Sistem deteksi yang dibangun terhubung dengan *wireless* EEG dan mendeteksi respon tingkat konsentrasi terhadap rangsangan suara yang diberikan secara *real-time* setiap enam detik. Sistem deteksi dapat dimanfaatkan untuk terapi peningkatan konsentrasi di pelayanan rehabilitasi medik dan bimbingan konsultasi pada lembaga pendidikan atau bimbingan belajar *private*.

V. KESIMPULAN

Penelitian ini telah menghasilkan sistem deteksi respon tingkat konsentrasi terhadap rangsangan suara berdasarkan sinyal Elektroensefalogram secara *real-time* menggunakan Wavelet dan Support Vector Machine. Hasil pengujian menunjukkan bahwa pelatihan tanpa ekstraksi Wavelet menghasilkan waktu pelatihan yang lebih cepat. Hal ini disebabkan karena pelatihan menggunakan Wavelet memerlukan waktu yang lebih lama untuk proses ekstraksi data sinyal asli ke dalam frekuensi Teta, Alfa, Beta dan Gamma. Namun penggunaan ekstraksi Wavelet mampu meningkatkan akurasi sebesar 3,6% dan mempercepat waktu deteksi sebanyak 0,003 detik. Dari hasil perbandingan dua kanal simetrik menunjukkan bahwa kanal AF3-AF4 0,2% lebih baik dalam mendeteksi respon konsentrasi dibandingkan dengan kanal T7-T8. Pengujian terhadap 3.840 data latih menghasilkan akurasi sebesar 93,6% sedangkan untuk 660 data uji menghasilkan akurasi sebesar 85%. Pengujian pada data uji di bawah 90% dapat disebabkan karena pengujian tersebut sangat bergantung pada hasil pelatihan dari sistem, sehingga ketelitian dalam memperoleh data latih sangat diperlukan agar dapat menghasilkan akurasi yang baik pada pengujian data uji. Rata-rata waktu deteksi yang diperoleh adalah sebanyak 0,068 detik

sehingga dapat direalisasikan pada deteksi *real-time* dengan waktu setiap enam detik.

DAFTAR PUSTAKA

- [1] E. C. Djamal and Suprijanto, "Recognition of Electroencephalogram Signal Pattern against Sound Stimulation using Spectral of Wavelet," in *TENCON*, Bali, 2011.
- [2] R. Wulansari, E. C. Djamal and T. Darmanto, "Klasifikasi Sinyal EEG Terhadap Rangsangan Suara Menggunakan Power Spectral Dencity Dan Multilayer Perceptron," in *SNST ke-7*, Semarang, 2016.
- [3] N. Jatupaiboon, S. Pan-ngum and P. Israsena, "Real-Time EEG-Based Happiness Detection System," *TheScientificWorldJournal*, vol. 2013, pp. 1-12, 2013.
- [4] Y.-P. Lin , C.-H. Wang , T.-L. Wu , S.-K. Jeng and J.-H. Chen , "EEG-Based Emotion Recognition In Music Listening: A Comparison Of Schemes For Multiclass Support Vector Machine," in *International Conference on Acoustics Speech and Signal Processing*, 2009.
- [5] M. Murugappan, M. Rizon, R. Nagarajan, S. Yaacob, D. Hazry and I. Zunaedi, "Time-Frequency Analysis of EEG Signals for Human Emotion Detection," in *Biomed 2008*, 2008.
- [6] R. Ekayama, E. C. Djamal and A. Komarudin, "Identifikasi Kondisi Rileks Dari Sinyal EEG Menggunakan Wavelet Dan Learning Vector Quantization," in *SNST ke-7*, Semarang, 2016.
- [7] R. Karmila, E. C. Djamal and D. Nursantika, "Identifikasi Tingkat Konsentrasi Dari Sinyal EEG Dengan Wavelet dan Adaptive Backpropagation," in *Seminar Nasional Aplikasi Teknologi Informasi*, Yogyakarta, 2016.
- [8] R.-N. Duan, . X.-W. Wang and B.-L. Lu, "EEG-Based Emotion Recognition in Listening Music by Using Support Vector Machine and Linear Dynamic System," *ICONIP 2012*, p. 468–475, 2012.
- [9] S. B. Akben, D. Tuncel and A. Alkan, "Classification of multi-channel EEG signals for migraine detection," *Biomed Res- India*, vol. 27, no. 3, pp. 743-748, 2016 .
- [10] T. J. Choi, J. O. Kim, S. M. Jin and Y. Gilwon, "Determination of the Concentrated State Using Multiple EEG Channels," *International Journal of Computer, Electrical, Automation, Control and Information Engineering* , vol. 8, pp. 1373-1376, 2014.
- [11] B. T. Nugraha, R. Sarno, D. A. Asfani, T. Igasaki and M. N. Munawar, "Classification Of Driver Fatigue State Based On EEG Using Emotiv EPOC+," *Journal of Theoretical and Applied Information Technology*, vol. 86, pp. 347-359, 2016.
- [12] S. Kumar and D. K. Atal, "Classification of Epileptic & Non Epileptic EEG Signal Using Matlab," *IJSRST*, vol. 2, pp. 203-207, 2016.
- [13] N.-H. Liu, C.-Y. Chiang and H.-C. Chu, "Recognizing the Degree of Human Attention Using EEG Signals from Mobile Sensors," *Sensors 2013*, pp. 10274-10286, 2013.
- [14] M. Soleymani, M. Pantic and T. Pun, "Multimodal Emotion Recognition in Response to Video," *IEEE TRANSACTIONS ON AFFECTIVE COMPUTING*, vol. 3, pp. 211-223, 2013.
- [15] P. Bhuvanewari and J. S. Kumar, "Support Vector Machine Technique for EEG Signals," *International Journal of Computer Applications* , vol. 63, pp. 1-5, 2013.