

Brain Computer Interface Untuk Aksi Memutar Lagu Terhadap Tiga Kondisi Emosional Menggunakan Spektral Daya dan Adaptive Backpropagation

Iyan Taufik Hidayat¹, Esmeralda C Djamil, Ridwan Ilyas
Jurusan Informatika, Fakultas MIPA
Universitas Jenderal Achmad Yani
Cimahi, Indonesia
[1iyantaufikhidayat@gmail.com](mailto:iyantaufikhidayat@gmail.com)

Abstrak— Musik dapat memberikan efek positif bagi kondisi psikologis dan emosional seseorang, misalnya bagi penyandang Tuna Laras dan penderita gangguan syaraf. Bagi orang yang memiliki keterbatasan fisik, mengoperasikan perangkat eksternal seperti memutar lagu tidaklah mudah. Oleh karena itu Brain Computer Interface (BCI) dengan Elektroensefalogram (EEG) sebagai perangkat intermediate adalah salah satu solusi untuk menangani masalah tersebut. Penelitian terdahulu menggunakan sinyal EEG untuk identifikasi kondisi emosi. Namun pola sinyal dari EEG tidak dapat diklasifikasikan langsung dalam bentuk kondisi emosional, sehingga dibutuhkan sebuah model komputasi yang dapat mengklasifikasikan emosi sebagai masukan dalam mengoperasikan musik dengan genre yang sesuai. Penelitian sebelumnya menggunakan BCI untuk mengendalikan kursi roda dan sebagai input dari video game. Penelitian ini telah membangun BCI melalui sinyal EEG untuk identifikasi kondisi emosional yang digunakan untuk memilih genre lagu yang dioperasikan. Model komputasi yang dibangun menggunakan Spektral Daya sebagai ekstraksi dan Adaptive Backpropagation sebagai identifikasi. Data EEG hasil perekaman diambil dua menit terakhir, dilakukan pada 10 naracoba untuk data latih dan 10 naracoba data uji dengan tiga kali perekaman dan lima kali perulangan. Sinyal EEG diekstraksi menggunakan Spektral Daya pada frekuensi 4-30 Hz dengan frekuensi sampling 128 Hz, dan diklasifikasikan menggunakan Adaptive Backpropagation. BCI terintegrasi dengan wireless EEG dalam bentuk perangkat lunak. Hasil penelitian memperoleh akurasi pengujian sebesar 99% untuk data yang telah dilatih dan 54% untuk pengujian data baru.

Kata kunci—Brain Computer Interface; Elektroensefalogram; Spektral Daya; Adaptive Backpropagation; Identifikasi Emosi

I. PENDAHULUAN

Genre lagu merupakan indikator utama dalam membedakan jenis lagu satu dengan yang lain. Ada beberapa alasan khusus bagi seseorang dalam menikmati sebuah lagu, salah satunya lagu dapat menurunkan *stress* sebesar 64% [1]. Tidak heran jika musik digunakan sebagai salah satu terapi untuk memperbaiki kondisi emosional seseorang, misalnya musik dapat memberikan efek positif bagi para penyandang Tuna Laras (cacat pengendalian diri). Untuk orang-orang yang memiliki kondisi fisik normal, mengoperasikan perangkat eksternal

seperti memutar lagu bukanlah hal yang sulit. Namun tidak begitu untuk orang-orang yang memiliki keterbatasan fisik. Ketika musik yang didengar tidak sesuai dengan kondisi emosional, mereka tidak dapat secara mudah untuk memindahkan lagu tersebut dengan *genre* yang sesuai kondisi emosional mereka. Oleh karena itu Brain Computer Interface adalah salah satu solusi untuk menangani hal-hal khusus seperti ini. Dengan bantuan teknologi ini, para penyandang Tuna Daksa dapat mengendalikan suatu perangkat eksternal tanpa melibatkan otot, suara dan gestur.

Brain Computer Interface (BCI) adalah teknologi yang memanfaatkan gelombang otak sebagai pemicu untuk mengendalikan sebuah perangkat, baik dalam bentuk perangkat lunak, ataupun perangkat keras. Otak merupakan pengendali utama pada teknologi ini. Dengan menggunakan perangkat *intermediate* seperti Elektroensefalogram, BCI mampu menerjemahkan sinyal gelombang yang dihasilkan oleh otak menjadi perintah perangkat eksternal. Penelitian sebelumnya banyak yang menggunakan BCI untuk mengendalikan perangkat keras seperti pengendalian robot secara *mobile* [2] dan mengendalikan peralatan rumah [3]. Ada juga yang menggunakan BCI untuk mengendalikan perangkat lunak seperti menggerakkan karakter *game* [4] dan menggerakkan kursor menggunakan pikiran [5].

Electroensefalogram (EEG) adalah suatu alat elektromedik untuk menangkap sinyal bioelektrik yang berasal dari aktivitas listrik pada otak. Sinyal EEG amplitudonya sangat kecil dan mempunyai pola tidak beraturan, meskipun begitu pola sinyal EEG dapat diidentifikasi menjadi pikiran tertentu. Penelitian terdahulu menggunakan EEG untuk mengidentifikasi perbedaan efek penggunaan ponsel di telinga kiri dan kanan [6], untuk identifikasi anak autisme [7], dan penelitian lain menggunakan sinyal EEG untuk mengklasifikasikan Epilepsi dan Non epilepsi [8]. Permasalahannya pola aktivitas listrik pada otak yang ditangkap sinyal EEG sangat kompleks termasuk membedakan kondisi pikiran seperti emosional. Oleh karena itu diperlukan ekstraksi sinyal terlebih dahulu sebelum diidentifikasi, salah satunya menggunakan Spektral Daya. Beberapa penelitian menggunakan Spektral Daya untuk mengekstraksi sinyal EEG sebelum dilakukan klasifikasi untuk mengendalikan komputer

[9], dan ekstraksi dalam mengenali pola sinyal EEG terhadap rangsangan suara [10].


Penelitian ini telah membangun sebuah sistem yang mampu mengidentifikasi kondisi emosional melalui sinyal EEG menggunakan Spektral Daya dan Adaptive Backpropagation. Sistem identifikasi diintegrasikan dengan *wireless* EEG dalam bentuk perangkat lunak yang dapat digunakan sebagai masukan untuk mengoperasikan lagu dengan *genre* tertentu, sehingga menjadi BCI yang dapat mengoperasikan lagu berdasarkan kondisi emosional.

Terdapat beberapa penelitian yang dilakukan dengan teknologi BCI menggunakan ekstraksi fitur Wavelet metode Bayes Net, SVM serta RBFN untuk mengendalikan kursi roda yang menghasilkan akurasi sebesar 99% [11]. Ada juga yang menggunakan BCI untuk mengontrol kursor menggunakan Discrete Wavelet Transform (DWT) sebagai ekstraksi dan SVM sebagai identifikasi, yang menghasilkan lima kelas gerakan kursor secara *real time* [12]. BCI juga digunakan untuk pasien abnormal yang diekstraksi menggunakan DWT dan diklasifikasikan menggunakan K-Nearest Neighbor (KNN) sehingga menghasilkan dua kelas [13]. Pada penelitian lain, BCI digunakan sebagai sistem kendali robot, pada penelitian tersebut menggunakan *microcontroller* untuk memproses sinyal EEG dan mengendalikan perangkat [14].

II. BRAIN COMPUTER INTERFACE

A. Akusisi Data EEG

Perolehan data didapatkan melalui perekaman pada sinyal otak dari naracoba menggunakan perangkat *wireless* EEG. EEG berfungsi untuk mengambil data bioelektrik yang berasal dari aktifitas listrik pada korteks atau permukaan kulit kepala. Sinyal yang dihasilkan dari perangkat EEG biasa disebut dengan sinyal EEG. Sinyal ini dihasilkan dari perekaman pada otak melalui elektroda EEG yang ditempel pada kulit kepala. Penempatan elektroda EEG merupakan faktor yang menentukan keberhasilan perekaman sinyal EEG. Sehingga dikeluarkan suatu metoda standar peletakan elektroda EEG oleh *International Federation of Societes of Electroencephalography* yang lebih banyak dikenal dengan istilah sistem 10-20. Dapat dilihat pada Gambar 1.



Sumber: <http://neurologiclabs.com/neuromonitoring/eeg/>

Gambar 1. Peletakan Standar Elektroda EEG

Lokasi dari masing-masing elektroda ditunjukkan dengan huruf yang terdapat pada Gambar 1 yang terdiri dari O (*occipital*), C (*Central*), T (*temporal*), P (*parietal*), Fp (*Freiprontal*), dan F (*frontal*). Ada beberapa variable yang mempengaruhi sinyal EEG diantaranya kondisi emosional, kesehatan, gangguan listrik dari tubuh yang lain, juga oleh berbagai bentuk rangsangan luar. Sementara itu rentang frekuensi EEG terdiri dari Delta (0-4 Hz), Theta (4-8 Hz), Alpha (8-13 Hz), Beta (13-30 Hz), dan Gamma (>30 Hz).

Sinyal EEG erat kaitannya dengan aktivitas kondisi pikiran seseorang. Penelitian sebelumnya melakukan identifikasi kondisi pikiran, biasanya satu variabel yang ditinjau sementara variabel lainnya dibuat konstan. Di antaranya identifikasi rileks menggunakan Wavelet dan Learning Vector Quantization dengan akurasi 63% [15], identifikasi korelasi emosi pada saat menonton tv [16], dan identifikasi kebahagiaan yang menghasilkan akurasi sebesar 76% untuk subjek dependen, dan 65% untuk subjek independen [17].

Pada penelitian ini proses perekaman menggunakan EEG Emotive Insight 4 kanal (AF3, AF4, T7, dan T8) dengan *frekuensi sampling* 128 Hz, dilakukan dalam waktu yang sama untuk setiap naracoba selama lima menit, namun data yang diambil adalah dua menit terakhir karena rangsangan yang digunakan untuk merangsang emosi berupa musik dan video yang biasanya dapat memicu emosi pada menit-menit terakhir. Jumlah naracoba sebanyak 20 naracoba, 10 untuk data latih dan 10 lainnya untuk data uji. Setiap perekaman dikondisikan untuk memunculkan kondisi emosional tertentu agar hasil perekaman memberikan data yang *valid* sesuai kondisi emosional yang diinginkan. Adapun kondisi emosional tersebut yaitu kondisi rileks, senang dan sedih. Proses perekaman menghasilkan sebanyak 150 set data untuk data latih (10 naracoba * 3 perekaman * 5 perulangan), dan 150 set data untuk data uji (10 naracoba * 3 perekaman * 5 perulangan). Setiap satu set data disegmentasi setiap 10 detik sehingga dalam satu set data menghasilkan sebanyak 12 segmen (120 detik/10 detik). Dalam satu segmen, masing-masing kanal menghasilkan sebanyak 1280 titik sinyal EEG (128 fs * 10). Jika dideretkan dalam 4 kanal, maka akan terdapat sebanyak 5.120 titik sinyal EEG yang menjadi vektor masukan untuk Adaptive Backpropagation.

Adapun skenario perekaman yang dilakukan adalah mengatur suhu ruangan pada suhu yang sesuai. Lalu naracoba diperintahkan untuk duduk dengan tegak pada kursi yang disediakan. Sebelum direkam, naracoba diperintahkan untuk menangkan pikiran dan tidak memikirkan hal-hal lain yang dapat berpengaruh pada hasil perekaman, selama maksimal 2 menit. Perekaman pertama dilakukan untuk kelas pertama yaitu kelas rileks, perekaman kedua dilakukan untuk kelas kedua, yaitu kelas sedih, dan perekaman ketiga dilakukan untuk kelas ketiga, yaitu kelas senang. Setiap perekaman dilakukan selama 5 menit. Perekaman data EEG dilakukan pada waktu-waktu tertentu untuk menghasilkan data yang lebih variatif pada jam-jam sebagai berikut.


1. Perulangan pertama dilakukan pada jam 08.00-10.00.
2. Perulangan kedua dilakukan pada jam 12.00-14.00.
3. Perulangan ketiga dilakukan pada jam 15.00-17.00.
4. Perulangan keempat dilakukan pada jam 18.00-20.00

5. Perulangan kelima dilakukan pada jam 20.00-21.00.

Data sinyal EEG yang dihasilkan dari perekaman disimpan dalam file berekstensi *.edf kemudian di *convert* ke dalam file berekstensi *.csv. Data inilah yang dimasukkan ke dalam sistem untuk diekstraksi menggunakan Spektral Daya dan diidentifikasi menggunakan Adaptive Backpropagation.

B. Sistem Kontrol BCI

Pada penelitian ini perangkat EEG merupakan kontrol utama dalam pembangunan teknologi BCI. Dengan memanfaatkan sinyal otak yang dihasilkan dari perangkat EEG, kita dapat mengendalikan perangkat eksternal lain diantaranya dapat memutar musik tanpa melibatkan fungsi fisik pada tubuh. Setiap sinyal EEG yang didapatkan dari hasil perekaman, dieksekusi melalui tahap praproses menggunakan Spektral Daya yang berfungsi untuk mengubah sinyal EEG dalam domain waktu menjadi domain frekuensi. Hasil dari proses ekstraksi ini digunakan sebagai neuron masukan untuk proses pelatihan menggunakan Adaptive Backpropagation untuk mengenali kelas dari setiap data, yang kemudian digunakan untuk memutar lagu dengan *genre* tertentu. Sistem kontrol BCI yang dibangun dalam penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Sistem Kontrol BCI

Pengujian yang dilakukan untuk sistem BCI pada penelitian ini terdiri dari pengujian secara *offline* dan identifikasi secara *real time*. Pada pengujian *offline* pengambilan data EEG dilakukan secara manual melalui perekaman, kemudian sistem diuji menggunakan data tersebut. Sementara itu untuk identifikasi *real time* pengambilan data dilakukan secara *real time* setiap 10 detik dan diolah secara langsung sebagai masukan untuk memutar musik dengan *genre* lagu tertentu.

III. METODE

Setiap data EEG yang dijadikan sebagai masukan untuk sistem, baik untuk pelatihan ataupun pengujian akan diolah terlebih dahulu melalui proses ekstraksi menggunakan Spektral Daya dan diidentifikasi menggunakan Adaptive Backpropagation.

A. Spektral Daya

Spektral Daya merupakan metode yang digunakan untuk mengolah sinyal EEG yang berada dalam domain waktu ke dalam domain frekuensi. Terdiri dari beberapa tahap, dimulai dari tahap *frame Based*, *windowing*, FFT, dan Analisis Spektral.

Proses *frame based* diawali dengan menggunakan Persamaan 1 untuk menghitung N (banyak data dari setiap *frame*) dan Persamaan 2 untuk mencari M (*overlap* pada sinyal), dengan fs merupakan *frekuensi sampling* yang digunakan dan besaran *overlap* pada setiap *frame* adalah 30-50%. Kemudian menghitung hasil akhir dari *frame based* menggunakan Persamaan 3, dengan y adalah nilai sinyal dan n merupakan indeks dari 0 sampai $N - 1$.

$$N = \text{sampling} * fs \quad (1)$$

$$M = N * \text{Overlap} \quad (2)$$

$$X(n) = y(M + n) \quad (3)$$

Tahap selanjutnya adalah proses *windowing*, bertujuan untuk meminimalisir diskontinuitas sinyal pada permulaan dan akhir setiap *frame*. Teknik *windowing* yang digunakan pada beberapa penelitian di antaranya adalah Hamming, yang mempunyai bentuk pada Persamaan 4. Hasil dari Hamming digunakan lebih lanjut pada Persamaan 5.

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), 0 \leq n \leq N - 1 \quad (4)$$

$$y(n) = y * w(n) \quad (5)$$

Langkah selanjutnya setelah *Windowing* yaitu tahap Fast Fourier Transform (FFT), bertujuan untuk mengkonversi setiap *frame* N sample dalam domain waktu ke domain frekuensi menggunakan Persamaan 6.

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x_n \left[\cos\left(\frac{2\pi kn}{N}\right) - j \left(\sin\left(\frac{2\pi kn}{N}\right) \right) \right] \quad (6)$$

Setelah proses FFT berakhir, maka langkah selanjutnya adalah melakukan analisis spektral dengan menggunakan metode Welch pada Persamaan 7. Dengan k adalah indeks FFT, x adalah banyaknya *frame* yang digunakan dalam setiap segmen, dan $y(k)$ adalah data hasil FFT ke- k pada saat *frame* ke- x .

$$S_k = \frac{1}{x} \sum_{n=1}^x y(k) \quad (7)$$

Sederhananya metode Welch merupakan metode yang digunakan untuk mengambil nilai rata-rata hasil proses FFT pada setiap segmen yang kemudian digunakan sebagai masukan untuk proses identifikasi.

Penelitian terdahulu menggunakan Spektral Daya untuk ekstraksi sinyal EEG terhadap rangsangan suara [10], [18], identifikasi trauma otak [19], dan ada juga yang menggunakan Spektral Daya untuk mengekstraksi sinyal EEG sebagai *trigger* untuk melakukan kendali pada komputer, pada penelitian tersebut dibagi menjadi dua kelas dengan hasil akurasi sebesar 73% untuk kelas pertama, dan 73% untuk kelas kedua [9].

Ekstraksi menggunakan Spektral Daya di pilih dengan pertimbangan, Spektral Daya dapat memberikan informasi setiap frekuensi dari data yang diolah ke dalam sistem, yang mana sebelumnya data tersebut masih berada dalam domain waktu. Selain itu, pertimbangan lainnya adalah karena proses klasifikasi kelas menggunakan Adaptive Backpropagation yang membutuhkan waktu yang cukup lama, maka proses ekstraksi diharuskan memiliki waktu yang lebih cepat, sehingga *delay* pada saat proses identifikasi *real time* menjadi lebih kecil. Oleh karena itu proses ekstraksi pada penelitian ini menggunakan Spektral Daya karena dapat memberikan waktu komputasi yang lebih cepat pada saat proses identifikasi *real time*.

B. Normalisasi Data

Meskipun Adaptive Backpropagation (ABP) memiliki akurasi yang cukup baik dalam mengenali suatu pola, disisi lain ABP mempunyai kelemahan yang dapat membuat pengenalan jaringan menjadi rusak dan menghasilkan akurasi pengujian yang cukup buruk. Hal ini dapat disebabkan oleh nilai data


masukannya ABP yang tidak berada pada *range* yang sama dengan nilai hasil dari fungsi aktivasi yang digunakan. Oleh karena itu salah satu cara untuk menangani kelemahan ini adalah dengan melakukan normalisasi pada data yang menjadi data masukan untuk ABP. Normalisasi data pada tahap ini dilakukan melalui penskalaan terhadap data hasil ekstraksi dalam *range* tertentu. Hal ini dilakukan agar nilai masukan dan target keluaran sesuai dengan *range* dari fungsi aktivasi yang digunakan dalam jaringan, dapat dilakukan menggunakan Persamaan 8.

$$x = \frac{(b-a) \cdot (x - x_{Min})}{x_{Max} - x_{Min}} + a \quad (8)$$

Dengan b adalah nilai rentang maksimal, a nilai rentang minimal, x merupakan data hasil ekstraksi, x_{Max} adalah data hasil ekstraksi terbesar, dan x_{Min} adalah data hasil ekstraksi terkecil.

C. Adaptive Backpropagation

Adaptive Backpropagation adalah salah satu modifikasi algoritma Backpropagation untuk perbaikan waktu komputasi dan akurasi. Metode ini merupakan bagian dari Jaringan Syaraf Tiruan (JST) yang menggunakan arsitektur Multilayer Perceptron (MLP). Arsitektur MLP terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*) seperti yang terlihat pada Gambar 3.



Gambar 3. Arsitektur Multilayer Perceptron

Algoritma Backpropagation menggunakan *error output* dibandingkan target untuk mengubah nilai bobot-bobotnya dalam arah mundur. Untuk mendapatkan *error* ini, tahap perambatan maju harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi seperti Sigmoid Biner menggunakan Persamaan 9.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

Implementasi Adaptive Backpropagation adalah mengganti nilai *learning rate* yang digunakan dalam koreksi bobot pada jaringan disetiap iterasi menggunakan Persamaan 10.

$$w^{t+1} = w^t - \lambda_t \nabla E(w^t) \quad (10)$$

Dengan w^{t+1} adalah bobot baru untuk iterasi berikutnya ($t + 1$), w^t adalah bobot pada iterasi saat (t), λ_t adalah *adaptive learning rate* dan $\nabla E(w^t)$ adalah fungsi *error* pada bobot iterasi saat (t). Nilai λ_t dapat diperoleh dari Persamaan 11.

$$\lambda_t = \begin{cases} \eta_t, & \left| \frac{\eta_t}{\eta_{t-1}} \right| \leq \mu \\ \mu \eta_{t-1}, & \text{kondisi lain} \end{cases} \quad (11)$$

Dimana $\eta_t = \frac{\delta_{t-1} \cdot \delta_{t-1}}{(\delta_{t-1} \cdot \psi_{t-1})}$ dan μ adalah faktor pertumbuhan maksimum. Sementara itu untuk mendapatkan nilai δ_{t-1} dapat menggunakan Persamaan 12, dan untuk mendapatkan nilai ψ_{t-1} dapat menggunakan Persamaan 13.

$$\delta_{t-1} = w^t - w^{t-1} \quad (12)$$

$$\psi_{t-1} = \nabla E(w^t) - \nabla E(w^{t-1}) \quad (13)$$

Dalam penelitian terdahulu, Adaptive Backpropagation digunakan untuk meningkatkan efisiensi kompleksitas iterasi pada proses pelatihan Backpropagation [20], juga dapat meningkatkan kecepatan *konvergensi* dan untuk meminimalkan *error* [21]. Penelitian lain menggunakan Adaptive Backpropagation untuk mendeteksi epilepsi dari sinyal EEG yang menghasilkan akurasi 54% untuk data uji dan 92% untuk data latih dari 10 naracoba yang telah diujikan [22].

Adaptive Backpropagation dipilih dengan pertimbangan dapat memberikan identifikasi suatu pola secara baik. Meskipun ABP memiliki waktu yang cukup lama dalam proses pelatihan, namun pada saat proses identifikasi, ABP memiliki waktu yang cukup signifikan untuk digunakan pada saat identifikasi secara *real time* karena proses yang digunakan hanya proses perambatan maju saja. Sehingga kombinasi antara Spektral Daya dan ABP merupakan kombinasi yang cukup baik dalam penelitian ini, karena dapat memberikan hasil identifikasi yang cukup sesuai dan waktu komputasi yang signifikan.

IV. HASIL DAN DISKUSI

Pengujian yang dilakukan dalam penelitian ini terdiri dari pengujian parameter pelatihan, pengujian pengaruh *adaptive learning rate* pada Backpropagation, dan pengujian pengaruh jumlah data latih.

Uji optimalisasi parameter pelatihan bertujuan untuk mencari parameter optimal proses pelatihan dengan JST (*learning rate*, minimal MSE, dan *epoch*) yang memberikan akurasi yang paling baik untuk data latih (DL) dan data baru (DB). Adapun hasil dari uji optimalisasi parameter pelatihan dapat dilihat pada Tabel 1.

TABEL I. OPTIMALISASI PARAMETER PELATIHAN

α	Epoch	Min. Error	MSE	Waktu (detik)	Akurasi (%)	
					DL	DB
0.01	5000	0.001	0.04038	43.037	95.0	53.0
		0.010	0.04462	42.226	99.0	57.0
		0.100	0.09988	1.157	89.0	51.0
	7000	0.001	0.00968	49.957	98.0	56.0
		0.010	0.03263	58.702	96.0	54.0
		0.100	0.09991	1.159	85.5	50.0
0.10	5000	0.001	0.09288	41.847	88.0	48.0
		0.010	0.11694	43.072	62.0	24.0
		0.100	0.12993	43.280	58.0	32.0
	7000	0.001	0.10312	44.366	84.5	55.5
		0.010	0.12634	60.840	67.0	46.0
		0.100	0.12571	19.589	73.5	56.0
0.2	5000	0.001	0.15445	43.602	44.0	31.0
		0.010	0.14021	42.981	40.0	23.0
		0.100	0.09478	0.767	32.0	21.0
	7000	0.001	0.14393	49.679	63.0	52.5
		0.010	0.12221	60.797	44.0	21.0
		0.100	0.09785	0.977	30.0	20.0
0.5	5000	0.001	0.24577	43.228	63.0	36.0

a	Epoch	Min. Error	MSE	Waktu (detik)	Akurasi (%)	
					DL	DB
	7000	0.010	0.23855	41.963	52.0	42.0
		0.100	0.06955	1.185	30.0	22.0
		0.001	0.30280	19.721	68.0	47.0
	0.010	0.13498	61.137	34.0	25.0	
	0.100	0.06222	1.3450	32.0	22.0	

Parameter optimal yang memberikan akurasi paling baik adalah parameter dengan *learning rate* 0.01, *epoch* 5000, waktu pelatihan selama 42.226 detik dan MSE 0.04462. Dengan parameter pelatihan tersebut menghasilkan akurasi sebesar 57.0% untuk data baru dan 99.0% untuk data latih.

Uji pengaruh Adaptive Backpropagation (ABP) dan Backpropagation (BP) memiliki tujuan untuk membandingkan akurasi dan waktu komputasi untuk data latih(DL) dan data baru(DB). Adapun hasil uji pengaruh ABP dan BP dapat dilihat pada Tabel 2.

TABEL II. UJI PENGARUH ADAPATIVE BACKPROPAGATION

Pelatihan	Waktu (detik)	Kelas	Akurasi (%)	
			DL	DB
Adaptive Backpropagation	42.226	Rileks	100	54
		Sedih	98	59
		Senang	99	58
Rata-rata			99	57
Backpropagation	59.672	Rileks	97	58
		Sedih	96	55
		Senang	96	52
Rata-rata			96	55

Pelatihan menggunakan Adaptive Backpropagation menghasilkan akurasi yang lebih baik bila dibandingkan dengan Backpropagation. Selain itu Adaptive Backpropagation dapat melakukan waktu pelatihan yang lebih cepat yaitu selama 42.226 detik, sedangkan Backpropagation memiliki waktu pelatihan selama 59.672 detik. Selain itu pelatihan menggunakan Adaptive Backpropagation menghasilkan akurasi yang lebih baik, yaitu sebesar 97% untuk pengujian data yang telah dilatih dan 57% untuk data yang tidak dilatih, sementara pada Backpropagation menghasilkan akurasi sebesar 96% untuk data latih, dan 55% untuk data baru.

Uji pengaruh jumlah data latih memiliki tujuan untuk melihat pengaruh jumlah data latih terhadap akurasi sistem pada saat identifikasi terhadap data latih(DL) itu sendiri dan data baru(DB) yang belum dilatihkan. Jumlah data latih yang digunakan pada percobaan pertama adalah 30 data latih rileks, 30 data latih sedih, dan 30 data latih senang, sehingga terdapat 90 data latih yang digunakan pada percobaan pertama. Sedangkan pada percobaan kedua jumlah data latih yang digunakan sebanyak 50 data rileks, 50 data sedih, dan 50 data senang, sehingga terdapat 150 data latih yang digunakan pada percobaan kedua. Adapun hasil uji pengaruh jumlah data latih terhadap akurasi sistem dapat dilihat pada Tabel 3.

TABEL III. PENGARUH JUMLAH DATA LATIH

Jumlah Data Latih	Waktu (detik)	Kelas	Akurasi (%)	
			DL	DB
90	36.338	Rileks	92	45
		Sedih	89	47

Jumlah Data Latih	Waktu (detik)	Kelas	Akurasi (%)		
			DL	DB	
150	61.459	Senang	90	43	
		Rata-rata		90	45
		Rileks	100	58	
		Sedih	98	60	
		Senang	99	54	
Rata-rata			99	57	

Proses pengujian menggunakan 90 data latih memang menghasilkan waktu yang lebih cepat dibandingkan dengan 150 data latih, namun pada jumlah data latih 150 menghasilkan akurasi yang lebih baik yaitu sebesar 99% untuk data latih dan 57% untuk data baru, sementara itu untuk jumlah data latih 90 menghasilkan akurasi sebesar 90% untuk data latih dan 45% untuk data baru.

Dari pengujian yang telah dilakukan, proses pengujian untuk data latih memang menghasilkan akurasi yang sangat baik, berada diatas 90%, hal ini dikarenakan data-data latih tersebut dijadikan sebagai data yang digunakan pada saat proses pelatihan. Sehingga pada saat proses pengujian untuk data latih, data-data tersebut mudah dikenali oleh sistem, sesuai dengan nilai keluaran yang diinginkan.

Sementara itu untuk data uji baru, proses pengujian menghasilkan akurasi yang cukup rendah karena data-data baru ini belum dikenali oleh sistem. Hal ini dapat dikarenakan jumlah data yang digunakan pada saat proses pelatihan masih sedikit dan karena adanya beberapa data yang cukup buruk yang dihasilkan dari proses perekaman naracoba namun tidak sesuai dengan kondisi emosional yang diharapkan dari naracoba tersebut.

V. KESIMPULAN

Penelitian ini telah menghasilkan sebuah sistem yang digunakan sebagai teknologi Brain Computer Interface(BCI) menggunakan Spektral Daya dan Adaptive Backpropagation. Parameter pelatihan yang digunakan adalah *learning rate* 0.01, *epoch* 5000 dan minimum *error* 0.001. Parameter pelatihan tersebut menghasilkan waktu pelatihan selama 42.226 detik, MSE 0.04462 dan menghasilkan akurasi sebesar 57.0% untuk data baru dan 99.0% untuk data latih.

Pelatihan dengan menggunakan Adaptive Backpropagation memiliki waktu pelatihan lebih cepat dibandingkan dengan pelatihan menggunakan Backpropagation, yaitu 42.226 detik untuk Adaptive Backpropagation dan 59.672 detik untuk Backpropagation.

Pengujian terhadap 150 data latih menghasilkan akurasi yang lebih baik dibandingkan dengan pengujian terhadap 90 data latih. Dengan jumlah data latih 150, menghasilkan akurasi sebesar 99% untuk data latih dan 57% untuk data baru, sementara itu untuk jumlah data latih 90 menghasilkan akurasi sebesar 90% untuk data latih dan 45% untuk data baru.

DAFTAR PUSTAKA

- [1] Ferawati and S. Amiyakun, "Pengaruh Pemberian Terapi Musik Terhadap Penurunan Kecemasan dan Tingkat Stress Mahasiswa," in *JUMAKiA*, Bojonegoro, 2015.

- [2] S. Ramesh, M. G. Krishna and M. Nakirekanti, "Brain Computer Interface System for Mind Controlled Robot using Bluetooth," in *International Journal of Computer Applications*, Hyderabad, 2014.
- [3] A. I. N. Alshbatat, P. J. Vial, P. Premaratne and L. C. Tran, "EEG-based brain-computer interface for automating home appliances," in *University of Wollongong Research Online*, Tafila, Jordan, 2014.
- [4] M. . Y. Abdullah, E. C. Djamal and F. Renaldi, "Aksi Game Arcade Berdasarkan Pikiran Menggunakan Filter Fast Fourier Transform dan Learning Vector Quantization," in *SNATi*, Yogyakarta, Indonesia, 2016.
- [5] Hindarto, M. Hariadi and M. H. Purnomo, "Identifikasi Sinyal Elektrode Encephalo Graph Untuk Menggerakkan Kursor Menggunakan Teknik Sampling Dan Jaringan Syaraf Tiruan," in *KURSOR*, Surabaya, Indonesia, 2011.
- [6] G. Singh, "The Effects of Mobile Phone Usage on Human Brain using EEG," in *International Journal of Computer Applications*, Jalandhar, 2014.
- [7] F. H. Duffy and H. Als, "A stable pattern of EEG spectral coherence distinguishes children with autism from neurotypical controls - a large case control study," in *BioMed Central*, Boston, 2012.
- [8] S. Kumar and D. K. Atal, "Classification of Epileptic & Non Epileptic EEG Signal Using Matlab," in *IJSRST*, Haryana, India, 2016.
- [9] J. F. D. Saa and M. S. Gutierrez, "EEG Signal Classification Using Power Spectral Features and linear Discriminant Analysis: A Brain Computer Interface Application," in *LACCEI*, Arequipa, 2010.
- [10] E. C. Djamal and Suprijanto, "Recognition of Electroencephalogram Signal Pattern against Sound Stimulation using Spectral of Wavelet," in *TENCON*, Bandung, 2011.
- [11] E. A. Mohamed, M. Z. B. Yusoff, N. K. Selman and A. S. Malik, "Enhancing EEG Signals in Brain Computer Interface Using Wavelet," in *IJIEE*, 2014.
- [12] M. H. Alomari, A. AbuBaker, A. Turani, A. M. Baniyounes and A. Manasreh, "EEG Mouse: A Machine Learning-Based Brain Computer Interface," in *IJACSA*, 2014.
- [13] S. Thejaswini, S. M. S, M. C, R. Saxena, T. R. Prasad and A. Tiwari, "Brain Computer Interface Systems To Assist Patients Using EEG Signals," in *International Journal of Innovative Research in Computer*, Bengaluru, India, 2015.
- [14] G. Varghese, J. James, L. Joseph, M. K. John, S. Mathew and S. Ramachandhran, "Human Robot Cooperative System Based on Non-invasive Brain Computer Interface," in *NCREEE*, Kothamangalam, 2015.
- [15] R. Ekayama, E. C. Djamal and A. Komarudin, "Identifikasi Kondisi Rileks Dari Sinyal EEG Menggunakan Wavelet Dan Learning Vector Quantization," in *SNST*, Semarang, 2016.
- [16] T. Nomura and Y. Mitsukura, "Extraction of Unconscious Emotions while Watching TV Commercials," in *IECON2015*, Yokohama, 2015.
- [17] N. Jatupaiboon, S. Pan-ngum and P. Israsena, "Real-Time EEG-Based Happiness Detection System," in *Hindawi*, Pathumthani, 2013.
- [18] R. Wulansari, E. C. Djamal and T. Darmanto, "Klasifikasi Sinyal EEG Terhadap Rangsangan Suara Menggunakan Power Spectral Dencity Dan Multilayer Perceptron," in *SNST*, Semarang, 2016.
- [19] A. Napoli, M. Barbe, K. Darvish and I. Obeid, "Assessing Traumatic Brain Injuries Using EEG Power Spectral Analysis and Instantaneous Phase," in *Annual International Conference of the IEEE EMBS*, California USA, 2012.
- [20] M. Khairani, "Improvisasi Backpropagation Menggunakan Penerapan Adaptive Learning Rate Dan Parallel Training," in *TECHSI*, Sumatera Utara, 2014.
- [21] S. J. Subavathi and T. Kathirvalavakuma, "Adaptive modified backpropagation algorithm based on differential errors," in *IJCSEA*, Tamilnadu, India, 2011.
- [22] W. E. Zulianto, E. C. Djamal and A. Komarudin, "Deteksi Epilepsi Dari Sinyal EEG Menggunakan Autoregressive," in *SNST*, Semarang, 2016.