

KLASIFIKASI AKTIVITAS MENTAL BERDASARKAN DATA EEG MENGGUNAKAN METODE HIBRID NEURAL NETWORK DAN FUZZY PARTICLE SWARM OPTIMIZATION DENGAN CROSS-MUTATED OPERATION

Stendy B. Sakur¹⁾, Handayani Tjandrasa²⁾

¹⁾ Jurusan Sistem Informasi, Politeknik Negeri Nusa Utara, Tahuna

²⁾ Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember, Surabaya
e-mail: aliefweb@gmail.com¹⁾, handatj@its.ac.id²⁾

ABSTRAK

Brain-computer Interface (BCI) merupakan sistem yang mentransformasikan aktivitas listrik otak terhadap kegiatan mental ke dalam pengontrolan sinyal. Electroencephalogram (EEG) merupakan salah satu sinyal yang diperoleh dari aktivitas listrik untuk melakukan klasifikasi terhadap aktifitas mental. Neural Network banyak digunakan untuk proses klasifikasi, namun proses pelatihan dengan algoritma back-propagation (BP) yang menggunakan metode gradient steepest descent solusinya banyak terjebak kedalam minimum lokal. Tujuan penelitian untuk melakukan optimalisasi dalam proses penentuan pembobotan dari metode neural network dalam mengklasifikasikan aktivitas mental sinyal EEG. Particle Swarm Optimization digunakan untuk mengoptimalkan bobot dari NN dengan Evolutionary Direction Operator dan Migration serta menggunakan Fuzzy Inference System untuk menentukan bobot inersia adaptif serta Cross-Mutated Operation merupakan strategi baru yang diusulkan. Metode ini menyediakan peningkatan akurasi untuk tiga pekerjaan aktivitas mental dimana rata-rata akurasi untuk subjek pertama adalah 54,20%, subjek dua 58,40% dan 54,48% untuk subjek tiga. Akurasi terbaik dari seluruh percobaan pada subjek pertama adalah 69,18%, subjek dua 67,20% dan 57,67% untuk subjek tiga. Dengan demikian metode yang diusulkan masih lebih baik dari metode sebelumnya.

Kata Kunci: Brain-Computer Interface, Electroencephalogram, Artificial Neural Network, Particle Swarm Optimization, Fuzzy Inertia Weight, Evolutionary Direction Operator.

ABSTRACT

Brain-Computer Interface (BCI) is a system that transforms the electrical activity of the brain against mental activities into the control signal. Electroencephalogram (EEG) is a signal derived from the electric activity to perform the classification of the mental activities. Neural Network is widely used for the classification process, but the process of training with back-propagation algorithm (BP), which uses gradient steepest descent method solution much trapped into local minimum. The aim of research to optimize the process of determining the weighting of neural network method in EEG signal classifying mental activity. Particle Swarm Optimization is used to optimize the weights of NN with Evolutionary Direction Operator and Migration and using Fuzzy Inference System to determine the adaptive inertia weight and Cross-mutated proposed a new strategy. This method provides increased accuracy for the three task mental activities where the average accuracy for the first subject was 54.20%, 58.40% subject two and 54.48% for the subject three. The best accuracy of the first subject was 69.18%, 67.20% subject two and 57.67% for the subject three. Thus the proposed method is better than the previous method.

Keywords: Brain-Computer Interface, Electroencephalogram, Artificial Neural Network, Particle Swarm Optimization, Fuzzy Inertia Weight, Evolutionary Direction Operator.

I. PENDAHULUAN

Brain-Computer Interface (BCI) menggunakan *Electroencephalography (EEG)* untuk mengukur sinyal aktivitas listrik pada otak yang merefleksikan keinginan ataupun tujuan dari pengguna sehingga dapat menyediakan keluaran *nonmuscular* baru untuk komunikasi dan kontrol sebagai sebuah teknologi antarmuka manusia dan komputer [1]. *Invasive* merupakan salah cara untuk mendapatkan aktivitas gelombang listrik dari otak dengan menanamkan elektroda secara langsung ke bagian *celebral cortex* sehingga gelombang listrik yang diperoleh tidak mengalami distorsi. Namun cara ini beresiko besar sehingga diperlukan alternatif lain yaitu pendekatan *Non-Invasive*, dimana aktivitas gelombang listrik di dapatkan melalui elektroda yang diletakkan pada

permukaan kulit kepala sehingga aman. Akan tetapi gelombang yang diperoleh tidak sekuat tipe *Invasive*, karena aktivitas listrik yang di dihasilkan oleh neuron – neuron dari otak *celebral cortex* dengan tegangan yang kecil (mV) akan dikirim melalui jaringan saraf menuju ke permukaan kulit kepala yang konsekuensinya akan mengalami distorsi yang cukup besar. *Brain-Computer Interface* bermanfaat bagi pengguna yang mengalami kerusakan total untuk saraf yang mengendalikan otot – otot gerak ataupun penyakit lain semisal *Amyotrophic lateral sclerosis (ALS)*, *brainstem stroke*, *brain* atau *spinal cord injury* (Cedera tulang belakang), *cerebral palsy*, *muscular dystrophies*, *multiple sclerosis*, yang telah mempengaruhi hampir dua juta orang di Amerika Serikat [2].

Electroencephalogram (EEG) berdasarkan pada BCI merupakan hasil pengukuran dari aktivitas gelombang listrik dari otak yang dihasilkan oleh bagian *celebral cortex* sekalipun beberapa bagian otak juga memberikan kontribusi gelombang listrik. Gelombang yang dihasilkan dari EEG – BCI berkisar antara 1 – 30 Hz band, dimana gelombang δ (1 – 3 Hz), θ (4 – 7 Hz), α (8 – 13 Hz) dan β (14 – 30 Hz) [1]. Teknik untuk memonitoring aktivitas otak termasuk signal *Electroencephalogram (EEG)*, *Electrocorticogram (ECoG)*, *Positron Emission Tomography (PET)*, *functional Magnetic Resonance Imaging (fMRI)*, dan *Magnetoencephalography (MEG)*, namun signal EEG lebih populer digunakan untuk mengimplementasi BCI dengan biaya yang rendah, *non-Invasive* dan relatif mudah untuk merekam sinyal otak [3]. Sinyal EEG dapat menjadi salah satu alternatif bagi pengguna keterbatasan fisik untuk menggerakkan kursi roda [1] dengan mengirimkan perintah hanya ke alat elektronik melalui aktivitas otak [4], berbagai macam penyakit seperti epilepsi dapat ditentukan melalui sinyal EEG [5]. Sinyal EEG yang di peroleh melalui pendekatan *Non-Invasive* memiliki gelombang yang cukup lemah sehingga sangatlah penting untuk melakukan proses digital agar dapat mengklasifikasikan perintah dengan benar.

Banyak penelitian dilakukan untuk mencari metode yang dapat menentukan tingkat keakuratan dan waktu komputasional dalam proses klasifikasi sinyal EEG, termasuk metode *hybrid* diusulkan untuk mencapai tujuan tersebut. Metode *Recurrent Neural Networks (RNNs)* digunakan untuk mengklasifikasikan sinyal EEG berdasarkan *Power Spectral Density (PSD)* menggunakan metode *Welch* yang bertujuan untuk menentukan penyakit *Epileptic Seizure*. Penelitian ini melakukan tiga tahapan proses yaitu fitur ekstraksi menggunakan metode *Welch*, mereduksinya menggunakan nilai statistik dan klasifikasi menggunakan *Recurrent Neural Networks*. Untuk menguji kinerja dari RNN dalam masalah klasifikasi yang sama maka digunakan *multilayer-perceptron neural network* dengan menggunakan *learning backpropagation* yang tingkat akurasi mencapai 100% sekalipun tidak dijelaskan waktu komputasinya [6]. Metode *hybrid* juga diusulkan untuk menentukan penyakit *Epileptic Seizure* dengan melakukan fitur ekstraksi menggunakan *Discreet Wavelete Transform (DWT)* yang kemudian direduksi menggunakan *Principle Component Analysis (PCA)*, *Independent Component Analysis (ICA)* dan *Linear Discriminant Analysis (LDA)*, hasil reduksi menjadi *input* untuk *Support Vector Machine (SVM)* dalam menentukan klasifikasi yaitu mengidap penyakit *Epileptic Seizure* atau tidak, hasilnya menunjukkan LDA mencapai 100% lebih tinggi dari keduanya yaitu ICA (99.5%) dan PCA (98.75%) [5], SVM hanya dapat digunakan untuk mengklasifikasikan sebanyak dua kelas. Penelitian lainnya yang tidak kalah penting adalah melakukan pengontrolan terhadap *electronic device* untuk berinteraksi dengan lingkungan sekitar, misalnya pengguna dengan keterbatasan fisik dapat menggunakan kursi roda yang dapat dikontrol dengan mengirimkan perintah melalui aktivitas otak ke BCI system. Metode *Artificial Neural Networks (ANN)* dengan menggunakan *Cross-Mutated (CM) Operation* digunakan untuk mengklasifikasikan tiga perintah dasar tersebut, dimana fitur ekstraksi menggunakan *Hilber-Huang Transform (HHT)*, yang hasilnya lebih baik dibandingkan dengan *Fast Fourier Transform (FFT)*, kemudian pembobotan dari ANN ditentukan dengan menggunakan *Particle Swarm Optimization (PSO)* dimana kecepatan dari partikel ditingkatkan dengan menggunakan *Fuzzy Intertia Weight* sehingga memiliki karakteristik *non-linear* [1]. Metode ini dikembangkan dari *improved particle swarm optimization* yang mengusulkan penambahan bobot inersia untuk menyeimbangkan pencarian global dan local [7;8]. Klasifikasi kegiatan mental merupakan hal penting untuk di perhatikan, sehingga banyak penelitian dilakukan sehubungan dengan hal tersebut. Metode *Neural Networks* yang proses pembobotannya dilakukan dengan menggunakan *Particle Swarm Optimization (PSO)* dimana PSO ditingkatkan dengan menggunakan *Evolutionary Direction Operator (EDO)* dan *Migration Operator* yang bertujuan untuk mempercepat pencarian global. Metode ini memiliki keuntungan yaitu (1) dapat mempertahankan dari konvergensi yang prematur, (2) dapat mempercepat pencarian global dengan menggunakan MEDO, dan (3) dapat menemukan solusi yang terbaik. Namun kelemahannya masih menggunakan bobot inersia yang memiliki sifat linear [9]. Klasifikasi dengan menggunakan metode *Correlation* berdasarkan EEG map di usulkan untuk menentukan aktivitas mental [10].

Dalam paper ini, diusulkan strategi baru dari pengembangan Metode *Improved Particle Swarm Optimization* menggunakan *Modified Evolutionary Direction Operator (MEDO)* dan *Migration* dengan menggunakan bobot inersia adaptif menggunakan *Fuzzy Inference System* dan operasi *Cross-Mutated* untuk mengklasifikasikan aktivitas mental yaitu imajinasi gerakan tangan kiri dan kanan serta mengucapkan kata.

Paper ini, akan dibagi menjadi beberapa bagian yaitu bagian 2 menjelaskan detail dari dataset EEG yang akan digunakan pada penelitian ini. Analisis strategi yang diusulkan, termasuk fitur ekstraksi, klasifikasi dan algoritma pelatihan dari NN akan dibahas pada bagian 3. Dan hasil pengujian ditunjukkan pada bagian 4. Akhirnya, kesimpulan dan pengembangan penelitian akan diberikan pada bagian 5.

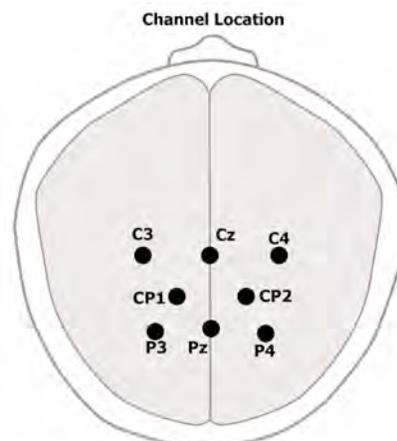
II. DATA SET SIGNAL EEG

Penelitian ini menggunakan Dataset yang disediakan oleh IDIAP Research Institute (Silvia Chaippa, José del R. Millán) [11] pada Data BCI Competition III Dataset V (Mental Imagary, Multi-Class). Dataset ini berisi data dari tiga subjek normal yang rekam selama 4 sesi tanpa umpan balik. Seluruh sesi yang dilakukan oleh subjek direkam pada hari yang sama dengan masing – masing paling kurang 4 menit dengan 5 – 10 menit waktu untuk istirahat. Setiap subjek akan melakukan pekerjaan selama 15 detik dan kemudian secara acak akan melaksanakan kegiatan lainnya sesuai permintaan dari operator. Data EEG tidak dipisahkan pada saat percobaan karena subjek akan secara menerus melakukan berbagai kegiatan aktivitas mental. Terdapat tiga aktivitas mental yang digunakan yaitu:

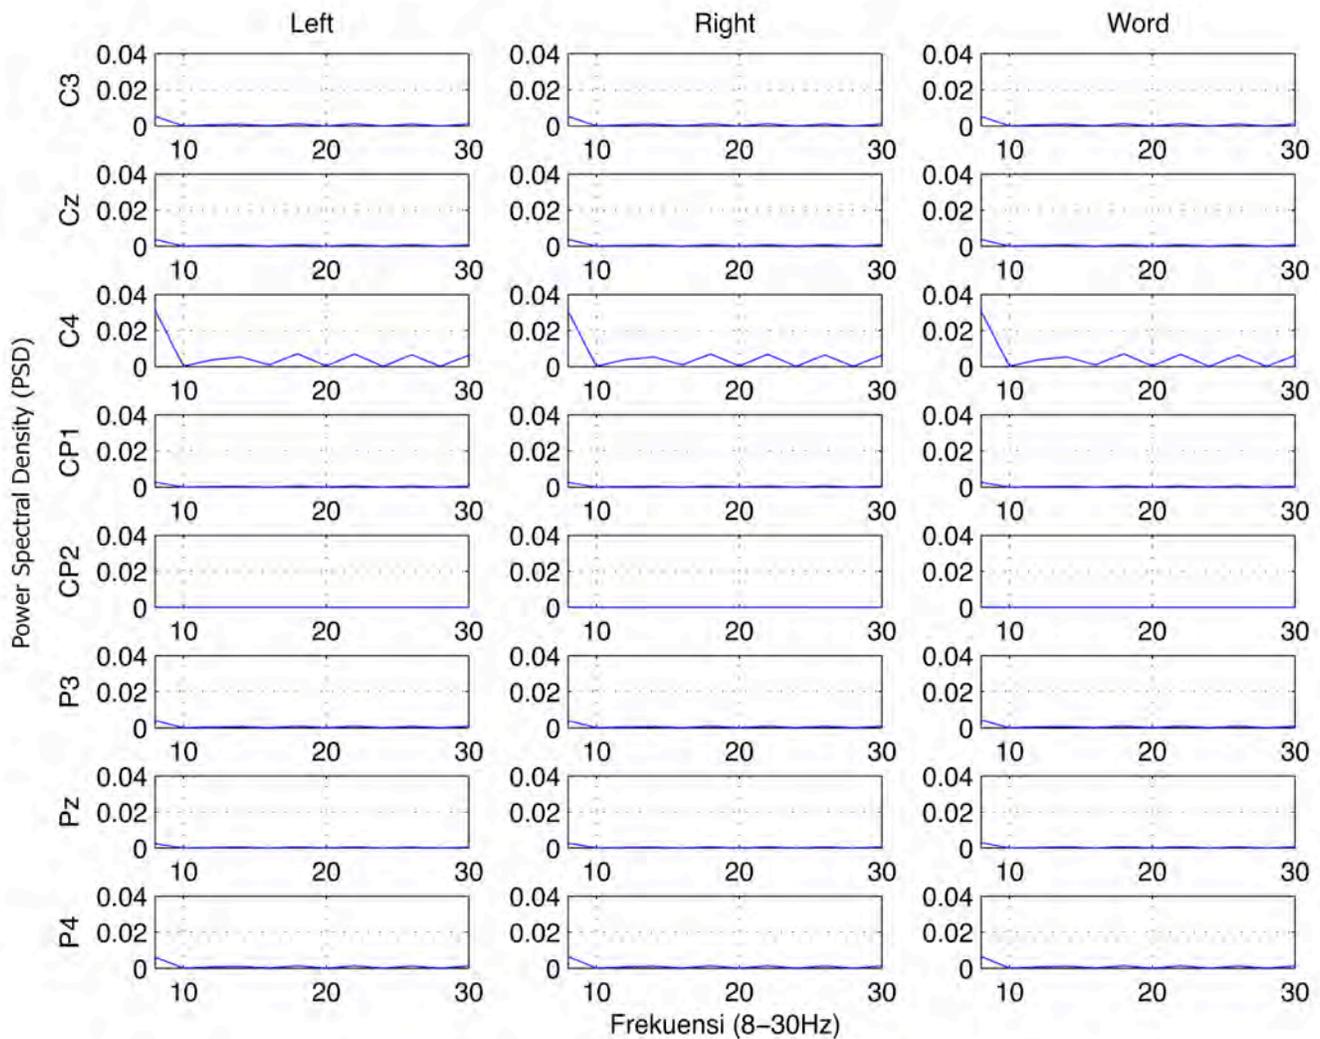
1. Membayangkan berulang kali pergerakan tangan kiri, (*kiri*, class 2)
2. Membayangkan berulang kali pergerakan tangan kanan, (*right*, class 3)
3. Membuat kata yang dimulai dengan huruf acak yang sama, (*word*, class 7)

Sinyal EEG direkam dengan sistem Biosemi menggunakan alat yang diletakkan pada permukaan kepala yang tergabung dengan 32 elektroda yang berlokasi pada standar posisi dengan sistem internasional 10 – 20 dengan *sampling rate* 512 Hz. Terdapat dua model dataset yang didistribusikan yaitu *precomputed features* dan *raw signal*. Di dalam dataset ini, data EEG tidak dipisahkan dalam percobaan karena subjek melakukan setiap kegiatan secara menerus. Data mentah EEG pertama kali di filter dengan menggunakan *surface laplacian* [11]. Elektroda EEG secara aktual diukur berdasarkan gabungan sinyal dari beberapa *neuronal clusters*, filter seperti halnya *surface laplacian* biasanya digunakan untuk menambahkan konsentrasi sinyal terhadap *neuronal cluster* tunggal [9].

Setiap 62,5 ms atau 16 kali perdetik *power spectral density* (PSD) pada band 8 – 30 Hz akan diperhitungkan selama detik terakhir dari data dengan resolusi frekuensi 2 Hz untuk 8 *centro-parietal channel* C3, Cz, C4, CP1, CP2, P3, Pz, dan P4 sehingga data EEG memiliki 96 dimensi vector yaitu 8 *channel* dikali dengan 12 frekuensi PSD setiap *channel* yang di hitung setiap 2 Hz, lokasi detail dari 8 *channel* terlihat pada Gambar 1. Metode *Welch periodogram* digunakan untuk menghitung nilai PSD [12]. Rata – rata nilai PSD untuk subjek 1 dapat dilihat pada Gambar 2, dimana pekerjaan mental dari membayangkan tangan kiri dan kanan serta mengucapkan kata – kata secara acak ditampilkan pada grafik dari kolom sebelah kiri, tengah dan kanan.



Gambar 1. Lokasi dari elektroda



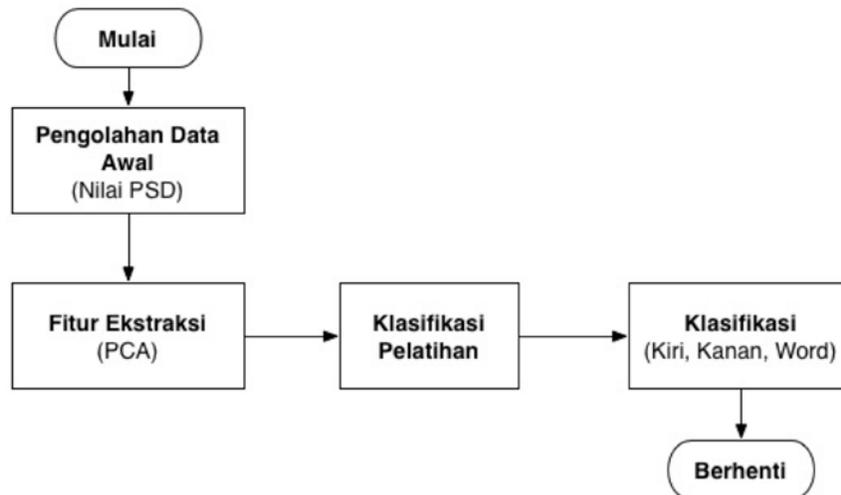
Gambar 2. Nilai PSD untuk Subjek 1

III. METODE ANALISIS

Bagian ini, akan menjelaskan metode analisis untuk klasifikasi pola EEG. Prosedur pengolahan data terlihat pada diagram alir dari Gambar 3. Secara umum, data EEG pertama kali direkam dengan *downsampling* 2 Hz yang kemudian dilakukan proses filter menggunakan *Head Geometry* berdasarkan pada *spherical surface laplacian*. Kedua, menggunakan *Principal Component Analysis* (PCA) untuk mereduksi dimensi vector fitur menjadi dimensi k . Ketiga, sinyal mental akan diklasifikasikan menggunakan tiga lapisan *Neural Network* (NN) dengan algoritma IPSONN dan Fuzzy Cross-Mutated. Setelah pelatihan jaringan, data klasifikasi dapat ditentukan. Secara detail deskripsi dari metode yang diusulkan akan dibahas pada sub bagian berikut.

A. Pengolahan Data Awal

Cross – validation digunakan untuk mengukur kinerja jaringan dan klasifikasi dari data EEG. Penggunaan prosedur *cross – validation* untuk pelatihan dari jaringan sebagai cara untuk mengendalikan data ganda selama proses pelatihan data. Pada penelitian ini, dipilih data latih sebanyak 75% dan 25% untuk data uji, dimana L simbol dari aktivitas membayangkan pergerakan tangan kiri, R merupakan simbol dari membayangkan pergerakan tangan kanan dan W merupakan pembentukan kata. Distribusi kelas yang digunakan dapat dilihat pada Tabel 1.



Gambar 3. Blok diagram dari prosedur analisis

B. Proses Filter Data EEG

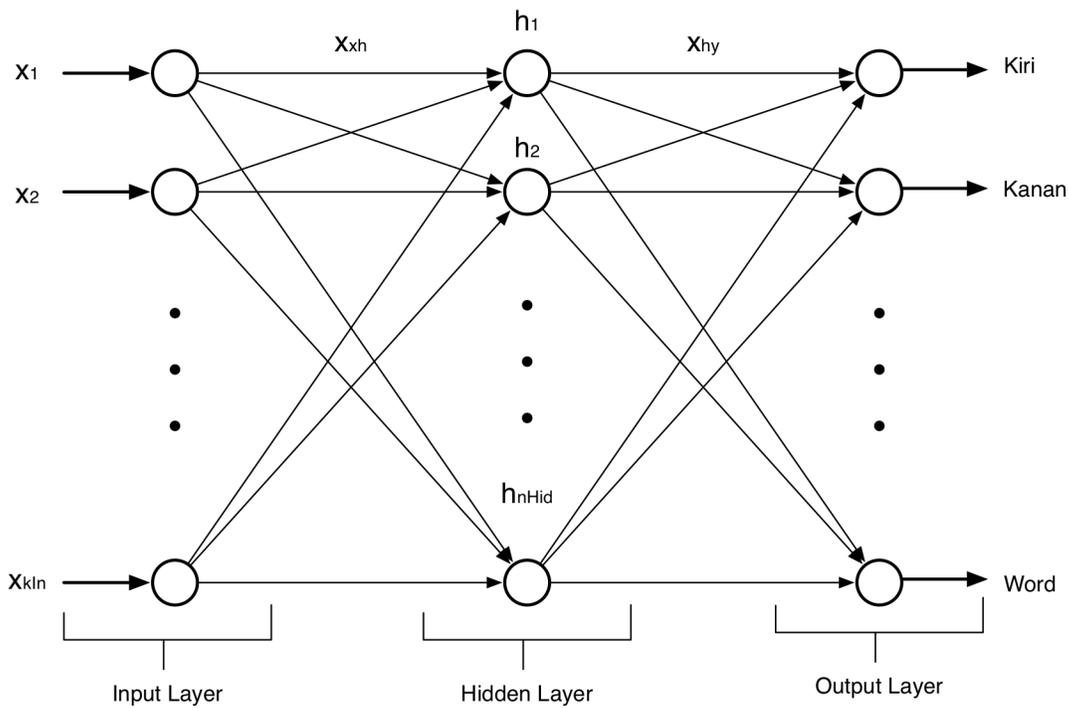
Tujuan dari filter adalah untuk memperkuat sinyal (konsentrasi) dari setiap elektroda hal ini disebabkan karena setiap channel elektroda di pengaruhi oleh electrode tetangga sehingga tegangan dari elektroda cukup besar. Melakukan proses filter akan mempertajam (konsentrasi) tegangan yang merupakan tegangan dari *channel* itu sendiri dengan menghilangkan gangguan dari elektroda tetangga. Metode *Realistic head geometry* berdasarkan pada *spherical surface laplacian* akan digunakan pada penelitian seperti yang diusulkan Siyi Deng, dkk [13]. Dengan menggunakan SSLTool [13] dapat ditingkatkan konsentrasi dari channel yang akan digunakan.

C. Fitur Ekstraksi menggunakan PCA

Sebelum melakukan proses klasifikasi, dilakukan reduksi data dari data PSD yang akan menjadi input dari proses klasifikasi. *Principal Component Analysis* (PCA) merupakan metode statistik yang digunakan secara luas untuk proses pengenalan pola. Dengan menggunakan PCA maka data PSD yang memiliki 96 fitur vector dapat direduksi menjadi dimensi k yang lebih kecil [8].

TABEL I
DISTRIBUSI KELAS UNTUK DATA LATIH DAN UJI

Subject	Class	Jumlah Data Training	Jumlah data Testing	Total Data
1	<i>L</i>	374	122	1700
	<i>R</i>	416	144	
	<i>W</i>	485	159	
2	<i>L</i>	354	123	1732
	<i>R</i>	428	142	
	<i>W</i>	517	168	
3	<i>L</i>	430	144	1720
	<i>R</i>	433	143	
	<i>W</i>	427	143	
Total Data				5152



Gambar 4. Tiga Layer Feed – Forward Neural Network [9]

D. Neural Network

Untuk klasifikasi tiga aktivitas mental, digunakan Neural Network sebagai pengklasifikasian untuk membedakan fitur PCA dari data nilai PSD sinyal EEG. Untuk mengatur parameter Neural Network secara efisien maka digunakan algoritma FMEDO (Fuzzy PSO Modified Evolutionary Direction Operator). Sebelum proses klasifikasi, data EEG perlu dinormalisasikan (yaitu, untuk data latih dan uji) dengan nilai yang berada diantara 0 dan 1.

Dalam penelitian ini akan digunakan tiga lapisan *feed-forward artificial Neural Network* dengan satu *hidden layer* dan satu *output layer* seperti terlihat pada Gambar 4, dimana kIn merupakan jumlah input node dan $nHid$ jumlah *hidden node*. Vector input akan digunakan pada input node dan di distribusikan ke setiap node yang ada di dalam *hidden layer*. Seluruh unit memiliki bobot vector yang akan dikalikan dengan input vector kemudian setiap unit akan dijumlahkan dan akan menghasilkan nilai yang akan di transformasikan oleh fungsi pengaktifan *non-linear*. Dalam penelitian ini menggunakan fungsi *Sigmoid*. Perhitungan akhir dari jaringan akan memberikan output yang merupakan hasil perkalian dari hidden layer dengan bobot vector yang kemudian diaktifkan dengan fungsi sigmoid yang hasilnya merupakan nilai output aktual dari Neural Network.

Penelitian ini, menggunakan struktur NN yang terdiri dari satu input layer, satu hidden layer dan satu output layer. Jumlah dari input layer berdasarkan jumlah dari fitur vector hasil reduksi data PSD dari proses PCA. Karena data EEG yang akan diklasifikasikan terdiri dari tiga kegiatan mental maka output layer terdiri dari tiga node yang berhubungan dengan kegiatan mental yaitu *left*, *right* dan *word*. Dimana ketiga output tersebut direpresentasikan ke dalam unit vector: $left = [1\ 0\ 0]$, $right = [0\ 1\ 0]$ dan $word = [0\ 0\ 1]$. Untuk hidden node yang akan digunakan mengikuti hasil eksperimen dari Lin [9].

E. Fuzzy IPSO (Modified EDO) dengan Cross-Mutated Operation

Particle Swarm Optimization (PSO), merupakan salah satu metode yang digunakan untuk mencari optimasi dan lebih baik dari metode algoritma genetik, dimana konsepnya mengadopsi kumpulan perilaku sosial organisme. Penelitian yang berhubungan dengan perilaku sosial organisme menjadi dukungan dalam melakukan perancangan algoritma optimasi yang sangat efisien. *Particle swarm optimization* (PSO) menggunakan model perilaku sosial dari

sekawanan burung, yang akan mencari posisi individu dan dikenal dengan partikel dalam suatu kawanan [14]. Seperti pada algoritma evolutionary lainnya, PSO membutuhkan populasi yang merupakan sekawanan organisme yang di dalamnya terdapat partikel dengan sejumlah elemen. Misalkan $X(t)$ disimbolkan sebagai sebuah kawanan pada iterasi ke t . Setiap partikel $\mathbf{x}^i(t) \in X(t)$ berisi n elemen $x_j^i(t) \in \mathbf{x}^i(t)$ pada iterasi ke t , dimana $i = 1, 2, \dots, \gamma$ dan $j = 1, 2, \dots, n$, dimana γ merupakan jumlah dari partikel di dalam kawanan dan n adalah dimensi dari partikel. Awalnya, partikel dari kawanan didefinisikan dan di evaluasi melalui fungsi fitness (objective). Di dalam PSO salah satu komponen yang penting adalah *velocity* (kecepatan), dimana berhubungan dengan kecepatan bergerak di dalam ruang pencarian. *Velocity* (kecepatan) $v_j^i(t)$ dan *Position* (posisi) $x_j^i(t)$ dari elemen ke j dan partikel ke p pada iterasi ke t , yang dapat dihitung sebagai berikut,

Untuk update kecepatan (Velocity) :

$$v_j^i(t) = v_j^i(t-1) + \varphi_1 \cdot r_1 \cdot (p_j^i - x_j^i(t-1)) + \varphi_2 \cdot r_2 \cdot (g_j - x_j^i(t-1)) \quad (1)$$

Sedangkan untuk posisi (*Position*):

$$x_j^i = x_j^i(t-1) + v_j^i(t) \quad (2)$$

dimana, $p_i = [p_1^i, p_2^i, \dots, p_n^i]$ dan $g = [g_1, g_2, \dots, g_n]$ posisi partikel i yang terbaik di tunjukkan dengan p^i , posisi terbaik dari partikel diantara seluruh partikel ditunjukkan dengan g ; r_1 dan r_2 angka acak diantara $[0,1]$.

Persamaan (1) memiliki tiga komponen yaitu kecepatan sebelumnya pada ruas pertama, bagian *cognition* atau *individual knowledge* yang merupakan perilaku pribadi dari partikel pada ruas tengah dan pada ruas akhir merupakan *social* atau *group knowledge* yang menunjukkan hubungan diantara individu dari kawanan. Persamaan tersebut dapat menyebabkan proses terlalu cepat sehingga nilai konvergensinya belum tercapai, untuk mengatasi masalah tersebut diusulkan untuk menambahkan nilai “Inertia” ω pada ruas pertama dari persamaan (1) yang bertujuan untuk menyeimbangkan antara pencarian global dan lokal, selain itu penambahan *faktor constriction* yang penting untuk memastikan konvergensi dari algoritma *particle swarm* [7], dimana persamaan (1) dimodifikasi dengan menambahkan nilai bobot inersia (*inertia weight*) dan nilai penyempitan (*constriction*) seperti berikut:

$$v_j^i(t) = k \cdot \left\{ \omega_k(t) \cdot v_j^i(t-1) + \varphi_1 \cdot r_1 \cdot (p_j^i - x_j^i(t-1)) + \varphi_2 \cdot r_2 \cdot (g_j - x_j^i(t-1)) \right\} \quad (3)$$

Secara matematis, nilai k (*constriction*) adalah fungsi dari φ_1 dan φ_2 yang terlihat seperti pada persamaan berikut,

$$k = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|} \quad (4)$$

dimana $\varphi = \varphi_1 + \varphi_2$ dan $\varphi > 4$ dan ω_k adalah faktor bobot inersia untuk menyediakan keseimbangan antara global dan lokal eksplorasi; φ_1 dan φ_2 adalah konstanta kecepatan; k merupakan faktor *constriction* yang berasal dari persamaan 2.21 untuk memastikan sistem konvergen tapi tidak dalam kondisi prematur [15], sedangkan secara umum ω_k diatur oleh persamaan berikut [8]:

$$\omega(t) = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T} \times t \quad (5)$$

dimana t jumlah iterasi yang aktif, T total jumlah iterasi, ω_{\max} dan ω_{\min} batas atas dan bawah dari bobot inersia yang secara normal di atur 1.1 dan 0.1 secara berturut – turut.

Metode *Modified Evolutionary Direction Operator (MEDO)* yang merupakan strategi untuk meningkatkan kemampuan dari PSO tradisional dalam mencari solusi yang optimal [9], dan merupakan pengembangan dari *Evolutionary Direction Operator (EDO)* tidak dapat beradaptasi dengan pergerakan dari partikel sehingga diusulkan metode FMEDO untuk mendapatkan solusi yang terbaik dengan membuat bobot inersia mampu beradaptasi dengan kondisi partikel menggunakan *Fuzzy Inference System* dan *Cross-Mutated Operation*. Persamaan (3) yaitu update kecepatan (*velocity*), *inertia weight* $\omega(t)$ digunakan untuk menyediakan keseimbangan antara global eksplorasi dan

lokal exploitasi. Dari hubungan linear antara ω dan t pada persamaan (5) terlihat bahwa ketika nilai $\frac{t}{T}$ adalah kecil maka global eksplorasi terjadi sebaliknya ketika nilai $\frac{t}{T}$ adalah besar maka lokal eksploitasi akan terjadi. Bagaimanapun banyak masalah optimasi yang memiliki sifat tidak linear, maka fuzzy bobot inersia $\tilde{\omega}(t)$ diusulkan untuk meningkatkan kemampuan pencarian [8]. Nilai $\tilde{\omega}(t)$ akan di evaluasi melalui 2 masukan *fuzzy inference system* yang juga akan menjadi keluaran untuk $\beta(t)$. Input dari system fuzzy adalah $\|\zeta(t)\|$ dan $\frac{t}{T}$. Parameter $\|\zeta(t)\|$ merupakan *normalisasi standar deviasi* diantara seluruh partikel, jika nilainya besar mengindikasikan lokasi dari partikel jauh dari lainnya, begitupun sebaliknya. Persamaan $\|\zeta(t)\|$ didefinisikan sebagai berikut,

$$\|\zeta(t)\| = \sqrt{\frac{1}{Y} \sum_{i=1}^Y (\|f(\mathbf{x}^i(t))\| - \|\bar{f}(\mathbf{x}^i(t))\|)^2} \quad (6)$$

dimana,

$$\|\bar{f}(\mathbf{x}^i(t))\| = \frac{1}{Y} \sum_{i=1}^Y \|f(\mathbf{x}^i(t))\| \quad (7)$$

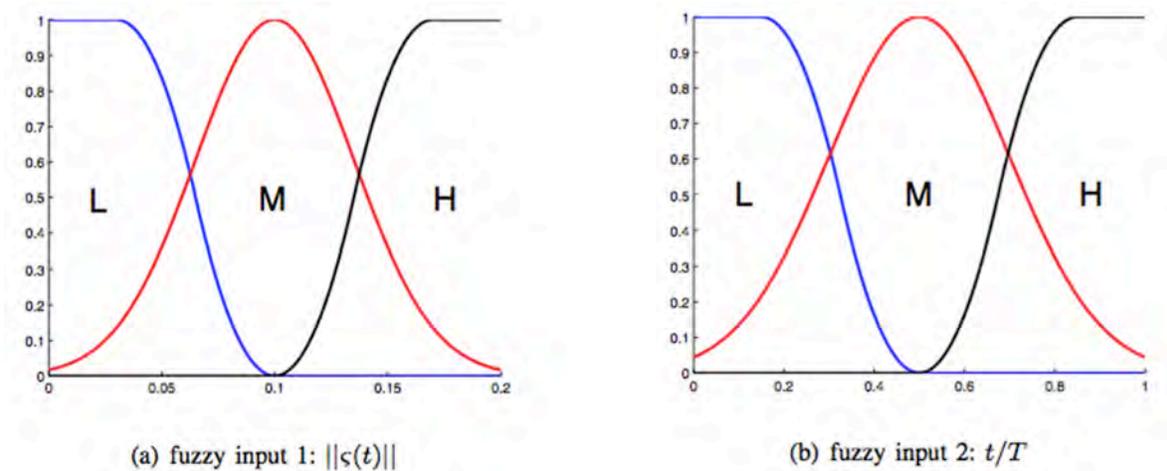
Dengan $\|\cdot\|$ di simbolkan sebagai *vector norm* (panjang vector). Sedangkan bobot inersia fuzzy megikuti aturan berikut ini,

$$\text{Rule } j: \text{IF } \|\zeta(t)\| \text{ is } N_1^j, \text{ AND } \frac{t}{T} \text{ is } N_2^j, \text{ THEN } \tilde{\omega}(t) = \sigma_j, \quad (8)$$

dimana $j = 1, 2, \dots, \varepsilon$ dan N_1^j dan N_2^j aturan dari rule j , ε disimbolkan dengan jumlah dari aturan, $\sigma_j \in [w_{\min}, w_{\max}]$ untuk kecepatan. Nilai akhir di berikan secara berurutan dari 0.1 sampai 1.1. Sehingga nilai akhir dari parameter $\tilde{\omega}(t)$ diberikan seperti persamaan berikut:

$$\tilde{\omega}(t) = \sum_{j=1}^{\varepsilon} m_j(t) \sigma_j \quad (9)$$

dimana,



Gambar 5. Fuzzy keanggotaan bobot inertia adaptif [8]

$$m_j(t) = \frac{\mu_{N_1^j}(\|\zeta(t)\|) \times \mu_{N_2^j}\left(\frac{t}{T}\right)}{\sum_{j=1}^{\epsilon} \left(\mu_{N_1^j}(\|\zeta(t)\|) \times \mu_{N_2^j}\left(\frac{t}{T}\right) \right)} \quad (10)$$

nilai $\mu_{N_1^j}(\|\zeta(t)\|)$ dan $\mu_{N_2^j}\left(\frac{t}{T}\right)$ merupakan nilai fungsi keanggotaan dari nilai N_1^j dan N_2^j seperti terlihat pada Gambar 5. Nilai bobot inersia $\omega(t)$ akan diganti dengan $\tilde{\omega}(t)$ untuk membuat kecepatan (*velocity*) $v_j^i(t)$ menggunakan *fuzzy inertia weight*. Sehingga persamaan (3) akan menjadi sebagai berikut:

$$v_j^i(t) = k \cdot \left\{ \tilde{\omega}(t) \cdot v_j^i(t-1) + \varphi_1 \cdot r_1 \cdot (p_j^i - x_j^i(t-1)) + \varphi_2 \cdot r_2 \cdot (g_j - x_j^i(t-1)) \right\} \quad (11)$$

Penelitian ini menggunakan aturan yang telah diusulkan Ling dkk [8], dengan menggunakan 3 fungsi keanggotaan untuk setiap input, dengan nama L (Low), M (Medium) dan H (High). Sedangkan untuk terminologi output diberi nama VL (Very Low), L (Low), M (Medium), H (high), dan VH (Very High) lihat Gambar 6. Dari sifat $\|\zeta(t)\|$ dan $\frac{t}{T}$ maka terdapat 9 *Linguistic value* IF-THEN aturan fuzzy untuk menentukan $\tilde{\omega}(t)$ seperti berikut ini:

RULE 1: IF $\|\zeta(t)\|$ is “L” AND $\frac{t}{T}$ is “L” THEN $\tilde{\omega}(t)$ is “VH” (=1.1)

RULE 2: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “L” THEN $\tilde{\omega}(t)$ is “H” (=0.85)

RULE 3: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “L” THEN $\tilde{\omega}(t)$ is “VH” (=1.1)

RULE 4: IF $\|\zeta(t)\|$ is “L” AND $\frac{t}{T}$ is “M” THEN $\tilde{\omega}(t)$ is “VH” (=0.6)

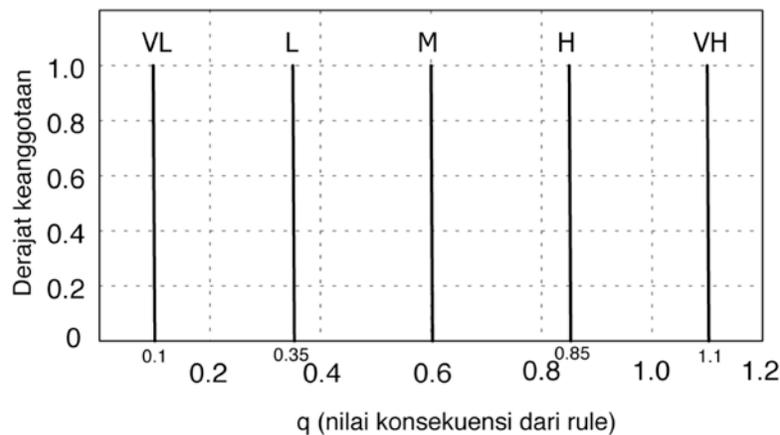
RULE 5: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “M” THEN $\tilde{\omega}(t)$ is “M” (=0.6)

RULE 6: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “M” THEN $\tilde{\omega}(t)$ is “H” (=0.85)

RULE 7: IF $\|\zeta(t)\|$ is “L” AND $\frac{t}{T}$ is “H” THEN $\tilde{\omega}(t)$ is “VL” (=0.1)

RULE 8: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “H” THEN $\tilde{\omega}(t)$ is “VL” (=0.1)

RULE 9: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “H” THEN $\tilde{\omega}(t)$ is “L” (=0.35)



Gambar 6. Output Singleton Fuzzy

Selain itu Ling dkk [8] mengusulkan penggunaan *Cross-mutated operation* yang ide dasarnya adalah menggabungkan operator *crossover* dan *mutation* dari algoritma genetik. Tujuan dari *cross-mutated operation* untuk membantu partikel keluar dari optimum lokal, dengan menggunakan parameter $\beta(t)$ yang diperoleh dari beberapa fungsi fuzzy berdasarkan pengetahuan manusia. Setiap elemen dalam partikel dari kawanan akan memiliki