

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 hasilkan 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 Inertia 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.

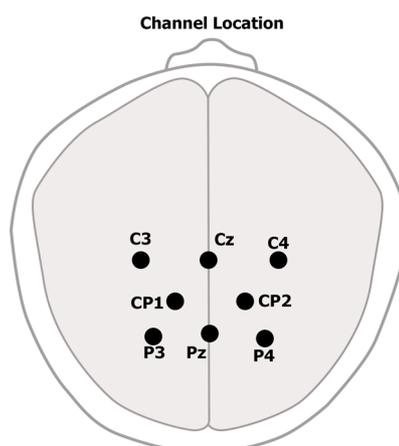
II. DATA SET SIGNAL EEG

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:

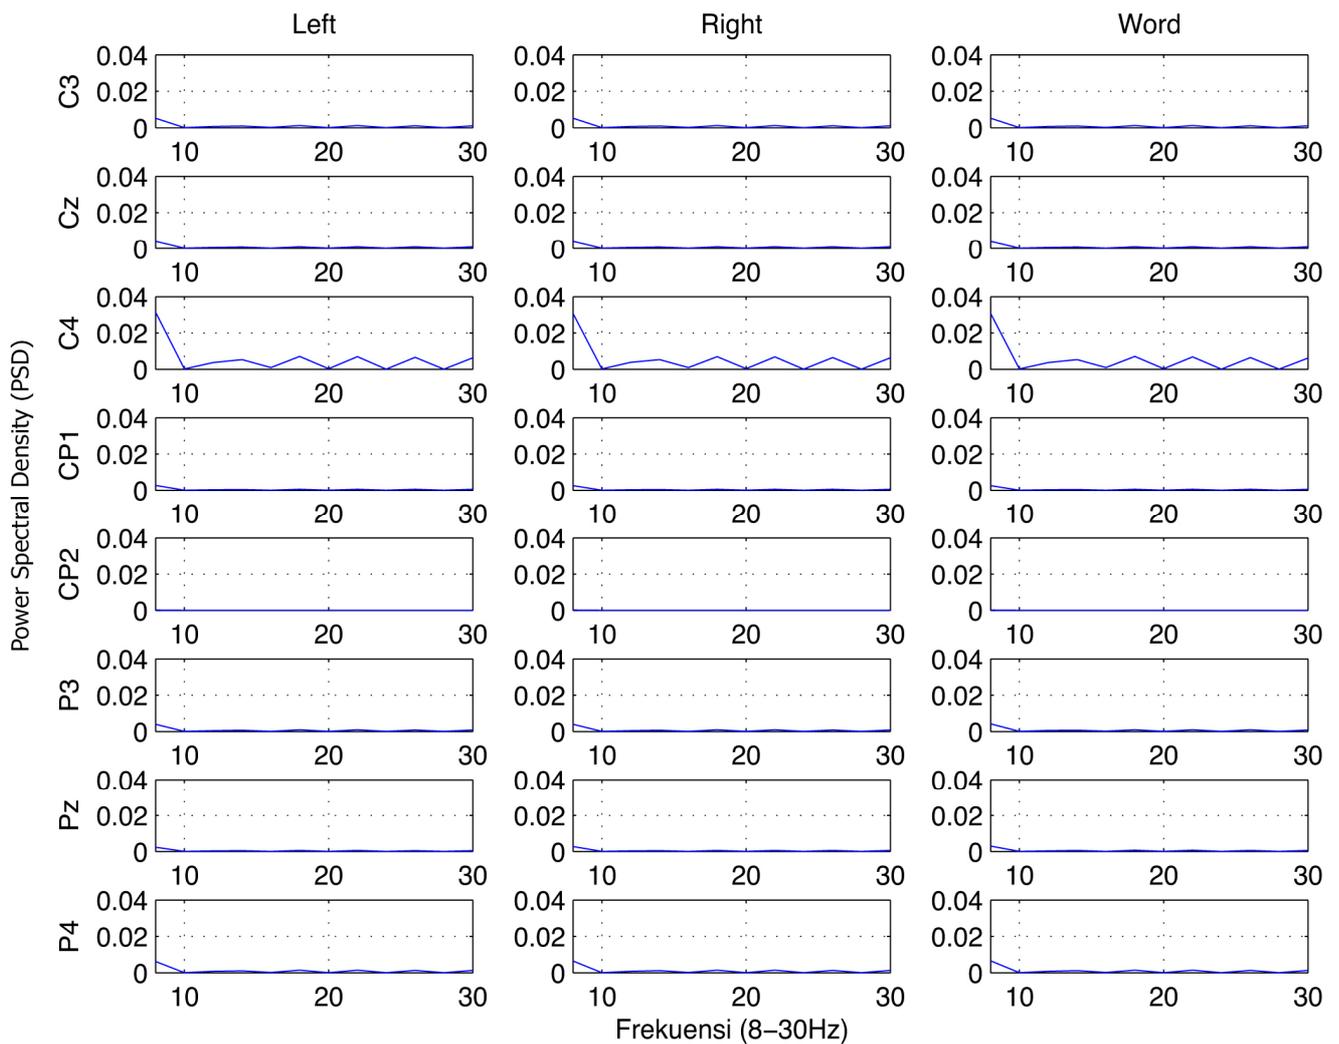
1. Membayangkan berulang kali pergerakan tangan kiri, (*kiri*, class 2)
2. Membayangkan berulang kali pergerakan tangan kanan, (*right*, class 3)
3. Membuat kata yang dimulai dengan huruf acak yang sama, (*word*, class 7)

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*. Didalam 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



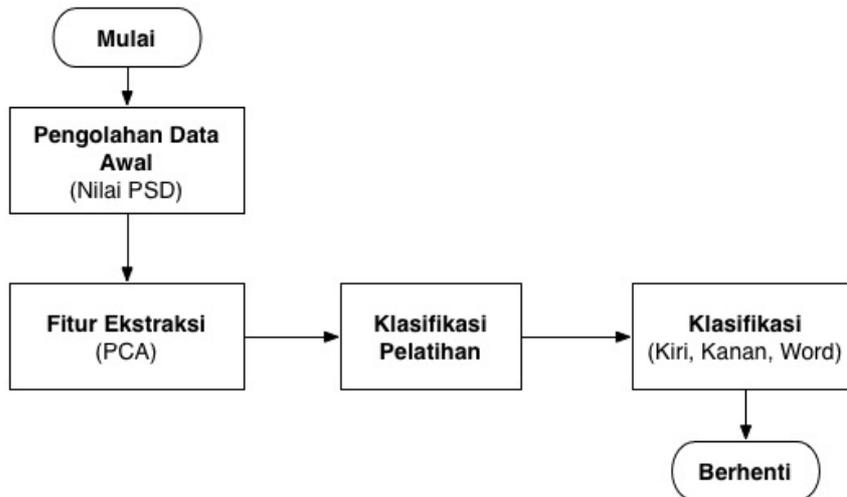
Gambar 2. Nilai PSD untuk Subjek 1

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 subbagian 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



Gambar 3. Blok diagram dari prosedur analisis

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.

B. Proses Filter Data EEG

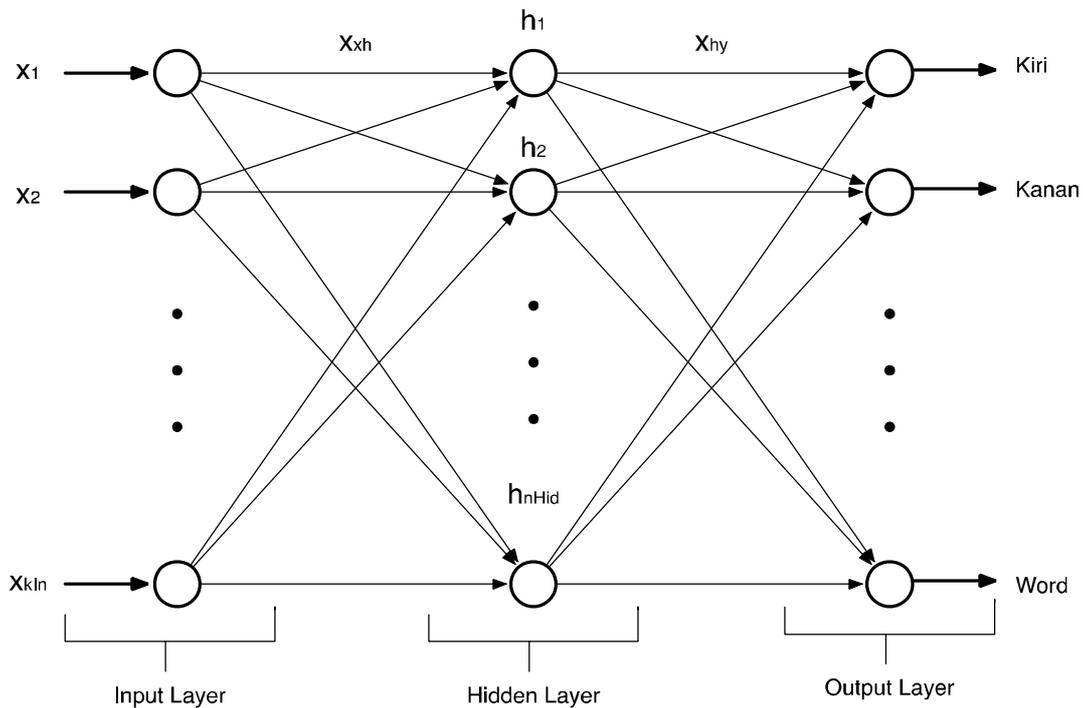
Tujuan dari filter adalah untuk memperkuat sinyal (konsentrasi) dari setiap elektroda hal ini disebabkan karena setiap channel elektroda di pengaruhi oleh electrode tetangga sehingga tegangan dari elektroda cukup besar. Melakukan proses filter akan mempertajam (konsentrasi) tegangan yang merupakan tegangan dari *channel* itu sendiri dengan menghilangkan gangguan dari elektroda tetangga. Metode *Realistic head geometry* berdasarkan pada *sphericalsurface 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]

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].

D. 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 didalamnya 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 dievaluasi melalui fungsi fitness (objective). Di dalam PSO salah satu komponen yang penting adalah *velocity* (kecepatan), dimana berhubungan dengan kecepatan bergerak didalam 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):

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

Sedangkan untuk posisi (*Position*):

$$x_j^i = x_j^i(t-1) + v_j^i(t) \tag{2}$$

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:

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

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

$$k = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|} \tag{4}$$

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]:

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

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 eksploitasi. 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 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 masukkan *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:

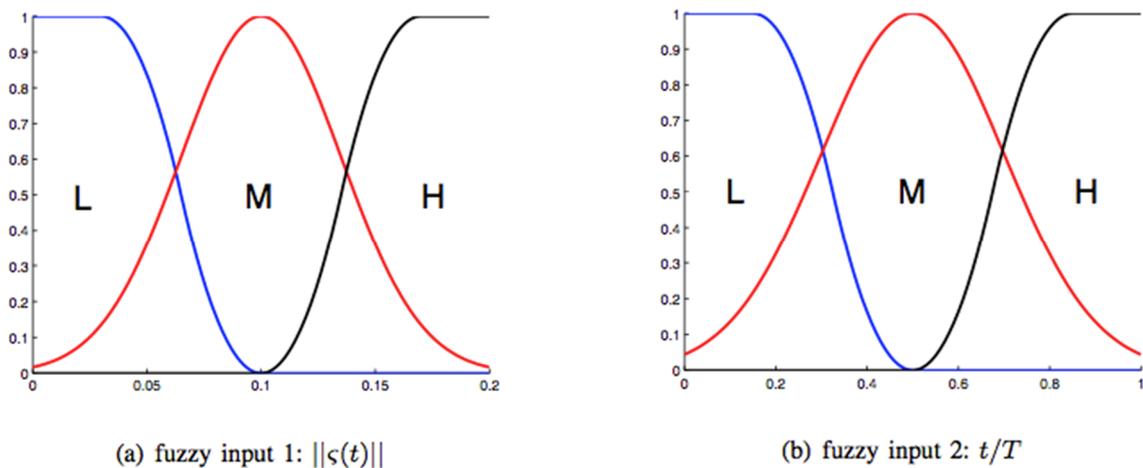
$$\tilde{\omega}(t) = \sum_{j=1}^{\varepsilon} m_j(t) \sigma_j \quad (9)$$

dimana,

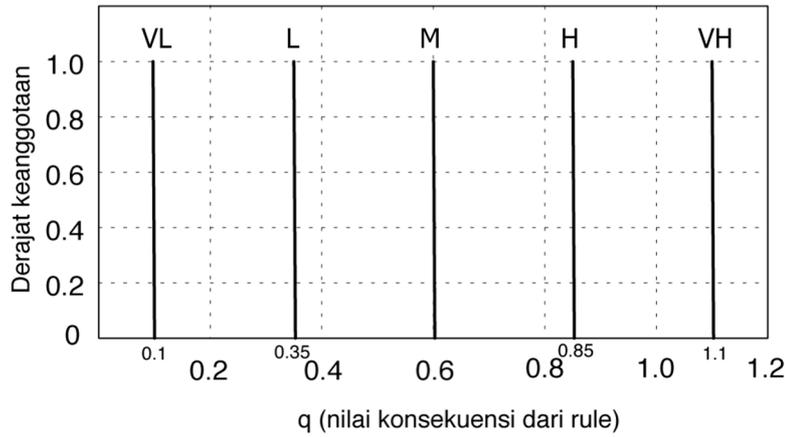
$$m_j(t) = \frac{\mu_{N_1^j}(\|\zeta(t)\|) \times \mu_{N_2^j}\left(\frac{t}{T}\right)}{\sum_{j=1}^{\varepsilon} \left(\mu_{N_1^j}(\|\zeta(t)\|) \times \mu_{N_2^j}\left(\frac{t}{T}\right) \right)} \quad (10)$$

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:

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



Gambar 5. Fuzzy keanggotaan bobot inertia adaptif [8]



Gambar 6. Output Singleton Fuzzy

Penelitian ini mengguakan 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)

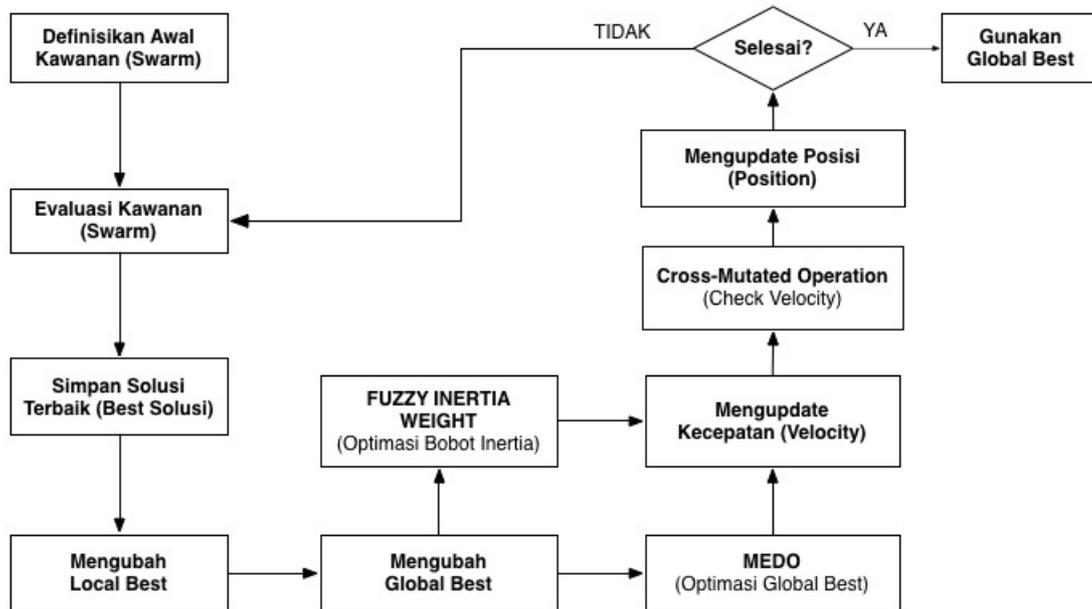
Selain itu Ling dkk [8] mengusulkan penggunaan *Cross-mutated operation* yang ide dasarnya adalah menggabungkan operator *crossover* dan *mutation* dari algoritma genetik. Tujuan dari *cross-mutated operation* untuk membantu partikel keluar dari optimum lokal, dengan menggunakan parameter $\beta(t)$ yang diperoleh dari beberapa fungsi fuzzy berdasarkan pengetahuan manusia. Setiap elemen dalam partikel dari kawanan akan memiliki kesempatan untuk mengalami *Cross-mutated* (CM) operation berdasarkan pada probabilitas CM, $p_{cm} \in [0, 1]$ yang didefinisikan oleh pengguna. Setiap elemen dalam partikel R_{cm} akan membuat bilangan acak antara 0 dan 1 jika nilainya lebih kecil dari p_{cm} maka operasi CM akan menggantikan posisi elemen tersebut. Pemilihan nilai p_{cm} akan memberi efek terhadap kualitas solusinya. Hasil kecepatan (*velocity*) dari elemen partikel di bawah operasi CM diberikan sebagai berikut,

$$\tilde{v}_j^i(t) = \begin{cases} (1 - \beta(t))v_j^i(t) + \beta(t)\tilde{v}_j^i(t), & r_3 > 0.5 \\ (1 - \beta(t))v_j^i(t) - \beta(t)\tilde{v}_j^i(t), & r_3 \leq 0.5 \end{cases} \tag{12}$$

dimana,

$$\tilde{v}_j^i(t) = 0.25 \{r_4 \cdot (\rho_{\max_j} - \rho_{\min_j}) + \rho_{\min_j}\}, \tag{13}$$

dimana $v_j^i(t)$ diperoleh dari persamaan (11), $\tilde{v}_j^i(t)$ merupakan bilangan acak untuk kecepatan (*velocity*) dari elemen partikel dan nilainya dibuat dari bilangan acak yang dibatasi pada jangkauan 0.25 dari nilai elemen partikel. Ini berarti kecepatan maksimum dan minimum dibatasi pada 0.25 dari jangkauan nilai elemen partikel.



Gambar 7. Bagan alir metode FMEDO

Diusulkan nilai $\beta(t)$ yang dapat dihitung berdasarkan aturan fuzzy berikut:

$$\text{Rule } j: \text{ IF } \|\zeta(t)\| \text{ is } N_2^j, \text{ THEN } \beta(t) = \chi_j, \quad j = 1, 2, \dots, \varepsilon \quad (14)$$

Nilai akhir dari $\beta(t)$ diberikan pada persamaan berikut:

$$\beta(t) = \sum_{j=1}^{\varepsilon} m_j(t) \chi_j. \quad (15)$$

Selain itu, penelitian ini juga menggunakan 9 *linguistic Value* IF-THEN aturan fuzzy untuk menentukan $\beta(t)$ yang diusulkan oleh Ling dkk [8] sebagai berikut:

- Rule 1: IF $\|\zeta(t)\|$ is “L” AND $\frac{t}{T}$ is “L”, THEN $\beta(t)$ is “VH” (=0.5)
- Rule 2: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “L”, THEN $\beta(t)$ is “H” (=0.4)
- Rule 3: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “L”, THEN $\beta(t)$ is “VH” (=0.5)
- Rule 4: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “M”, THEN $\beta(t)$ is “H” (=0.4)
- Rule 5: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “M”, THEN $\beta(t)$ is “M” (=0.3)
- Rule 6: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “M”, THEN $\beta(t)$ is “H” (=0.4)
- Rule 7: IF $\|\zeta(t)\|$ is “L” AND $\frac{t}{T}$ is “H”, THEN $\beta(t)$ is “VL” (=0.1)
- Rule 8: IF $\|\zeta(t)\|$ is “M” AND $\frac{t}{T}$ is “H”, THEN $\beta(t)$ is “L” (=0.2)
- Rule 9: IF $\|\zeta(t)\|$ is “H” AND $\frac{t}{T}$ is “H”, THEN $\beta(t)$ is “L” (=0.2)

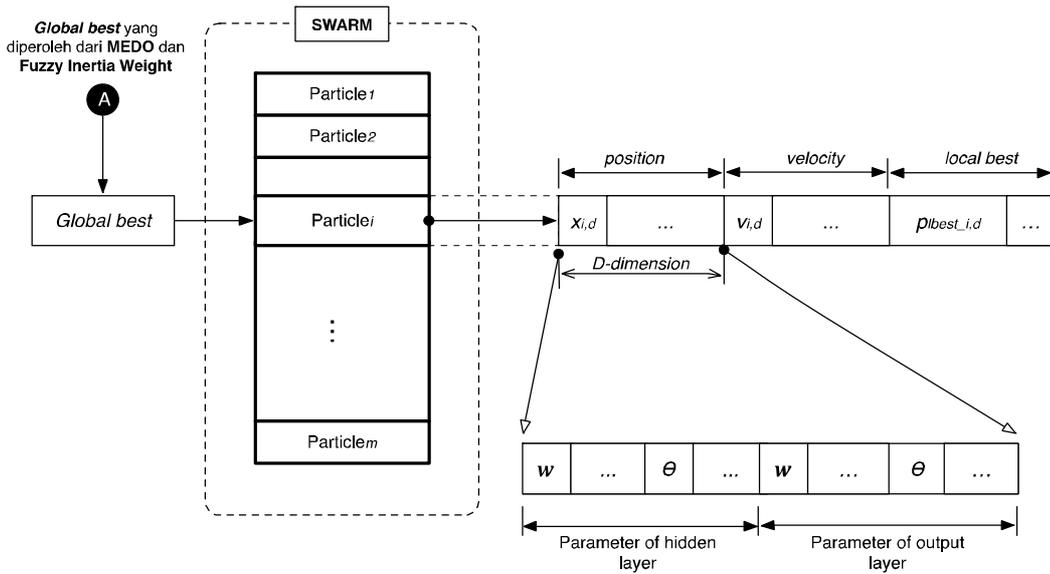
Strategi baru ini disebut FMEDO dan bagan alirnya terlihat seperti pada Gambar 7. Yang mana penjelasan dari proses pelatihan akan diuraikan sebagai berikut:

1) *Definisi Awal kawan (swarm)*

Definisi awal jumlah kawan m partikel dengan posisi dan kecepatan secara acak dari dimensi D dalam ruang pencarian. Dalam penelitian ini, koordinat posisi dari partikel di dalam dimensi d berhubungan dengan setiap variabel (bobot dan bias) yang akan dilatih pada jaringan saraf tiruan (Gambar 8).

2) *Mengevaluasi kawan*

Setiap partikel akan dievaluasi *fitness* tergantung pada optimasi yang diinginkan. Untuk evaluasi dari NN menggunakan *mean absolute error* (MAE) [16] yang di hitung sebagai berikut:



Gambar 8. Struktur dari kawanan (swarm) [9]

$$MAE = \sqrt{\frac{1}{nTr} \sum_{i=1}^{nTr} \sum_{j=1}^{nOut} |t_{i,j} - y_{i,j}|} \tag{16}$$

dimana nTr merupakan jumlah data training, $nOut$ jumlah dari output jaringan, dan $t_{i,j}$ dan $y_{i,j}$ merupakan target output ke- j dan jaringan output sesungguhnya dari data pelatihan ke- i . fungsi fitness didefinisikan sebagai berikut:

$$Fitness = \frac{1}{1 + MAE} \tag{17}$$

3) Mengubah local best dan global best

Kemudian dilakukan perubahan pada *local best* dan *global best*. Jika nilai *fitness* dari partikel lebih tinggi daripada *local best* maka *local best* akan menggantikan partikel, dan lebih lanjut jika *local best* lebih baik dari *global best* saat ini, maka *global best* harus di ubah di dalam kawanan.

4) Modified Evolutionary Direction Operator

Dengan menggunakan MEDO akan dipilih tiga solusi terbaik didalam setiap generasi untuk melakukan operasi arah evolusi. Gambar 9 memperlihatkan bagan alir untuk MEDO [9]. Setelah proses pembelajaran akan di tentukan tiga nilai partikel yang terbaik dan akan di urutkan berdasarkan fungsi fitness yaitu “low”, “medium” dan “high” partikel. Tiga input (preferred) dan partikel keluaran (created) yang di simbolkan sebagai berikut:

Partikel Input:

Partikel “low”, $C_l = (C_{l1}, C_{l2}, C_{l3}, \dots, C_{ld})$, dengan fitness F_l

Partikel “medium”, $C_m = (C_{m1}, C_{m2}, C_{m3}, \dots, C_{md})$, dengan fitness F_m

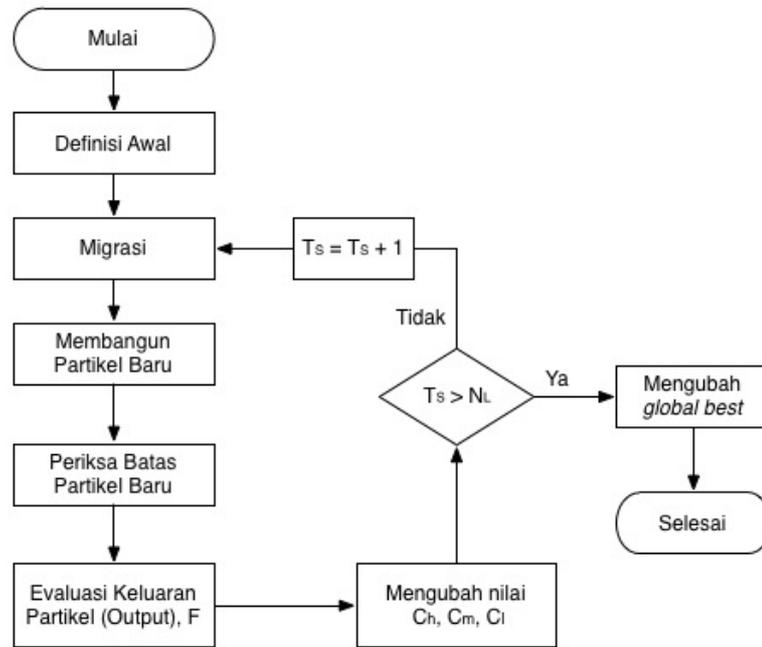
Partikel “high”, $C_h = (C_{h1}, C_{h2}, C_{h3}, \dots, C_{hd})$, dengan fitness F_h

Partikel Output, $C_o = (C_{o1}, C_{o2}, C_{o3}, \dots, C_{od})$, dengan fitness F_o .

Secara ringkas dapat di jelaskan prosedur dari MEDO,

Step 1: Mengatur *magnitudes* dari dua arah evolusi dengan 1 (*misl*, $D_1 = 1$ dan $D_2 = 1$), mendefinisikan nilai awal index dengan nilai 1 ($T_s = 1$), mendefinisikan akhir dari iterasi dengan 10 ($N_L=10$).

Step 2: Lakukan operasi migrasi untuk membangun populasi baru yang beragam dan dibentuk berdasarkan pada individu yang terbaik, $X_t = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{id})$ dan *low particle* (C_l) serta *medium particle* (C_m) akan di update dengan persamaan:



Gambar 9. Bagan Alir dari MEDO

$$x_{id} = \begin{cases} x_{id} + \rho(x_{id}^L - x_{id}) & \text{if } r_1 < \frac{x_{id}^U - x_{id}^L}{x_{id}^U - x_{id}^L} \\ x_{id} + \rho(x_{id}^U - x_{id}) & \text{lainnya} \end{cases} \quad (18)$$

dimana ρ dan r_1 merupakan bilangan acak $[0,1]$. x_{id}^L batas bawah dari partikel dan x_{id}^U batas atas dari partikel. Jika nilai fitness tidak mengalami peningkatan maka proses migrasi dilakukan.

Step 3: Hitung nilai C_o dengan menggunakan persamaan

$$C_{oj} = C_{lj} + D_1 \times (C_{lj} - C_{mj}) + D_2 \times (C_{lj} - C_{hj}) \quad (19)$$

dimana, C_{oj} merupakan output partikel ke $-j$, C_{lj} , merupakan nilai partikel “Low“ yang ke $-j$, C_{mj} , merupakan partikel “Medium” yang ke $-j$, dan C_{hj} merupakan partikel “High” ke $-j$.

Step 4: Periksa apakah partikel yang baru melewati batasan yang telah ditentukan yaitu dengan menggunakan persamaan,

$$C_{op} = \max[\min(C_{oj}, C_o^{MAX}), C_o^{MIN}]; \quad p = 1, \dots, n \quad (20)$$

Step 5: Evaluasi fitness baru F_o dari partikel output yang baru dibuat (C_{op}).

Step 6: Update partikel “Low” (C_l), partikel “Medium” (C_m) dan partikel “High” (C_h). Dengan cara berikut [16],

- (1) IF $F_o > F_h$ then $D_1 = D_1 \times -0.5$ and $D_2 = D_2 \times -0.5$
- (2) IF $F_o < F_h$ and $F_o = F_l = F_m$ then $C_{oj} = C_{oj} + N_r$, dimana $N_r \in [0,1]$
- (3) IF $F_o < F_h$ and $F_o \neq F_l \neq F_m$ then
- (4) IF $F_o < F_l$ then $C_l = C_o$;
- (5) IF $F_o < F_m$ and $F_l < F_o$ then $C_m = C_o$
- (6) IF $F_o < F_h$ and $F_m < F_o$ then $C_h = C_o$

Step 7: Jika MEDO berakhir lanjut ke langkah terakhir jika tidak langkah kedua diulangi dengan menaikkan

$$T_s = T_s + 1.$$

TABEL 2
PARAMETER YANG DIGUNAKAN UNTUK PELATIHAN DAN PENGUJIAN

Parameter	IPSONN (Metode NN + PSO + Migration)	FMEDO (Metode NN + PSO + Migration + Fuzzy + Cross-Mutation)	Keterangan
Batas Atas Partikel	100	100	Untuk membatasi pencarian partikel dalam ruang pencarian.
Batas Bawah Partikel	-100	-100	
Velocity (Kecepatan; V_{max})	2	0.2	Untuk Fuzzy 10% - 20%.
Jumlah Partikel	50	50	Hanya digunakan pada metode FMEDO.
Probabilitas Cross-mutated (P_{cm})	-	0.001	
Inertia Cognitive	0.99	(Bobot Fuzzy Dinamis)	Untuk Fuzzy+CM Inertia Cognitive dicari berdasarkan iterasi dan standar deviasi.
Cognitive Coefficient	1.99	2.05	Untuk Fuzzy+CM total nilai ini harus > 4.
Social Coefficient	1.99	2.05	
D1	1.0	1.0	Jumlah proses Migrasi.
D2	1.0	1.0	
N_L	10.0	10.0	
Constriction (k)	-	0.7298	Berdasarkan Persamaan 2.22. $k = \frac{2}{ 2 - \varphi - \sqrt{\varphi^2 - 4\varphi} }$

TABEL 3
STRUKTUR NEURAL NETWORK DAN PARAMETER LAIN

Komponen	IPSONN (Metode NN + PSO + Migration)	FMEDO (Metode NN + PSO + Migration + Fuzzy + Cross-Mutation)	Keterangan
Iterasi	1000	1000	-
Struktur Neural Network:			
Feed-Forward Neural Network	1 Input Layer; 1 Hidden Layer dan; 1 Output layer		-
Lapisan Input	20 node	20 node	Berdasarkan reduksi data dari PCA.
Lapisan Hidden	22 node	22 node	-
Lapisan Output	3 node	3 node	Left (1 0 0); Right (0 1 0); Word (0 0 1)
Elemen Particle Swarm Optimization			
Elemen Partikel	531	531	Merupakan jumlah dari bobot dan bias pada input layer + hidden layer + output layer.

TABEL 4
HASIL PENGUJIAN UNTUK KEDUA METOD
(HASIL RATA – RATA DARI BEBERAPA KALI PENGUJIAN)

Metode	Akurasi Subjek 1 (%)	Akurasi Subjek 2 (%)	Akurasi Subjek 3 (%)	Rata – rata Akurasi (%)
FMEDO (Fuzzy + MEDO)	54.20	58.43	50.80	54.48
IPSONN	52.94	45.80	50.00	49.58
Peningkatan	+(1.26)	+(12.63)	+(0.80)	

Step 8: Update *global best* setelah itu hitung velocity beserta dengan komponen *fuzzy inertia weight*.

5) *Hitung Adaptive Bobot Inersia*

Jika *global best* telah menemukan parameter yang tepat, maka dapat dihitung bobot inersia dengan menggunakan *fuzzy inertia weight* seperti pada Gambar 10.

6) *Update Velocity*

Setelah *global best* diperoleh melalui MEDO dan bobot inersia diperoleh dari metode *Fuzzy Inertia Weight* maka persamaan kecepatan (velocity) dapat dihitung.

7) *Periksa Minimum Lokal*

Langkah selanjutnya kecepatan akan diperiksa untuk mencegah agar tidak terjebak dalam minimum lokal dengan menggunakan operasi *Cross-mutated*(CM).

8) *Hitung Posisi Partikel*

Selanjutnya hitung posisi dari setiap elemen yang ada di dalam partikel dengan *global best* yang sudah ditemukan pada langkah MEDO. Jika kondisinya seperti yang di harapkan maka ambil nilai dari *global best* untuk menggunakan seluruh posisi dari elemen yang ada di dalam partikel dan dijadikan sebagai *bobot* dan *bias* pada jaringan saraf tiruan. Selanjutnya proses pelatihan dari jaringan dilanjutkan jika bobot sudah konvergensi maka gunakan sebagai parameter pengujian dari signal EEG.

IV. HASIL PENGUJIAN

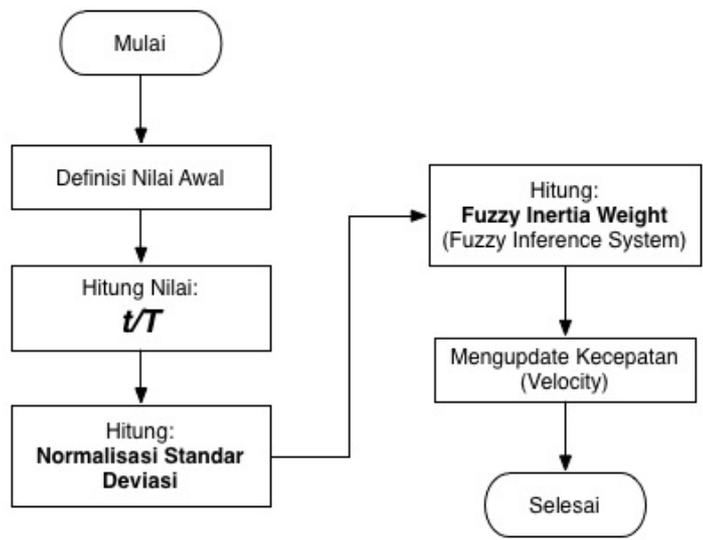
Bagian ini digunakan untuk menguraikan proses klasifikasi terhadap sinyal EEG (electroencephalogram) untuk tiga pekerjaan mental. Proses pelatihan (training) dilakukan dengan menggunakan *Neural network feed-forward* dimana proses pembobotan dari jaringan di optimasi menggunakan *particle swarm optimization* yang menggunakan bobot inersia dinamis dengan aturan fuzzy yang telah di tentukan.

A. *Pengaturan Bobot*

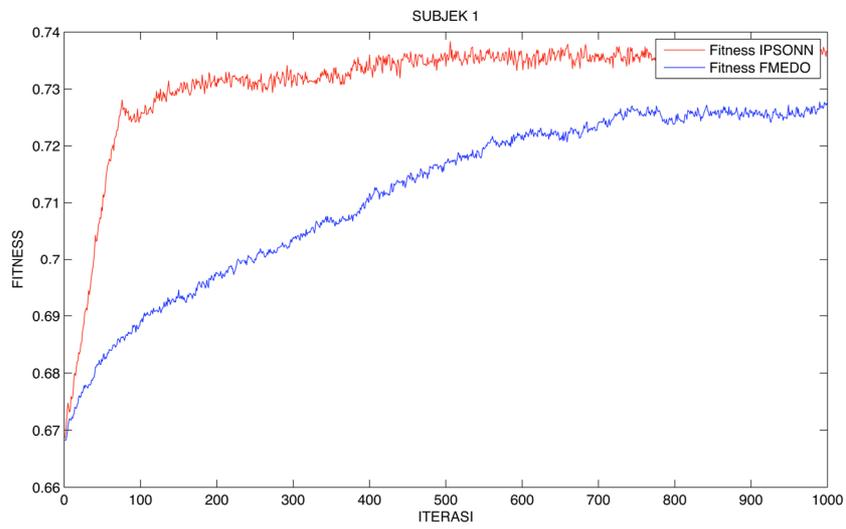
Penggunaan parameter dapat dilihat pada Tabel 2 dimana parameter yang digunakan berdasarkan penelitian sebelumnya. Kedua metode memiliki parameter yang berbeda untuk mendapatkan hasil yang maksimal, selain itu Tabel 3 menunjukkan struktur NN yang digunakan.

B. *Hasil Pengujian*

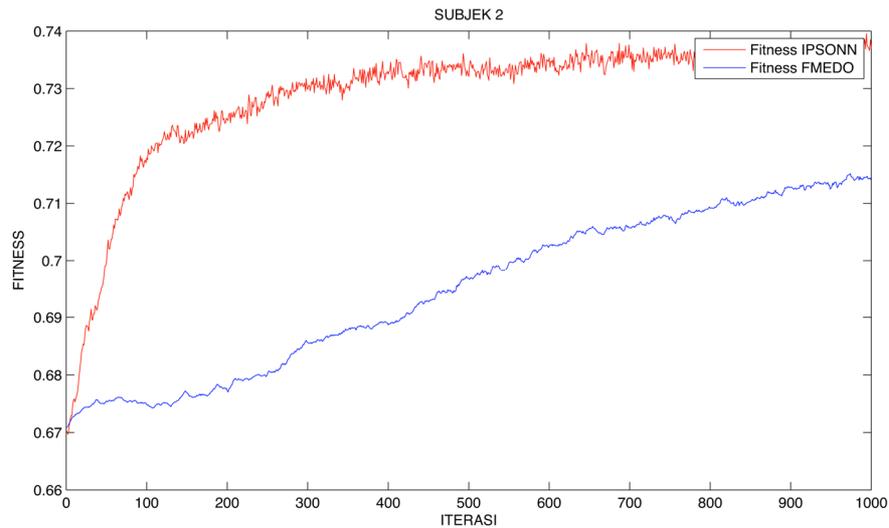
Pengujian dilakukan dengan menggunakan sistem yang dibangun berdasarkan pada algoritma IPSONN dan algoritma usulan yaitu FMEDO dimana data yang digunakan berdasarkan pada reduksi PCA dari nilai PSD dengan jumlah data 25% untuk data uji dan 75% untuk data latih. Setelah dilakukan proses pelatihan dan pengujian terhadap data dengan kedua metode hasil pengujian terlihat pada Tabel 4, Hasil penelitian menunjukkan terdapat peningkatan sekalipun tidak signifikan dimana subjek 1 meningkat sebesar 1,26%, subjek 2 sebesar 12,63% dan subjek tiga sebesar 0,80%. Rata – rata akurasi dari seluruh percobaan yang diperoleh dari metode usulan yaitu untuk subjek 1 sebesar 54,20%, subjek 2 sebesar 58,43% dan subjek 3 sebesar 50,80%. Dimana akurasi terbaik dari subjek 1 untuk seluruh percobaan adalah 69,18%, subjek 2 sebesar 67,20% dan subjek 3 adalah 57,67%. Grafik untuk proses pembelajaran dari subjek 1 terlihat pada Gambar 11, subjek 2 Gambar 12 dan subjek 3 Gambar 13.



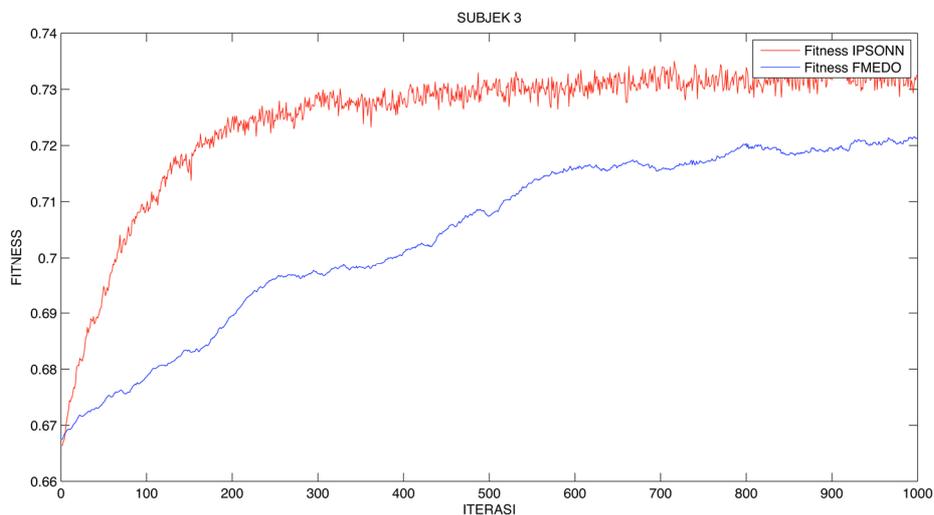
Gambar 10. Bagan Alir untuk menentukan bobot inertia



Gambar 11. Fitness dari Subjek 1



Gambar 12. Fitness dari Subjek 3



Gambar 13. Fitness dari Subjek 3

1) Perbandingan Fitness

Berdasarkan Gambar 11 s.d Gambar 13, menunjukkan perbedaan peningkatan fitness dari setiap subjek untuk kedua metode. Pola peningkatan dari metode IPSONN sangat cepat mengalami kenaikan fitness pada 100 – 200 iterasi, selanjutnya perubahan terjadi secara perlahan. Sedangkan metode FMEDO terjadi peningkatan fitness secara perlahan dengan pola yang jelas membentuk linear. Fitness diperoleh dari pelatihan yang dilakukan pada jaringan saraf tiruan dimana proses pembobotan didapatkan dari nilai posisi (X_t) yang diproses berdasarkan perubahan partikel melalui kecepatan sebelumnya dan posisi awal, sehingga semakin beragamnya pembentukan posisi akan menyebabkan semakin bervariasi nilai fitness yang dibentuk. Berbeda halnya dengan FMEDO yang membatasi kecepatan dari partikel agar tidak melawati batas kecepatan yang ditetapkan, ini merupakan salah satu strategi untuk mengatasi agar tidak terlalu bervariasinya posisi yang akan dibentuk oleh partikel.

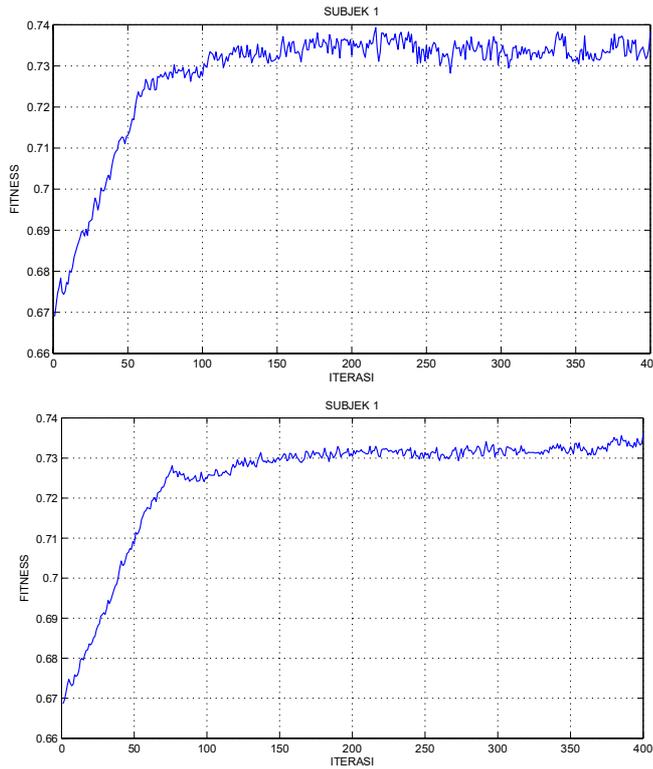
2) Pengaruh Jumlah Pengujian

Salah satu pengaruh yang cukup besar pada kekonvergensian dari pola pelatihan dan pengujian (testing) adalah jumlah percobaan yang dilakukan, semakin banyak proses pengujian dapat menyebabkan bentuk grafik dari fitness dan kinerja jaringan akan mengurangi gelombang pada jaringan, sebagai contoh Gambar 14 (kiri), menunjukkan Subjek 1 – Test.1 yang di tampilkan sendiri dan Gambar 14 (kanan) menunjukkan rata – rata dari Subjek 1 – Test.1, Test.2 dan Test.3 setelah melakukan tiga kali percobaan untuk metode IPSONN. Gambar 14(kiri) menunjukkan bahwa jangkauan dari fitness masih berada diantara 0.73 – 0.74 dengan variasi nilai yang masih sangat besar namun pada Gambar 14 (kanan) dengan mengambil nilai rata – rata maka hasilnya

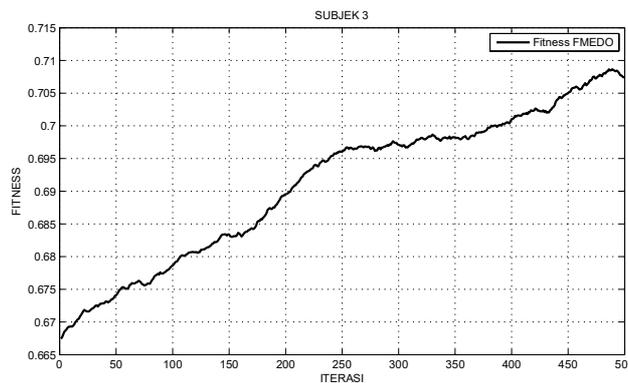
menunjukkan nilai variasinya masih cukup kecil.

3) Pengaruh Pembatasan Kecepatan dan Posisi

Salah satu bagian penting dari proses konvergensi dan peningkatan akurasi adalah penentuan fitness dari setiap partikel yang diperoleh dari proses pelatihan jaringan atau neural network. Dimana bobot Neural Network diperoleh dari jumlah elemen pada *swarm* yang dibangun secara acak pada saat pertama kali proses dimulai. Proses perubahan posisi dan kecepatan bergantung kepada kecepatan dan posisi partikel sebelumnya, apabila posisi dan kecepatan yang diupdate sebagai nilai baru berada diluar jangkauan dari partikel sebelumnya hal ini dapat menyebabkan proses pencarian jauh dari jangkauan awal sehingga nilai fitness akan sangat bervariasi. Hal ini terjadi pada metode IPSONN karena secara konsep tidak memberikan suatu batasan yang jelas pada kecepatan dan posisi, namun untuk mencegah partikel terjebak dalam lokal yang ekstrem IPSONN menggunakan migrasi untuk membangun populasi baru namun hal ini tidak membuat berkurangnya variasi fitness dari partikel.



Gambar 14. Pengaruh Jumlah Pengujian



Gambar 15. Fitness dari Subjek 3 (rata – rata fitness dari tiga subjek)

Untuk mencegah variasi fitness yang tinggi maka FMEDO menggunakan strategi untuk membatasi kecepatan partikel baru agar tidak melewati batas yang telah ditentukan, berdasarkan percobaan dibatasi pada 10% – 20% atau berkisar 0.1 sampai 0.2, selain pembatasan kecepatan strategi lainnya adalah pembatasan posisi baru dimana posisi yang diupdate haruslah berada pada posisi maksimum dan minimum dari posisi sebelumnya, hal ini untuk menjaga agar partikel tidak akan melewati posisi dan kecepatan dari partikel sebelumnya sehingga pergerakan partikel berada pada jalur yang terarah oleh karena itu, penggunaan dua strategi ini menyebabkan grafik pada Gambar 15 akan selalu bergerak dengan membentuk jalur atau track yang tidak bergerak jauh dari jalur

sebelumnya. Dengan demikian nilai fitness dan kurva pelatihan dari metode FMEDO akan membentuk jalur yang mendekati model linear.

4) Pengaruh Fuzzy Bobot Inersia

Bagian berikut ini bertujuan untuk menganalisa pengaruh bobot adaptif terhadap hasil pengujian untuk sinyal EEG. Metode IPSONN menggunakan bobot inersia statis yang digunakan pada seluruh generasi, hal ini dapat menyebabkan sistem tidak cerdas dalam menangani kecepatan sebelumnya sehingga tidak akan terjadi keseimbangan antara pencarian global dan lokal. Bobot inersia adaptif dapat berperilaku cerdas dalam menilai dan menurunkan kecepatan sebelumnya dalam mengupdate posisi dan kecepatan yang baru, dengan menggunakan *fuzzy inference system* perubahan bobot inersia dapat disesuaikan dengan jumlah generasi yang akan dilalui, dimana semakin jauh partikel bergerak maka bobot inersia akan menyesuaikan nilainya dalam melakukan perubahan kecepatan sebelumnya sehingga pergerakan dari partikel lebih dapat dikontrol. Dari hasil penelitian terlihat bahwa semakin jauh partikel bergerak maka bobot inersia akan semakin kecil dengan demikian kecepatan sebelumnya yang akan digunakan sebagai salah satu komponen untuk mengupdate posisi dan kecepatan baru lebih besar dan akan mempengaruhi seluruh perubahan sistem.

5) Pengaruh Nilai Constriction

Metode IPSONN tidak mempertimbangkan menggunakan nilai k yang dapat digunakan untuk mencapai nilai konvergensi dimana nilai k diperoleh dari penggabungan antara *Cognitive coefficient* dan *Social coefficient* yang dapat menyebabkan hasil dari kecepatan yang baru lebih rendah dari kecepatan yang diusulkan pada metode IPSONN.

V. KESIMPULAN

Paper ini mengusulkan metode FMEDO yang menggunakan bobot inersia adaptif dengan *Fuzzy Inference System*. Berdasarkan pengujian FMEDOMemberikan hasil yang lebih baik dibandingkan dengan IPSONN dimana rata – rata akurasi Subjek 1 sebesar 54,20%, Subjek 2 sebesar 58,40% dan Subjek 3 sebesar 50,80% dengan rata – rata akurasi seluruh subjek adalah 54.48% dimana peningkatan yang terjadi pada Subjek 1 adalah 1.26%, Subjek 2 adalah 12.63% dan Subjek 3 adalah 0.80%. Untuk akurasi terbaik pada seluruh percobaan, subjek 1 memberikan hasil sebesar 69,18%, subjek 2 sebesar 67,20% dan subjek 3 adalah 57,67%. Pemilihan parameter menjadi bagian yang penting dalam keberhasilan peningkatan akurasi, penggunaan bobot inersia adaptif dengan *fuzzy inference system* yang menjadi tujuan penelitian telah menunjukkan keberhasilan dalam meningkatkan akurasi klasifikasi. Sekalipun demikian masih terdapat kelemahan yaitu kurva pelatihan yang masih terlihat belum mengalami nilai konvergensi yang kemungkinan terjadi akibat adanya *noise* dan *artefek* yang tidak diperhitungkan dalam proses penelitian. Sehingga dibutuhkan studi lebih lanjut untuk mengatasi masalah tersebut.

DAFTAR PUSTAKA

- [1] CHAI, R., LING, S. H., HUNTER, G. P., TRAN, Y. & NGUYEN, H. T. 2014. Brain-Computer Interface Classifier for Wheelchair Commands Using Network with Fuzzy Particle Swarm Optimization. *IEEE Journal of Biomedical and Health Informatics*, Vol.18, No.5, September 2014.
- [2] WOLPAW, J. R., BIRBAUMER, N., MCFARLAND, D. J., PFURTSCHELLER, G. & VAUGHAN, T. M. 2002. Brain-Computer Interfaces for Communication and Control. *Journal Clinical Neurophysiology*, Volume 113, 767-791.
- [3] ZHOU, S.-M., GAN, J. Q. & SEPULVEDA, F. 2008. Classifying mental task based on fetures of higher-order statistics from EEG signals in brain-computer interface. *Information Sciences*, 178, 1629-1640.
- [4] LOTTE, F., CONGEDO, M., LECUYER, A. & LAMARCHE, F. 2007. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Natural Engineering, Institute of Physics: Hybrid Open Access*, 4. <inria-00134950>.
- [5] SUBASI, A. & GURSOY, M. I. 2010. EEG Signal Classification using PCA, ICA, LDA and Support vector machines. *Expert System With Applications*, Vol. 37, p. 8659-8666.
- [6] NADERI, M. A. & MAHDAVI-NASAB, H. Analysis and classification of EEG signals using spectral analysis and recurrent neural networks. *Proceedings of the 17th Iranian Conference of Biomedical Engineering (ICBME2010)*, 3-4 November 2010, 2010.
- [7] EBERHART, R. C. & SHI, Y. 2000. Comparing Inertia Weight and Constriction factors in Particle Swarm Optimization. *IEEE - Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*, Vol. 1, 16 - 19 Jul 2000, p.84-88, 84-88.
- [8] LING, S. H., NGUYEN, H. T., LEUNG, F. H. F., CHAN, K. Y. & JIANG, F. 2012. Intelligent Fuzzy Particle Swarm Optimization with Cross-Mutated Operation. *WCCI 2012 IEEE World Congress on Computational Intelligence*, June, 10-15, 2012 - Brisbane, Australia
- [9] LIN, C.-J. & HSIEH, M.-H. 2009. Classification of Mental Task from EEG Data Using Neural Network based on Particle Swarm Optimization *Neurocomputing*, Vol. 72, 1121 - 1130.
- [10] UBEDA, A., LANEZ, E., AZORIN, J. M., SABATER, J. M. & FERNANDEZ, E. 2013. Classification method for BCIs based on the Correlation of EEG maps. *Neurocomputing*, 114, 98-106.
- [11] CHIAPPA, S. & MILLAN, J. D. R. *BCI Competitions 2003 Web Source: Data Set V description*, viewed 28 Feb. 2015 [Online]. Available: http://bbci.de/competition/iii/desc_V.html.
- [12] WELCH, P. D. 1967. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. *IEEE Transactions on Audio And Electroacoustics*, Vol. AU-15, No. 2, June 1967.
- [13] DENG, SIYI., WILLIAM WINTER, SAMUEL THORPE, RAMESH SRINIVASAN. EEG Surface Laplacian using realistic head geometry. *International Journal of Bioelectromagnetism*, Vol. 13, No.4, pp. 173 – 177, 2011.

- [14] KENEDY, J. & EBERHART, R. 1995. Particle Swarm Optimization. Neural Network, 1995. Proceedings., IEEE International Conference. Vol. 4. Nov/Dec 1995, p.1942-1948.
- [15] LING, H. S, JIANG, F., NGUYEN, T.H., & CHAN, K.Y., 2011. Permutation Flow Shop Scheduling: Fuzzy Particle Swarm Optimization Approach. IEEE International Conferene on Fuzzy Systems, June 27-30, 2011, Taipei, Taiwan.
- [16] CHIANG, CHAO-LUNG., Improved Genetic Algorithm for Power Economic Dispatch of Units With Valve – Point Effects and Multiple Fuels., IEEE Transactions on Power Systems, Vol. 20, No. 4, November 2005.