

Klasifikasi Pergerakan Tangan dan Kaki Berbasis Sinyal EEG Menggunakan *Common Spatial Patterns* dan *Multilayer Perceptron Backpropagation*

Rahmat Widadi^{#1}, Dodi Zulherman^{#2}

[#]Program Studi S1 Teknik Telekomunikasi, Institut Teknologi Telkom Purwokerto

Jalan D.I. Panjaitan No. 128, Purwokerto, Jawa Tengah, Indonesia

¹rahmat@ittelkom-pwt.ac.id

²zulherman.dodi@ittelkom-pwt.ac.id

Abstract— *The artificial bionic appendicular systems, such as hands and feet movement, require the Brain-Computer Interface (BCI) to control the movement. The BCI based movement controlling in a bionic device utilises the EEG signal directly, but the EEG signal classification has to design before it implemented in a BCI device. This study aims to design a classification system for hands and feet movements based on beta channel EEG signals. The system design used the Common Spatial Pattern (CSP) method for feature extraction and stochastic gradient descent in Multilayer Perceptron Backpropagation (MLP-BP) for the hands and feet movement classification. We use the EEG signal from ten subjects to evaluate the design. Also, the variation number of node in MLP-BP to get the system performance based on the confusion matrix. Based on the test results, the improvement of the number of nodes brought the accuracy increasing, especially for variation two, four and eight nodes. The highest mean of system design accuracy reached 94.38% for eight nodes.*

Keywords— BCI, hands and feet, EEG, CSP, MLP-BP

Abstrak— Teknologi brain computer interface (BCI) dibutuhkan untuk mekanisme pengaturan gerak dari alat bantu bionik sistem appendicular, khususnya tangan dan kaki. Pengendali pergerakan devais bionik berbasis BCI dapat menggunakan sinyal EEG, namun sistem pengelompokan sinyal EEG untuk pergerakan tangan dan kaki dibutuhkan sebagai tahapan awal pengimplementasian tersebut. Penelitian ini bertujuan untuk merancang sebuah sistem klasifikasi pergerakan tangan dan kaki berdasarkan sinyal EEG gelombang beta. Rancangan sistem menggunakan metode *Common Spatial Patterns* (CSP) pada tahap ekstraksi fitur dan *stochastic gradient descent* dalam *Multilayer Perceptron Backpropagation* (MLP-BP) untuk mengklasifikasi pergerakan tangan dan kaki. Pengujian sistem menggunakan *confusion matrix* terhadap sepuluh subjek dan variasi jumlah node MLP-BP. Berdasarkan hasil pengujian, nilai rata-rata akurasi sistem dengan jumlah *node* dua, empat dan delapan meningkat sebanding dengan peningkatan jumlah *node*, namun nilai rata-rata akurasi menurun kembali saat jumlah *node* ditingkatkan menjadi enam belas. Rata-rata akurasi rancangan sistem yang tertinggi mencapai 94,38 % pada sistem dengan delapan *node* pada *hidden layer*.

Kata Kunci— BCI, tangan dan kaki, EEG, CSP, MLP-BP

I. PENDAHULUAN

Kemampuan komputasi cerdas alami yang dimiliki otak dalam mengendalikan semua aktivitas, seperti perilaku manusia, pikiran dan gerakan anggota tubuh mendorong pengembangan penelitian dalam bidang pengolahan sinyal dan kendali agar dapat meniru kemampuan otak manusia. Salah satu penelitian yang berkembang, yaitu *Brain-Computer Interface* (BCI) yang bertujuan untuk menerjemahkan pola aktivitas otak pengguna menjadi pesan atau perintah dalam aplikasi interaktif. Teknologi BCI memungkinkan pengguna untuk mengendalikan komputer atau perangkat eksternal lainnya melalui aktivitas otak [1]. Pembacaan pola aktivitas otak manusia dapat dilakukan dengan menggunakan sinyal *Electroencephalography* (EEG) yang merupakan interpretasi dari perubahan potensial pada korteks serebral yang disebabkan oleh interaksi berbagai neuron yang saling berhubungan. Sinyal EEG merupakan salah satu sarana penting untuk mendapatkan informasi dari otak manusia [2].

Prinsip dasar dalam sistem BCI melalui pengenalan ciri atau fitur dari sinyal EEG yang diberikan, biasa dikenal sebagai ekstraksi fitur. Metode *Common Spatial Patterns* (CSP) merupakan salah satu metode ekstraksi fitur yang menggunakan filter spasial sehingga memaksimalkan varian pada sebuah kelas dan meminimalkan varian untuk kelas lainnya [3], [4]. CSP merupakan metode yang efisien dalam desain sistem BCI [5], [6] namun sensitif terhadap *noise* dan terpengaruh oleh jumlah data latih yang sedikit [5]. Ekstraksi fitur CSP digunakan dalam sistem BCI pada penelitian [6]–[9] dengan menghasilkan akurasi di atas 60%. Penelitian BCI berupa klasifikasi pergerakan kedua tangan dan kedua kaki telah dilakukan pada penelitian [10]. Penelitian ini menggunakan CSP pada tahap ekstraksi fitur untuk sistem BCI klasifikasi gerakan tangan dan kaki. Rerata akurasi yang diperoleh pada penelitian ini sebesar 86,17%. Nilai akurasi ini dapat ditingkatkan dengan memilih algoritma klasifikasi yang dapat mempelajari data pelatihan. *Multilayer perceptron Backpropagation* (MLP-BP) memiliki beberapa kelebihan di antaranya mampu beradaptasi berdasarkan data pelatihan yang diberikan [11]. Selain itu, MLP-BP tergolong efektif dalam bidang pengenalan pola [12].

Berdasarkan permasalahan yang telah dipaparkan, penelitian ini bertujuan untuk mengklasifikasi dua kelas sinyal EEG. Sinyal EEG pertama diperoleh pada saat subjek

membuka dan menutup kedua tangan, sedangkan sinyal EEG kedua diperoleh pada saat subjek menggerakkan kedua kakinya. Sinyal difilter terlebih dahulu sebelum masuk ke tahap ekstraksi fitur. *Filtering* dimaksudkan untuk melewati kanal tertentu dari sinyal EEG. Pada tahap ekstraksi fitur menggunakan Algoritma CSP, hasil yang diperoleh berupa fitur *spatial* yang digunakan sebagai masukan MLP-BP. Selanjutnya proses pelatihan dalam MLP-BP menggunakan algoritma *stochastic gradient descent* (SGD) untuk meminimalkan fungsi *cost* MLP-BP. Pengukuran akurasi klasifikasi menggunakan metode *confusion matrix*. Akurasi yang diperoleh diharapkan lebih tinggi dari penelitian sebelumnya [10].

II. METODOLOGI

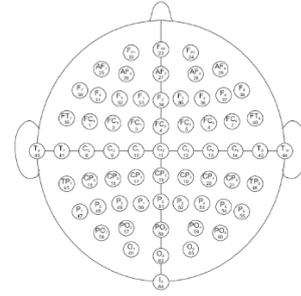
Pembentukan sistem klasifikasi pergerakan tangan dan kaki berdasarkan sinyal EEG dilaksanakan dalam beberapa tahapan yang saling berkelanjutan. Tahapan awal proses *filtering* untuk mengkondisikan sinyal dengan melewati kanal tertentu. Sinyal yang sudah difilter selanjutnya diolah untuk menghasilkan fitur-fitur sinyal. Ekstraksi fitur menggunakan metode *common spatial patterns*, kemudian fitur-fitur sinyal digunakan dalam proses pelatihan dan pengujian (proses ini menggunakan metode *multilayer perceptron backpropagation*). Uraian lebih rinci terkait dengan proses-proses di atas dijabarkan pada bagian ini.

A. Dekripsi Data

Dataset *eegmddb* diperoleh dari *physionet* [13]. Data dipublikasikan pada 9 September 2009. Data ini berupa sinyal EEG yang direkam menggunakan instrumentasi BCI2000 [14]. Sistem internasional 10-10 memiliki 64 elektroda yang ditempatkan pada kulit kepala subjek. Gambar 1 menggambarkan posisi penempatan elektroda berdasarkan sistem internasional 10-10. Frekuensi sampling sinyal EEG sebesar 160 Hz. Setiap subjek melakukan 14 proses eksperimen, yaitu 2×1 menit pergerakan awal (mata tertutup dan mata terbuka). Masing-masing 2 menit dari empat jenis percobaan adalah sebagai berikut: membayangkan membuka dan menutup kepalan tangan kanan atau kiri, membuka dan menutup kedua tangan atau kedua kaki, membayangkan membuka dan menutup kedua tangan atau kedua kakinya. Daftar empat belas percobaan adalah sebagai berikut:

1. *Baseline*, mata terbuka
2. *Baseline*, mata tertutup
3. Percobaan 1 (buka dan tutup tangan kiri atau kanan)
4. Percobaan 2 (bayangkan membuka dan menutup kepalan kiri atau kanan)
5. Percobaan 3 (buka dan tutup kedua tangan atau kedua kaki)
6. Percobaan 4 (bayangkan membuka dan menutup kedua tangan atau kedua kaki)

Percobaan 7 dan 11 akan sama dengan percobaan 3, percobaan 8 dan 12 sama dengan percobaan 4, percobaan 9 dan 13 sama dengan percobaan 5, dan percobaan 10 dan 14 sama dengan percobaan 6.



Gambar 1 Susunan elektroda sistem 10-10 [13]

B. Filtering

Jenis filter yang digunakan pada penelitian ini adalah filter *Finite Impulse Response* (FIR). Filter FIR dipilih karena lebih mudah dikendalikan, selalu stabil, memiliki *passband* yang terdefinisi dengan baik, dan pergeseran fase linier [15]. *Paper review* mengenai metode desain filter untuk data *electrophysiological* pada [16] merekomendasikan filter FIR untuk keperluan analisis sinyal EEG.

Filter FIR merupakan filter digital yang memiliki tanggapan *impulse* yang terbatas. Filter ini tidak memiliki bagian *feedback* pada blok diagramnya. Pada bagian fungsi transfer hanya memiliki *zeros* pada ranah z . *Zeros* ini yang menentukan karakteristik tanggapan frekuensi dari filter. Filter FIR adalah filter yang memiliki fungsi transfer polinomial dalam z^{-1} . Secara umum fungsi alih dari sistem waktu diskret didefinisikan sebagai:

$$H(z) = \frac{\sum_{i=0}^{Q-1} b_i z^{-i}}{\sum_{j=0}^{P-1} a_j z^{-j}} = \frac{b_0 + b_1 z^{-1} + \dots + b_Q z^{-Q}}{1 + a_0 z^{-1} + \dots + a_P z^{-P}} \quad (1)$$

dengan Q adalah orde *numerator* polinomial, b_i merupakan koefisien ke- i dari *numerator* polinomial, P merupakan orde *denominator* polinomial, dan a_i merupakan koefisien ke- i dari *denominator* polinomial. Filter FIR tidak memiliki bagian rekursif dari fungsi alih, sehingga fungsi transfer filter FIR yaitu:

$$H(z) = \sum_{i=0}^{Q-1} b_i z^{-i} \quad (2)$$

Proses desain filter FIR melalui fungsi *window* dapat dibagi menjadi beberapa langkah:

1. Menentukan spesifikasi filter: frekuensi *sampling* f_s , frekuensi *cut-off* f_c , dan orde filter $N - 1$.
2. Menentukan fungsi *window* berdasarkan spesifikasi filter. *Hamming window* dipilih pada penelitian ini.
3. Menghitung koefisien fungsi *window* $w[n]$. *Hamming window* merupakan pengembangan dari *Hann window* yang memiliki bentuk *cosine window* dengan bentuk:

$$w[n] = 0,54 - 0,46 \left(1 - \cos \left(\frac{2\pi n}{N-1} \right) \right) \quad (3)$$

dengan $w[n]$ merupakan koefisien *window* ke- n dan N merupakan orde filter. Nilai n memiliki rentang nilai dari $0 - N$.

4. Menghitung koefisien filter ideal sesuai dengan *unit sample response* $h_d[n]$. Nilai $h_d[n]$ untuk *bandpass* filter dideskripsikan:

$$h_d[n] = \begin{cases} \frac{\sin(\omega_{c2}(n-M))}{\pi(n-M)} - \frac{\sin(\omega_{c1}(n-M))}{\pi(n-M)} & ; n \neq M \\ \frac{\omega_{c2} - \omega_{c1}}{\pi} & ; n = M \end{cases} \quad (4)$$

dengan $M = \frac{N}{2}$ dan ω_{c2} , ω_{c1} masing-masing merupakan frekuensi *cutoff* dalam rad/s.

5. Menghitung koefisien filter FIR sesuai dengan fungsi *window* yang diperoleh dan koefisien filter ideal.

$$h[n] = h_d[n]w[n] \quad (5)$$

C. Common Spatial Pattern (CSP)

Ekstraksi fitur digunakan untuk mereduksi ukuran data *raw*. *Common Spatial Pattern* (CSP) merupakan metode ekstraksi fitur yang menghitung komponen spasial yang sama dari kedua kelas. Namun, varian data dari kedua kelas yang diproyeksikan terhadap komponen ini berbeda. Matriks proyeksi memberikan bobot pada setiap elektroda yang dapat digunakan untuk menghasilkan sinyal baru di ruang spasial. Penjelasan algoritma CSP adalah sebagai berikut: [17].

Setiap terdapat data berukuran $N \times T$, di mana N adalah jumlah *channel* / elektroda dan T adalah jumlah sampel per *channel* (panjang data). Selanjutnya, matriks *covariance* spasial untuk dua kelas dideskripsikan sebagai:

$$c_h = \frac{X_h X_h^T}{\text{trace}(X_h X_h^T)} \quad (6)$$

$$c_f = \frac{X_f X_f^T}{\text{trace}(X_f X_f^T)} \quad (7)$$

dengan C_h adalah matriks *covariance* untuk sinyal EEG gerakan motorik tangan (X_h), C_f merupakan sinyal EEG gerakan motorik kaki (X_f), dan $\text{trace}(x)$ adalah jumlah dari elemen diagonal x . $\text{trace}(x)$ digunakan untuk normalisasi matriks C_h dan C_f . Matriks *covariance* pada masing-masing kelas dirata-rata sehingga diperoleh \bar{C}_h dan \bar{C}_f . Kedua matriks tersebut kemudian ditambahkan untuk membentuk matriks C .

$$C = \bar{C}_h + \bar{C}_f \quad (8)$$

Matriks C selanjutnya difaktorkan sehingga diperoleh $C = U \lambda U^T$, dengan U merupakan matriks *eigenvectors* dan λ adalah matriks diagonal dari *eigenvalues*. Selanjutnya, matriks *whitening transformation* P dihitung dengan persamaan:

$$P = \sqrt{\lambda^{-1} U^T} \quad (9)$$

Matriks P menyamakan varian dalam ruang yang direntang oleh *eigenvector* di U . Matriks P diterapkan pada rata-rata *covariance* matriks \bar{C}_h dan \bar{C}_f .

$$S_h = P \bar{C}_h P^T \quad (10)$$

$$S_f = P \bar{C}_f P^T \quad (11)$$

Jumlah *eigenvalues* yang bersesuaian dari S_h dan S_f akan selalu sama dengan l . Dua matriks ini juga membagikan *eigenvector* yang sama yaitu:

$$S_h = B \lambda_h B^T \quad (12)$$

$$S_f = B \lambda_f B^T \quad (13)$$

dan

$$\lambda_h + \lambda_f = I \quad (14)$$

dengan I merupakan matriks identitas. Dikarenakan jumlah dua *eigenvalue* antar data yang bersesuaian sama dengan satu, maka *eigenvector* dengan *eigenvalue* terbesar untuk S_h memiliki nilai *eigenvalue* yang terkecil untuk S_f dan sebaliknya. Karakteristik ini menjadikan *eigenvector* B berguna sebagai fitur dalam klasifikasi dua kelas. Matriks proyeksi W dideskripsikan pada persamaan (15) berikut.

$$W = B^T P \quad (15)$$

Pada saat *eigenvalue* S_f diurutkan dari nilai yang paling besar, sebanyak m nilai *eigenvector* tertinggi berpengaruh terhadap varian maksimum kelas pertama dan varian minimal pada kelas kedua. Hal ini dikarenakan batasan pada persamaan (14). Demikian pula, sebanyak m nilai *eigenvector* terendah juga berpengaruh terhadap varian minimum pada kelas pertama dan varian maksimum kelas kedua. Oleh karena itu, hanya m kolom *eigenvector* tertinggi dan terendah dari W yang digunakan untuk menentukan pola pembeda antar kelas sekaligus untuk membentuk matriks proyeksi baru W_{2m} . Hasil dekomposisi (*mapping*) dari setiap sinyal EEG X yaitu:

$$Z = W_{2m}^T \left(\frac{X}{\sqrt{\text{trace}(XX^T)}} \right) \quad (16)$$

Kolom W_{2m}^T merupakan *common spatial patterns*. Kolom tersebut dapat dilihat sebagai vektor distribusi sinyal EEG *time-invariant*. Pada setiap subjek sebanyak $2m$ dihitung nilai varian dari Z . Nilai ini selanjutnya digunakan sebagai fitur sinyal EEG yang bersesuaian.

D. Multilayer Perceptron Backpropagation (MLP-BP)

Tujuan utama pembelajaran *backpropagation* adalah untuk memetakan *input-output* ke dalam bobot antar *node* dari *multilayer perceptron*. Algoritma *backpropagation* secara simultan akan mengirimkan *error* dari *output layer* kembali ke *hidden layer*. *Error* ini akan terkait dengan fungsi *cost* dari *multilayer perceptron*. Gradien dari fungsi *cost* akan dihasilkan pada proses pembelajaran. MLP-BP digunakan pada klasifikasi sinyal EEG lain dan memberikan hasil akurasi diatas 95 % [18]. Gambar 2 menunjukkan arsitektur *multilayer perceptron* yang memiliki 3 *layer*. Contoh penulisan bobot antar *node*, w_{24}^3 merupakan bobot yang menghubungkan *node* ke-4 pada *layer* ke-2 terhadap *node* ke-2 pada *layer* ke-3.

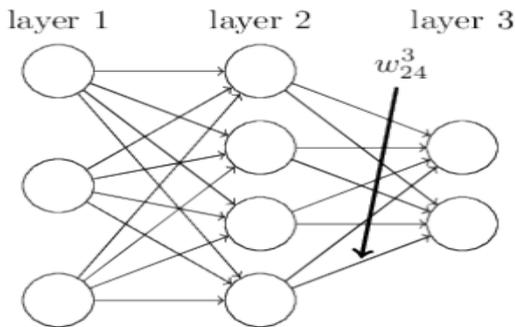
Secara lengkap, algoritma MLP-BP adalah sebagai berikut:

1. **Input x**: menghitung *output* setiap *node* α_j^l berdasarkan *input x* yang diberikan berdasarkan persamaan (17).

$$\alpha_j^l = \sigma \left(\sum_k w_{jk}^l \alpha_k^{l-1} + b_j^l \right) \quad (17)$$

dengan α_j^l adalah *node* ke- j pada *layer* ke- l . Fungsi σ merupakan fungsi aktivasi yang digunakan. Matriks w_{jk}^l menunjukkan bobot yang menghubungkan *node* ke- k pada *layer* $l-1$ terhadap *node* ke- j pada *layer* ke- l . Pada *layer* pertama maka persamaan (17) menjadi:

$$\alpha^1 = \sigma \left(\sum_k w_k^1 x_k + b^1 \right) \quad (18)$$



Gambar 2 Arsitektur *multilayer perceptron*

dengan α^1 merupakan matrik *output layer* pertama. w_k^l adalah bobot yang terhubung dengan *input* baris ke- k (yaitu x_k) dan b^1 merupakan bias pada *layer* pertama.

2. **Feedforward**: untuk setiap *layer* $l = 1, 2, 3, \dots, L$ hitung z^l

$$z^l = w^l \alpha^{l-1} + b^l \quad (19)$$

dan

$$\alpha^l = \sigma(z^l) \quad (20)$$

3. **Output error**: Hitung vektor δ^l

$$\delta^l = \nabla_{\alpha} C \odot \sigma'(z^l) \quad (21)$$

Notasi \odot menandakan *hadamard product* antar vektor.

4. **Backpropagate the error**: untuk setiap $l = L-1, L-2, \dots, 2$ hitung

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad (22)$$

5. **Output**: gradien dari fungsi *cost* ditunjukkan oleh:

$$\frac{\partial C}{\partial w_{jk}^l} = \alpha_k^{l-1} \delta_j^l \quad (23)$$

dan

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad (24)$$

Algoritma *backpropagation* yang telah dijelaskan hanya menghitung gradien dari fungsi *cost* pelatihan tunggal, $C = C_x$. Pada pelatihan dengan iterasi diperlukan metode untuk meminimalkan fungsi *cost*. Metode yang dapat digunakan yaitu *Stochastic Gradient Descent* (SGD). Metode ini menghitung gradien pada banyak pelatihan. Berikut ini penerapan SGD pada sebuah pelatihan *mini-batch*.

1. **Input data latih**.
2. **Pada setiap data latih x**: hitung setiap *output* dari fungsi aktivasi $\alpha^{x,1}$ dan lakukan langkah berikut:
 - **Feedforward**: pada setiap *layer* $l = 2, 3, \dots, L$ hitung $z^{x,l} = w^l \alpha^{x,l-1} + b^l$ dan $\alpha^{x,l} = \sigma(z^{x,l})$.
 - **Output error**: $\delta^{x,L} = \nabla_{\alpha} C_x \odot \sigma'(z^{x,L})$.
 - **Backpropagate the error**: pada setiap $l = L-1, L-2, \dots, 2$ hitung $\delta^{x,l} = ((w^{l+1})^T \delta^{x,l+1}) \odot \sigma'(z^{x,l})$.
3. **Gradient descent**: pada setiap $l = L, L-1, \dots, 2$ perbarui bobot dan bias berdasarkan aturan

$$w_{new}^l = w_{old}^l - \frac{\eta}{m} \sum_x \delta^{x,l} (\alpha^{x,l-1})^T \quad (25)$$

$$b_{new}^l = b_{old}^l - \frac{\eta}{m} \sum_x \delta^{x,l} \quad (26)$$

Optimasi fungsi *cost* dalam penerapan SGD membutuhkan iterasi yang terdiri dari beberapa *epoch* pelatihan. Proses iterasi dengan algoritma SGD menghasilkan nilai bobot dan bias akhir. Nilai bobot dan bias akhir digunakan sebagai parameter sistem pada tahap pengujian.

Pengujian unjuk kerja rancangan dilakukan terhadap data sinyal EEG dari sepuluh subjek dengan pengamatan hanya tiga sesi dari total 14 sesi per subjek. Ketiga sesi ini merupakan sesi pergerakan membuka dan menutup kedua kepalan tangan serta sesi pergerakan membuka dan menutup kedua kaki. Urutan sesi yang dimaksud yaitu sesi 5, 9, dan 13. Jumlah data yang diperoleh dari setiap subjek sebanyak 45. Jadi, total data yang digunakan pada penelitian ini yaitu 450 sinyal EEG.

Tantangan lain yaitu memilih kanal frekuensi sinyal EEG. Gelombang otak manusia memiliki rentang frekuensi 0-100 Hz. Secara khusus, fungsi sistem motorik pada otak manusia berada pada frekuensi 15-30 Hz. Oleh karena itu, pada penelitian ini sinyal EEG difilter menggunakan *bandpass filter* dengan rentang frekuensi 15 Hz hingga 30 Hz. Pemilihan rentang frekuensi ini juga dapat digunakan untuk mengantisipasi *noise line frequency* pada rentang frekuensi 50 Hz hingga 60 Hz [19]. Perancangan dan implementasi filter menggunakan *SciPy library* [20].

Sinyal EEG yang telah difilter kemudian diekstraksi fiturnya. Algoritma CSP diimplementasikan menggunakan *MNE tool* [21]. Fitur yang diperoleh selanjutnya digunakan sebagai masukan MLP-BP. Proses pelatihan dan pengujian menggunakan metode *K-fold Cross Validation*. Pada penelitian ini nilai K adalah 10. Hasil keluaran MLP-BP dianalisis menggunakan *confusion matrix* sehingga dapat dihitung tingkat akurasi. Implementasi dan pengujian MLP-BP menggunakan *Scikit-learn* [22]. Perancangan dan implementasi sistem menggunakan perangkat lunak *Spyder* (Anaconda 3) versi 3.3.6.

III. HASIL DAN PEMBAHASAN

A. Filtering

Filtering sebagai tahapan awal rancangan sistem BCI berfungsi untuk menghilangkan pengaruh frekuensi lain di luar *band* frekuensi sinyal EEG motorik dengan menggunakan filter FIR untuk melewatkan sinyal kanal *Beta* (15-30 Hz). Gambar 3 menunjukkan *Power Spectral Density* (PSD) dari Subjek-1 sebelum difilter. Berdasarkan tampilan pada Gambar 3 terlihat bahwa sinyal frekuensi rendah memiliki daya yang tinggi.

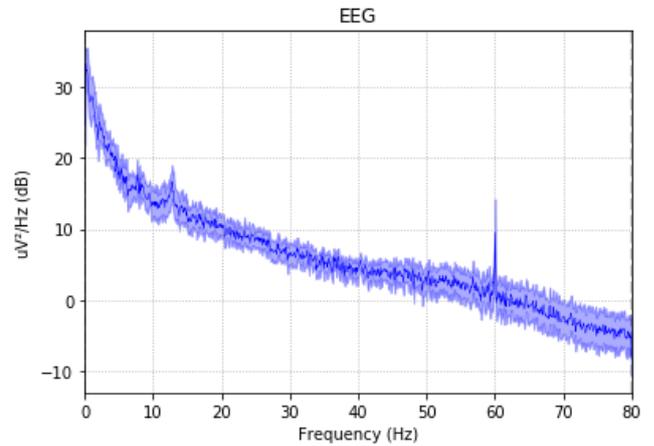
Perancangan filter menggunakan library “firwin”. Hasil rancangan berupa tanggapan *impulse* dan tanggapan frekuensi dari filter FIR yang ditampilkan pada Gambar 4. Tanggapan *impulse* yang dimiliki filter FIR memiliki dua sisi, namun

mengalami pergeseran karena filter merupakan sistem yang kausal. Filter hanya beroperasi pada sampel yang ada tanpa melibatkan sampel yang akan datang. Tanggapan frekuensi filter dibagi menjadi tanggapan magnitudo dan tanggapan fase. Tanggapan magnitudo menunjukkan filter hanya melewatkan sinyal sesuai spesifikasi yang diharapkan. Filter FIR hasil desain juga memiliki tanggapan fase yang linear. Gambar 4a menunjukkan tanggapan *impulse* dan Gambar 4b merupakan tanggapan frekuensi filter FIR.

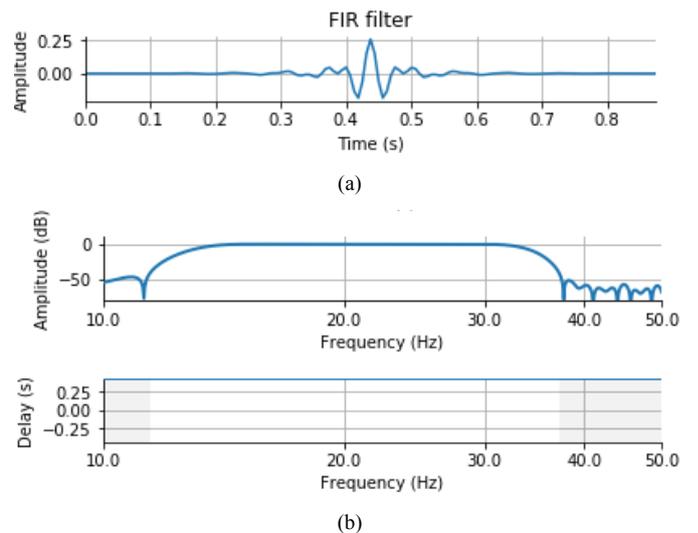
Filter yang telah didesain selanjutnya diterapkan pada *raw data*. Nilai PSD dari sinyal Subjek-1 yang telah difilter ditunjukkan pada Gambar 5. Berdasarkan gambar ini, filter melewatkan frekuensi di sekitar 15-30 Hz dan melemahkan sinyal EEG pada frekuensi yang lain. Hal ini sesuai kebutuhan untuk melewatkan sinyal pada kanal *Beta* (15-30 Hz).

B. Ekstraksi fitur menggunakan CSP

Ekstraksi fitur digunakan untuk mereduksi ukuran data. Pengaturan nilai CSP yaitu $m = 2$ sehingga jumlah *spatial pattern* ada $2m = 4$. *Spatial pattern* dari sinyal EEG subjek-1 yang diperoleh dari persamaan (16) ditunjukkan pada Gambar 6.



Gambar 3 PSD Subjek-1 (*raw signal*)



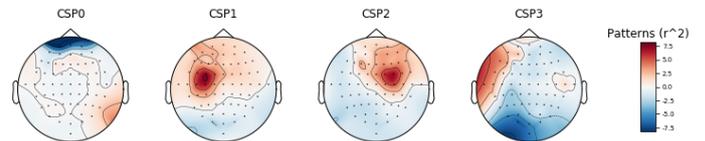
Gambar 4 Tanggapan *impulse* (a) dan tanggapan frekuensi (b)

CP1 dan CP2 merupakan dua *spatial pattern* yang memiliki nilai W_{2m}^T tinggi pada masing-masing kelas, sedangkan CP0 dan CP3 merupakan dua *spatial pattern* yang memiliki nilai W_{2m}^T rendah. Gambar 6 menunjukkan topografi nilai kovarian pada keseluruhan elektrode. Warna merah menunjukkan nilai kovarian positif dan warna biru menunjukkan nilai kovarian negatif. Selanjutnya, dihitung nilai varian dari ke-4 *spatial pattern* untuk digunakan sebagai fitur masukan MLP-BP.

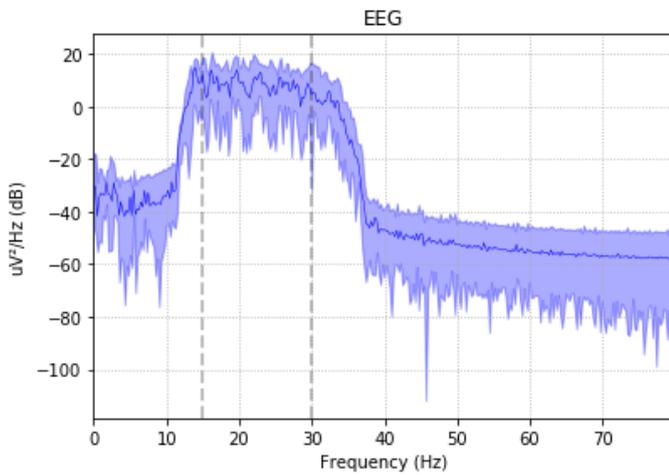
C. MLP-BP Classification

MLP-BP yang digunakan pada penelitian ini terdiri dari 1 *input layer*, 1 *hidden layer*, dan 1 *output layer*. Terdapat 4 *node* pada *input layer*. Jumlah *node* pada *input layer* sama dengan banyaknya fitur keluaran algoritma CSP. Jumlah *node* pada *hidden layer* divariasikan dari 2 (2^1) *node* sampai 16 (2^4) *node*. Optimisasi pembelajaran menggunakan *stochastic gra-*

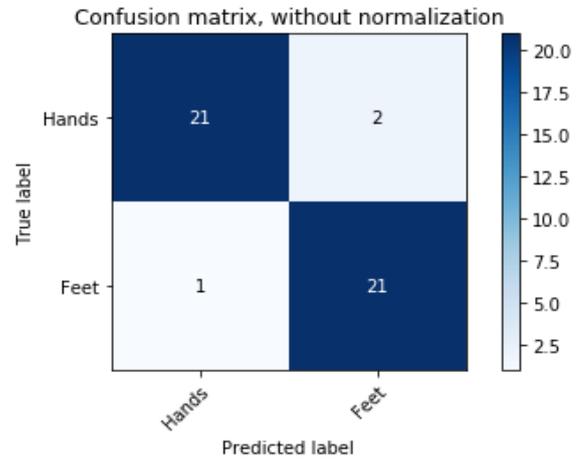
dient descent. Proses pelatihan dan pengujian menggunakan algoritma *10-fold cross validation*. Secara keseluruhan terdapat 10 *confusion matrix* per subjek pada setiap skenario jumlah *node hidden layer*. Gambar 7 menunjukkan *confusion matrix* yang diperoleh dari subjek-1. Berdasarkan *confusion matrix* ini dihitung nilai akurasi klasifikasi. Rerata akurasi klasifikasi setiap subjek ditunjukkan pada Tabel I.



Gambar 6 *Spatial Pattern* dari Sinyal EEG Subjek-1



Gambar 5 PSD Subjek-1 setelah difilter



Gambar 7 *Confusion Matrix* Subjek-1 skenario 2 *node* pada *hidden layer*

TABEL I

RERATA AKURASI KLASIFIKASI

Jumlah Node	Subjek										Rerata Akurasi (%)
	1	2	3	4	5	6	7	8	9	10	
2	93,33	100	90	93,33	83,33	78	92,5	95	80	92,5	89,80
4	93,33	100	90	93,33	93,33	88,83	95	95	92,5	92,5	93,88
8	93,33	100	95	93,33	93,33	91,33	95	95	92,5	95	94,38
16	93,33	100	95	93,33	93,33	88,83	95	95	92,5	95	93,88

IV. KESIMPULAN

Rancangan sistem BCI berdasarkan sinyal EEG menggunakan fitur CSP dari sinyal EEG kanal *Beta* (frekuensi *motor system function* tubuh manusia pada rentang 15 – 30 Hz) dan MLP-BP dapat digunakan untuk klasifikasi pergerakan tangan dan kaki. Rerata akurasi tertinggi diperoleh konfigurasi MLP-BP dengan delapan-*node* pada *hidden layer*, yaitu sebesar 94,38%. Penelitian ini menggunakan keseluruhan elektrode pada tahap ekstraksi fitur, dan rencana penelitian lanjutan difokuskan pada seleksi fitur.

UCAPAN TERIMA-KASIH

Terima kasih kami sampaikan kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat Institut Teknologi Telkom Purwokerto.

DAFTAR REFERENSI

- [1] J. N. Mak dan J. R. Wolpaw, "Clinical Applications of Brain-Computer Interfaces: Current State and Future Prospects," *IEEE Rev. Biomed. Eng.*, vol. 2, hlm. 187–199, 2009.
- [2] D. B. MacDonald, "Electroencephalography: Basic Principles and Applications," dalam *2015 International Encyclopedia of the Social & Behavioral Sciences (Second Edition)*, Second Edi., J. D. Wright, Ed. Oxford: Elsevier, 2015, hlm. 353–363.
- [3] H. Ramoser, J. Muller-Gerking, dan G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Trans. Rehabil. Eng.*, vol. 8, no. 4, hlm. 441–446, 2000.
- [4] G. Dornhege, B. Blankertz, M. Krauledat, F. Losch, G. Curio, dan K.-Muller, "Combined Optimization of Spatial and Temporal Filters for Improving Brain-Computer Interfacing," *IEEE Trans. Biomed. Eng.*, vol. 53, no. 11, hlm. 2274–2281, 2006.
- [5] B. Reuderink dan M. Poel, *Robustness of the Common Spatial Patterns algorithm in the BCI-pipeline*, no. DTR08-9/TR-CTIT-08–52. Netherlands: Centre for Telematics and Information Technology (CTIT), 2008.
- [6] S. Selim, M. M. Tantawi, H. A. Shedeed, dan A. Badr, "A CSP\AM-BA-SVM Approach for Motor Imagery BCI System," *IEEE Access*, vol. 6, hlm. 49192–49208, 2018.
- [7] M. Hersche, T. Rellstab, P. D. Schiavone, L. Cavigelli, L. Benini, dan A. Rahimi, "Fast and Accurate Multiclass Inference for MI-BCIs Using Large Multiscale Temporal and Spectral Features," dalam *2018 26th European Signal Processing Conference (EUSIPCO)*, 2018, hlm. 1690–1694.
- [8] F. Lotte dan C. Guan, "Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 2, hlm. 355–362, 2011.
- [9] Y. Kim, J. Ryu, K. K. Kim, C. C. Took, D. P. Mandic, dan C. Park, "Motor Imagery Classification Using Mu and Beta Rhythms of EEG with Strong Uncorrelating Transform Based Complex Common Spatial Patterns," *Comput. Intell. Neurosci.*, vol. 2016, hlm. 1–13, 2016.
- [10] Z. Tang, C. Li, J. Wu, P. Liu, dan S. Cheng, "Classification of EEG-based single-trial motor imagery tasks using a B-CSP method for BCI," *Front. Inf. Technol. Electron. Eng.*, vol. 20, no. 8, hlm. 1087–1098, 2019.
- [11] S. B. Wankhede, "Analytical Study of Neural Network Techniques: SOM, MLP and Classifier-A Survey," *IOSR J. Comput. Eng.*, vol. 16, no. 3, hlm. 86–92, 2014.
- [12] G. Panchal, A. Ganatra, Y. P. Kosta, dan D. Panchal, "Behaviour Analysis of *Multilayer perceptrons* with Multiple *Hidden Neurons* and *Hidden Layers*," *Int. J. Comput. Theory Eng.*, vol. 3, no. 2, hlm. 332–337, 2011.
- [13] A. L. Goldberger, dkk., "PhysioBank, PhysioToolkit, and PhysioNet," *Circulation*, vol. 101, no. 23, hlm. e215–e220, 2000.
- [14] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, dan J. R. Wolpaw, "BCI2000: a general-purpose brain-computer interface (BCI) system," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, hlm. 1034–1043, 2004.
- [15] B. Mulgrew, P. Grant, dan J. Thompson, "Finite impulse response digital filters," *Digital Signal Processing: Concepts and Applications*, B. Mulgrew, P. Grant, dan J. Thompson, Eds. London: Macmillan Education UK, 1999, hlm. 150–175.
- [16] A. Widmann, E. Schröger, dan B. Maess, "Digital filter design for electrophysiological data – a practical approach," *J. Neurosci. Methods*, vol. 250, hlm. 34–46, 2015.
- [17] Z. J. Koles, M. S. Lazar, dan S. Z. Zhou, "Spatial patterns underlying population differences in the background EEG," *Brain Topogr.*, vol. 2, no. 4, hlm. 275–284, Jun. 1990.
- [18] R. Widadi, I. Soesanti, dan O. Wahyunggoro, "EEG classification using elliptic filter and multilayer perceptron based on gamma activity features," *Proceedings - 2018 4th International Conference on Science and Technology, ICST 2018*, 2018.
- [19] G. Ellis, "Chapter 9 - Filters in control systems," dalam *Control System Design Guide (Fourth Edition)*, G. B. T.-C. S. D. G. (Fourth E. Ellis, Ed. Boston: Butterworth-Heinemann, 2012, hlm. 165–183.
- [20] P. Virtanen, dkk., "SciPy 1.0--Fundamental Algorithms for Scientific Computing in Python," *arXiv e-prints*, p. arXiv:1907.10121, Jul. 2019.
- [21] A. Gramfort, dkk., "MEG and EEG data analysis with MNE-Python," *Front. Neurosci.*, vol. 7, hlm. 267, 2013.
- [22] F. Pedregosa, dkk., "Scikit-learn: Machine Learning in Python," *J. Mach. Learn. Res.*, vol. 12, hlm. 2825–2830, 2011.

Rahmat Widadi, kelahiran kota Purwokerto. Penulis menyelesaikan jenjang sarjana di Pendidikan Teknik Elektronika, Universitas Negeri Yogyakarta dan jenjang Magister di Teknik Elektro Universitas Gadjah Mada. Aktivitas sehari-hari penulis sebagai dosen Program Studi S1 Teknik Telekomunikasi, Institut Teknologi Telkom Purwokerto. Bidang Penelitian yang ditekuni adalah Pengolahan Sinyal Biomedis, khususnya sinyal EEG dan *Machine Learning*.

Dodi Zulherman, kelahiran kota Padang. Riwayat pendidikan sarjana di Teknik Elektro Universitas Andalas dan magister di Teknik Elektro Institut Teknologi Bandung dengan bidang peminatan Teknik Biomedika. Saat ini aktif bertugas sebagai dosen pada Program Studi S1 Teknik Telekomunikasi. Peminatan dalam penelitian meliputi bidang pengolahan sinyal biomedis dan komunikasi optis.

Halaman kosong