

## Kombinasi Sinyal EEG dan Girooskop untuk Kendali Mobil Virtual dengan Menggunakan Modifikasi ICA dan SVM

Ahmad Reza Musthafa<sup>1</sup>, Handayani Tjandrasa<sup>2</sup>

Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember

Jl. Raya ITS, Kampus ITS, Sukolilo, Surabaya 60111

E-mail: <sup>1</sup>rezaaltraz@yahoo.com, <sup>2</sup>handatj@its.ac.id

Masuk: 14 Desember 2015; Direvisi: 8 Januari 2016; Diterima: 14 Januari 2016

**Abstract.** *Electroencephalogram (EEG) signals has been widely researched and developed in many fields of science. EEG signals could be classified into useful information for the application of Brain Computer Interface topic (BCI). In this research, we focus in a topic about driving a car using EEG signal. There are many approaches in EEG signal classification, but some approaches do not robust EEG signals that have many artifacts and have been recorded in real time. This research aims to classify EEG signals to obtain more optimal results, especially EEG signals with many artifacts and can be recorded in realtime. This research uses Emotiv EPOC device to record EEG signals in realtime. In this research, we propose the combination of Automatic Artifact Removal (AAR) and Support Vector Machine (SVM) which has 71% of accuracy that can be applied to drive a virtual car.*

**Keyword:** *EEG signal classification, automatic artifact removal, brain computer interface*

**Abstrak.** Penelitian berbasis sinyal *Electroencephalogram* (EEG) telah banyak diteliti dan dikembangkan pada berbagai bidang ilmu pengetahuan. Sinyal EEG dapat diklasifikasikan ke dalam bentuk informasi untuk pengaplikasian topik *Brain Computer Interface* (BCI). Pada penelitian ini difokuskan pada topik pengendalian mobil menggunakan perintah sinyal EEG. Terdapat beberapa pendekatan dalam klasifikasi sinyal EEG, tetapi beberapa pendekatan tersebut tidak *robust* terhadap sinyal EEG yang memiliki banyak artefak dan direkam secara *realtime*. Penelitian ini bertujuan untuk mengklasifikasikan sinyal EEG dengan hasil lebih optimal, khususnya pada sinyal EEG yang memiliki banyak artefak dan direkam secara *realtime*. Penelitian ini menggunakan perangkat Emotiv EPOC untuk merekam sinyal EEG secara *realtime*. Pada penelitian ini diusulkan kombinasi *Automatic Artifact Removal* (AAR) dan *Support Vector Machine* (SVM) yang menghasilkan hasil akurasi sebesar 71% untuk klasifikasi sinyal EEG pada kasus pengendalian mobil *virtual*.

**Kata Kunci:** *EEG signal classification, automatic artifact removal, brain computer interface*

### 1. Pendahuluan

Penelitian berbasis sinyal EEG dewasa ini telah banyak diteliti dan dikembangkan pada berbagai bidang ilmu pengetahuan. Sinyal EEG merupakan sinyal yang diperoleh dari aktivitas otak manusia, yang memiliki hubungan dengan beberapa aktivitas tubuh manusia. Sinyal EEG dapat diklasifikasikan kedalam bentuk informasi yang bermanfaat, misalkan informasi motorik pada manusia. Dengan adanya klasifikasi terhadap sinyal EEG, dapat menjadi solusi teknologi yang bermanfaat bagi manusia berkebutuhan khusus, khususnya cacat fisik, sehingga manusia berkebutuhan khusus dapat melakukan aktivitas seperti manusia pada umumnya.

Terdapat beberapa penelitian yang relevan terhadap topik klasifikasi sinyal EEG untuk pengaplikasian topik *Brain Computer Interface* (BCI). Penelitian dengan menggunakan kombinasi *wavelet* dan *Support Vector Machine* (SVM) memiliki akurasi yang tinggi (Alomari, dkk., 2014). Penelitian yang memiliki akurasi yang paling tinggi dalam klasifikasi sinyal EEG menggunakan kombinasi metode *wavelet* dan *Interval Type-2 Fuzzy Logic System* (IT2FLS) (Nguyen, dkk., 2015) berdasarkan teori penelitian sebelumnya (Liang & Mendel, 2000). Akan

tetapi metode pada penelitian tersebut kurang optimal apabila data *input* yang digunakan memiliki banyak artefak yang disebabkan oleh pergerakan kepala atau kedipan mata. Penelitian tersebut juga belum optimal apabila diterapkan pada sinyal EEG yang diperoleh secara *realtime*. Terdapat beberapa pendekatan yang dapat digunakan untuk penghilangan artefak pada sinyal EEG. Berdasarkan studi literatur yang dilakukan antara tahun 2010 sampai 2015. Beberapa penelitian dengan tujuan atau kasus penghilangan artefak pada sinyal EEG melakukan penghilangan artefak dengan hanya menggunakan metode *Independent Component Analysis* (ICA). Selain itu terdapat pendekatan yang menggunakan metode ICA untuk dikombinasikan dengan beberapa metode lainnya, seperti *Lifting Wavelet Transform* dan *Wavelet Transform*. Pada pendekatan-pendekatan tersebut hanya melakukan penghilangan dari artefak yang disebabkan oleh kedipan (Bertrand & Moonen, 2014), pergerakan bola mata, dan perubahan interferensi tegangan pada EEG. Tidak terdapatnya penghilangan artefak yang disebabkan oleh pergerakan kepala. Pendekatan-pendekatan tersebut akan mengalami kesulitan apabila data referensi sinyal EEG yang digunakan memiliki banyak artefak yang disebabkan oleh pergerakan kepala. Hal tersebut dikarenakan pergerakan kepala dapat mempengaruhi hampir keseluruhan sinyal EEG dari tiap-tiap *channel* elektroda dari perangkat EEG.

Berdasarkan permasalahan yang terdapat pada kasus klasifikasi sinyal EEG dan kasus penghilangan artefak pada sinyal EEG tersebut, diusulkan *Automatic Artifact Removal* (AAR) menggunakan modifikasi metode ICA yang memanfaatkan referensi sinyal EEG dan sensor giroskop. Pada penelitian sebelumnya menggunakan sensor giroskop pada pendeteksian artefak dengan memanfaatkan analisis distribusi (O'Regan, dkk., 2013), sedangkan pada penelitian ini menggunakan modifikasi ICA. Modifikasi ICA pada penelitian ini dilakukan untuk mendapatkan hasil berupa *independent component* yang memiliki indeks urut. Penggunaan referensi sensor giroskop diharapkan dapat mengatasi masalah referensi sinyal EEG yang juga memiliki banyak artefak yang disebabkan oleh pergerakan kepala. Penghilangan artefak pada penelitian ini melalui dua tahap, diantaranya yaitu penghilangan artefak yang disebabkan oleh pergerakan kepala dan kedipan mata, serta tidak menutup kemungkinan penghilangan artefak yang disebabkan oleh hal lain. Dengan otomatisasi penghilangan artefak kedipan mata dan pergerakan kepala pada sinyal EEG, diharapkan dapat meningkatkan hasil klasifikasi sinyal EEG ke dalam suatu informasi untuk menggerakkan mobil *virtual* tiga dimensi dengan menggunakan metode *Support Vector Machine* (SVM) sebagai pengklasifikasi.

## **2. Pendekatan dan Tinjauan Pustaka**


### **2.1. Pengambilan Data**

Data sinyal EEG yang digunakan pada penelitian ini direkam menggunakan perangkat Emotiv EPOC dari pengguna dengan umur 19 sampai 32 tahun (Golz, dkk., 2013), tidak mempunyai cacat mental, dan tidak pernah minum minuman beralkohol. Umur mempengaruhi produksi sinyal EEG (Vysata, dkk., 2014). Jenis klasifikasi sinyal EEG yang digunakan pada penelitian ini yaitu berupa sinyal aksi atau suatu perintah yang diberikan dengan hanya memikirkan perintah tersebut. Pada kasus untuk mengendalikan mobil membutuhkan lima macam perintah atau aksi, diantaranya perintah untuk mundur, maju, kanan, kiri, dan berhenti. Pada penelitian ini, aksi maju, mundur, atau berhenti menggunakan masukan sinyal EEG sedangkan aksi kanan atau kiri menggunakan masukan sensor giroskop. Pada proses perekaman sinyal, pengguna harus memperhatikan visual yang terdapat pada layar monitor. Hal tersebut bertujuan untuk mengatasi masalah variasi pada data yang direkam.

### **2.2. Pemrosesan Sinyal EEG**

Pemrosesan sinyal EEG merupakan suatu cara bagaimana memproses dan menerjemahkan sinyal EEG menjadi suatu informasi yang bermanfaat. Dengan adanya klasifikasi terhadap sinyal EEG, dapat menjadi solusi teknologi yang bermanfaat bagi manusia berkebutuhan khusus, khususnya cacat fisik, sehingga manusia berkebutuhan khusus dapat melakukan aktivitas seperti manusia pada umumnya. Namun, pemrosesan sinyal EEG memiliki banyak tantangan, khususnya masalah *noise* atau artefak yang terdapat pada sinyal EEG.

Artefak dapat disebabkan oleh kedipan mata, pergerakan kepala, aktivitas otot, kualitas elektroda, dsb., sehingga dapat mengganggu kualitas sinyal EEG tersebut, serta mengakibatkan hasil klasifikasi sinyal EEG jauh dari yang diharapkan. Gambar 1 adalah gambar sinyal EEG yang dipengaruhi artefak. Penelitian ini mengusulkan modifikasi metode ICA dengan memanfaatkan data referensi EEG dan sensor giroskop untuk mengatasi masalah artefak pada sinyal EEG.



Gambar 1. Sinyal EEG yang Dipengaruhi Artefak (Sumber: O'Regan, dkk., 2013)

**2.3. Independent Component Analysis (ICA)**

Independent Component Analysis (ICA) adalah sebuah teknik pemrosesan sinyal untuk menemukan faktor-faktor atau komponen tersembunyi yang membentuk sekumpulan variabel acak (hasil dari pengukuran, sinyal atau secara umum data). Apabila A adalah  $n \times m$  matriks pencampuran dan n merupakan derau, sinyal teramati (campuran) vektor x dapat dirumuskan dengan persamaan (1). Kemudian setelah memperkirakan matriks A, dapat dihitung inversnya (yang disebut dengan W). Setelah W didapatkan, maka dapat dihitung perkiraan sinyal sumber seperti pada persamaan (2).

$$x = As + n \tag{1}$$

$$y = Wx \tag{2}$$

Pada model ICA, akan terjadi kerancuan seperti tidak dapat ditentukannya varian dari komponen independen dan tidak dapat ditentukannya urutan dari komponen independen. Oleh karena itu, pada penelitian ini dilakukan modifikasi ICA berupa perbandingan nilai standar deviasi pada masing-masing komponen, sehingga dapat diperoleh komponen independen yangurut dan sesuai dengan variannya.

**2.4. Fast Fourier Transform (FFT)**

FFT merupakan algoritma yang efisien untuk menghitung Discrete Fourier Transform (DFT) dan kebalikannya, sehingga dapat menurunkan jumlah perhitungan DFT, dimana prinsip DFT adalah mentransformasikan sinyal analog menjadi sinyal diskret dalam domain waktu, dan kemudian diubah ke dalam domain frekuensi. Hal ini dilakukan dengan mengalikan sinyal diskrit dengan suatu fungsi kernel. Persamaan (3) merupakan perhitungan FFT, berasal dari DFT-N data, dengan i merupakan indeks dalam domain waktu, sedangkan m merupakan indeks dalam domain frekuensi (Sugeng & Agus, 2009). Kesimpulan dari algoritma FFT yaitu memiliki waktu komputasi yang lebih rendah dibandingkan dengan algoritma DFT. Perhitungan DFT secara langsung akan membutuhkan operasi aritmatikasebanyak  $O(N^2)$ , sedangkan perhitungan dengan FFT hanya membutuhkan operasi sebanyak  $O(N \log N)$ .

$$X(m) = \sum_{i=0}^{N-1} x(n)e^{-j\left(\frac{2\pi}{N}\right)mi} \tag{3}$$

**2.5. Power Spectral Density (PSD)**


Metode ini pertama sekali dikemukakan oleh Welch (1967). Isyarat masukan dibagi menjadi segmen-segmen yang pendek dan perhitungan periodogram dilakukan berdasarkan

perhitungan FFT, dengan demikian untuk mencari estimasi spektrum daya dapat dilakukan dengan perhitungan yang lebih efisien. Setiap segmen data dimodifikasi dengan mengalikan pada suatu fungsi jendela (*window*), sebelum dilakukan perhitungan *periodogram*. Selanjutnya *periodogram* yang telah dimodifikasi ini dirata-ratakan dan akan menghasilkan estimasi spektrum yang lebih baik. Persamaan (4) merupakan persamaan untuk menghitung *power spectrum* dengan memanfaatkan FFT, dengan  $s(e^{j\omega})$  merupakan *power spectrum*, dan  $w_i$  merupakan koefisien *window*.

$$s(e^{j\omega}) = \frac{\frac{1}{N} \left| \sum_{i=1}^N w_i x_i e^{-j\omega i} \right|^2}{\frac{1}{N} \left| \sum_{i=1}^N w_i \right|^2} \quad (4)$$

## 2.6. Support Vector Machine

Pengklasifikasian menggunakan konsep *Support Vector Machine* (SVM) memiliki hasil akurasi yang baik (Damayanti, dkk., 2010). Metode SVM dapat diterapkan pada beberapa kasus untuk proses klasifikasi secara *realtime*, khususnya klasifikasi mental dalam berkendara (Zhao, dkk., 2011), klasifikasi tingkat rasa kantuk pengemudi ketika berkendara (Sun, dkk., 2015), dsb. Pada penelitian ini menggunakan metode SVM untuk kasus pengendalian mobil secara *realtime*. Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*. Seperti yang terlihat pada Gambar 2 (Lenc & Král, 2015). *Hyperplane* pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat ini disebut sebagai *support vector*. SVM dapat melakukan klasifikasi data yang terpisah secara linier (*Linearly separable*) dan non-linier (*nonlinear separable*) (Burges, 1998). *Linearly separable* data merupakan data yang dapat dipisahkan secara linier.



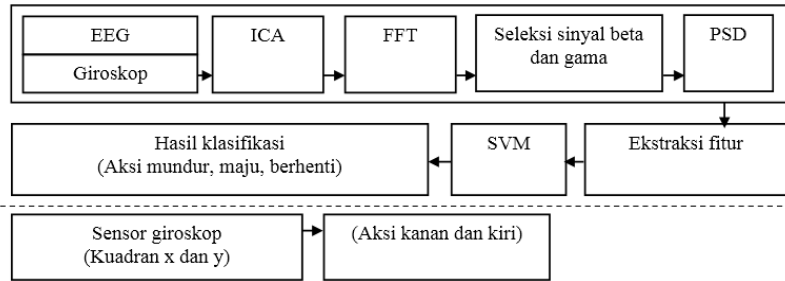
Gambar 2. Hyperline SVM

SVM pertama kali dikembangkan untuk klasifikasi biner, namun selanjutnya dikembangkan untuk klasifikasi *multiclass* (banyak kelas). Pendekatannya adalah dengan membangun *multiclass classifier*, yaitu dengan cara menggabungkan beberapa SVM biner. Pendekatan ini terdiri dari metode satu lawan semua (*One Against All*) dan metode satu lawan satu (*One Against One*) (Hsu & Lin, 2002).


## 3. Metodologi

Gambar 3 menunjukkan desain dari penelitian. Penelitian ini memanfaatkan dua jenis sinyal, yaitu sinyal EEG dan sinyal yang diperoleh dari sensor giroskop. Sesuai tujuan dan batasan pada penelitian ini, jenis sinyal EEG yang digunakan pada penelitian ini yaitu berupa sinyal *beta* dan *gamma*. Hal tersebut dikarenakan sinyal beta terjadi pada saat seseorang mengalami aktivitas mental yang terjaga secara penuh khususnya berpikir, dan sinyal *gamma*

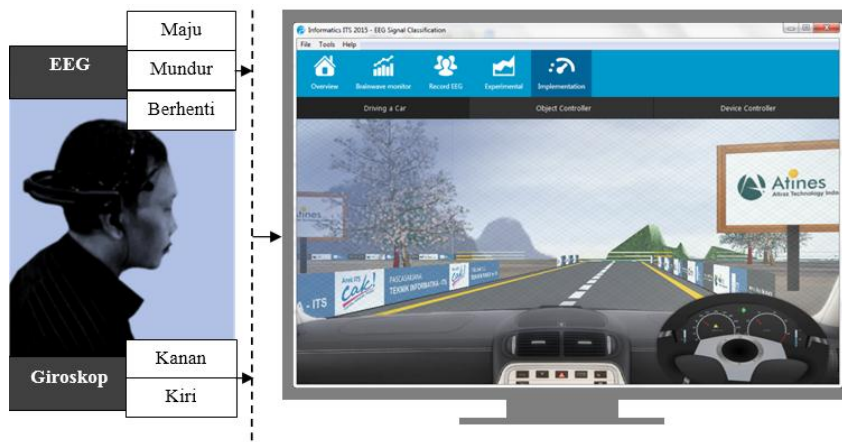
dihasilkan saat seseorang dalam keadaan berpikir keras. Data yang diperoleh dari sensor giroskop akan digunakan untuk mendukung penghilangan artefak setelah proses perekaman sinyal EEG. Gambar 4 merupakan pemrosesan sinyal EEG pada penelitian ini, dan Gambar 5 menunjukkan penerapan hasil pemrosesan sinyal EEG sebagai kendali mobil *virtual*.



Gambar 3. Desain Penelitian



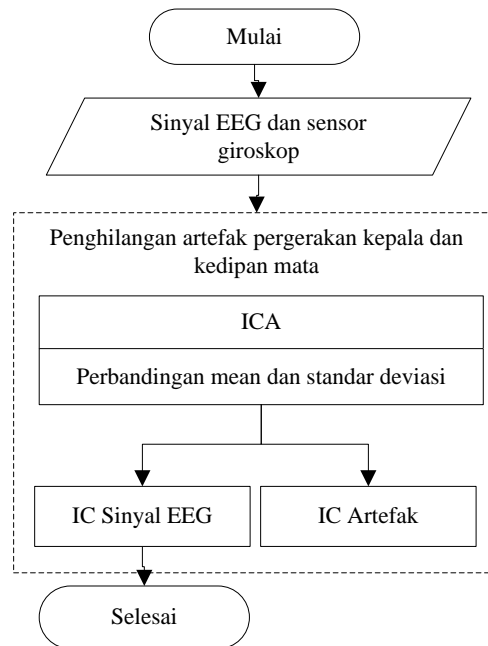
Gambar 4. Pemrosesan Sinyal EEG: (a) Sinyal EEG, (b) Reduksi Artefak Menggunakan ICA, (c) Hasil FFT, (d) Ekstraksi Sinyal Beta dan Gama, (e) Hasil PSD, (f) Ekstraksi Fitur



Gambar 5. Penerapan Hasil Pemrosesan Sinyal EEG Sebagai Kendali Mobil *Virtual*

### 3.1. Automatic Artifact Removal (AAR)

Pada penelitian ini mengusulkan kombinasi penghilangan artefak secara otomatis atau AAR menggunakan modifikasi metode ICA dengan memanfaatkan referensi sinyal EEG dan sensor giroskop, khususnya untuk penghilangan artefak yang disebabkan oleh kedipan mata dan pergerakan kepala. Gambar 6 menunjukkan proses penghilangan artefak atau *noise* pada sinyal EEG. Hasil sinyal yang dihasilkan oleh metode ICA kadang memiliki indeks yang tidakurut antara sinyal yang ber-*noise* dan tidak ber-*noise*. Untuk mengatasi hal tersebut dilakukan perbandingan antara nilai *mean* dan standar deviasi dari tiap-tiap *index output* ICA. Sehingga *index output* dari ICA selalu dalam keadaan urut antara sinyal yang ber-*noise* dan tidak ber-*noise*.



Gambar 6. Penghilangan Artefak atau *Noise* Pada Sinyal EEG

### 3.2. Ekstraksi Fitur

Ekstraksi fitur sinyal EEG terdapat beberapa pendekatan, seperti analisis spektrum, *bayesian* (Suk & Lee, 2013), analisis statistika, dsb. Pada penelitian ini menggunakan *Zero Crossing Rate* (ZCR). Tahap ini bertujuan untuk mendapatkan fitur-fitur yang terpilih dari masukkan data-data pelatihan. Fitur-fitur yang terpilih nantinya digunakan untuk proses klasifikasi pelatihan dan digunakan untuk ekstraksi fitur data pengujian. Ekstraksi fitur pada proses pengujian dilakukan dengan mengambil hasil ekstraksi fitur pada proses pelatihan diterapkan pada data pengujian. Hasil ekstraksi fitur pada data pengujian ini nantinya digunakan sebagai masukan pada proses klasifikasi pengujian.

### 3.3. Klasifikasi

Pengklasifikasian dengan metode *SVM* dibagi menjadi dua proses, yaitu proses pelatihan dan pengujian. Pada proses pelatihan *SVM* menggunakan matriks ciri yang dihasilkan pada proses ekstraksi ciri pelatihan sebagai *input*. Sedangkan pada pengujian *SVM* memanfaatkan matriks ciri yang dihasilkan pada proses ekstraksi ciri pengujian sebagai *input*.

Algoritma pelatihan untuk masing-masing pengklasifikasi *SVM* biner dapat dituliskan sebagai berikut: *input* berupa matriks  $B$  (matriks hasil ekstraksi ciri pelatihan) dan vektor  $Y$  sebagai pasangan *input-target* dan *output*-nya adalah  $w, x, b$  (variabel-variabel persamaan *hyperplane*). Langkah-langkahnya (Damayanti, dkk., 2010) dijelaskan sebagai berikut: (1) Tentukan *Input* ( $Z = B$ ) dan *Target* ( $Y$ ) sebagai pasangan pelatihan dari dua kelas. (2) Hitung

Kernel Gaussian  $K(Z, Z_i) = \exp\left(\frac{-|Z - Z_i|^2}{(2\sigma^2)}\right)$ . (3) Hitung Matriks Hessien  $H = K(Z, Z_i) * Y * Y^T$ .

(4) Tetapkan  $c$  dan  $\epsilon$ . (5) Tetapkan vektor  $e$  sebagai vektor satuan yang memiliki dimensi sama dengan dimensi  $Y$ . (6) Hitung solusi *quadratic programming*:  $\min L(\alpha) = \frac{1}{2} \alpha^T H \alpha - e^T \alpha$ , dimana  $y^T \alpha = 0$  dan  $0 \leq \alpha \leq c$ .

Pengklasifikasian SVM untuk *multiclass One Against All* akan membangun sejumlah  $k$  SVM biner ( $k$  adalah jumlah kelas). Fungsi *kernel* yang digunakan pada penelitian ini adalah Gaussian. Perhitungan ini dapat dilihat pada persamaan (5). Sejumlah *support vector* pada setiap data pelatihan harus dicari untuk mendapatkan solusi bidang pemisah terbaik. Solusi bidang pemisah didapatkan dengan rumus  $w = \sum \alpha_i y_i x_i$ ;  $b = y_k - w^T x_k$  untuk setiap  $x_k$ , dengan  $\alpha_k \neq 0$ . Proses pengujian atau klasifikasi dilakukan juga pada setiap SVM biner menggunakan nilai  $w$ ,  $b$ , dan  $x_i$  yang dihasilkan pada proses pelatihan di setiap SVM biner. Fungsi yang dihasilkan untuk proses pengujian dapat dilihat pada persamaan (6), dimana  $i = 1$  sampai  $k$ ;  $x_i = \text{support vector}$ ;  $x_d = \text{data pengujian}$ . *Output*-nya adalah berupa indeks  $i$  dengan  $f_i$  terbesar yang merupakan kelas dari data pengujian. Pada penelitian ini menggunakan *library LIBSVM* (Chang & Lin, 2011).

$$K(x, y) = \exp\left(\frac{-|x - y|^2}{(2\sigma^2)}\right). \quad (5)$$

$$f_i = K(x_i, x_d) w_i + b_i \quad (6)$$

#### 4. Hasil dan Pembahasan

Data yang digunakan pada penelitian ini lebih dari 800 sinyal EEG yang terdiri dari delapan *channel* pada setiap kelas. Data sinyal EEG tersebut direkam sendiri menggunakan perangkat Emotiv EPOC secara langsung. Proses perekaman sinyal EEG dengan durasi dua detik. Sehingga menghasilkan 256 bit untuk tiap *channel* perangkat EEG. Proses perekaman sinyal EEG harus mempertimbangkan syarat-syarat perekaman yang digunakan pada penelitian ini, seperti umur 19 sampai 32 tahun, tidak pernah minum minuman beralkohol, dan tidak memiliki cacat mental. Data sinyal EEG yang telah direkam akan diproses menggunakan metode yang diusulkan pada penelitian ini, kemudian disimpan ke dalam *database* untuk digunakan sebagai *data training* dan *data testing*. Sebesar 70% data akan digunakan sebagai *data training*, sedangkan 30% akan digunakan sebagai *data testing*. Hasil klasifikasi sinyal EEG akan menghasilkan suatu aksi berupa aksi maju, mundur, atau berhenti.

Pada tahap pengujian secara *offline* dilakukan perbandingan nilai akurasi terhadap beberapa metode yang telah dilakukan pada penelitian sebelumnya. Sedangkan pengujian secara *online* dilakukan dengan mencoba mengendalikan mobil *virtual* dengan menggunakan perintah sinyal EEG manusia secara *realtime*.




Tabel 1 merupakan hasil penelitian untuk klasifikasi sinyal EEG yang terdiri dari tiga kelas (maju, mundur, dan berhenti). Modifikasi ICA pada penelitian dilakukan dengan menambahkan perbandingan nilai *mean* dan standar deviasi untuk mendapatkan komponen independen yang memiliki indeks yang sesuai dengan varian, serta memanfaatkan referensi sinyal EEG dan sensor giroskop. Penggunaan referensi sensor giroskop mampu mengatasi masalah artefak yang disebabkan oleh pergerakan kepala. Hal tersebut dikarenakan pada perangkat Emotiv EPOC sensor giroskop dan sinyal EEG direkam secara bersamaan. Pada hasil tersebut, hanya diperoleh akurasi sebesar 71% dikarenakan sulitnya mendapatkan informasi detail dan pasti dari sinyal EEG, karena perangkat EEG hanya membaca perubahan potensial pada permukaan kepala manusia. Perubahan tersebut juga tidak selalu disebabkan oleh aktivitas otak manusia saja, namun perubahan atau pergerakan otot juga mempengaruhi data yang dibaca oleh perangkat EEG. Nilai akurasi tersebut dapat diperoleh apabila pengguna berkonsentrasi tinggi ketika sinyal EEG direkam.

**Tabel 1. Hasil Eksperimen Pemrosesan dan Klasifikasi Sinyal EEG**

Metode yang dibandingkan	Precision	Recall	F-Measure
FFT, dan SVM	0.54	0.83	0.65
FFT, PSD, dan SVM	0.62	0.96	0.75
ICA, FFT, PSD, dan SVM	0.69	0.94	0.79
<b>Mod-ICA, FFT, PSD, dan SVM</b>	<b>0.71</b>	<b>0.95</b>	<b>0.81</b>

Terdapat perbedaan hasil akurasi apabila menggunakan metode ICA dan menggunakan modifikasi ICA. Perbedaan tersebut terjadi apabila data sinyal EEG yang digunakan memiliki artefak yang disebabkan oleh pergerakan kepala. Ketika pengguna menggerakkan kepala, akan mengakibatkan adanya artefak yang mempengaruhi setiap elektroda pada perangkat EEG. Hal tersebut mengakibatkan proses penghilangan artefak yang hanya memanfaatkan referensi sinyal EEG kurang maksimal. Gambar 7 merupakan sinyal EEG yang dipengaruhi oleh pergerakan kepala. Sedangkan Gambar 8 merupakan sinyal yang diperoleh dari sensor giroskop dan direkam bersamaan dengan sinyal EEG.

Apabila hanya menggunakan referensi sinyal EEG akan sulit memisahkan sinyal yang disebabkan oleh pergerakan kepala tersebut. Oleh karena itu, pada penelitian ini menggunakan dua referensi pada metode ICA yang diusulkan untuk penghilangan artefak, khususnya artefak pergerakan kepala. Metode modifikasi ICA yang diusulkan pada penelitian ini mampu menghilangkan artefak tersebut, seperti ditunjukkan pada Gambar 9. Dihilangkan suatu sinyal EEG yang terpisah dari sinyal yang terindikasi sebagai artefak.

**Gambar 7. Sinyal EEG yang Dipengaruhi Artefak Pergerakan Kepala****Gambar 8. Sinyal Giroskop yang Direkam Bersamaan dengan Sinyal EEG****Gambar 9. Sinyal EEG yang Terpisah dari Artefak**

Dengan diperoleh sinyal EEG yang sudah terpisah dari artefak, maka dapat meningkatkan akurasi pada tahap klasifikasi sinyal EEG. Pada penelitian ini, komputasi yang dibutuhkan oleh komputer cukup besar, khususnya apabila menggunakan data sinyal EEG secara *realtime*. Hal tersebut juga dipengaruhi dengan proses *rendering* lingkungan *virtual* tiga dimensi.

## 5. Kesimpulan

Pemrosesan dan klasifikasi sinyal EEG dengan menggunakan metode yang diusulkan pada penelitian ini memiliki akurasi sebesar 71% khususnya dengan data sinyal EEG yang direkam secara langsung menggunakan perangkat Emotiv EPOC. Dengan hasil penelitian tersebut, pengguna dapat mengontrol mobil *virtual* yang terdapat pada aplikasi penelitian ini dengan menggunakan perintah sinyal EEG, khususnya pada tiga kelas aksi, yaitu maju, mundur, atau berhenti. Sedangkan kelas kanan atau kiri menggunakan sensor giroskop. Pada penelitian ini penggunaan modifikasi ICA dikhususkan pada penghilangan artefak yang disebabkan oleh



kedipan mata dan pergerakan kepala, sehingga dapat meningkatkan akurasi klasifikasi sinyal EEG. Pada penelitian ini, penerapan pemrosesan sinyal EEG secara *realtime* membutuhkan komputasi yang cukup tinggi, dikarenakan setiap dua detik sinyal EEG akan diproses bersamaan dengan *rendering* lingkungan *virtual* tiga dimensi.

## 6. Penelitian Selanjutnya

Berdasarkan hasil penelitian yang telah dilakukan pada penelitian ini, kedepannya akan dilakukan penelitian dengan pendekatan baru untuk mendapatkan nilai akurasi yang lebih baik, sehingga klasifikasi sinyal EEG pada kasus kendali mobil secara *realtime* menjadi lebih optimal.

## Referensi

- Alomari, M. H., Abubaker, A., Turani, A., Baniyounes, A. M., & Manasreh, A. 2014. EEG Mouse: A Machine Learning-Based Brain Computer Interface. *IJACSA) International Journal of Advanced Computer Science and Applications*, 5(4), 193-198.
- Bertrand, A., & Moonen, M. 2014. Distributed eye blink artifact removal in a wireless EEG sensor network. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 5849-5853). IEEE.
- Burges, C. J. 1998. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- Chang, C. C., & Lin, C. J. 2011. LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), 27.
- Damayanti, F., Arifin, A. Z., & Soelaiman, R. 2010. Pengenalan citra wajah menggunakan metode two-dimensional linear discriminant analysis dan support vector machine. *Jurnal Ilmiah Kursor*, 5(3), 147-156.
- Golz, M., Sommer, D., Trutschel, U., Krajewski, J., & Sirois, B. (2013). Driver Drowsiness Immediately before Crashes—A Comparative Investigation of EEG Pattern Recognition. In *7th International Driving Symposium on Human Factors in Driver Assessment, Training, and Vehicle Design* (No. 78).
- Hsu, C. W., & Lin, C. J. 2002. A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2), 415-425.
- Lenc, L., & Král, P. 2015. Automatic face recognition system based on the SIFT features. *Computers & Electrical Engineering*, 46, 256-272.
- Liang, Q., & Mendel, J. M. 2000. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on Fuzzy systems*, 8(5), 535-550.
- Nguyen, T., Khosravi, A., Creighton, D., & Nahavandi, S. 2015. EEG signal classification for BCI applications by wavelets and interval type-2 fuzzy logic systems. *Expert Systems with Applications*, 42(9), 4370-4380.
- O'Regan, S., Faul, S., & Marnane, W. 2013. Automatic detection of EEG artefacts arising from head movements using EEG and gyroscope signals. *Medical engineering & physics*, 35(7), 867-874.
- Sugeng, R., & Agus, P. 2009. Algoritma Fast Fourier Transform (FFT) Decimation in Time (DIT) dengan Resolusi 1/10 Hertz. In *Seminar Nasional Penelitian, Pendidikan, dan Penerapan MIPA 2009*.
- Suk, H. I., & Lee, S. W. 2013. A novel Bayesian framework for discriminative feature extraction in brain-computer interfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(2), 286-299.
- Sun, H., Bi, L., Chen, B., & Guo, Y. 2015. EEG-based Safety Driving Performance Estimation and Alertness Using Support Vector Machine. *International Journal of Security and Its Applications*, 9(6), 125-134.
- Vysata, O., Kukal, J., Prochazka, A., Pazdera, L., Simko, J., & Valis, M. 2014. Age-related changes in EEG coherence. *Neurologia i neurochirurgia polska*, 48(1), 35-38.
- 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*, 15(2), 70-73.

Zhao, C., Zheng, C., Zhao, M., Liu, J., & Tu, Y. 2011. Automatic classification of driving mental fatigue with EEG by wavelet packet energy and KPCA-SVM. *Int. J. Innov. Comput. Control*, 7(3), 1157-1168.