

PENGARUH CIRI TEMPORAL, SPASIAL, DAN FREKUENSI PADA KLASIFIKASI *MOTOR IMAGERY*

Afin Muhammad Nurtsani¹, Muhammad Adib Syamlan², Agung Wahyu Setiawan^{*3}

^{1,2,3}Institut Teknologi Bandung, Bandung

Email: ¹23220068@std.stei.itb.ac.id, ²23220091@std.stei.itb.ac.id, ³awsetiawan@stei.itb.ac.id

*Penulis Korespondensi

(Naskah masuk: 25 Oktober 2021, diterima untuk diterbitkan: 02 Juni 2022)

Abstrak

Interaksi mesin-komputer merupakan suatu keniscayaan dan akan menjadi bagian yang tidak terpisahkan dari kehidupan dalam waktu dekat, terutama di bidang rekayasa rehabilitasi. Salah satu bidang yang berkembang adalah klasifikasi *Motor Imagery* (MI) berbasis sinyal EEG. Set data pada studi ini diambil dari BCI Competition IV - 2b. Prapemrosesan data dilakukan dengan menggunakan BPF *Butterworth orde 5* dengan frekuensi *cut-off* sebesar 8 – 30 Hz. Pada studi ini, dilakukan investigasi pengaruh ciri temporal; spasial; dan frekuensi serta kombinasi ciri temporal-spasial dan temporal-spasial-frekuensi. Ciri temporal diekstraksi dengan menggunakan ICA, ciri spasial dengan CSP, dan frekuensi dengan STFT. Terdapat empat pengklasifikasi yang digunakan, yaitu SVM; RF; k-NN; dan NB. Salah satu temuan pada studi ini adalah meskipun digunakan kombinasi ciri temporal-spasial maupun temporal-spasial-frekuensi, nilai akurasi yang diperoleh sama, yaitu sekitar 72%. Kinerja kedua kombinasi ciri ini masih kalah apabila dibandingkan dengan hanya menggunakan ciri independen temporal dengan nilai akurasi mencapai 73%. Selain itu, pengklasifikasi RF memberikan kinerja yang paling baik dibandingkan dengan SVM; k-NN; serta NB.

Kata kunci: *motor imagery, temporal, spasial, frekuensi, random forest*

EFFECT OF SPATIAL, TEMPORAL, AND FREQUENCY FEATURES IN THE *MOTOR IMAGERY CLASSIFICATION*

Abstract

Human-computer interaction is a necessity and will be deployed in the near future, especially in rehabilitation engineering. One of the development is focused on the classification of Imagery Motor (MI) based on EEG signals. In this study, the dataset is taken from BCI Competition IV - 2b. The first step of the classification process is data preprocessing that is performed using BPF Butterworth 5th order with a cut-off frequency of 8 - 30 Hz. The aim of this study is to investigate the effect of independent feature such as temporal, spatial, frequency, and the combination of temporal-spatial and temporal-spatial-frequency features. Temporal feature is extracted using ICA, spatial feature using CSP, and frequency feature using STFT. In this study, four classifiers are used, i.e., SVM; RF; k-NN; and NB. One of the main findings in this study is that although the combination of temporal-spatial and temporal-spatial-frequency features is used, the accuracy value of 72% are obtained. The performance of these two combinations of features is still inferior when compared to independent temporal feature with an accuracy value of 73%. In addition, RF classifier provides the best performance compared to SVM; k-NN; and NB.

Keywords: *motor imagery, temporal, spatial, frequency, random forest*

1. PENDAHULUAN

Motor Imagery (MI) merupakan suatu metode di mana seseorang membayangkan sedang menggerakkan bagian tubuh tertentu. Aktivitas membayangkan ini akan menstimulasi aktivitas otak, tepatnya pada bagian korteks sensorimotor primer, yang dikenal dengan nama *Sensorimotor Rhythms* (SMR). Peningkatan dan penurunan dari osilasi

SMR ini dikaitkan dengan *event-related synchronization* (ERS) dan *event-related desynchronization* (ERD). ERS dan ERD MI pada gelombang otak dapat dideteksi pada gelombang α di *sensorimotor region* yang biasa dikenal dengan gelombang μ , dan pada gelombang β .

Penelitian akan pendeteksian MI sudah banyak diteliti. Beberapa penelitian tersebut menggunakan

set data publik yang didapatkan dari situs kompetisi dan penelitian terbuka. Lu dkk menggunakan set data PyhsioNet EEG MI (Schalk dkk, 2004) dengan metode *Temporal Convolution Network* (TCN) dengan akurasi sebesar 97,89% (Lu dkk, 2020). Korhan dkk menggunakan *Common Spatial Network* (CSP) dengan *Convolution Neural Network* (CNN) pada set data BCI Competition III-3a (Blankertz dkk, 2004) dengan akurasi 93,75% (Korhan dkk, 2019). Machingal dkk menggunakan *Robust Common Spatial Pattern* (RoCSP) sebagai ekstraksi ciri dan diklasifikasi oleh *Distributed Coding Spiking Neural Network* dengan akurasi sebesar 82,79% (Machingal dkk, 2020) pada set data BCI Competition IV-2a (Tangermann dkk, 2012).

Beberapa peneliti juga menggunakan dataset BCI Competition IV-2b sebagai data primer penelitian (Tangermann dkk, 2012). Yang dkk menggunakan metode *Long-Short Term Memory* (LSTM) yang digabungkan dengan CNN dan menghasilkan akurasi sebesar 76,4% (Yang dkk, 2019). Wang dkk menggunakan *Short-time Fourier Transform* (STFT) yang dilanjutkan dengan Shallow CNN (SCNN) dengan akurasi sebesar 73% (Wang dkk, 2019). Zhao dkk menggunakan *Deep Convolution Network* (DNN) yang memiliki lapisan konvolusi khusus untuk mengidentifikasi untuk ciri temporal dan spasial. Metode ini memberikan akurasi sebesar 83,98% (Zhao dkk, 2021). Namun dari penelitian-penelitian tersebut masih belum bisa diketahui besar pengaruh ciri pada EEG secara independen atau gabungan dari ciri tersebut.

Studi mengenai MI ini diharapkan dapat menjadi sarana interaksi manusia-mesin yang diperkirakan akan muncul seiring dengan waktu (Rashid dkk, 2020). Secara umum, terdapat dua tahapan utama dari deteksi gerakan berbasis MI, yaitu ekstraksi ciri dan klasifikasi. Terdapat 3 macam ciri dasar yang dapat diambil dari sinyal MI EEG, yaitu temporal, frekuensi, dan spasial (Padfield dkk, 2019), (Xu dkk, 2020). Selain ketiga ciri dasar tersebut, beberapa peneliti menggunakan kombinasi ciri-ciri tersebut, seperti *Common Spatial Pattern* (CSP) dan *Fast Fourier Transform* (FFT) *Energy Maps* sebagai ekstraksi ciri pada domain spasial-frekuensi (Rammy dkk, 2020). Selain itu, terdapat beberapa pengembangan dari metode CSP ini, yaitu CSP *Local Characteristic-Scale Decomposition* (CSP-LCSD) (Liu dkk, 2017); *Filter Bank Common Spatial Pattern* (FBCSP) (Ha & Jeong, 2019). Pada studi yang lain, dilakukan investigasi terhadap pengaruh kanal-kanal EEG yang berisi informasi yang lebih berkorelasi, yaitu dengan menggunakan *All Channels CSP* (AC-CSP); *All Channels Regularized CSP* (AC-RCSP); *Correlation-based Channel Selection CSP* (CCS-CSP); dan CCS-RCSP (Jin dkk, 2019). Selain itu, terdapat studi yang menerapkan CSP dengan metode seleksi interval waktu yang optimal untuk setiap subjek, yaitu CSP *Fixed Time Interval* (CSP-FTI);

CSP *Optimum Time Interval* (CSP-OTI); dan CSP *Optimum Time* (CSP-OT) (Selim dkk, 2020). Perbandingan ekstraksi ciri ini dapat dilihat pada Tabel 1.

Tabel 1. Perbandingan Metode Ekstraksi Ciri & Klasifikasi

Penulis	Set Data	Ekstraksi Ciri	Pengklasifikasi	Akurasi (%)
(Liu dkk, 2017)	BCIC IV 2a	CSP-LCSD	SRDA	57
		CSP-LCSD	FA-LA-SRDA	70
		CSP-LCSD	GA	60
		CSP-LCSD	APSO	60
(Ha & Jeong, 2019)	BCIC IV 2b	FBCSP	FBCSP	67
		FBCSP	KNN	67
		FBCSP	RF	71
		FBCSP	LDA	62
		FBCSP	SVM	72
		FBCSP	NB	71
(Jin dkk, 2019)	BCIC IV 2a	AC-CSP	SVM	56
		AC-RCSP	SVM	76
		CCS-CSP	SVM	78
		CCS-RCSP	SVM	82
(Padfield dkk, 2019)	BNCI Horizon 2020 4	TM	SVM	72
		SM	SVM	73
		A-BP	SVM	67
		S-BP	SVM	72
(Selim dkk, 2020)	BCIC IV 2a	fast FFT	SVM	70
		CSP-FTI	SVM	64
		CSP-OTI	SVM	65
		CSP-OTI	BA-SVM	72
		CSP-OT	AM-SVM	73
		CSP-OT	BA-SVM	79

Namun demikian, pada studi yang telah dilakukan tersebut belum ada yang menjelaskan mengenai pengaruh tiga ciri MI terhadap kinerja klasifikasi. Oleh karena itu, pada studi ini akan dilakukan investigasi pada pengaruh ketiga ciri sinyal μ dan β terhadap kinerja klasifikasi. Ekstraksi ciri temporal akan dilakukan dengan menggunakan *Independent Component Analysis* (ICA). Pemilihan metode ini didasarkan bahwa ICA sudah umum digunakan pada pengolahan sinyal EEG (Zhu dkk, 2020), (Huang, Condor, & Huang, 2020). Selanjutnya, *Short-Time Fourier Transform* (STFT) digunakan pada ekstraksi ciri frekuensi. Penggunaan STFT sebagai ekstraksi ciri pada sinyal EEG sudah sangat umum dan populer yang digunakan untuk melihat sebaran frekuensi sinyal 1 dimensi. Sedangkan ciri ketiga, spasial, diekstraksi menggunakan CSP. Metode ini dipilih karena CSP memiliki efektifitas yang lebih baik (Ha & Jeong, 2019). Selain itu, akan dilakukan perbandingan dari gabungan ketiga metode tersebut untuk mengetahui apakah ada pengaruhnya pada klasifikasi MI.

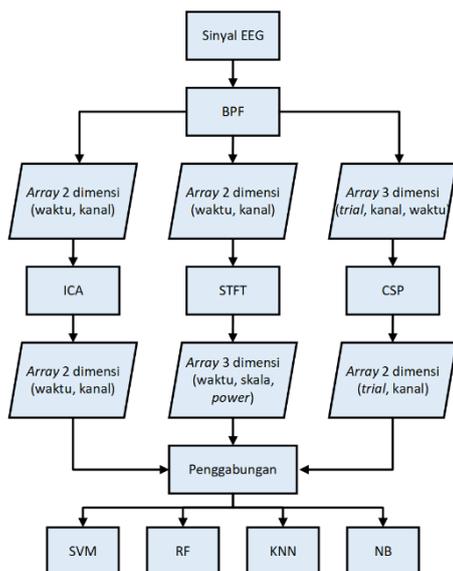
Salah satu pertimbangan utama dalam pemilihan metode klasifikasi adalah pentingnya efisiensi beban komputasi, di mana kinerjanya sudah tidak dapat ditingkatkan lagi secara signifikan (Padfield dkk, 2019). Oleh karena itu, pada studi ini digunakan teknik klasifikasi tradisional yang memiliki beban komputasi yang relatif lebih ringan. Keuntungan lebih lanjut dari penggunaan metode klasifikasi ini adalah proses klasifikasi dapat dilakukan secara *near real-time* (Padfield dkk,

2019). Metode yang digunakan pada klasifikasi di MI merupakan teknik yang sudah umum digunakan, yaitu *Support Vector Machine (SVM)* (Jin dkk, 2019), (Padfield dkk, 2019); *Attractor Metagene SVM (AM-SVM)* serta *Bat optimization Algorithm (BA-SVM)* (Selim dkk, 2020); *k-Nearest Neighbors algorithm (k-NN)*; *Random Forest (RF)*; *Linear Discriminant Analysis (LDA)*; dan *Naive Bayes (NB)*, (Ha & Jeong, 2019). Selain itu, terdapat teknik klasifikasi yang diimplementasikan, yaitu *Spectral Regression Discriminant Analysis (SRDA)*; *Firefly Algorithm Learning Automata SRDA (FA-LA-SRDA)*, *Genetic Algorithm (GA)*, serta *Adaptive Weight Particle Swarm Optimization (APSO)* (Liu dkk, 2017). Detail teknik-teknik klasifikasi ini dapat dilihat pada Tabel 1.

2. METODE PENELITIAN

2.1. Set Data

Salah satu permasalahan utama dalam klasifikasi MI adalah standarisasi sinyal EEG (Rashid dkk, 2020). Oleh karena itu, pada studi ini digunakan set data publik yang sudah umum dipakai pada studi-studi sebelumnya. Set data pada studi ini diambil dari BCI Competition IV - 2b (Tangermann dkk, 2012) yang terdiri dari sembilan subjek. Set data ini dipilih karena lebih efisien yaitu fokus pada ketiga elektroda (C3, Cz, C4) yang peletakkannya tepat diatas *sensorimotor cortex*, cocok untuk pendeteksian MI (Tangermann dkk, 2012). Selain itu, berbagai penelitian menggunakan set data lain dengan jumlah elektroda banyak namun berfokus pada tiga elektroda ini, seperti pada penggunaan set data BCI Competition IV-2a (Tangermann dkk, 2012) dan penggunaan BNCI Horizon 2020 (Padfield dkk, 2019).



Gambar 1. Blok Diagram Sistem

Pengukuran difokuskan pada tiga kanal dengan jumlah percobaan sebanyak 10 kali yang diulangi

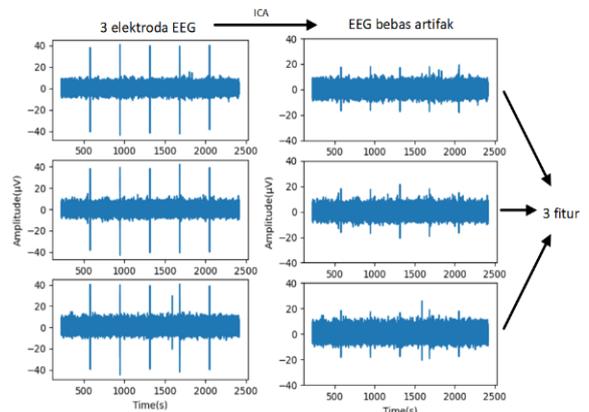
sebanyak 6 sesi eksperimen dan 2 macam kelas. Sehingga total terdapat 20 percobaan per *run* dan 120 percobaan per *session*. Frekuensi pencuplikan yang digunakan adalah 250 Hz. Jenis tapis yang digunakan adalah *Band Pass Filter (BPF)* 0,5 – 100 Hz serta *Notch filter* 50 Hz.

2.2. Prapemrosesan

Secara umum, terdapat tiga tahapan dalam studi ini, yaitu prapemrosesan; ekstraksi ciri; serta klasifikasi. Blok diagram sistem yang digunakan pada studi dapat dilihat pada Gambar 1. Pada prapemrosesan, digunakan BPF *Butterworth orde 5* dengan frekuensi *cut-off* sebesar 8 – 30 Hz. Proses penapisan ini tidak hanya digunakan untuk menghilangkan derau, tetapi juga untuk mendapatkan sinyal EEG khususnya pada gelombang μ dan β . Gelombang μ memiliki rentang frekuensi 8 – 13 Hz, sedangkan gelombang β memiliki rentang frekuensi 12,5 – 30 Hz, di mana informasi yang digunakan untuk MI berada pada rentang frekuensi tersebut. Hasil dari prapemrosesan menjadi basis untuk ekstraksi fitur yang dilakukan pada tahap selanjutnya.

2.3. Independent Component Analysis (ICA)

Meskipun telah ditapis dengan menggunakan BPF, masih terdapat beberapa komponen informasi yang perlu dihilangkan pada sinyal tertapis tersebut. Artefak ini berupa informasi pergerakan mata, kedipan mata, detak jantung, serta pada saat subjek berbicara. Oleh karena itu, artefak ini perlu dihilangkan atau dikurangi tanpa mengurangi informasi penting yang terdapat pada sinyal EEG yang akan digunakan untuk klasifikasi MI. Metode yang dapat digunakan untuk mengekstrak informasi dari gelombang μ dan β sinyal EEG yang diperlukan untuk klasifikasi MI adalah dengan ICA. Gambar 2 mengilustrasikan ekstraksi informasi ini.



Gambar 2. Prosedur Ekstrak Ciri Temporal Dengan Metode ICA

ICA merupakan suatu metode untuk memisahkan data menjadi komponen independen, berbasis multikanal EEG. Metode ICA termasuk

pada kelas *Blind Source Separation* (Lin dkk, 2015). ICA bekerja pada data yang diasumsikan bahwa komponen data tersebut independen. Sebelum menjalankan algoritma ICA, dilakukan prapemrosesan yang meliputi *centering* dan *whitening*. Perhitungan dekomposisi ICA dituliskan pada persamaan (1),

$$X = A \times U \quad (1)$$

di mana, A adalah *mixing matrix*, U adalah komponen independen, dan X adalah sinyal EEG hasil prapemrosesan menggunakan BPF. Pada studi ini digunakan data dengan jumlah kanal, $n = 3$ dengan jumlah sampel sebanyak T , sehingga dihasilkan komponen independen U berjumlah tiga. Bentuk masing-masing matriks A ($n \times m$), matriks U ($m \times T$), dan matriks X ($n \times T$). Proses untuk mendapatkan matriks A dilakukan dengan metode *Singular Value Decomposition* (SVD).

Dengan mendapatkan komponen independen (U), maka dapat diamati apakah komponen independen tersebut mengandung artefak atau tidak. Setelah dilakukan proses reduksi komponen, dilakukan dekomposisi matriks U untuk mendapatkan sinyal EEG yang bebas dari artefak. Perhitungan dekomposisi balik ICA dilakukan dengan menggunakan persamaan (2),

$$U = A^{-1}S \quad (2)$$

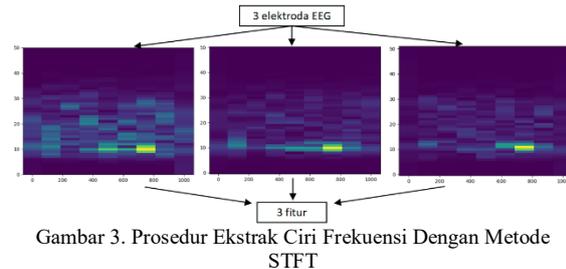
di mana A^{-1} adalah *unmixing matrix* yang nilainya merupakan *inverse* dari A , dan S adalah matriks data EEG bebas artefak. Hasil yang didapatkan berupa matriks S yang berdimensi $n \times T$. Kemudian, ciri temporal dapat diekstrak berdasarkan matriks S yang berjumlah tiga, sesuai dengan jumlah kanal sinyal EEG.

2.4. Short Time Fourier Transform (STFT)

Metode STFT digunakan untuk mentransformasi sinyal 1 dimensi pada domain waktu menjadi domain frekuensi 2 dimensi. Perhitungan metode STFT dapat dituliskan pada Persamaan (3),

$$STFT(\tau, w) = \int x(t)w(t - \tau)e^{-j\omega t} \quad (3)$$

di mana $x(t)$ merupakan sinyal masukan, dan $w(t)$ merupakan fungsi *window*. Terdapat beberapa fungsi *window* yang dapat digunakan, seperti *rectangular*; *hanning*; dan *hamming*. Pada penelitian ini, sinyal masukan yang digunakan berupa sinyal hasil prapemrosesan dengan BPF pada setiap kanal. Hasil yang didapatkan pada setiap kanal berupa sebaran frekuensi pada keseluruhan rentang data di setiap *trial*. Sebaran frekuensi inilah yang digunakan sebagai ciri frekuensi, masukan untuk pengklasifikasi.



Gambar 3. Prosedur Ekstrak Ciri Frekuensi Dengan Metode STFT

Penggunaan metode STFT untuk ekstraksi ciri frekuensi pada studi ini dapat dilihat pada Gambar 3. Pada klasifikasi MI, diperlukan suatu ciri yang dapat membedakan informasi pada masing-masing elektroda, yang dapat berbentuk sebagai informasi pada domain frekuensi-waktu. Informasi ini penting diperoleh karena digunakan untuk menentukan kapan terjadi Event-related Desynchronization (ERD) dan Event-related Synchronization (ERS) (Aoh dkk, 2019). Pada studi ini, dilakukan pencarian jenis dan lebar *window* pada klasifikasi MI, dan diperoleh hasil awal yaitu dengan jenis *window* berupa *hanning* dan lebar *window* sebesar 32, maka didapatkan suatu matriks berukuran 33×33 .

2.5. Common Spatial Pattern (CSP)

CSP merupakan suatu teknik untuk menganalisis data multikanal berbasis tapis spasial. Pada penelitian ini CSP digunakan untuk mengidentifikasi informasi spasial dari sinyal EEG. Tujuannya adalah untuk memaksimalkan varian sinyal EEG yang tertapis BPF dari suatu kelas sambil meminimalkan varian sinyal EEG dari kelas lain. Secara formal, CSP menggunakan tapis spasial w dengan fungsi pada persamaan (4)

$$J(w) = \frac{w^T X_1^T X_1 w}{w^T X_2^T X_2 w} = \frac{w^T C_1 w}{w^T C_2 w} \quad (4)$$

di mana X_i adalah matriks data untuk kelas i dan C_i adalah matriks kovariansi spasial dari sinyal EEG dari kelas i , dengan asumsi rata-rata nol untuk sinyal EEG. Pada penelitian ini, matriks data X_i yang digunakan berupa sinyal hasil prapemrosesan dengan BPF. Keluaran dari CSP adalah energi spasial dari setiap kanal EEG. Jumlah kanal ini dapat diubah sesuai dengan jumlah komponen yang diinginkan.

3. HASIL & PEMBAHASAN

Pada studi ini, dilakukan klasifikasi dua kelas MI yang terdiri dari tangan kanan dan kiri. Terdapat tiga ciri independen, yaitu ciri temporal, frekuensi, spatial. Selain itu, pada studi ini akan dilakukan perbandingan kinerja dari masing-masing ciri dengan kombinasi dari dua atau tiga ciri tersebut. Performansi pengklasifikasi diukur dengan menghitung akurasi dan koefisien kappa. Akurasi merujuk pada kemampuan pengklasifikasi memprediksi kelas dengan benar, sedangkan

koefisien kappa merujuk pada "agreement" dari prediksi dan target. Klasifikasi MI dilakukan pada suatu komputer personal dengan spesifikasi sebagai berikut: Prosesor AMD *Ryzen 7 4700U* dengan RAM sebesar 20 GB. Implementasi dilakukan dengan menggunakan bahasa pemrograman *Python* dengan menggunakan *Scikit Learn* serta MNE EEG *Library*.

3.1. Ciri Independen

Penggunaan ciri temporal sebagai masukan untuk klasifikasi menggunakan pengklasifikasi SVM, RF, k-NN, serta NB memberikan nilai akurasi yang bervariasi, seperti yang ditunjukkan pada Tabel 2. Metode klasifikasi RF menghasilkan rerata akurasi paling tinggi, yaitu 73%. Namun demikian, apabila dilihat lebih detail dari setiap subjeknya, diperoleh hasil bahwa penggunaan SVM memberikan kinerja tertinggi pada subjek #4 di mana nilai akurasinya mencapai 91%. Terdapat parameter yang memengaruhi kinerja atau nilai akurasi pada klasifikasi menggunakan ciri temporal ini, yaitu adanya *thresholding* pada ICA.

Selanjutnya, ciri frekuensi digunakan sebagai masukan pengklasifikasi SVM, RF, k-NN, dan NB. Hasil kinerja dari ciri frekuensi serta keempat pengklasifikasi ini dapat dilihat pada Tabel 3. Terlihat bahwa penggunaan ciri frekuensi dengan pengklasifikasi RF menghasilkan rerata akurasi paling tinggi, yaitu mencapai 72%. Apabila dilihat per subjek, pengklasifikasi SVM memberikan kinerja tertinggi dengan akurasi mencapai 91% pada subjek 4. Disamping itu, SVM memiliki akurasi sedikit dibawah kinerja RF, dengan rerata mencapai 72%.

Tabel 2. Akurasi dan Koefisien Kappa pada Klasifikasi MI Menggunakan Ciri Temporal

Subyek #	SVM	RF	NB	KNN
1	63	74	56	64
2	59	66	50	51
3	53	63	53	49
4	91	86	80	84
5	69	71	51	64
6	83	70	80	65
7	66	72	50	63
8	80	76	78	77
9	81	75	54	72
Rata-rata	72	73	61	65
Koef. Kappa	0,4	0,5	0,2	0,3

Tabel 3. Akurasi dan Koefisien Kappa pada Klasifikasi MI Menggunakan Ciri Frekuensi

Subyek #	SVM	RF	NB	KNN
1	64	74	55	65
2	60	66	50	53
3	53	63	53	46
4	91	85	81	82
5	69	69	51	61
6	84	70	81	64
7	66	71	50	64
8	79	76	78	75
9	80	74	54	73
Rata-rata	72	72	61	65
Koef. Kappa	0,4	0,4	0,2	0,3

Dengan membandingkan kinerja pada penelitian sebelumnya pada Tabel 1 (Ha & Jeung, 2019), hasil yang diperoleh pada studi tidak memiliki perbedaan yang signifikan. Meskipun terdapat perbedaan parameter waktu yang diambil untuk diekstrak pada setiap *trial*-nya, akan tetapi hal ini tidak terlalu memengaruhi kinerja klasifikasi. Pada penelitian (Ha & Jeung, 2019), data yang diproses pada selang 0,5 hingga 2,5 detik setelah periode *cue* (3,5 hingga 5,5 detik setelah dimulainya *trial*), sedangkan pada studi ini mengambil keseluruhan periode *cue* dan *imaginary* (3 hingga 7 detik setelah dimulainya *trial*).

Ciri independen yang ketiga pada studi ini adalah ciri spasial hasil keluaran dari CSP. Kinerja ciri spasial dengan menggunakan pengklasifikasi SVM, RF, k-NN, dan NB ditunjukkan pada Tabel 4. Penggunaan RF pada skema ini menghasilkan rerata kinerja paling tinggi dibandingkan dengan pengklasifikasi yang lain dengan nilai akurasi mencapai 73%. Seperti kedua ciri sebelumnya, kinerja SVM juga memberikan kinerja tertinggi pada subjek #4 dengan nilai akurasi mencapai 91%. Salah satu parameter yang memengaruhi perbedaan kinerja ini adalah karena waktu yang diekstrak pada setiap *trial*-nya. Pada metode CSP, diambil keseluruhan periode *cue* dan *imaginary* (3 hingga 7 detik setelah dimulainya *trial*) yang menunjukkan keadaan otak sedang dalam melakukan kegiatan *imagery* untuk tangan. Selain parameter tersebut, akurasi yang dihasilkan CSP juga bisa dipengaruhi oleh jumlah kanal yang tersedia pada set data. Pada set data BCI *competition IV 2b* hanya ada 3 kanal data mentah EEG yang bisa dimasukkan ke dalam CSP. Hal ini berpengaruh karena luaran dari CSP adalah nilai *trials* dari tiap kanal yang dimasukkan kepada masukan secara *default* dari modul yang ada adalah sebesar 4 kanal.

3.2. Kombinasi Ciri

Pada skema kombinasi ciri ini, dua atau tiga ciri independen digunakan sebagai masukan pengklasifikasi SVM, RF, k-NN, serta NB. Kombinasi data ini digunakan sebagai pembandingan dari dua kelas pada dataset yang digunakan, yaitu tangan kiri dan kanan pada MI.

Tabel 4. Akurasi dan Koefisien Kappa pada Klasifikasi MI Menggunakan Ciri Spasial

Subyek #	SVM	RF	NB	KNN
1	66	73	63	63
2	59	65	52	49
3	53	62	56	53
4	91	84	87	82
5	73	71	65	67
6	83	71	84	68
7	67	73	62	62
8	79	78	78	77
9	80	76	76	73
Rata-rata	72	73	69	66
Koef. Kappa	0,4	0,5	0,4	0,3

Tabel 5. Akurasi dan Koeffisien Kappa pada Klasifikasi MI Menggunakan Ciri Spasial & Frekuensi

Subyek #	SVM	RF	NB	KNN
1	64	74	63	65
2	57	66	51	53
3	57	64	49	46
4	88	85	84	82
5	68	70	63	61
6	85	70	65	64
7	65	72	64	64
8	83	76	77	75
9	80	75	72	73
Rata-rata	72	72	65	65
Koef. Kappa	0,4	0,4	0,3	0,3

Tabel 6. Akurasi dan Koeffisien Kappa pada Klasifikasi MI Menggunakan Ciri Temporal, Spasial, & Frekuensi

Subyek #	SVM	RF	NB	KNN
1	64	74	58	63
2	56	66	50	51
3	56	63	55	49
4	87	84	84	84
5	68	70	57	62
6	85	71	83	65
7	64	72	53	63
8	81	76	79	77
9	79	76	64	72
Rata-rata	71	72	65	65
Koef. Kappa	0,4	0,5	0,3	0,3

Penggunaan kombinasi ciri antara ciri temporal dan frekuensi sebagai masukan untuk klasifikasi menghasilkan akurasi sesuai dengan yang ditunjukkan pada Tabel 5. Penggunaan RF menghasilkan kinerja paling tinggi, dengan nilai akurasi mencapai 72%. Akurasi yang dihasilkan pada klasifikasi setiap subjek juga tidak ada perubahan yang signifikan dari ciri independen, di mana penggunaan SVM memberikan kinerja tertinggi pada subjek #4 dengan nilai akurasi mencapai 88%.

Kinerja kombinasi tiga ciri, temporal; frekuensi; dan spasial, yang digunakan sebagai masukan pengklasifikasi ditunjukkan pada Tabel 6. Dengan menggunakan semua ciri yang digunakan pada studi ini, pengklasifikasi RF memberikan kinerja paling tinggi dengan nilai akurasi mencapai 72%.

Dengan membandingkan hasil klasifikasi menggunakan ciri independen dengan kombinasi ciri, diperoleh hasil bahwa kinerja paling tinggi dicapai dengan menggunakan hanya ciri temporal serta pengklasifikasi RF. Nilai rerata akurasi yang diperoleh dengan skema ciri temporal dan RF ini mencapai 73%. Kinerja kombinasi ciri, baik itu yang menggunakan ciri gabungan spasial-frekuensi maupun temporal-spasial-frekuensi masih lebih rendah dibandingkan dengan ciri independen temporal, dengan nilai rerata paling tinggi hanya sekitar 72% dan 72%.

Berdasarkan Tabel 7 dapat terlihat bahwa metode yang digunakan pada penelitian ini masih dibawah performa. Namun jika dibandingkan dengan metode *Deep Learning*, selisih nilai akurasi dengan metode yang digunakan terhitung kecil. Berdasarkan selisih tersebut, metode ekstraksi ciri

dan algoritma pengklasifikasi sederhana dapat bersaing dengan metode *Deep Learning*. Namun jika dibandingkan dengan metode DNN yang memiliki lapisan konvolusi yang mengambil ciri temporal dan spasial yang dihubungkan secara seri, selisih nilai akurasi semakin besar.

4. KESIMPULAN

Pada studi ini telah diimplementasikan klasifikasi MI dengan menggunakan ciri temporal, spasial, dan frekuensi. Selain itu, dieksplorasi juga kinerja kombinasi ciri gabungan spasial-frekuensi serta temporal-spasial-frekuensi. Terdapat empat pengklasifikasi yang digunakan pada studi, yaitu SVM; RF; k-NN; dan NB. Kinerja paling tinggi dicapai oleh penggunaan ciri independen temporal dan pengklasifikasi RF, dengan akurasi mencapai 73%. Nilai akurasi ini lebih tinggi jika dibandingkan dengan penggunaan kombinasi dua atau tiga ciri, yang didapatkan sebesar 72%. Sehingga disimpulkan bahwa penggunaan dua atau tiga ciri tidak meningkatkan kinerja klasifikasi. Oleh karena itu, salah satu temuan penting lain pada penelitian ini adalah rekomendasi penggunaan ciri temporal dengan pengklasifikasi RF untuk klasifikasi MI. Jika dibandingkan dengan performa *Deep Learning* pada penelitian lain sesuai Tabel 7, metode ekstraksi ciri dan algoritma pengklasifikasi sederhana ini masih dapat bersaing dengan selisih akurasi yang rendah.

Batasan yang ada pada studi ini adalah seluruh klasifikasi dilakukan untuk membedakan dua kelas saja. Selain itu, belum dilakukan optimasi nilai parameter *thresholding* yang ada pada ICA. Apabila nilai *threshold* terlalu rendah, maka artefak akan tereduksi; sedangkan apabila terlalu tinggi, maka ada potensi kehilangan informasi. Oleh karena itu, pada studi lanjutan akan dilakukan dengan menambah jumlah kelas. Sebagai tambahan, perlu dilakukan penentuan nilai parameter *thresholding* yang optimal.

Tabel 7. Perbandingan Klasifikasi MI dengan algoritma yang berbeda

Metode	Akurasi (%)
DNN (Zhao dkk)	83,98
STFT + Caps Net (Ha dkk)	78,44
LSTM + CNN (Yang dkk)	76,4
STFT+ SCNN (Wang dkk)	73
ICA-RF	73
FFT-RF	72
CSP-RF	73

DAFTAR PUSTAKA

- AOH, Y., HSIAO, H.J., LU, M.K., MACEROLLO, A., HUANG, H.C., HAMADA, M., TSAI, C.H. & CHEN, J.C., 2019. Event-related desynchronization/synchronization in spinocerebellar ataxia type 3. *Frontiers in Neurology*, [online] 10(JUL), p.822. <https://doi.org/10.3389/fneur.2019.00822>

- BLANKERTZ, B., MULLER, K.-R., CURIO, G., VAUGHAN, T. M., SCHALK, G., WOLPAW, J. R., SCHLOGL, A., NEUPER, C., PFURTSCHELLER, G., HINTERBERGER, T., SCHRODER, M., & BIRBAUMER, N., 2004. The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials. *IEEE Transactions on Biomedical Engineering*, 51(6), 1044–1051. <https://doi.org/10.1109/TBME.2004.826692>
- HA, K.-W., & JEONG, J.-W., 2019. Motor Imagery EEG Classification Using Capsule Networks. *Sensors*, 19(13), 2854. <https://doi.org/10.3390/s19132854>
- HUANG, H.-H., CONDOR, A. & HUANG, H.J., 2020. Classification of EEG Motion Artifact Signals Using Spatial ICA. [online] Springer, Cham.pp.23–35. https://doi.org/10.1007/978-3-030-33416-1_2
- JIN, J., MIAO, Y., DALY, I., ZUO, C., HU, D. & CICHOCKI, A., 2019. Correlation-based channel selection and regularized feature optimization for MI-based BCI. *Neural Networks*, 118, pp.262–270. <https://doi.org/10.1016/j.neunet.2019.07.008>
- KORHAN, N., DOKUR, Z., & OLMEZ, T., 2019. Motor Imagery Based EEG Classification by Using Common Spatial Patterns and Convolutional Neural Networks. 2019 Scientific Meeting on Electrical-Electronics Biomedical Engineering and Computer Science (EBBT), 1–4. <https://doi.org/10.1109/EBBT.2019.8741832>
- LIN, L., MENG, Y., CHEN, J. & LI, Z., 2015. Multichannel EEG compression based on ICA and SPIHT. *Biomedical Signal Processing and Control*, 20, pp.45–51. <https://doi.org/10.1016/j.bspc.2015.04.001>
- LU, N., YIN, T., & JING, X., 2020. Deep Learning Solutions for Motor Imagery Classification: A Comparison Study. 2020 8th International Winter Conference on Brain-Computer Interface (BCI), 1–6. <https://doi.org/10.1109/BCI48061.2020.9061612>
- MACHINGAL, P., THOUSIF, M., DORA, S., & SUNDARAM, S., 2020. Self-regulated Learning Algorithm for Distributed Coding Based Spiking Neural Classifier. 2020 International Joint Conference on Neural Networks (IJCNN), 1–7. <https://doi.org/10.1109/IJCNN48605.2020.9207620>
- PADFIELD, N., ZABALZA, J., ZHAO, H., MASERO, V. & REN, J., 2019. EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors (Switzerland)*, [online] 19(6), p.1423. <https://doi.org/10.3390/s19061423>
- RAMMY, S.A., ABRAR, M., ANWAR, S.J. & ZHANG, W., 2020. Recurrent Deep Learning for EEG-based Motor Imagination Recognition. In: 3rd International Conference on Advancements in Computational Sciences, ICACS 2020. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ICACS47775.2020.9055952>
- RASHID, M., SULAIMAN, N., P. P. ABDUL MAJEED, A., MUSA, R.M., AHMAD, A.F., BARI, B.S. & KHATUN, S., 2020. Current Status, Challenges, and Possible Solutions of EEG-Based Brain-Computer Interface: A Comprehensive Review. *Frontiers in Neurobotics*. <https://doi.org/10.1109/ICACS47775.2020.9055952>
- SCHALK, G., MCFARLAND, D. J., HINTERBERGER, T., BIRBAUMER, N., & WOLPAW, J. R., 2004. BCI2000: A general-purpose brain-computer interface (BCI) system. *IEEE Transactions on Biomedical Engineering*, 51(6), 1034–1043. <https://doi.org/10.1109/TBME.2004.827072>
- SELIM, S., TANTAWI, M.M., SHEDEED, H.A. & BADR, A., 2018. A CSP\AM-BA-SVM Approach for Motor Imagery BCI System. *IEEE Access*, 6, pp.49192–49208. <https://doi.org/10.1109/ACCESS.2018.2868178>
- TANGERMANN, M., MÜLLER, K. R., AERTSEN, A., BIRBAUMER, N., BRAUN, C., BRUNNER, C., LEEB, R., MEHRING, C., MILLER, K. J., MÜLLER-PUTZ, G. R., NOLTE, G., PFURTSCHELLER, G., PREISSEL, H., SCHALK, G., SCHLÖGL, A., VIDAURRE, C., WALDERT, S., & BLANKERTZ, B., 2012. Review of the BCI competition IV. *Frontiers in Neuroscience*, JULY, 55. <https://doi.org/10.3389/fnins.2012.00055>
- WANG, T., DONG, E., DU, S., & JIA, C., 2019. A Shallow Convolutional Neural Network for Classifying MI-EEG. 2019 Chinese Automation Congress (CAC), 5837–5841. <https://doi.org/10.1109/CAC48633.2019.8996981>
- XU, J., ZHENG, H., WANG, J., LI, D. & FANG, X., 2020. Recognition of eeg signal motor

imagery intention based on deep multi-view feature learning. *Sensors (Switzerland)*, [online] 20(12), pp.1–16. <https://doi.org/10.3390/s20123496>

YANG, B., FAN, C., GUAN, C., GU, X., & ZHENG, M., 2019. A Framework on Optimization Strategy for EEG Motor Imagery Recognition. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 774–777. <https://doi.org/10.1109/EMBC.2019.8857672>

ZHAO, H., ZHENG, Q., MA, K., LI, H., & ZHENG, Y., 2021. Deep Representation-Based Domain Adaptation for Nonstationary EEG Classification. *IEEE Transactions on Neural Networks and Learning Systems*, 32(2), 535–545. <https://doi.org/10.1109/TNNLS.2020.3010780>

ZHU, Y., ZHANG, C., POIKONEN, H., TOIVAINEN, P., HUOTILAINEN, M., MATHIAK, K., RISTANIEMI, T. & CONG, F., 2020. Exploring Frequency-Dependent Brain Networks from Ongoing EEG Using Spatial ICA During Music Listening. *Brain Topography*, [online] 33(3), pp.289–302. <https://doi.org/10.1007/s10548-020-00758-5>