

## COARSE GRAINED LYAPUNOV EXPONENT SEBAGAI EKSTAKSI FITUR PADA KLASIFIKASI SINYAL ELEKTROENSEFALOGRAF IMAGINASI GERAK

Nadya Silva Arline<sup>1</sup>, Inung Wijayanto<sup>2</sup>, Sugondo Hadiyoso<sup>3</sup>

<sup>1, 2, 3</sup> Universitas Telkom, Bandung

nadyasilvaarline@student.telkomuniversity.ac.id<sup>1</sup>, iwijayanto@telkomuniversity.ac.id<sup>2</sup>,  
sugondo@telkomuniversity.ac.id<sup>3</sup>

### Abstrak

*Motor imagery* merupakan suatu kondisi dimana seseorang sedang dalam keadaan secara mental mensimulasikan suatu tindakan, atau dalam kata lain orang tersebut sudah merasa melakukan suatu tindakan tetapi pada kenyataannya orang tersebut belum atau tidak dapat melakukan tindakan tersebut. Hal ini biasanya dialami oleh penderita cacat motorik atau lumpuh. Untuk mengukur adanya ketidaknormalan atau gangguan pada motor *imagery* dapat melakukan pemeriksaan aktivitas kelistrikan otak menggunakan *elektroensefalogram* (EEG). EEG akan menangkap aktivitas listrik seseorang saat otak menerima atau menanggapi stimulus. Dengan demikian aktivitas *motor imagery* dapat diamati.

Pada Tugas Akhir ini dilakukan klasifikasi *motor imagery* untuk memprediksi gerakan motoric seseorang berdasarkan sinyal EEG. *Motor imagery* yang disimulasikan terdiri dari dua isyarat meliputi gerakan tangan kanan dan gerakan tangan kiri. Lalu dilakukan proses *multiscale* menggunakan *Coarse Grained Procedure*. Sinyal EEG diekstraksi menggunakan metode *Largest Lyapunov Exponent* (LLE) untuk mendapatkan set fitur dalam numerik. Setelah itu dilakukan klasifikasi sinyal berdasarkan nilai LLE tersebut menggunakan *K-Nearest Neighbor* (kNN). Proses pengklasifikasian menggunakan metode *cosine similarity* untuk mengukur jarak data latih yang paling dekat dengan objek.

Dari simulasi yang telah dilakukan, akurasi maksimum yang dapat dicapai adalah 60%. Diharapkan penelitian ini dapat membantu dalam analisis *motor imagery* EEG sehingga dapat mengidentifikasi jika terdapat ketidaknormalan syaraf motoric khususnya bagian otak.

**Kata Kunci:** *Motor Imagery, Elektroensefalograph, Lyapunov Exponent, K-Nearest Neighbor.*

### Abstract

*Motor imagery* is a condition in which the person is in a mental state simulating an action, or in other words, the person feels that he or she has taken an action but in fact the person has not or has not done that action. This is usually experienced by people with motor disabilities or paralysis. To measure the presence of abnormalities or disturbances in motor imagery, you can check the electrical activity of the brain using an electroencephalogram (EEG). EEG will capture a person's electrical activity when the brain receives or responds to a stimulus. Thus the image of motor activity can be observed.

In this final project, the classification of motor imagery is carried out to predict a person's motor movements based on EEG signals. The imagery motor that was simulated consisted of two supports including right hand movement and left hand movement. Then the multiscale process is carried out using the Coarse Grained Procedure. The EEG signal was extracted using the Largest Lyapunov Exponent (LLE) method to obtain the feature set in numeric. After that, the classification is based on the LLE value using K-Nearest Neighbor (kNN). The classification process uses the cosine similarity method to measure the distance of the closest training data to the object.

From the simulation that has been done, the accuracy achieved is 60%. It is hoped that this research can help in analyzing motor EEG images so that they can identify if there are motor nerve abnormalities, especially the brain.

**Keywords:** *Motor Image, Electroencephalograph, Lyapunov Exponent, K-Nearest Neighbor.*

## 1. Pendahuluan

*Motor imagery* atau bisa di sebut imajinasi motorik yaitu suatu kondisi dimana seseorang sedang dalam keadaan secara mental mensimulasikan suatu tindakan, dengan kata lain orang tersebut merasa melakukan suatu tindakan tetapi pada kenyataannya orang tersebut belum atau tidak dapat melakukan tindakan apapun [2].

Dalam mempelajari kelistrikan otak dapat melalui metode *invasif* ( *Electrocorticogram* – ECoG ) dan metode *non invasif* ( *Electroencephalogram* – EEG ). Metode invasif di mana elektroda ditanamkan di bawah kulit kepala yang dapat melibatkan risiko klinis dan kesulitan teknis yang cukup besar [3]. Sedangkan metode *non-invasif* dimana elektroda hanya di tempatkan di sepanjang kulit kepala. Metode non-invasif lebih banyak dipilih dengan mempertimbangkan keamanan dan kenyamanan pasien. EEG dianggap lebih tepat untuk digunakan dalam mengamati *motor imagery*.

Oleh karena itu, pada penelitian ini diusulkan sebuah metode untuk mengenali imajinasi gerak berdasarkan sinyal rekaman EEG. Sinyal EEG yang disimulasikan terdiri dari imajinasi gerak tangan kanan dan gerak tangan kiri. Sinyal di ekstraksi menggunakan *Largest Lyapunov Exponent* (LLE) untuk mendapatkan set fitur dalam numerik. Setelah itu dilakukan klasifikasi sinyal berdasarkan nilai LLE tersebut menggunakan *K-Nearest Neighbor* (kNN). Evaluasi performa usulan metode berupa akurasi klasifikasi.

## 2. Dasar Teori

### 2.1 Elektroensefalograph (EEG)

*Elektroensefalograph* merupakan suatu kegiatan perekaman sinyal listrik yang terdapat pada otak dalam periode waktu tertentu. Perekaman sinyal EEG lebih baik di lakukan dalam keadaan tenang dan kedap suara agar di dapatkan hasil yang baik untuk meminimalisir noise. Pengukuran EEG menggunakan metode *non-invasif* dimana elektroda di tempatkan pada kulit kepala[7].

EEG bekerja dengan mengukur fluktuasi tegangan yang di hasilkan oleh arus ionik dalam neuron dari otak. Untuk merekam sinyal EEG dapat menggunakan aktif AgCl elektroda dimana penempatannya sudah di atur dalam standar internasional dengan sistem 10-20 internasional. Tempat perekaman dan aktivitas otak pada saat perekaman akan mempengaruhi amplitudo dan frekuensi sinyal EEG[4].

#### 2.1.1 Sistem 10-20 internasional

Berdasarkan aktivitas listrik di dalam otak, dibedakan menjadi 4 titik ukur, yaitu pertama Frontal (F) untuk kemampuan bicara,

pengontrolan, pengenalan dan perencanaan gerakan. Kedua, Parietal (P) untuk

menerima rangsangan dari suatu sentuhan, posisitubuh, temperatur dan vibrasi; Occipital (O) untuk menerima rangsangan berupa visual dan arti tulisan; dan Temporal (T) untuk menerima rangsangan dari telinga atau pendengaran dan berhubungan dengan memori atau ingatan[9].

### 2.1.2 Jenis jenis gelombang otak

Berikut jenis jenis gelombang otak berdasarkan frekuensinya:

#### 1. Delta

Delta merupakan gelombang otak yang berada pada frekuensi antara 0,5-4 Hz dan memiliki amplitudo yang besar.

#### 2. Theta

Theta merupakan gelombang otak yang berada pada frekuensi antara 4-8 Hz. Gelombang theta biasanya terjadi pada saat seseorang sedang tidur atau mengantuk. Selain pada saat tertidur juga pada kondisi sedang melakukan sesuatu yang penuh dengan konsentrasi.

#### 3. Alpha

Alpha merupakan gelombang otak yang berada pada frekuensi 8-12 Hz. Gelombang alpha biasanya terjadi pada saat seseorang mengalami relaksasi atau sedang berada pada situasi relaks. Frekuensi pada gelombang alpha merupakan frekuensi pengendali dan penghubung pikiran sadar dan bawah sadar.

#### 4. Beta

Beta merupakan gelombang otak yang berada pada frekuensi 12-19 Hz. Gelombang beta biasanya terjadi ketika seseorang sedang berada pada aktivitas mental yang terjaga penuh, contoh ketika sedang melakukan aktivitas sehari-hari atau berinteraksi dengan orang lain. Gelombang beta terbagi menjadi 3 kelompok, yaitu gelombang *lowbeta* (12-16 Hz), gelombang beta (15-18 Hz), gelombang *highbeta* (>19 Hz).

#### 5. Gamma

Gamma merupakan gelombang otak yang berada pada frekuensi 19-100 Hz. Gelombang gamma biasanya terjadi ketika seseorang sedang berada pada kondisi mental yang sangat tinggi, contoh saat berada di depan banyak orang, saat ketakutan, saat panik, saat berada pada suatu pertandingan, dll[9].

#### 6. *Sensory Motor Rhythm*

Apabila seseorang tidak bisa menghasilkan gelombang ini, itu artinya orang tersebut tidak mampu berkonsentrasi atau sulit untuk berkonsentrasi. Contoh pada penderita epilepsi,autis, dll. Gelombang ini termasuk kepada gelombang *lowbeta* dimana gelombang *lowbeta* dihasilkan oleh seseorang ketika sedang

berkonsentrasi[9].

## 2.2 Brain Computer Interface

Teknologi BCI memiliki 5 tahapan yaitu tahap akuisisi sinyal, pada tahap ini sinyal dapat melakukan pemrosesan artefak dan juga pengurangan kebisingan. Selanjutnya tahap *pre-processing* merupakan tahapan untuk mempersiapkan sinyal dan bentuk yang sesuai untuk selanjutnya sinyal tersebut diproses. Selanjutnya tahap ekstraksi fitur, pada tahap ini bertujuan untuk mengidentifikasi informasi yang didapat dari sinyal otak yang telah dilakukan perekaman sebelumnya. Selanjutnya tahap klasifikasi, pada tahap ini dengan mempertimbangkan vektor fitur akan dapat mengklasifikasikan sinyal. Selanjutnya tahap kontrol antarmuka, pada tahap ini bertujuan untuk menerjemahkan suatu sinyal menjadi perintah[8]. cara kerja BCI yaitu dengan menerjemahkan gelombang otak yang sudah di dapat sebelumnya yang kemudian di ekstrak dari sinyal EEG menjadi sinyal yang dapat menjalankan perintah pada suatu perangkat keras yang dikendalikan oleh suatu perangkat lunak[9].

## 2.3 Motor Imagery

Menurut Jeannerod (1994, 1995) *motor imagery* mewakili hasil dari niat suatu gerakan, yang biasanya dilakukan tanpa sadar selama persiapan gerakan. Jeannerod menyimpulkan bahwa imajinasi motorik sadar dan persiapan motorik bawah sadar berbagi mekanisme umum dan setara secara fungsional. Maka dari itu untuk meningkatkan kinerja motorik perlu dilakukan pelatihan imajinasi motorik[10].

Hubungan antara eksekusi motorik dan imajinasi di gambarkan oleh James (1890) dan Jacobsen (1930) bahwa imajinasi mental suatu gerakan selalu diikuti oleh pelepasan otot-otot targetnya. Untuk membedakan antara eksekusi gerakan dan imajinasi, pelepasan ini harus dihindari. Oleh karena itu, subjek diinstruksikan untuk tidak melakukan gerakan otot target dan ini dikendalikan oleh *electromyography* (EMG). Dengan menghambat eksekusi gerakan, akses sadar persiapan motorik dapat dimungkinkan untuk terjadi[10].

## 2.4 Coarse Grained Procedure

Berikut langkah langkah multiscale menggunakan Coarse Grained:

Langkah 1 : Dianggap sebagai deret waktu diskrit  $\{T_a, a = 1, 2, 3, 4, \dots, N\}$ , titik data dirata-ratakan dalam keadaan tidak tumpang tindih dengan panjang bertambah. Deret waktu dihitung menggunakan persamaan berikut. Di mana  $\tau$  mewakili faktor skala dan panjang setiap deret sama dengan deret waktu asli dibagi  $\tau$

$$Q_j^{(\tau)} = \frac{1}{\tau} \sum_{a=(b-1)\tau+1}^{b\tau} T \mathbf{1} \leq \mathbf{b} \leq \frac{N}{\tau} \quad (2.1)$$

Langkah 2 : Entropi permutasi dihitung menggunakan prosedur berikut: Pertimbangkan deret waktu  $\{Q_a, a = 1, 2, 3 \dots M\}$ , yang tertanam dalam ruang dimensi m

$$Q_j = (q(b), q(b + L), \dots, q(b + (m - 1)L)) \quad (2.2)$$

Dimana m adalah dimensi embedding dan L adalah time delay. Untuk setiap b, m bilangan dimensi dari nilai riil  $Q_b = (q(b), q(b + L), \dots, q(b + (m-1)L)$  dapat diatur dalam urutan naik.

$$(q(b + (b_1 - 1)L) \leq q(b + b_2 - 1)L, \dots \leq q(b + (b_m - 1)L) \quad (2.3)$$

Untuk memetakan secara unik setiap vektor  $Q_b$  ke  $(b_1, b_2, b_3, \dots, b_m)$  kita membutuhkan  $m!$  permutasi m simbol berbeda  $(1, 2, 3, \dots, m)$ . Pertimbangkan distribusi probabilitas untuk simbol yang berbeda  $(S_1, S_2, S_3 \dots S_k)$ , di mana  $k \leq m!$ , entropi permutasi untuk deret waktu didefinisikan sebagai entropi Shannon dihitung sebagai:

$$H_p(m) = - \sum_{a=1}^k S_i \ln S_i \quad (2.4)$$

Dimana  $S_b = 1 / m!$ ,  $H_p(m)$  mencapai nilai maksimum  $\ln(m!)$ . Untuk m sampel yang berbeda, akan ada  $m!$  kemungkinan pola ordinal,  $\pi$ , yang disebut 'motif'. Untuk setiap motif tunggal  $\pi_j$ ,  $l_{\pi_j}$  ( $\pi_j$ ) menunjukkan frekuensi kemunculannya dalam deret waktu. Jadi, frekuensi relatifnya adalah:

$$P(\pi_j) = \frac{f(\pi_j)}{N-m+1} \quad (2.5)$$

Untuk dimensi embedding tetap  $m > 2$  dan jedawaktu tetap  $L = \tilde{L}$ , PE didefinisikan sebagai:

$$H(m, \tilde{L}) = - \sum_{\pi_j}^{m!} P(\pi_j) \log_2 P(\pi_j) \quad (2.6)$$

Dimana jumlahnya habis  $m!$  motif  $\pi$ . Nilai maksimum  $H(m)$  adalah  $\log_2(m!)$  Hal ini berarti semua motif mempunyai probabilitas yang sama. Nilai terkecil dari  $H(m)$  adalah nol yang menunjukkan deret waktu yang sangat teratur, yaitu hanya berulang dengan beberapa motif dasar[11].

## 2.5 Largest Lyapunov Exponent

*Lyapunov Exponent* digunakan untuk menganalisa perubahan pada keadaan suatu sistem karena suatu peristiwa. Pada studi kestabilan *lyapunov exponent* menentukan ketergantungan sistem pada saat keadaannya berubah dengan keadaan awal. *Lyapunov exponent* merepresentasikan dua buah vektor keadaan dengan satu titik keseimbangan. Berikut persamaan hubungan antara dua keadaan tersebut :

$$\| \delta x(t) \| = e^{\lambda t} \| \delta x_0 \| \quad (2.7)$$

Dimana :

$\delta x(t)$  = Keadaan akhir  
 $\delta x_0$  = Keadaan awal

Dari persamaan di atas dijelaskan bahwa *lyapunov exponent* mengukur nilai dari divergensi atau konvergensi dari dua buah lintasan yang terletak dekat dengan sistem dinamika.

Berikut persamaan untuk mencari nilai  $\lambda$  :

$$\lambda = \frac{1}{t} \ln \frac{\| \delta x(t) \|}{\| \delta x_0 \|} \quad (2.8)$$

Dimana :

$\lambda$  = Lyapunov Exponent  
 $t$  = Waktu uji  
 $\delta x(t)$  = Perubahan jarak pada waktu rentang Uji  
 $\delta x_0$  = Jarak awal

### 2.6 Algoritma K-Nearest Neighbor

Untuk mengklasifikasikan suatu objek salah satunya menggunakan algoritma *k-nearest neighbor*. Proses pengklasifikasian menggunakan metode *cosine similarity* untuk mengukur jarak data latih yang paling dekat dengan objek. Pengklasifikasian berdasarkan *k* buah data latih yang memiliki jarak paling dekat dengan objek tersebut. Untuk nilai *k* harus bernilai ganjil dan besar dari satu, nilai *k* harus lebih besar dari nilai data latih [13].

Rumus *cosine similarity* sebagai berikut :

$$\cos(\theta_{QD}) = \frac{\sum_{i=1}^n Q_i D_i}{\sqrt{\sum_{i=1}^n (Q_i)^2} \cdot \sqrt{\sum_{i=1}^n (D_i)^2}} \quad (2.9)$$

Dimana :

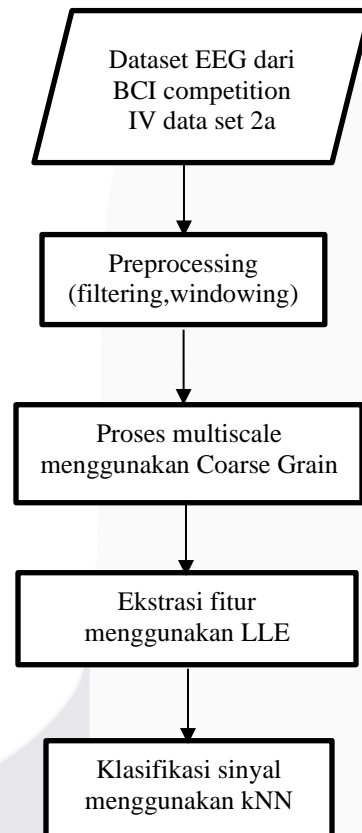
$\cos(\theta_{QD})$  = Kemiripan *Q* terhadap dokumen *D*  
 $Q$  = Data uji  
 $D$  = Data latih  
 $n$  = Banyak data

## 3. Perencanaan Sistem

### 3.1. Sistem Perancangan Dataset

Kumpulan data ini terdiri dari data electroencephalographic (EEG) dari 9 subject. Paradigma BCI berbasis isyarat terdiri dari empat kelas *motor imagery* yang berbeda, yaitu gerakan imajinasi tangan kiri (kelas 1), tangan kanan (kelas 2), kedua kaki (kelas 3), dan lidah (kelas 4). Dua sesi pada hari yang berbeda dicatat untuk masing-masing sesi subyek. Setiap sesi terdiri dari 6 *runs* yang dipisahkan oleh istirahat pendek. Satu sesi terdiri dari 48 percobaan (12 untuk masing-masing dari empat percobaan kelas), menghasilkan total 288 percobaan per sesi.

### 3.2. Model dan Perancangan Dataset



Data set sinyal EEG harus dilakukan *pre-processing* terlebih dahulu karna pada data set sinyal EEG tersebut masih terdapat *noise* yang cukup tinggi. Proses *pre-processing* dilakukan dengan cara *filtering* agar *noise* tersebut dapat berkurang, *filter* yang di gunakan adalah *Band Pass Filter*. Data set sinyal EEG juga memiliki sifat *non-stasioner* dimana juga harus dilakukan proses *filtering*.

**4. Hasil dan Analisis**

**4.1 Hasil Klasifikasi**

**4.1.1. Nilai akurasi klasifikasi KNN menggunakan fitur A01T dan A01E**

**Tabel 4.1 Hasil Klasifikasi Fitur A01T dan A01E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	53,4722	46,5278	49,3056	50,0000
Cityblock	47,9167	51,3889	47,2222	45,1389
Minkowski	53,4722	46,5278	49,3056	50,0000
Chebychev	47,9167	45,8333	47,9167	44,4444

**4.1.2. Nilai akurasi klasifikasi KNN menggunakan fitur A02T dan A02E**

**Tabel 4.2 Hasil Klasifikasi Fitur A02T dan A02E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	61,1111	55,5556	53,4722	48,6111
Cityblock	61,1111	55,5556	50,6944	51,3889
Minkowski	61,1111	55,5556	53,4722	48,6111
Chebychev	57,6389	51,3889	54,8611	51,3889

**4.1.3. Nilai akurasi klasifikasi KNN menggunakan fitur A03T dan A03E**

**Tabel 4.3 Hasil Klasifikasi Fitur A03T dan A03E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	55,5556	56,2500	48,6111	49,3056
Cityblock	56,9444	52,0833	48,6111	47,9167
Minkowski	55,5556	56,2500	48,6111	49,3056
Chebychev	56,9444	62,5000	55,5556	56,2500

**4.1.4. Nilai akurasi klasifikasi KNN menggunakan fitur A05T dan A05E**

**Tabel 4.4 Hasil Klasifikasi Fitur A05T dan A05E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	49,3056	54,8611	55,5556	53,4722
Cityblock	50,6944	55,5556	56,2500	55,5556
Minkowski	49,3056	54,8611	55,5556	53,4722
Chebychev	53,4722	59,7222	55,5556	54,1667

**4.1.5. Nilai akurasi klasifikasi KNN menggunakan fitur A06T dan A06E**

**Tabel 4.5 Hasil Klasifikasi Fitur A06T dan A06E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	53,4722	56,2500	50,0000	51,3889
Cityblock	52,7778	51,3889	48,6111	48,6111
Minkowski	53,4722	56,2500	50,0000	51,3889
Chebychev	51,3889	52,7778	48,6111	49,3056

**4.1.6. Nilai akurasi klasifikasi KNN menggunakan fitur A07T dan A07E**

**Tabel 4.6 Hasil Klasifikasi Fitur A07T dan A07E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	51,3889	51,3889	47,2222	46,5278
Cityblock	51,3889	51,3889	50,0000	47,9167
Minkowski	51,3889	51,3889	47,2222	46,5278
Chebychev	47,2222	48,6111	45,8333	49,3056

**4.1.7. Nilai akurasi klasifikasi KNN menggunakan fitur A08T dan A08E**

**Tabel 4.7 Hasil Klasifikasi Fitur A08T dan A08E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	50,0000	46,5278	46,5278	48,6111
Cityblock	54,1667	50,6944	53,4722	47,9167
Minkowski	50,0000	46,5278	46,5278	48,6111
Chebychev	50,0000	47,2222	45,8333	45,8333

**4.1.8. Nilai akurasi klasifikasi KNN menggunakan fitur A09T dan A09E**

**Tabel 4.8 Hasil Klasifikasi Fitur A09T dan A09E**

Fungsi jarak	Distance (k)			
	1	3	5	7
Euclidean	52,0833	53,4722	57,6389	55,5556
Cityblock	54,8611	55,5556	54,8611	54,1667
Minkowski	52,0833	53,4722	57,6389	55,5556
Chebychev	49,3056	51,3889	52,0833	50,0000

**4.2. Analisa Hasil Pengujian**

Berikut hasil akurasi tertinggi pada masing masing fitur

**Tabel 4.9 Analisa Hasil Pengujian**

Fitur	Distance	Akurasi
A01E dan A01T	Euclidean, 1 dan Minkowski, 1	53,4722%
A02E dan A02T	Cityblock, 1	61,1111%
A03E dan A03T	Chebychev, 3	62,5000%
A04E dan A04T		
A05E dan A05T	Chebychev, 3	59,7222%
A06E dan A06T	Euclidean, 3 dan Minkowski, 3	56,2500%
A07E dan A07T	Cityblock, 1	51,3889%
A08E dan A08T	Cityblock, 1	54,1667%
A09E dan A09T	Euclidean, 5 dan Minkowski, 5	57,6389%

Terdapat dua metode hitung jarak yang memperoleh hasil akurasi tertinggi dengan nilai yang sama persis. Yaitu metode hitung jarak Euclidean dan Minkowski dengan

nilai k yang juga sama. Kesamaann hasil akurasi tertinggi tersebut terdapat pada 3 fitur yaitu fitur A01E dan A01T, A06E dan A06T. A09E dan A09T. Dari semua fitur pada data set, nilai akurasi tertinggi terdapat pada fitur A03E dan A03T menggunakan metode hitung jarak chebyhev dengan nilai k yaitu 3 sebesar 62,5000%. Tetapi pada fitur lain metode hitung jarak chabychev tidak menghasilkan nilai akurasi tertinggi, hanya pada fitur A03E dan A03T, A05E dan A05T. Untuk metode hitung jarak cityblock memperoleh nilai akurasi tertinggi pada fitur A02E dan A02T, A07E dan A07T, A08E dan A08T.

**5. Kesimpulan**

1. Pada setiap fitur menghasilkan nilai akurasi yang berbeda walaupun menggunakan metode hitung jarak dan nilai k yang sama.
2. Pada fitur A01T dan A01E nilai akurasi tertinggi terdapat pada metode hitung jarak Euclidean dan Minkowski dengan nilai k masing masing 1 yaitu sebesar 53,4722% dan juga pada fitur A02T dan A02E nilai akurasi tertinggi terdapat pada metode hitung jarak Cityblock dengan nilai k yaitu 1 sebesar 61,1111%. Kedua fitur ini menandakan bhawa metode hitung jarak dan k yang digunakan menghasilkan nilai akurasi tertinggi yang berbeda.

**6. REFERENSI**

[1] M. Kaya, M. K. Binli, E. Ozbay, H. Yanar, and Y. Mishchenko, "Data descriptor: A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces," *Sci. Data*, vol. 5, no. August, pp. 1–16, 2018.

[2] M. Z. Al Faiz and A. A. Al-Hamadani, "Online Brain Computer Interface Based Five Classes EEG To Control Humanoid Robotic Hand," *2019 42nd Int. Conf. Telecommun. Signal Process.*, pp. 406–410, 2019.

[3] H. Azmy and N. M. Safri, "EEG based BCI using visual imagery task for robot control," *J. Teknol. (Sciences Eng.*, vol. 61, no. 2 SUPPL, pp. 7–11, 2013.

[4] Ivan, Antonius. "Pengembangan Sistem Deteksi Emosi Menggunakan Sinyal EEG "EmoClass"". *Jakarta: Universitas Bina Nusantara*. 2017

[5] E. Yulianto, A. Susanto, T. S. Widodo, and S. Wibowo, "Spektrum Frekuensi Sinyal EEG Terhadap Pergerakan Motorik dan Imajinasi Pergerakan Motorik," *Forum Tek.*, vol. 35, pp. 21–32, 2013.

[6] M. R. A. Putra, E. C. Djamal, and R. Ilyas, "Brain Computer Interface untuk Menggerakkan Robot Menggunakan Recurrent Neural Network," *Pros. Semin. Nas. Rekayasa Teknol. Inf. / SNARTISI*, vol. 1, no. 1, pp. 205–211, 2018.

[7] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain computer interfaces, a review," *Sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.

[8] P. Putu *et al.*, "Terhadap Rangsangan Impuls Suhu Air Dengan Brain Computer Interface ( Bci ) the Stimulation of Water Temperature Impulse By Using Brain Computer," 2018.

[9]M. Lotze and U. Halsband, "Motor imagery," *J.*

*Physiol. Paris*, vol. 99, no. 4–6, pp. 386–395, 2006.

[10] A. D. Candra and P. E. Suryani, “Perbandingan Metode Eemd Dan Emd Untuk Mereduksi Noise Pada Sinyal Seismik,” *J. Ilm. Teknosains*, vol. 4, no. 1, p. 47, 2018.

[12] Primatara Egi, “Estimasi Stabilitas Sudut Rotor Secara Dinamis dengan Metode Lyapunov Eksponen Maksimum pada Sistem Tenaga Listrik Wilayah Lampung” *Lampung: Universitas Lampung* 2018.

[13] M. Rivki and A. M. Bachtiar, “Implementasi Algoritma K-Nearest Neighbor Dalam Pengklasifikasian Follower Twitter Yang Menggunakan Bahasa Indonesia,” *J. Sist. Inf.*, vol. 13, no. 1, p. 31, 2017.