

PERANCANGAN SISTEM DETEKSI KANAL SINYAL STROKE EEG MENGGUNAKAN METODE *SPATIAL SELECTION*

THE DESIGN OF STROKE EEG CHANNEL SELECTION SYSTEM USING SPATIAL SELECTION METHOD

Irena Arvianda¹, Hilman Fauzi T.S.P, S.T., M.T., Ph.D.², R. Yunendah Nur F., S.T., M.T.³
^{1,2,3} Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom, Bandung

¹irenarvianda@student.telkomuniversity.ac.id, ²hilmanfauzitsp@telkomuniversity.ac.id,
³yunendah@telkomuniversity.ac.id

Abstrak

Stroke dapat diartikan sebagai gangguan fungsi sistem saraf yang terjadi secara mendadak dan disebabkan oleh tersumbatnya pembuluh darah yang terjadi di otak. Umumnya upaya yang digunakan untuk mengurangi jumlah pasien stroke yaitu dengan metode diagnosis menggunakan Magnetic Resonance Imaging (MRI). Namun, biaya pemeriksaan menggunakan metode MRI relative mahal dan tidak portable. Salah satu cara untuk mengatasi permasalahan tersebut yaitu menggunakan alat *Electroencephalograph* (EEG) untuk mendeteksi sinyal stroke pada bagian otak.

EEG merupakan alat yang dilakukan untuk mengukur aktivitas kelistrikan pada otak untuk mendeteksi adanya kelainan dari otak. Tindakan ini menggunakan sensor khusus yaitu elektroda yang dipasang di kepala dan dihubungkan melalui kabel menuju komputer. Pada penelitian sebelumnya pengolahan sinyal stroke EEG telah dilakukan menggunakan metode *Brain Symmetry Index* dan *Hilbert Huang Transform* (BSI-HHT). Akan tetapi, pada penelitian tersebut tidak membahas secara spesifik tentang seleksi kanal pada sinyal stroke EEG. Dengan adanya permasalahan tersebut, pada penelitian ini penulis akan mengolah sinyal stroke EEG menggunakan metode *Spatial Selection* yang dimodifikasi menggunakan metode *Fast Fourier Transform* (FFT) melalui konfigurasi komposisi kanal aktif agar dapat diolah untuk mendapatkan hasil yang relevan. Dan proses klasifikasi yang dilakukan yaitu menggunakan metode *k- Nearest Neighbor* (k-NN) dan *Extreme Learning Machine* (ELM).

Pada implementasi klasifikasi k-NN menunjukkan bahwa metode *spatial selection* dapat menemukan komposisi kanal yang tepat dengan hasil akurasi yang sama dengan data normal pada beberapa wilayah. Sedangkan pada klasifikasi ELM mampu meningkatkan hasil akurasi sebesar 2% lebih besar dibandingkan data normal pada wilayah Highmean dengan komposisi kanal yang sedikit.

Kata Kunci : *Stroke, Electroencephalogram (EEG), Spatial Selection.*

Abstract

Stroke can be interpreted as a nervous system malfunction that occurs suddenly and is caused by blocked blood vessels that occur in the brain. Generally, the effort used to reduce the number of stroke patients is by using magnetic resonance imaging (MRI) diagnosis methods. However, the cost of examinations using the MRI method is relatively expensive and not portable. One way to overcome these problems is to use an electroencephalograph (EEG) tool to detect stroke signals in parts of the brain.

In previous studies, EEG stroke signal processing has been carried out using the Brain Symmetry Index and Hilbert Huang Transform (BSI-HHT) methods. However, this study does not specifically address channel selection in EEG stroke signals. Given these problems, in this study, the writer will process the EEG stroke signal using the Spatial selection method which is modified using the Fast Fourier Transform (FFT) method. The data used are 8 data from stroke patients and 8 healthy data whose accuracy will be compared. The classification process is carried out using the k-Nearest Neighbor (k-NN) and Extreme Learning Machine (ELM) methods.

In the implementation of the k-NN classification, the optimal results reach a value of 1 when the value of $k = 1$ with the same accuracy results with normal data in several regions. Whereas the ELM classification has an increase in the 0.027 Highmean regions from the normal data that is the Highmean data with the results of 0.859 and the normal data of 0.832. And the implementation of the Spatial Selection method can find the relevant channel composition in each data.

Keywords: *Stroke, Electroencephalogram (EEG), Spatial Selection.*

1. Pendahuluan

Stroke merupakan gangguan fungsi sistem saraf yang terjadi secara mendadak dan disebabkan oleh gangguan pembuluh darah yang terjadi di dalam otak. Gangguan peredaran darah itu terjadi karena tersumbatnya pembuluh darah, atau pecahnya pembuluh darah di dalam otak[1]. Berdasarkan data statistik dari Riset Kesehatan Dasar (RISKERDAS) jumlah pasien stroke di Indonesia yang tercatat sejak 2013 – 2018 meningkat dari 0,7% menjadi 1,09%[2]. Melihat kenaikan presentase yang tinggi tersebut dibutuhkan suatu upaya untuk mengurangi jumlah penderita stroke yaitu dengan pemutakhiran metode diagnosis yang di antaranya menggunakan *Magnetic Resonance Imaging* (MRI). Namun demikian, biaya pemeriksaan penggunaan MRI relatif mahal dan tidak *portable*. Salah satu alternatif untuk mengatasi permasalahan tersebut yaitu dengan menggunakan Elektroensefalogram (EEG) yang dapat mendeteksi sinyal stroke pada bagian otak.

EEG adalah alat yang digunakan untuk merekam aktivitas elektrik pada otak manusia yang ditempatkan di kulit kepala. EEG sangat berguna dalam memahami disfungsi neurologis stroke dan memungkinkan peningkatan perawatan dan rehabilitasi sehingga lebih aman bagi pasien karena tidak memerlukan adanya pembedahan pada otak[3] Pada penelitian sebelumnya telah dilakukan penelitian menggunakan metode BSI-HHT. Namun pada penelitian tersebut tidak membahas spesifik tentang seleksi kanal pada sinyal EEG. Dan pada penelitian ini penulis akan mengolah sinyal EEG menggunakan *spatial selection* yang bekerja pada domain waktu. Selain itu, proses pemilihan kanal EEG akan dilakukan untuk mengetahui area stroke pada otak. Sistem ini akan dirancang menggunakan *spatial selection* yang dimodifikasi dengan metode FFT yang umum digunakan untuk melihat pola dari sinyal EEG. Melalui rancangan ini, diharapkan area stroke dapat diketahui dengan optimasi sistem yang baik. Selain itu, digunakan *k-Nearest Neighbor* (k-NN) dan *Extreme Learning Machine* (ELM) sebagai metode klasifikasi ciri.

2. Konsep Dasar

2.1 Stroke

Stroke dapat diartikan sebagai gangguan fungsi sistem saraf yang terjadi secara mendadak dan disebabkan oleh gangguan pembuluh darah yang terjadi di dalam otak. Gangguan peredaran darah itu terjadi karena tersumbatnya pembuluh darah, atau pecahnya pembuluh darah di dalam otak. Penyakit stroke telah banyak mengakibatkan kecacatan seperti gangguan gerak, kelumpuhan dalam berbicara, kemampuan dalam mengingat, proses berfikir dan juga kecacatan yang lain sebagai akibat timbulnya gangguan fungsi otak [1]

2.2 Stroke iskemik

Stroke iskemik adalah tanda klinis disfungsi atau kerusakan jaringan otak yang disebabkan kurangnya aliran darah ke otak sehingga dapat mengganggu aliran darah dan oksigen di otak[4]. Berdasarkan faktor risiko tersebut maka dapat dilakukan tindakan pencegahan dan penanggulangan penyakit stroke, terutama untuk menurunkan angka kejadian stroke iskemik[5].

2.3 Elektroensefalogram (EEG)

EEG adalah perangkat yang digunakan untuk merekam aktivitas elektrik pada otak manusia dengan menempatkan EEG pada kulit kepala. EEG merupakan salah satu perangkat yang dilakukan dengan metode *non-invasive*[6]. Sinyal EEG dapat diukur dengan meletakkan elektroda pada kulit kepala dengan urutan peletakan elektroda yang mengacu pada standar sistem 10-20 yang dikenal dengan istilah “*International Electrode Placement System*” yang ditetapkan secara internasional oleh *International Federation on Electroencephalography and Clinical Neurophysiology*[7].

2.4 Frequency Band EED

Gelombang otak manusia memiliki rentang frekuensi dan amplitudo yang bervariasi dan digolongkan menjadi gelombang delta, theta, alpha dan beta[8]. Gamma (35 Hz - 45Hz), Gelombang gamma terjadi pada saat seseorang sedang mengalami aktifitas mental yang sangat tinggi, seperti saat sedang di arena pertandingan, tampil di muka umum, sangat panik, atau sedang ketakutan. Dan kondisi ini terjadi dalam kesadaran penuh[8]. Beta (13 Hz – 30 Hz), Gelombang otak yang terjadi pada saat seseorang mengalami aktifitas mental yang terjaga penuh. Kondisi ini, seperti terjadi ketika sedang melakukan aktifitas sehari-hari atau ketika sedang berinteraksi dengan orang lain[8].

Alpha (8 Hz-13Hz), Gelombang otak yang terjadi saat sedang mengalami relaksasi atau mulai istirahat dengan tanda-tanda mata mulai menutup atau mulai mengantuk. Seseorang menghasilkan gelombang alpha setiap akan tidur, tepatnya saat masa peralihan antara sadar dan tidak sadar[8].Theta (4Hz – 8Hz), Gelombang otak yang terjadi saat seseorang sedang mengalami tidur ringan atau sangat mengantuk. [8].Delta (0.5 Hz – 4Hz) Gelombang otak yang memiliki amplitude dan frekuensi yang besar dan frekuensi yang rendah, yaitu dibawah 3Hz. Fase delta adalah fase istirahat bagi tubuh dan pikiran. Pada fase ini tubuh melakukan proses penyembuhan diri, memperbaiki kerusakan jaringan, dan aktif memproduksi sel-sel baru saat sedang tertidur lelap[8].

2.5 Spatial Selection

Spatial Selection terdiri dari dua memprosesan yaitu, *energy extraction* dan *energy selection*. Pada *energy extraction*, terdapat dua metode perhitungan energi diantaranya adalah L2-norm dan leverage score[9]. Metode *energy extraction* yang digunakan yaitu L2-norm. L2-norm dari *energy extraction* dapat didefinisikan dengan persamaan sebagai berikut :

$$p_j = \frac{\sum_{i=1}^m A(i,j)^2}{\sum_{i=1}^m \sum_{j=1}^n A(i,j)^2} \quad (2.1)$$

di mana p merupakan nilai energy, i merupakan baris dan j merupakan kolom. A adalah matriks dari data, m dan n merupakan nomor dari baris dan kolom masing-masing.

Metode *energy selection*, *spatial selection* terbagi menjadi manual dan *automatic spatial selection*. Pada metode *Automatic spatial selection* dibagi menjadi empat wilayah, yaitu : (1) *mean*, (2) *high mean*, (3) *box*, dan (4) *high in box*. Daerah energi dibagi oleh beberapa nilai diantaranya adalah \bar{x} , x_{min} , x_{max} dan S_1 , S_2 . Dimana x dilambangkan sebagai nilai energi kanal, yang dimana \bar{x} sebagai rata-rata energi dari semua kanal. x_{min} dan x_{max} direpresentasikan sebagai energy ekstrim maksimum dan minimum nilai kanal dari masing-masing nilai x [9]. Sementara itu, S_1 dan S_2 merupakan batas dari nilai energi, yang dapat didefinisikan dengan persamaan :

$$S_1 = \frac{\bar{x} - x_{min}}{2} \quad (2.2)$$

$$S_2 = \frac{x_{max} - \bar{x}}{2} \quad (2.3)$$

Berikut rumus untuk daerah seleksi kanal yang ditunjukkan pada sebagai berikut

A. Mean Technique

Mean technique ditunjukkan pada persamaan berikut :

$$Ce \geq \bar{x} \quad (2.4)$$

B. High Mean Technique

High Mean Technique dapat ditunjukkan pada persamaan berikut :

$$Ce \geq S_2 \quad (2.5)$$

C. Box Technique

Box Technique dapat ditunjukkan pada persamaan berikut :

$$S_2 \geq Ce \geq S_1 \quad (2.6)$$

D. High in Box

High in box technique dapat ditunjukkan pada persamaan berikut :

$$S_2 \geq Ce \geq \bar{x} \quad (2.7)$$

2.7 Fast Fourier Transform (FFT)

FFT merupakan algoritma yang efisien untuk menghitung koefisien dari Discrete Fourier Transform (DFT) ke suatu finite sekuen dari data yang kompleks. Persamaan FFT bisa didefinisikan sebagai berikut:

$$x[k] = \sum_{n=0}^{N-1} x[n] e^{-\frac{j2k\pi}{N} \cdot n} \quad (2.9)$$

dengan $n=0, \dots, N-1$ dan $k=0, \dots, N-1$, $x(k)$ adalah nilai dari spektrum ke- k (domain frekuensi), k merupakan indeks dari frekuensi ke- N , dan $x(n)$ adalah nilai sinyal pada domain waktu dengan n adalah indeks waktunya. Secara umum FFT tergantung pada pemfaktoran dari N [10].

2.8 k-Nearest Neighbor (k-NN)

Klasifikasi *k-Nearest Neighbor* (k-NN) adalah salah satu klasifikasi untuk EEG yang memiliki metode klasifikasi yang intuitif dan sederhana. k-NN membandingkan data uji dan data latih untuk pengklasifikasinya[11]. Salah satu metode adalah *Euclidean distance*. Persamaan tersebut mewakili variable i dan j dan dapat dihitung dengan persamaan berikut :

$$R_{ij}(t) = \|X_i(t), X_j(t)\|_2 \tag{2.12}$$

2.9 Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) merupakan bagian dari jaringan saraf tiruan yang biasanya disebut dengan Single Hidden Layer Feedforward Neural Network (SLNs). Jaringan ELM terdiri dari 3 layer, yaitu input layer, hidden layer, dan output layer[12]. Persamaan ELM dapat dilihat pada persamaan 2.12 berikut.

$$H\beta = T \tag{2.13}$$

di mana,

$$H(w_1, \dots, w_N, b_1, \dots, b_N, X_1, \dots, X_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_N \cdot x_N + b_N) \end{bmatrix}_{N \times N} \tag{2.14}$$

$$\beta = \begin{pmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{pmatrix}_{N \times m} \text{ dan } T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix}_{N \times m} \tag{2.15}$$

H merupakan matriks hidden layer output dari neural network dan kolom ke-i dari matriks H merupakan hidden output node ke-i dengan memperhatikan input (x1, x2, ..., xN)[13].

3. HASIL PERCOBAAN DAN ANALISA

3.1 Hasil dan Analisis Pengujian Skenario 1

Pada pengujian skenario 1 ini, merupakan hasil pemetaan kanal pada data A di wilayah highmean, mean, highbox, dan box.

DATA A					
HIGHMEAN (a)			HIGHBOX (b)		
NORMAL	SEHAT	STROKE	NORMAL	SEHAT	STROKE
MEAN (c)			BOX (d)		
NORMAL	SEHAT	STROKE	NORMAL	SEHAT	STROKE

Tabel 1. Hasil pemetaan kanal pada data A di seluruh wilayah (channel mapping)

Hasil dari skenario 1 ini menunjukkan kanal yang telah terpilih dari data normal di wilayah mean, highmean, high box, dan box pada data A. Hasil dari data A yang sudah dilakukan pemilihan seleksi kanal pada seluruh wilayah berdasarkan energi tertinggi. Terdapat garis putus-putus pada area cortex pada data sehat dan stroke. Pada pemilihan seleksi kanal dengan jumlah yang berbeda-beda pada setiap wilayah mean, highmean, highbox, dan box.

3.2 Hasil dan Analisis Pengujian Skenario 2

Pengujian pada skenario ini membandingkan hasil akurasi antara data yang sudah diimplementasikan dengan spatial selection dengan menggunakan ekstraksi ciri FFT dan klasifikasi K-NN dengan percobaan k=1, k=3, dan k=5. Dengan percobaan ini di harapkan menghttasilkan adanya performansi atau peningkatan hasil akurasi pada metode Spatial Selection.

Berikut merupakan hasil akurasi pada nilai K = 1

Ekstraksi ciri FFT	K=1				
	Normal	Highmean	Highbox	Box	Mean

Data A	1	1	1	1	1
Data B	1	1	1	1	1
Data C	1	1	1	1	1
Data D	1	1	1	1	1
Data E	1	1	1	1	1
Data F	0,5	0,5	0,5	0,5	0,5
Data G	1	1	1	1	1
Data H	1	1	1	1	1
Average Accuracy	0,93	0,93	0,93	0,93	0,93

Tabel 2 Hasil Akurasi K-NN dengan k=1 dengan ekstraksi ciri FFT.

Pada skenario ini, pada parameter k = 1 hasil akurasi menunjukkan angka yang konstan yang ditandai dengan warna hijau yaitu pada table 2, yaitu sebesar 0,93. Dan terdapat nilai akurasi sebesar 0,5 pada data F hal ini disebabkan oleh pengaruh dari jumlah kanal yang terdapat pada data tersebut. Akan tetapi, performa paling baik adalah wilayah Highmean hal ini disebabkan karena pada saat proses channel selection wilayah Highmean yang memiliki jumlah kanal terpilih paling sedikit yaitu ditunjukkan pada table 2.

Berikut merupakan tabel hasil akurasi nilai K = 3

Ekstraksi ciri FFT	K = 3				
	Normal	Highmean	Highbox	Box	Mean
Data A	1	1	1	1	1
Data B	0,6667	0,6667	0,6667	0,6667	0,6667
Data C	1	83,33	1	1	1
Data D	1	1	1	1	1
Data E	1	1	1	1	1
Data F	0,5	0,5	0,5	0,5	0,5
Data G	0,5	0,5	0,5	0,5	0,5
Data H	1	1	1	1	1
Average Accuracy	0,89	0,87	0,89	0,89	0,89

Tabel 3. Hasil Akurasi K-NN dengan k=3 dengan ekstraksi ciri FFT.

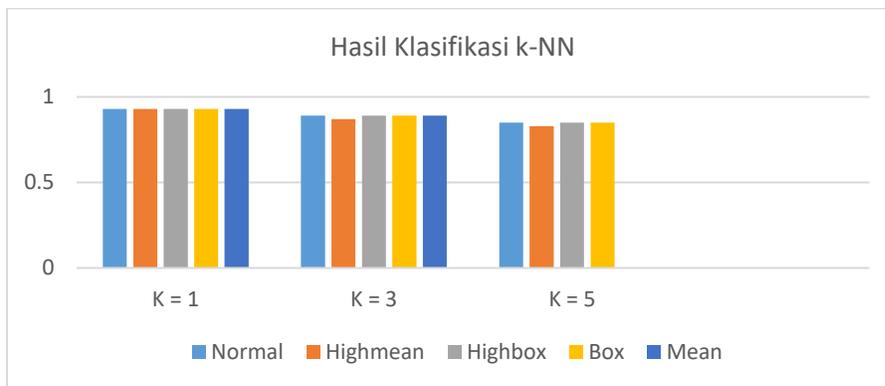
Pada skenario ini, pada saat parameter k=3 diperoleh rata-rata akurasi tertinggi yang ditandai dengan warna hijau pada table 4.3, yaitu sebesar 0,89 pada data normal, mean, Highbox, dan Box. Dan pada data mean menjadi nilai akurasi rata-rata terendah yang di tandai dengan warna merah pada table 4, yaitu sebesar yaitu 0,87 hal ini disebabkan karena pada data G dan data B memiliki penurunan akurasi pada parameter k = 3.

Berikut merupakan table hasil akurasi pada parameter K = 5

Ekstraksi ciri FFT	K = 5				
	Normal	Highmean	Highbox	Box	Mean
Data A	0,6667	0,6667	0,6667	0,6667	0,6667
Data B	0,6667	0,6667	0,6667	0,6667	0,6667
Data C	1	0,8333	1	1	1
Data D	1	1	1	1	1
Data E	1	1	1	1	1
Data F	1	1	1	1	1
Data G	0,5	0,5	0,5	0,5	0,5
Data H	1	1	1	1	1
Average Accuracy	0,85	0,83	0,85	0,85	0,85

Tabel 4. Hasil Akurasi K-NN dengan k=5 dengan ekstraksi ciri FFT.

Pada skenario ini, pada saat parameter k=5 dapat memperoleh rata-rata akurasi tertinggi yang ditandai dengan warna hijau pada tabel 4, yaitu sebesar 0,85 pada Data normal, mean, Highbox, dan Box. Nilai akurasi rata-rata terendah yang di tandai dengan warna merah pada table 4.2, pada wilayah Highmean yaitu sebesar 0,83 hal ini disebabkan penurunan performa pada data A, B dan G pada k =5.



Gambar 1. Grafik Perbandingan rata-rata akurasi menggunakan ekstraksi ciri FFT dan klasifikasi K-NN.

Berdasarkan Gambar 1, Sinyal EEG stroke menggunakan metode spatial selection dengan ekstraksi ciri fft dan klasifikasi k-NN pada nilai K =1, K=3, dan K=5 pada wilayah Highbox, Box dan Mean memiliki rata-rata akurasi yang konstan dengan data normal sedangkan wilayah Highmean khususnya pada data A, B, dan G hal ini disebabkan karena kenaikan nilai k pada data tersebut. Dan pada wilayah Highmean menjadi akurasi terendah hal ini disebabkan karena bertambahnya jumlah nilai k dan juga dapat dipengaruhi oleh jumlah kanal yang sedikit pada Highmean sehingga dapat mengakibatkan berkurangnya hasil akurasi pada beberapa data.

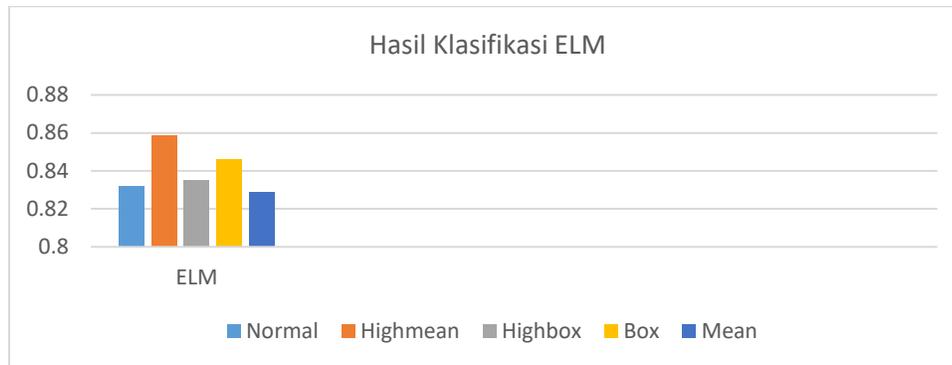
3.3 Hasil dan Analisis Pengujian Skenario 3

Pengujian pada skenario ini membandingkan hasil akurasi data set sudah diimplementasikan dengan *spatial selection* dengan menggunakan ekstraksi ciri FFT dengan klasifikasi ELM Dengan percobaan ini di harapkan menghasilkan adanya performansi atau peningkatan hasil akurasi pada metode *spatial selection*.

Pada skenario ini, dapat memperoleh rata-rata akurasi tertinggi yang ditandai dengan warna hijau pada Tabel 5, yaitu sebesar 0,859 pada wilayah Highmean. Dan wilayah mean menjadi nilai akurasi rata-rata terendah yang di tandai dengan warna merah pada tabel 5, yaitu sebesar 0,829. Pada wilayah mean memiliki akurasi yang relatif lebih kecil yaitu memiliki penurunan sebesar 0,3 hal ini disebabkan karena pada wilayah mean memiliki jumlah kanal yang cenderung lebih sedikit akan tetapi hasil akurasi dari wilayah mean tidak jauh berbeda dengan data normal secara rata-rata

	Normal	Highmean	Highbox	Box	Mean
Data A	0,811	0,877	0,805	0,822	0,872
Data B	0,883	0,9778	0,911	0,955	0,955
Data C	0,816	0,8722	0,827	0,888	0,777
Data D	0,805	0,8056	0,811	0,750	0,777
Data E	0,905	0,905	0,861	0,916	0,861
Data F	0,822	0,805	0,844	0,838	0,805
Data G	0,755	0,811	0,744	0,772	0,755
Data H	0,872	0,844	0,877	0,827	0,888
<i>Average Accuracy</i>	0,832	0,859	0,835	0,846	0,829

Tabel 5. Hasil akurasi FFT menggunakan ELM



Gambar 2. Hasil Akurasi menggunakan klasifikasi ELM.

Berdasarkan Gambar 2, Sinyal EEG stroke metode *spatial selection* dengan ekstraksi ciri FFT dan klasifikasi ELM memiliki kenaikan nilai akurasi paling besar yaitu dengan akurasi rata-rata 0,027 lebih besar dari Sinyal EEG stroke tanpa metode *spatial selection*.

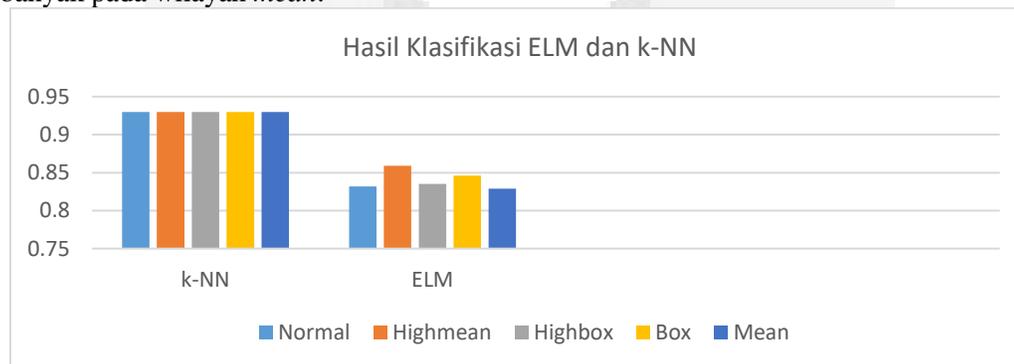
Pada skenario ini dapat diperoleh hasil rata-rata akurasi tertinggi yaitu pada wilayah Highmean memiliki peningkatan. Pada wilayah mean memiliki akurasi yang relative lebih kecil yaitu memiliki penurunan sebesar 0,003 hal ini disebabkan karena pada wilayah mean memiliki jumlah kanal yang cenderung lebih sedikit akan tetapi hasil akurasi dari wilayah mean tidak jauh berbeda dengan data normal secara rata-rata. Berdasarkan hasil pengujian, peningkatan akurasi tertinggi terdapat pada data B wilayah Highmean yaitu sekitar 0,945 dari data normal dimana pada wilayah ini memiliki jumlah kanal paling sedikit dibandingkan wilayah yang lain. Namun demikian, penurunan akurasi terendah terdapat pada data D wilayah box yaitu sekitar 0,005 dimana pada wilayah ini memiliki jumlah kanal yang paling banyak di bandingkan dengan wilayah lain.

3.4 Hasil dan Analisis Umum

Analisis umum didapat dari seluruh skenario yaitu, mengambil parameter konstan dari setiap skenario yaitu $k=1$ membandingkan hasil akurasi dari nilai k yang lain. Hasil Perbandingan skenario 2 dan skenario 3, dan dapat dilihat pada Gambar 3.

Berdasarkan Gambar 3, pada skenario 2 menunjukkan bahwa nilai yang paling konstan berada pada $k = 1$. Pada klasifikasi k -NN ini menunjukkan bahwa semakin bertambah nilai k dan semakin sedikit kanal yang terpilih maka akan mempengaruhi penurunan pada akurasi. Akan tetapi, pada klasifikasi k -NN memiliki akurasi 1 di beberapa data.

Dan pada skenario 3 hasil pengujian pada klasifikasi ELM sekitar 0,027 dari metode Spatial Selection pada wilayah Highmean mengalami akurasi yang lebih baik dibandingkan data normal. Dan pada wilayah Mean memiliki penurunan akurasi yang relatif lebih kecil yaitu sekitar 0,003 hal ini dipengaruhi dengan jumlah kanal yang relatif banyak pada wilayah *mean*.



Gambar 3. Grafik Perbandingan rata-rata akurasi menggunakan ekstraksi ciri FFT dan klasifikasi ELM.

4. KESIMPULAN

4.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan pada Tugas Akhir ini, maka dapat didapatkan kesimpulan sebagai berikut:

Metode *spatial selection* pada data set sinyal EEG stroke ini dapat diimplementasikan untuk meningkatkan tingkat akurasi dan dapat memfilter data set agar mendapat hasil kanal yang lebih relevan. Hasil yang didapatkan dari klasifikasi ELM memiliki peningkatan pada wilayah *Highmean* sebesar 0,027 dari data normal yaitu data *Highmean* dengan hasil 0,859 dan data normal dengan hasil 0,832. Sedangkan hasil akurasi dengan klasifikasi k-NN memiliki nilai optimal pada saat nilai $k = 1$ dengan performansi sebesar 1 pada beberapa data, akan tetapi pada nilai k yang lain mengalami penurunan. Peningkatan dan penurunan hasil akurasi dapat dipengaruhi oleh beberapa faktor yaitu karakteristik data dan jumlah kanal dari setiap data.

DAFTAR PUSTAKA

- [1] V. Adelina, D. E. Ratnawati, and M. A. Fauzi, "Klasifikasi Tingkat Risiko Penyakit Stroke Menggunakan Metode GA-Fuzzy Klasifikasi Tingkat Risiko Penyakit Stroke Menggunakan Metode GA- Fuzzy Tsukamoto," *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 2, no. September, pp. 3015–3021, 2018.
- [2] KEMENKES, "Hasil Utama Riskesdas Tentang Prevalensi Diabetes Mellitus di Indonesia 2018," *Has. Utama Riskesdas Tentang Prevalensi Diabetes Melitus di Indones. 2018*, p. 8, 2018.
- [3] 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.
- [4] G. Y. C. R. Kabi, R. Tumewah, and M. A. H. N. Kembuan, "Gambaran Faktor Risiko Pada Penderita Stroke Iskemik Yang Dirawat Inap Neurologi Rsup Prof. Dr. R. D. Kandou Manado Periode Juli 2012 - Juni 2013," *e-CliniC*, vol. 3, no. 1, pp. 1–6, 2015.
- [5] S. Hemoragik and K. Bengkulu, "S riwijaya j ournal of m edicine ;," 2018.
- [6] M. Arvaneh, S. Member, C. Guan, K. K. Ang, and C. Quek, "Optimizing the Channel Selection and Classification Accuracy in □ Introduction □ Experiments □ Results And □ Conclusion," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 6, pp. 1865–1873, 2012.
- [7] L. Bi, X. A. Fan, and Y. Liu, "EEG-based brain-controlled mobile robots: A survey," *IEEE Trans. Human-Machine Syst.*, vol. 43, no. 2, pp. 161–176, 2013.
- [8] Y. Akbar, "Pola Gelombang Otak Abnormal Pada," no. May 2014, pp. 1–6, 2014.
- [9] H. Fauzi, M. I. Shapiai, S. Shah Abdullah, and Z. Ibrahim, "Automatic Energy Extraction Methods for EEG Channel Selection," *Proc. - 2018 Int. Conf. Control. Electron. Renew. Energy Commun. ICCEREC 2018*, pp. 70–75, 2019.
- [10] S. N. Farihah, K. Y. Lee, W. Mansor, N. B. Mohamad, Z. Mahmoodin, and S. A. Saidi, "EEG average FFT index for dyslexic children with writing disorder," *ISSBES 2015 - IEEE Student Symp. Biomed. Eng. Sci. By Student Student*, pp. 118–121, 2016.
- [11] V. L. Kaundanya, A. Patil, and A. Panat, "Performance of k-NN classifier for emotion detection using EEG signals," *2015 Int. Conf. Commun. Signal Process. ICCSP 2015*, pp. 1160–1164, 2015.
- [12] A. S. M. M. S. Ramakrishnan, "Hierarchical multi - class SVM with ELM kernel for epileptic EEG signal classification," *Med. Biol. Eng. Comput.*, 2015.
- [13] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," *IEEE Int. Conf. Neural Networks - Conf. Proc.*, vol. 2, pp. 985–990, 2004.