

Identifikasi EEG Epilepsi Menggunakan Wavelet dan Learning Vector Quantization

Erry Fuadillah¹, Esmeralda C Djamal, Agus Komarudin

Jurusan Informatika, Fakultas Sains dan Informatika

Universitas Jenderal Achmad Yani

Jl. Terusan Sudirman, Cimahi

¹erryfuadillah@live.com

Abstrak— Epilepsi merupakan salah satu penyakit neurologis kronis yang dapat menyerang sekitar 50 juta orang di semua usia. Di Indonesia terdapat lebih dari 1.400.000 kasus Epilepsi setiap tahun dengan 70.000 penambahan kasus setiap tahunnya. Sekitar 40-50% terjadi pada anak-anak. Salah satu pemeriksaan Epilepsi menggunakan Elektroensefalogram (EEG) yang mengidentifikasi frekuensi 2,8-5,4 Hz, dan loncatan amplitudo atau berbentuk spike. Agar pemeriksaan cukup akurat, sinyal EEG dalam domain waktu perlu diproses dalam domain lain untuk identifikasi adanya Epilepsi. Pada penelitian ini telah dibangun sistem identifikasi Epilepsi menggunakan transformasi Wavelet dan Learning Vector Quantization (LVQ). Pembelajaran dan pengujian menggunakan set data EEG dari University of Bonn. Data terdiri atas empat kondisi, yaitu orang normal mata terbuka (Z), orang normal mata tertutup (O), penderita Epilepsi saat serangan (S), dan penderita Epilepsi saat tidak terjadi serangan (F). Sinyal EEG direkam dengan frekuensi sampling 173,5 Hz selama 23,6 detik sehingga setiap set data mempunyai 4097 titik. Wavelet untuk mengekstraksi sinyal EEG yang mempunyai frekuensi sampling menjadi 2,8-5,4 Hz. Sistem identifikasi menggunakan LVQ dengan fitur spektral daya pada frekuensi 2,8-5,4 Hz dan nilai absolut dari amplitudo rata-rata setiap seperempat detik. Sehingga diperoleh 220 fitur. Sistem telah diuji menggunakan data S dan Z dengan akurasi 67% terhadap data non latih. Penggunaan Wavelet dapat meningkatkan akurasi dari 67% menjadi 72%. Penambahan fitur rata-rata amplitudo dapat meningkatkan akurasi menjadi 94%. Sistem juga telah diuji menggunakan set data ZO dan FS dengan hasil 73% tanpa ekstraksi Wavelet, 65% dengan ekstraksi Wavelet dan 75% untuk Wavelet dengan fitur lengkap. Sistem identifikasi juga telah diuji terhadap data latih dengan akurasi 100%.

Kata kunci— epilepsi; sinyal EEG; rata-rata amplitudo; wavelet, learning vector quantization;

I. PENDAHULUAN

Epilepsi adalah gangguan pada sistem saraf otak manusia yang mengakibatkan adanya aktivitas yang tidak normal yaitu aktivitas berlebihan dari sel neuron pada otak. Aktivitas dari neuron yang berlebihan akan menimbulkan dampak seperti melamun sesaat, kejang-kejang, gangguan kesadaran, kontraksi otot, serta kesemutan. Epilepsi ditunjukkan dengan adanya lonjakan amplitudo atau bentuk spike yang dicatat pada 3-4 Hz [1]. Dari banyak studi menunjukkan bahwa rata-rata kejadian Epilepsi 2,7-17,6 per 1.000 penduduk, dan angka serangan mencapai 51 per 100.000 penduduk [2]. Di Indonesia terdapat lebih dari 1.400.000 kasus Epilepsi setiap tahun

dengan 70.000 penambahan kasus setiap tahunnya. Sekitar 40-50% terjadi pada anak-anak.

Otak manusia dapat melakukan banyak aktivitas baik normal maupun tidak normal. Kondisi normal terdiri dari kondisi fisik seperti tidur dan beraktivitas, kondisi tidak normal seperti kejang pada Epilepsi [3]. Salah satu metode yang banyak digunakan untuk menilai aktivitas otak adalah melalui sinyal Elektroensefalogram (EEG). Sinyal EEG muncul selama otak manusia beraktivitas. Bentuk sinyal EEG setiap orang sangat bervariasi tergantung dari aktivitas, kesehatan dan kondisi pikiran. Dalam dunia medik, sinyal EEG sering digunakan untuk deteksi penyakit Epilepsi [4], klasifikasi penyakit Epilepsi [5][6] dan prediksi kemungkinan mengidap Epilepsi [7][8].

Sistem identifikasi Epilepsi dibangun dengan tahap ekstraksi dan identifikasi. Beberapa metode yang dapat digunakan untuk proses ekstraksi dalam sinyal EEG seperti Wavelet, Entropy dan Empirical Mode Decomposition (EMD). Ekstraksi Wavelet sangat cocok digunakan untuk melakukan analisis sinyal non stasioner seperti sinyal EEG. Penelitian terdahulu melakukan klasifikasi Epilepsi dengan menggunakan Wavelet dengan akurasi 91,2% [9]. Penelitian lain untuk *monitoring* emosi menggunakan Wavelet [10] serta klasifikasi Epilepsi dengan menggunakan Wavelet [11][12]. Pada beberapa penelitian Wavelet juga digunakan untuk klasifikasi emosi manusia [13], klasifikasi penyakit Epilepsi [11][14] dan klasifikasi sinyal EEG menggunakan LVQ [15] dan tingkat *stress* [16]. Sedangkan identifikasi dapat dilakukan dengan menggunakan Euclidean Distance (ED), Learning Vector Quantization (LVQ) dan Support Vector Machine (SVM). Penelitian lain untuk *monitoring* emosi menggunakan LVQ [10]. LVQ dapat melakukan pembelajaran dengan lebih cepat dibandingkan dengan pelatihan yang lain.

Sistem untuk identifikasi Epilepsi telah dibangun menggunakan ekstraksi Wavelet dan identifikasi LVQ dengan menggunakan beberapa set data yang terdiri atas 4 kondisi, yaitu orang normal mata terbuka (Z), orang normal mata tertutup (O), penderita Epilepsi saat serangan (S) dan penderita Epilepsi saat tidak terjadi serangan (F). Set data dibagi menjadi dua jenis yaitu data latih dan data baru. Pelatihan menggunakan LVQ dengan fitur spektral daya pada frekuensi 2,8-5,4 Hz dan nilai absolut dari amplitudo rata-rata setiap seperempat detik. Sistem yang dibuat telah diimplementasikan pada perangkat lunak.

II. METODE

A. Set data

Set data sinyal EEG didapat dari klinik fur Epileptologie Universitas Bonn German dengan *frekuensi sampling* 173,6 Hz yang terdiri dari empat jenis set data (Z,O,F dan S) masing-masing set data berisi 100 data dari satu kanal selama 23,6 detik, data merupakan hasil segmentasi untuk membuang artefak seperti aktivitas otot atau gerakan mata. Setiap set data terdiri dari kondisi yang berbeda, yaitu orang normal mata terbuka (Z), orang normal mata tertutup (O), penderita Epilepsi saat serangan (S), dan penderita Epilepsi saat tidak terjadi serangan (F).

Pada penelitian ini digunakan set data Z, O, F dan S sehingga terdapat 400 data yang digunakan. 200 untuk kelas Epilepsi dan 200 untuk 200 untuk kelas tidak Epilepsi. Terdapat dua jenis penggunaan data yang berbeda untuk masing-masing analisis:

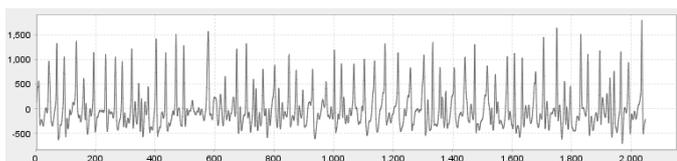
- Pertama, dua set data Z dan S sebagai kondisi yang mewakili kondisi tidak Epilepsi dan Epilepsi secara normal.
- Kedua, dua set data Z dan F sebagai kondisi yang mewakili kondisi tidak Epilepsi dan orang dengan riwayat Epilepsi.
- Ketiga, semua data yang tergolong kelas Epilepsi dan tidak Epilepsi digunakan (Z, O, F dan S). yaitu Z dan O untuk kelas tidak Epilepsi serta F dan S untuk kelas Epilepsi.

Untuk masing-masing set data setiap kelas dapat dilihat seperti Tabel I.

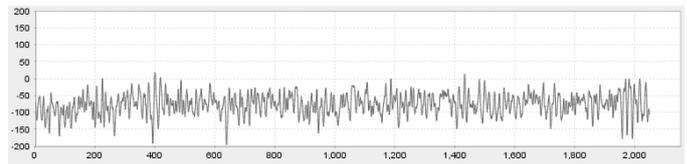
TABEL I. AKUISI DATA

Data	Kelas	Jumlah	
		Data latih	Data baru
Z - S	Tidak Epilepsi (Z)	50	50
	Epilepsi (S)	50	50
	total	100	100
Z - F	Tidak Epilepsi (Z)	50	50
	Epilepsi (F)	50	50
	total	100	100
ZO - FS	Tidak Epilepsi (Z,O)	100	100
	Epilepsi (F,S)	100	100
	total	200	200

Pada beberapa penelitian terdahulu telah menggunakan set data yang sama untuk melakukan analisis Epilepsi dan tidak Epilepsi. Terdapat perbedaan bentuk gelombang dari Epilepsi dan tidak Epilepsi yang diambil dari set data (S) untuk Epilepsi dan (Z) untuk Tidak Epilepsi. Seperti terlihat pada Gambar 1 dan Gambar 2.



Gambar 1. Gelombang Epilepsi (s)

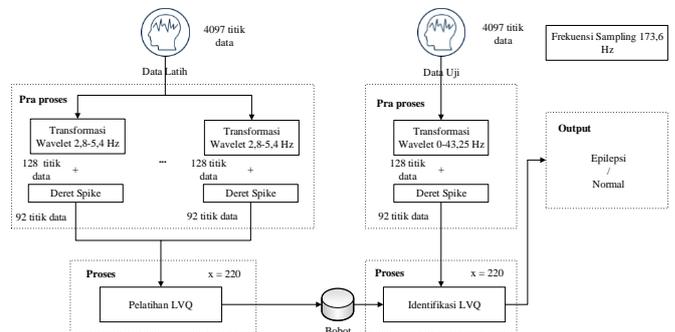


Gambar 2. Gelombang tidak Epilepsi (z)

Pada Gambar 1 dan Gambar 2 terlihat perbedaan antara sinyal tidak Epilepsi dan Epilepsi, sinyal tidak Epilepsi cenderung terlihat lebih stabil, sedangkan sinyal Epilepsi menunjukkan adanya loncatan amplitudo dan ketika frekuensi rendah akan terlihat lebih renggang.

B. Perancangan Sistem Identifikasi

Sistem identifikasi Epilepsi dengan tahap perolehan data. Kemudian dilanjutkan dengan tahap pengambilan nilai absolut rata-rata amplitudo setiap seperempat detik (deret spike) menghasilkan 92 titik data, selanjutnya sinyal diproses dengan menggunakan ekstraksi Wavelet untuk mendapatkan gelombang 2,8 - 5,4 Hz yang akan digunakan sebagai fitur masukan pada proses pembelajaran. Proses pembelajaran mesin menggunakan Learning Vector Quantization (LVQ). Perancangan sistem identifikasi Epilepsi seperti terlihat pada Gambar 3.



Gambar 3. Sistem Identifikasi Epilepsi dengan Wavelet dan Learning Vector Quantization

Pada Gambar 3 terlihat bahwa terdapat 4097 titik data masukan yang akan diolah dengan mengambil nilai rata-rata amplitudo setiap detik menjadi 92 titik, selanjutnya 4097 diekstraksi pada gelombang 2,8 - 5,4 Hz menjadi 128 titik data sehingga terdapat 220 titik yang akan digunakan sebagai data pelatihan dan identifikasi.

C. Transformasi Wavelet

Transformasi merupakan suatu proses perubahan data bentuk kedalam bentuk lain agar mudah dianalisis, transformasi Wavelet merupakan proses pengubahan sinyal kedalam berbagai Wavelet basis (*mother wavelet*) dengan berbagai fungsi pergeseran (translasi) dan penyekalaan. Secara garis besar transformasi Wavelet adalah dengan melewati sinyal yang akan dianalisis pada *filter* menggunakan frekuensi dan skala yang berbeda. Sebuah sinyal harus dilewatkan dalam dua filtrasi Wavelet yaitu *high-pass filter* dan *low-pass filter*. Transformasi Wavelet terhadap sinyal $x(n)$ ditunjukkan pada Persamaan 1.

$$\psi_{\sigma,\tau}(n) = \frac{1}{\sqrt{|\sigma|}} \psi\left(\frac{n-\tau}{\sigma}\right) \quad (1)$$

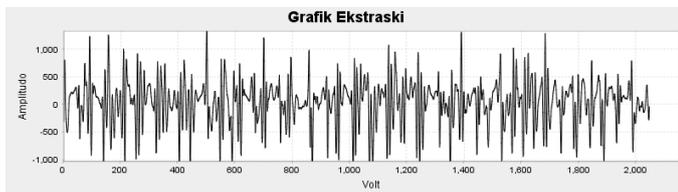
$\psi_{\sigma,\tau}(n)$ adalah fungsi basis Wavelet, dengan σ dan τ adalah faktor skala.

Dalam analisis Wavelet diskrit, digunakan untuk menguraikan sinyal ke dalam rincian yang semakin halus, seperti terlihat pada Persamaan 2 dan Persamaan 3 setelah sinyal difiltrasi maka bentuk sinyal akan berubah sesuai basis Wavelet seperti terlihat pada Gambar 4 dan Gambar 5.

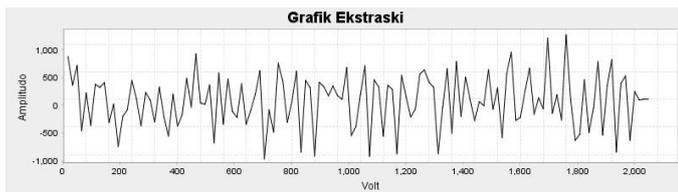
$$\text{Aproksimasi} = y_{high}[k] = \sum_n x[n].g[2k-n] \quad (2)$$

$$\text{Detil} = y_{low}[k] = \sum_n x[n].h[2k-n] \quad (3)$$

Dimana $y_{high}[k]$ dan $y_{low}[k]$ adalah hasil dari *high-pass filter* dan *low-pass filter*, $x[n]$ merupakan sinyal asal, $h[n]$ adalah *high-pass filter* dan $g[n]$ adalah *low-pass filter*.



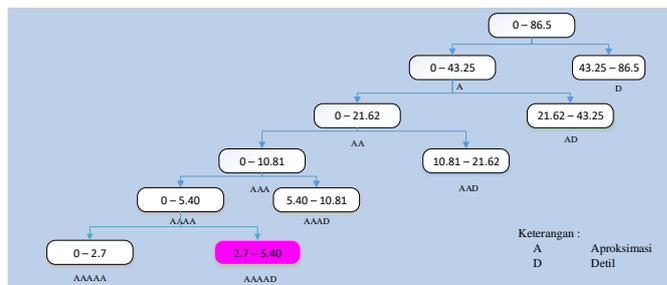
Gambar 4. Gelombang Epilepsi asli (s)



Gambar 5. Gelombang Epilepsi setelah transformasi Wavelet 2,8 – 5,4 Hz

Pada penelitian ini dilakukan transformasi wavelet dengan membagi dua 0 – 86,5 Hz menjadi 2,8 – 5,4 Hz selanjutnya 0 – 21,6 Hz dan seterusnya secara berulang sehingga menghasilkan gelombang 0,5 – 2,27 Hz, 2,8 – 5,4 Hz, 5,5 – 10,8 Hz, 10,9 – 21,6 Hz dan 21,7 – 43,2 Hz sesuai dengan potensi kemunculan penyakit secara umum. Namun untuk Epilepsi hanya menggunakan gelombang 2,8 – 5,4 Hz. Seperti terlihat pada Gambar 6.

Pada penelitian terdahulu transformasi Wavelet digunakan untuk identifikasi Disleksia menggunakan fungsi Symlets Wavelet order 5, 7, 8 dan 9 ditemukan bahwa Symlets order 5 dan 7 memberikan hasil yang paling konsisten [17]. Pada penelitian ini digunakan Symlet 5 untuk identifikasi gelombang Epilepsi. Symlet 5 (sym5) memiliki sepuluh koefisien *low-pass filter* (dinotasikan dengan g_n) dan sepuluh koefisien *high-pass filter* (dinotasikan dengan h_n). Untuk Symlet 5 dapat dilihat pada Tabel II.



Gambar 6. Transformasi Wavelet 2,8 – 5,4 Hz

TABEL II. KOEFISIEN SYMLET 5

Koefisien Low Pass Filter (g_n)	Koefisien High Pass Filter (h_n)
0.027333068345077982	-0.019538882735286728
...	...
0.019538882735286728	0.027333068345077982

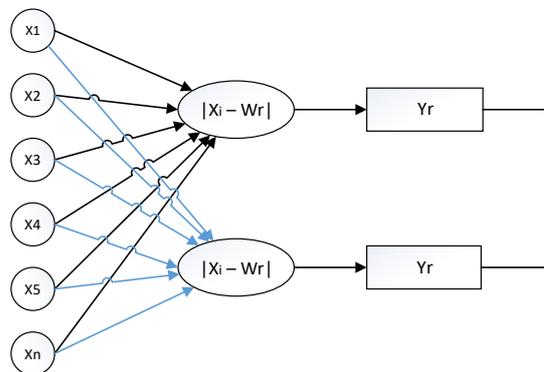
Pemilihan koefisien yang tepat dapat menentukan identifikasi karakteristik sinyal utama dari sinyal asli [15].

Dekomposisi gelombang 2,8 - 5,4 Hz pada konvolusi kesatu sampai ketiga menggunakan koefisien *low-pass filter*. Setelah itu pada konvolusi keempat menggunakan koefisien *high-pass filter* Symlet 5. Hasil ekstraksi Wavelet pada gelombang 2,8 - 5,4 Hz dari sinyal EEG selama 23,6 detik dan mereduksi jumlah data dari 4097 menjadi 128 data.

D. Learning Vector Quantization

Learning Vector Quantization (LVQ) merupakan sebuah metode klasifikasi yang dibangun dengan dua lapisan kompetitif yaitu vektor masukan dan vektor keluaran sebagai sebuah kelas. Kelas merupakan hasil perbandingan jarak dari vektor-vektor masukan.

Pada penelitian ini terdapat 220 *neuron input* (vektor masukan) yang didapat dari hasil pengambilan nilai rata-rata amplitudo setiap detik sebanyak 94 data ditambah hasil transformasi Wavelet pada gelombang 2,8 – 5,4 Hz sebanyak 128 data dan *neuron output* (vektor keluaran) sebanyak 2 yang mewakili kelas Epilepsi dan kelas tidak Epilepsi. Arsitektur LVQ untuk Identifikasi Epilepsi terlihat seperti Gambar 7.



Gambar 7. Arsitektur Learning Vector Quantization

Gambar 7 memperlihatkan bahwa yang bertindak sebagai *dendrit* atau data masukan adalah $X_1 - X_n$, yang bertindak sebagai bobot adalah $\|X-W\|$ yang menghubungkan lapisan

masuk ke lapisan keluaran, dan yang bertindak sebagai akson atau data keluaran adalah Y.

Proses pelatihan dilakukan dengan mencari nilai bobot yang akan digunakan sebagai perwakilan untuk masing - masing kelas. Pada tahap awal proses pelatihan adalah dengan menentukan jumlah iterasi (Epoch), nilai *learning rate* dan nilai error. Pada penelitian terdahulu ditetapkan nilai *learning rate* 0.1 dengan jumlah Epoch sebanyak 55. Pada penelitian ini dilakukan beberapa percobaan penentuan nilai *learning rate* dan nilai pengurangan *learning rate* untuk setiap iterasi untuk mendapatkan nilai akurasi maksimum. Pada percobaan pertama ditetapkan nilai *learning rate* 0.1 dengan pengurangan setiap iterasi 0.01, nilai error adalah 0.0001 dan maksimum Epoch 5000 serta bobot yang diambil secara acak untuk setiap kelas. Jarak antara bobot dengan data latih dapat dihitung dengan persamaan (4) selanjutnya dilakukan perbaikan bobot untuk setiap iterasi dengan persamaan (5).

$$d(i) = \sqrt{\sum_{m=1}^n (X_i - W_i)^2} \quad (4)$$

$$W_j(\text{baru}) = W_j(\text{lama}) \pm \alpha (x - W_j(\text{lama})) \quad (5)$$

Dimana d(i) merupakan jarak, x adalah data latih dan w adalah bobot.

III. HASIL DAN DISKUSI

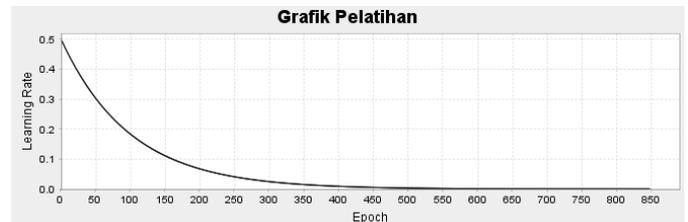
Pembelajaran sistem dilakukan dengan dua set data yang berbeda, data dikelompokkan menjadi dua yaitu data latih dan data baru. Jumlah masing - masing dibagi sesuai dengan kondisi pasien. Pertama menggunakan set data S untuk kelas Epilepsi dan set data Z untuk kelas tidak Epilepsi dengan 100 data latih dan 100 data baru serta. Selanjutnya untuk mengukur kemampuan sistem dalam melakukan identifikasi digunakan set data S dan F untuk kelas Epilepsi serta set data Z dan O untuk kelas tidak Epilepsi dengan 200 data latih dan 200 data baru.

Pembelajaran yang pertama dilakukan untuk mencari nilai *learning rate* paling optimal dengan nilai akurasi paling tinggi. Nilai *Learning rate* diuji dari 0,1 – 0,6 dengan pengurangan *learning rate* 0,01 – 0,03 dan error 0,0001. Analisis laju pembelajaran dapat dilihat pada Tabel III.

TABEL III. ANALISIS LAJU PEMBELAJARAN

No	Learning rate	Pengurangan Learning rate	Akurasi %	
			Data Latih	Data baru
1	0,5	0,01	100	95
2	0,4	0,01	100	96
3	0,3	0,01	99	94
4	0,2	0,01	100	96
5	0,1	0,01	99	94
6	0,4	0,02	100	93
7	0,4	0,03	100	90
8	0,4	0,04	100	91
9	0,4	0,05	99	94
10	0,4	0,001	100	89

Hasil analisis Tabel III menunjukkan bahwa akurasi tertinggi diperoleh pada *learning rate* 0.4 dan pengurangan *learning rate* 0,01, sehingga parameter yang digunakan untuk pembelajaran yaitu *learning rate* 0,4 dan pengurangan *learning rate* 0,01. Akurasi dihitung dari nilai kelas asal dengan label data. Nilai akurasi juga dipengaruhi dari pengambilan bobot awal dari random data latih sehingga setiap kali pembelajaran akan menghasilkan nilai akurasi yang berbeda - beda. Perubahan *learning rate* pada awal iterasi mengalami perubahan yang signifikan, namun pada akhir iterasi perubahan *learning rate* akan stabil seperti terlihat pada Gambar 8.



Gambar 8. Perubahan Learning rate

Pada Gambar 8 terlihat bahwa perubahan nilai *learning rate* pada semakin lama mengalami perubahan yang stabil. Selanjutnya pengujian adalah untuk menentukan pengaruh ekstraksi Wavelet dan rata-rata absolut amplitudo pada akurasi pembelajaran dan pengujian. Hasil pengujian terhadap ekstraksi dan spike dapat dilihat pada Tabel IV.

TABEL IV. PENGUJIAN TERHADAP EKSTRAKSI DAN SPIKE

No	Data	Jumlah	Skenario Percobaan	Akurasi %	
				Data Latih	Data Baru
1	S - Z	200	Ekstraksi	100	72
			Ekstraksi + Spike	100	94
			Tanpa Ekstraksi	100	67
2	Z - F	200	Ekstraksi	99	70
			Ekstraksi + Spike	99	75
			Tanpa Ekstraksi	100	75
3	ZO - FS	400	Ekstraksi	100	65
			Ekstraksi + Spike	87	75
			Tanpa Ekstraksi	80	73

Pada Tabel IV menunjukkan bahwa akurasi dipengaruhi oleh ekstraksi dan nilai rata-rata amplitudo (spike), karena data yang melalui ekstraksi akan mengalami perubahan data yang lebih sedikit serta data yang mewakili kelas masing-masing, sehingga pemilihan variabel fitur yang mewakili kelas akan mempengaruhi akurasi.

Selanjutnya pengujian dilakukan untuk menentukan pengaruh kondisi pasien untuk masing-masing kelas. Pengujian dapat dilihat pada Tabel V.

TABEL V. PENGUJIAN TERHADAP EKSTRAKSI DAN SPIKE

No	Kondisi Pasien/ Subyek	Jumlah	Kelas	Akurasi %
1	S - Z	200	Epilepsi	90
			Tidak Epilepsi	98
2	Z - F	200	Epilepsi	76
			Tidak Epilepsi	74
2	ZO - FS	400	Epilepsi	63
			Tidak Epilepsi	83

Tabel V menunjukkan hasil Pengujian terhadap kondisi pasien menunjukkan perbedaan yang signifikan, dikarenakan setiap kondisi dapat menjadi pembeda setiap kelas. Sehingga pada kondisi saat serangan (S) menjadi fitur terbaik untuk kelas Epilepsi, sedangkan kondisi orang normal saat mata terbuka (Z) menjadi fitur terbaik untuk kelas tidak Epilepsi.

Pengujian terakhir dilakukan untuk menentukan jumlah data latih dan data baru terhadap nilai akurasi. Pengujian dapat dilihat pada Tabel VI.

TABEL VI. PENGUJIAN TERHADAP JUMLAH DATA LATIH

No	Jumlah		Akurasi %
	Data Latih	Data Uji	
1	25	75	86
2	50	50	90
3	75	25	94

Pada Tabel VI menunjukkan bahwa jumlah data latih yang digunakan pada proses pelatihan berpengaruh pada pengujian. Semakin banyak data latih yang digunakan pada proses pelatihan maka akurasi semakin baik.

IV. KESIMPULAN

Penelitian ini telah menghasilkan sebuah sistem identifikasi Epilepsi terhadap sinyal Elektroensefalogram (EEG) menggunakan ekstraksi Wavelet dan pelatihan dan pengujian menggunakan Learning Vector Quantization (LVQ). Kondisi yang ditinjau adalah Epilepsi dan tidak Epilepsi. Set data yang digunakan dari University of Bonn atas 4 kondisi, yaitu orang normal mata terbuka (Z), orang normal mata tertutup (O), penderita Epilepsi saat serangan (S) dan penderita Epilepsi saat tidak terjadi serangan (F). Parameter optimal yang memberikan nilai akurasi paling tinggi yaitu nilai *learning rate* 0,4 dengan konstanta pengurang 0,01. Parameter tersebut digunakan pada proses pembelajaran dan pengujian. Penggunaan Wavelet memberikan akurasi yang berbeda, yaitu dengan adanya perubahan nilai akurasi untuk masing-masing set data untuk set data Z-S dari 67% menjadi 72%, set data Z-F dari 75% menjadi 70%, set data ZO-FS dari 73% menjadi 65,0%. Sedangkan dengan menambahkan nilai rata-rata amplitudo dan ekstraksi Wavelet menunjukan adanya peningkatan nilai akurasi yang lebih baik. Set data Z-S menghasilkan akurasi mencapai 94%, set data Z-F menghasilkan akurasi mencapai 75%, set data ZO-FS menghasilkan akurasi mencapai 75% dan pengujian data latih pada semua set data mencapai 100% jika dibandingkan dengan penelitian terdahulu oleh R. Panda dkk tentang klasifikasi Epilepsi dari sinyal EEG menggunakan Wavelet dan SVM terdapat peningkatan nilai akurasi yang semula 91,2% menjadi 94%. Sehingga pada penelitian ini menghasilkan nilai akurasi yang lebih baik dari penelitian sebelumnya tentang identifikasi Epilepsi dari sinyal EEG.

REFERENSI

[1] X. Bai, "Dynamic Time Course of Typical Childhood Absence Seizures: EEG, Behavior, and Functional Magnetic Resonance Imaging," *J. Neurosci.*, vol. 30, no. 17, pp. 5884–5893, 2010.
 [2] P. N. Banerjee, D. Filippi, and A. H. W., "The Descriptive Epidemiology of Epilepsy-A Review," *Epilepsy Res.*, vol. 85, no. 1, pp. 31–45, 2009.

[3] V. Joshi, R. B. Pachori, and A. Vijesh, "Classification of Ictal And Seizure-Free EEG Signals Using Fractional Linear Prediction," *Biomed. Signal Process Control*, vol. 9, no. 1, pp. 1–5, 2014.
 [4] K. A. Paschalis, Bizopoulos, G. Dimitrios, Tsalikakis, T. Alexandros, "EEG Epileptic Seizure Detection Using K-Means Clustering and Marginal Spectrum Based on Ensemble Empirical Mode Decomposition," November, 2013.
 [5] R. Sharma and R. B. Pachori, "Classification of Epileptic Seizures in EEG Signals Based on Phase Space Representation of Intrinsic Mode Functions," *Expert System.*, vol. 42, no. 3, pp. 1106–1117, 2015.
 [6] M. Z. Parvez and M. Paul, "Epileptic Seizure Detection By Analyzing EEG Signals Using Different Transformation Techniques," *Neurocomputing*, vol. 145, pp. 190–200, 2014.
 [7] J. Williamson, "Epileptic Seizure Prediction using The Spatiotemporal Correlation Structure of Intracranial EEG," *Acoust. Speech Signal Process.*, pp. 665–668, 2011.
 [8] M. J. Cook *et al.*, "Prediction of Seizure Likelihood With A Long-Term, Implanted Seizure Advisory System in Patients With Drug-Resistant Epilepsy: A First-In-Man Study," *Lancet Neurol.*, vol. 12, no. 6, pp. 563–571, 2013.
 [9] R. Panda *et al.*, "Classification of EEG Signal Using Wavelet Transform and Support Vector Machine For Epileptic Seizure Diction," *2010 Int. Conf. Syst. Med. Biol.*, no. December, pp. 405–408, 2010.
 [10] E. C. Djamal, P. Lodaya, and H. Lestari, "EEG Based Emotion Monitoring Using Wavelet and Learning Vector Quantization," *EECSI 2017 (Accepted)*, no. September, pp. 19–21, 2017.
 [11] S. H. Lee, J. S. Lim, J. K. Kim, J. Yang, and Y. Lee, "Classification of Normal and Epileptic Seizure EEG Signals Using Wavelet Transform, Phase-Space Reconstruction, and Euclidean Distance," *Computer Methods Programs Biomed.*, vol. 116, no. 1, pp. 10–25, 2014.
 [12] W. P. Ani and H. Hindarto, "Ekstraksi Ciri Sinyal EEG Untuk Gangguan Penyakit Epilepsi Menggunakan Metode Wavelet," *J. Ilmu Komput. dan Teknol. Inf.*, vol. 9, no. 2, pp. 62–65, 2017.
 [13] M. Murugappan, N. Ramachandran, and Y. Sazali, "Classification of Human Emotion From EEG Using Discrete Wavelet Transform," vol. 2010, no. April, pp. 390–396, 2010.
 [14] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, "Wavelet-Based EEG Processing For Computer-Aided Seizure Detection and Epilepsy Diagnosis," *Seizure*, vol. 26, pp. 56–64, 2015.
 [15] A. M. Kashtiban, I. Khameneh Branch, Islamic Azad Univ., Tabriz, and M. K. Razmi, H. ; Kozehkonan, "Combined L VQ Neural Network and Multivariate Statistical Method Employing Wavelet Coefficient for EEG Signal Classification," *2011 IEEE Int. Conf. Mechatronics (ICM)*, pp. 809–814, 2011.
 [16] G. J. J. de Vries, S. C. Pauws, and M. Biehl, "Insightful Stress Detection From Physiology Modalities Using Learning Vector Quantization," *Neurocomputing*, vol. 151, no. P2, pp. 873–882, 2015.
 [17] Z. Mahmoodin, "Selection of Symlets Wavelet Function Order for EEG Signal Feature Extraction in Children with Dyslexia," pp. 113–117, 2015.