

Denoising Sinyal EEG dengan Algoritma Recursive Least Square dan Least Mean Square

EEG Signal Denoising with Recursive Least Square and Least Mean Square Algorithms

Nor Kumalasari Caecar Pratiwi^{1*}, Rita Magdalena², Yunendah Nur Fuadah³, Sofia Saidah⁴,
Syamsul Rizal⁵, Muhamad Rokhmat Isnaini⁶
Fakultas Teknik Elektro, Telkom University
Jl. Telekomunikasi No.1 Bandung 40257, telp (022) 7566456
caecarnkcp@telkomuniversity.ac.id^{1*}, ritamagdalen@telkomuniversity.ac.id²,
yunendah@telkomuniversity.ac.id³, sofiasaidahsfi@telkomuniversity.ac.id⁴,
syamsul@telkomuniversity.ac.id⁵, isnaini.isnen@gmail.com⁶

Abstrak – EEG mengukur fluktuasi tegangan yang dihasilkan dari arus ionik yang beredar sepanjang neuron otak. Dalam pengaturan eksperimental, sinyal EEG sering terkontaminasi dengan berbagai noise akibat gerakan otot dan jantung. Noise dengan magnitudo yang lebih tinggi dari sinyal aslinya akan merusak sinyal EEG dan bisa berakibat fatal dalam analisis diagnosa. Sehingga diperlukan sebuah sistem denoising yang mampu secara maksimal mengurangi noise, tanpa menghilangkan komponen informasi penting dari sinyal EEG. Salah satu algoritma yang dapat digunakan dalam mereduksi noise pada sinyal biomedis adalah RLS dan LMS. Keuntungan utama dari penggunaan adaptif filtering termasuk RLS dan LMS adalah dapat digunakan pada lingkungan non-stasioner. Tujuan penelitian adalah melakukan uji perbandingan performansi filtering RLS dan LMS dalam mereduksi noise pada sinyal EEG. Parameter performansi yang diukur adalah waktu komputasi, MSE, SNR, dan PSNR. Dari hasil pengujian, diperoleh bahwa adaptif filtering dengan RLS dan LMS mampu mereduksi noise pada sinyal EEG dengan baik. Filter LMS memiliki kelebihan pada waktu komputasinya yang singkat, rata-rata waktu komputasi filter LMS selama 0.7 detik, jauh berbeda dengan filter RLS yang membutuhkan waktu sampai dengan 113 detik. Tetapi kehandalan sistem dari sisi MSE, SNR dan PSNR untuk filter LMS masih berada dibawah RLS untuk intensitas noise yang rendah. Besarnya parameter SNR dan PSNR pada filter RLS cenderung lebih stabil pada intensitas noise 10 dB, 20 dB, dan 30 dB. Hal berbeda terjadi pada denoising dengan menggunakan filter LMS, terjadi perubahan SNR yang signifikan dari 16.14 dB pada noise 10 dB, 21.09 dB untuk noise sebesar 20 dB, dan 25.81 dB untuk intensitas noise sebesar 30 dB.

Kata Kunci: Electroencephalography, Recursive Least Square, Least Mean Square, Mean Square Error, Signal to Noise Ratio, Peak Signal to Noise Ratio

Abstract – EEG measures the voltage fluctuations that result from ionic currents circulating along brain neurons. In experimental settings, EEG signals are often contaminated with various noise due to muscle and heart movements. Noise which has a magnitude higher than the original signal will damage the EEG

signal and could be fatal in diagnostic analysis. So we need a denoising system that is able to reduce noise optimally, without removing important information components from the EEG signal. One algorithm that can be used in reducing noise in biomedical signals is RLS and LMS. The main advantage of using this method is that it can be used in non-stationary environments. The purpose of this study is to conduct a comparison test of RLS and LMS filtering performance in reducing noise in EEG signals. The performance was measured using several parameters, such as computational time, MSE, SNR, and PSNR. The result show that adaptive filtering with RLS and LMS are able to reduce noise in EEG signals well. The performance using LMS filters has better performance on computation time, where the average computation time of LMS is 0.7 seconds and RLS is 113 seconds. Meanwhile, the reliability of the system in terms of MSE, SNR and PSNR for RLS is better than LMS. The magnitude of SNR and PSNR parameters in RLS filters tends to be more stable in noise intensity of 10 dB, 20 dB and 30 dB. Different with the LMS filter, there was a significant change in SNR of 16.14 dB at 10 dB noise, 21.09 dB for noise of 20 dB and 25.81 dB for noise intensity of 30 dB.

Keywords: *Electroencephalography, Recursive Least Square, Least Mean Square, Mean Square Error, Signal to Noise Ratio, Peak Signal to Noise Ratio*

1. Pendahuluan


Electroencephalography (EEG) adalah tes elektrofisiologis non-invasif yang memantau aktivitas listrik otak melalui beberapa elektroda yang diletakkan di kulit kepala. EEG mengukur fluktuasi tegangan yang dihasilkan dari arus ionik yang beredar sepanjang neuron otak [1]. Sinyal *Electroencephalogram* (EEG) telah digunakan secara luas dibanyak bidang, seperti ilmu saraf, penelitian psikofisiologis, neurolinguistik dan banyak lagi [2]. EEG telah dieksplorasi dalam studi klinis termasuk gangguan otak, gangguan tidur, epilepsi, dan disfungsi neurologis lainnya. Dalam pengaturan eksperimental, sinyal EEG yang direkam sering terkontaminasi dengan berbagai *noise*. *Noise* yang muncul pada perekaman sinyal EEG diantaranya akibat gerakan otot dan jantung. *Noise* dengan magnitudo yang lebih tinggi dari sinyal aslinya akan merusak sinyal EEG dan bisa berakibat fatal dalam analisis diagnosa. Dilatarbelakangi hal tersebut, diperlukan sebuah sistem *denoising* yang tepat, pemilihan *filter denoising* yang mampu secara maksimal mengurangi *noise* tanpa menghilangkan komponen informasi penting dari sinyal. Pengurangan *noise* pada citra digital adalah skema *pre-processing* yang penting untuk dilakukan, termasuk pada segmentasi gambar medis [3]. Salah satu algoritma yang dapat digunakan dalam mereduksi *noise* pada sinyal biomedis adalah *Recursive Least Square* (RLS) dan *Least Mean Square* (LMS). Keuntungan utama dari penggunaan adaptif *filtering* termasuk RLS dan LMS adalah dapat digunakan pada lingkungan non-stasioner, dikarenakan sistem secara terus-menerus mampu beradaptasi untuk perubahan statistik dalam data [4]. Tujuan dari penelitian ini adalah melakukan uji perbandingan performansi *filtering* RLS dan LMS dalam *denoising noise* pada sinyal EEG. Parameter performansi yang diukur adalah waktu komputasi, *Mean Square Error* (MSE), *Signal to Noise Ratio* (SNR) dan *Peak Signal to Noise Ratio* (PSNR).

Telah banyak penelitian terkait *denoising* untuk sinyal biomedis, termasuk sinyal EEG. Diantaranya adalah penelitian yang dilakukan oleh Xun Chen [5]. Dalam penelitiannya, Chen menggunakan kombinasi *Multivariate Empirical Mode Decomposition* (MEMD) dan *Canonical Correlation Analysis* (CCA). Hasil eksperimen menunjukkan bahwa metode yang diusulkan mampu untuk mereduksi *noise* yang diakibatkan oleh pergerakan otot dalam beberapa saluran kanal EEG. Studi lain dilakukan oleh Edson Estrada [6], dalam mengeksplorasi penerapan metode *denoising* sinyal EEG dengan metode *wavelet*. Hasil menunjukkan bahwa kombinasi *soft thresholding* pada *detailed wavelet* koefisien memberikan kinerja yang lebih baik dengan MSE yang lebih kecil dan SNR yang lebih besar. Pranjali Gajbhiye [7] dalam penelitiannya yang berjudul “*Novel Approaches for the Removal of Motion Artifact from EEG Recordings*”, memberikan hasil bahwa metode *filtering Multiresolution Total Variation* (MTV) and *Multiresolution Weighted Total Variation* (MWTV) memiliki kinerja *denoising* yang lebih baik. Performansi sitem ditunjukkan dengan SNR rata-rata sebesar 29,12 dB (MTV) dan 29,29 dB (MWTV) dengan koefisien korelasi sebesar 68,56%, dan 67,51%. Penelitian dengan judul

“Biomedical Signals Analysis by DWT Signal Denoising with Neural Networks” [8] menganalisa secara mendalam proses *denoising* dan *compressing* pada sinyal EEG, ECG dan EMG dengan transformasi *wavelet* diskrit. Performansi sistem diuji untuk berbagai *mother wavelet*, seperti *haar*, *daubiches*, *symlet*, dan *bior*. Sepideh Hajipour Sardouie [9] dalam penelitiannya menyimpulkan bahwa *Time-Frequency-Generalized Eigen Value Decomposition* (TF-GEVD) dan *Time-Frequency-Denoising Source Separation* (TF-DSS) memiliki kehandalan yang lebih tinggi jika dibandingkan dengan *Canonical Correlation Analysis* (CCA) dan *Independent Component Analysis* (ICA) dalam proses menghilangkan *noise* akibat pergerakan otot pada sinyal EEG. Penelitian terkait reduksi *noise* pada sinyal EEG juga dilakukan oleh Kafiul Islam [10]. Dalam tulisannya, disajikan metode yang mampu memetakan probabilitas *noise* pada sinyal EEG berdasarkan ciri statistik entropi, kurtosis, *skewness*, dan *Periodic Waveform Index* (PWI). Hasil eksperimental membuktikan kehandalan metode yang dapat mengurangi *noise* sinyal EEG dengan sedikit distorsi pada sinyal aslinya. Harender dalam tulisannya yang berjudul “*EEG Signal Denoising based on Wavelet Transform*” menyajikan metode *denoising* berdasarkan kombinasi *Stationary Wavelet Transform* (SWT), *universal threshold*, *statistical threshold* dan *Discrete Wavelet Transform* (DWT). Hasilnya menunjukkan peningkatan kinerja yang signifikan pada parameter *Signal to Artifacts Ratio* (SAR), *Correlation Coefficient* (CC) dan *Normalized Mean Squared error* (NMSE) [11].

2. Metode Penelitian

Algoritma *Recursive Least-Squares* (RLS) dan *Least Mean Square* (LMS) termasuk dalam metode adaptif *filtering*. Proses menghilangkan *noise* dari sinyal asli dengan menggunakan adaptif *filtering* ditunjukkan oleh Gambar 1 dibawah ini.



Gambar 1. *Denoising* dengan Adaptif *Filtering* [12]

Algoritma RLS menawarkan tingkat konvergensi yang lebih baik pada sinyal *input* dengan korelasi yang tinggi, namun demikian, kompleksitas komputasi juga akan tinggi [13]. Dalam algoritma RLS, bobot *filter* diperbarui menggunakan persamaan (1) - (3) [14]:

$$w(n) = \overline{w}^T(n-1) + k(n)\overline{e}_{n-1}(n) \quad (1)$$

$$k(n) = \frac{u(n)}{(\lambda + X^T(n)u(n))} \quad (2)$$


$$u(n) = \overline{w}_\lambda^{-1}(n-1)X(n) \quad (3)$$

Persamaan (2) dan (3) digunakan untuk mencari *gain vector filter*, dimana λ adalah nilai positif konstan yang kurang dari 1, sangat mendekati 1. Sinyal keluaran *filter* $y(n)$ dihitung dengan persamaan (4) dan (5) [14]:

$$\overline{y_{n-1}}(n) = \overline{w^T}(n-1) + X(n) \quad (4)$$


$$\overline{e_{n-1}}(n) = d(n) - \overline{y_{n-1}}(n) \quad (5)$$

Dimana $X(n)$ adalah masukan sistem, $d(n)$ sinyal yang diinginkan, dan $e(n)$ adalah *error* pada *output*. Konfigurasi adaptif *filtering* ditunjukkan oleh Gambar 2 [14].



Gambar 2. Konfigurasi adaptif *filtering*.

Diagram blok *denoising* dengan algoritma LMS ditunjukkan pada Gambar 3 [15].



Gambar 3. *Denoising* dengan Algoritma *Least Mean Square* (LMS).

Algoritma LMS dibuat oleh Widrow dan Hoff pada tahun 1960 untuk digunakan dalam pelatihan *neural network*. Algoritma LMS menggunakan perkiraan *gradient* dalam mencari vektor bobot w_n yang diinginkan. Sinyal masukan adalah penggabungan antara sinyal yang diinginkan $d(n)$ dan sinyal *noise* $v(n)$, sebagaimana ditunjukkan oleh persamaan (6) [15]

$$u(n) = d(n) + v(n). \quad (6)$$

Variabel *filter* memiliki respon *impuls* terbatas (*finite impulse response* – FIR). Koefisien *filter* dengan *orde filter* p didefinisikan dengan persamaan (7)

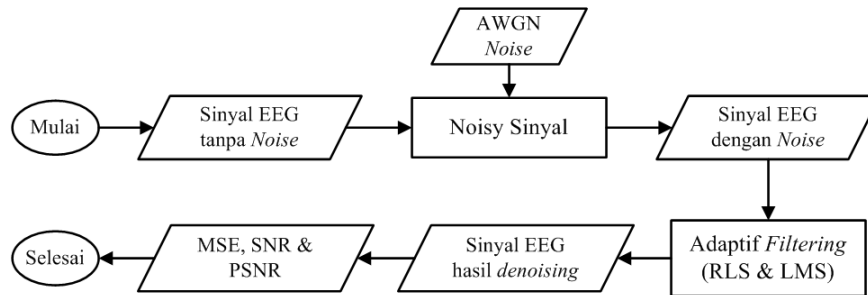
$$W_n = [w_n(0), w_n(1), \dots, w_n(p)]^T. \quad (7)$$

Sinyal *error* $e(n)$ adalah selisih antara sinyal yang sebenarnya dan sinyal hasil estimasi, dinyatakan dengan persamaan (8)

$$e(n) = d(n) - \hat{d}(n). \quad (8)$$

Sinyal estimasi $\hat{d}(n)$ merupakan hasil konvolusi antara koefisien *filter* W_n dan respon *impuls* $u(n)$.

Data yang akan digunakan dalam penelitian ini adalah sinyal otak bersih atau *cleaned EEG signal* yang diambil dari bank sinyal *PhysioNet* [15]. Sinyal *noise* yang digunakan pada penelitian ini merupakan sinyal AWGN (*Additive White Gaussian Noise*) dengan variasi intensitas sebesar 10 dB, 20 dB, dan 30 dB. Alur penelitian diilustrasikan pada Gambar 4.




Gambar 4. Alur metode penelitian *denoising* sinyal EEG dengan Algoritma RLS dan LMS.

Penelitian dimulai dengan mempersiapkan lima sinyal EEG *original* yang akan digunakan sebagai objek penelitian. Lima sinyal tersebut berasal dari lima pasien, dengan kondisi kesehatan yang sama. Data sinyal *original* yang akan digunakan adalah data sinyal otak bersih yang diambil dari bank signal Physionet. Tahap selanjutnya adalah menambahkan *noise* kedalam sinyal *original*. Sinyal yang ditelah ditambahkan *noise*, akan dilakukan analisis proses *denoising* dengan menggunakan algoritma *adaptive filter*. Selanjutnya, sinyal *denoising* akan direkonstruksi. Kinerja metode *adaptive filtering* akan dianalisis melalui parameter – parameter MSE, SNR dan PSNR.

3. Hasil dan Pembahasan

Skenario pengujian terhadap sistem *denoising* sinyal EEG menggunakan metode *adaptive filtering* algoritma RLS dan LMS. Data sinyal EEG yang akan diuji berjumlah 5, diambil dari lima pasien berbeda, dengan kondisi kesehatan yang sama (eegsignal1, eegsignal2, eegsignal3, eegsignal 4 dan eegsignal 5). Setiap sinyal di-*sampling* dengan frekuensi sebesar 2048 Hz, dan *sampling interval* 0.00048 mV. Kemudian *noise* yang akan digunakan adalah *Additive White Gaussian Noise* dengan variasi intensitas SNR yang akan diuji sebesar 10 dB, 20 dB dan 30 dB. Proses *denoising* sinyal EEG dengan intensitas *noise* sebesar 30 dB ditunjukkan pada Gambar 5.



Gambar 5. Proses *denoising* sinyal EEG dengan intensitas *noise* sebesar 30 dB.

Setelah melakukan pengujian pada 5 sinyal *input* EEG dengan LMS dan RLS, masing-masing sinyal di uji coba sebanyak 3 kali percobaan, dan diperoleh nilai rata-rata untuk parameter waktu komputasi, MSE, SNR dan PSNR sebagaimana dimuat pada Tabel 1.

Tabel 1. Kinerja sistem *denoising* dengan intensitas *noise* sebesar 10 dB.

Sinyal	Pengujian Ke-	Waktu Komputasi (Detik)		MSE		SNR (dB)		PSNR (dB)	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Eegsignal1	1	0.7017	122.16	0.0067	0.0002	16.40	24.19	16.94	24.73
	2	0.7071	115.98	0.0083	0.0001	15.93	25.57	16.47	26.11
	3	0.7098	113.70	0.0076	0.0027	16.14	18.35	16.68	18.89
Eegsignal2	1	0.6994	111.22	0.0103	0.0022	16.54	19.89	17.29	20.64
	2	0.6962	111.16	0.0098	0.0004	16.65	38.51	17.40	39.26
	3	0.6918	112.50	0.0133	0.0001	15.99	25.77	16.74	26.52
Eegsignal3	1	0.7155	113.86	0.0111	0.0016	16.43	20.69	17.03	21.29
	2	0.7303	113.80	0.0120	0.0005	16.27	23.02	16.87	23.62
	3	0.7043	113.67	0.0130	0.0000	16.08	35.62	16.68	36.22
Eegsignal4	1	0.7149	111.71	0.0067	0.0001	15.84	25.82	16.52	26.50
	2	0.7040	113.65	0.0060	0.0007	16.09	20.69	16.76	21.37
	3	0.6882	113.04	0.0074	0.0002	15.64	23.88	16.32	24.55
Eegsignal5	1	0.7025	113.09	0.0064	0.0005	15.97	21.35	16.73	22.12
	2	0.7101	114.26	0.0054	0.0002	16.34	23.07	17.10	23.84
	3	0.7093	114.46	0.0069	0.0000	15.80	27.29	16.57	28.06
Rata-rata		0.7057	113.88	0.0087	0.0006	16.14	24.91	16.81	25.58

Dari Tabel 1 diatas, terlihat bahwa rata-rata waktu komputasi *filter* RLS jauh lebih besar dibandingkan dengan LMS. Jika LMS rata-rata mampu menyelesaikan proses *denoising* selama 0.7 detik, jauh berbeda dengan *filter* RLS yang membutuhkan waktu sampai dengan 113 detik. Tetapi, waktu komputasi yang lama pada RLS dibayar dengan performansi yang cukup handal, terlihat dari parameter MSE, SNR dan PSNR yang lebih unggul dibandingkan dengan algoritma LMS seperti ditunjukkan pada Tabel 2.

Tabel 2. Kinerja sistem *denoising* dengan intensitas *noise* sebesar 20 dB.

Sinyal	Pengujian Ke-	Waktu Komputasi (Detik)		MSE		SNR (dB)		PSNR (dB)	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Eegsignal1	1	0.7244	113.57	0.0006	0.0007	21.49	21.25	22.03	21.79
	2	0.7034	113.41	0.0008	0.0007	21.14	21.31	21.68	21.85
	3	0.7211	112.80	0.0007	0.0001	21.38	26.10	21.92	26.64
Eegsignal2	1	0.6928	111.66	0.0013	0.0001	21.02	27.66	21.77	28.41
	2	0.6899	110.91	0.0010	0.0001	21.58	25.88	22.33	26.63
	3	0.7028	110.86	0.0013	0.0004	20.98	23.65	21.73	24.40
Eegsignal3	1	0.7112	119.71	0.0017	0.0006	20.53	22.66	21.13	23.26
	2	0.7034	113.43	0.0014	0.0001	20.93	27.95	21.53	28.56
	3	0.7112	117.64	0.0013	0.0034	21.08	19.02	21.68	19.62
Eegsignal4	1	0.7002	110.83	0.0006	0.0013	21.08	19.49	21.76	20.16
	2	0.6924	112.41	0.0009	0.0004	20.24	22.26	20.91	22.93
	3	0.6961	112.24	0.0005	0.0000	21.55	29.80	22.22	30.47
Eegsignal5	1	0.7088	114.26	0.0008	0.0000	20.54	26.79	21.30	27.55
	2	0.7038	113.69	0.0003	0.0003	22.76	22.44	23.53	23.21
	3	0.7057	114.83	0.0010	0.0001	19.98	24.69	20.75	25.46
Rata-rata		0.7045	113.48	0.0009	0.0005	21.09	24.06	21.75	24.73

Hal yang sama juga terjadi pada saat sinyal EEG diberikan intensitas *noise* sebesar 20 dB. Dari Tabel 2 terlihat bahwa rata-rata waktu komputasi *filter* RLS sebesar 113.48 detik, masih jauh lebih besar dibandingkan dengan *filter* LMS, yang hanya membutuhkan waktu rata-rata selama 0.7 detik. Tetapi, waktu komputasi yang lama pada RLS dibayar dengan performansi yang cukup handal, terlihat dari parameter SNR sebesar 24.06 dB dan PSNR sebesar 24.73 dB, lebih unggul dibandingkan dengan algoritma LMS, yang memiliki SNR dan PSNR berturut-turut sebesar 21.09 dB dan 21.75 dB sebagaimana ditunjukkan pada Tabel 3.

Tabel 3. Kinerja sistem *denoising* dengan intensitas *noise* sebesar 30 dB

Sinyal	Pengujian Ke-	Waktu Komputasi (Detik)		MSE		SNR (dB)		PSNR (dB)	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Eegsignal1	1	0.7317	113.92	0.00001	0.00189	31.36	19.15	31.90	19.69
	2	0.71	115.48	0.00004	0.00002	27.83	28.77	28.37	29.31
	3	0.7083	114.21	0.00013	0.00065	25.03	21.48	25.57	22.02
Eegsignal2	1	0.7038	111.24	0.00045	0.00209	23.34	20.00	24.09	20.75
	2	0.695	110.60	0.00151	0.00009	20.71	26.93	21.46	27.67
	3	0.69	112.91	0.00009	0.00003	26.77	29.38	27.52	30.13
Eegsignal3	1	0.7061	113.42	0.00148	0.00008	20.80	27.21	21.41	27.82
	2	0.7047	112.94	0.00019	0.00001	25.31	32.41	25.91	33.02
	3	0.6981	113.92	0.00031	0.00048	24.21	23.25	24.82	23.85
Eegsignal4	1	0.7134	111.20	0.00010	0.00032	24.94	22.43	25.62	23.10
	2	0.697	110.90	0.00000	0.00014	31.87	24.25	32.54	24.92
	3	0.6974	112.33	0.00003	0.00051	27.59	24.69	28.27	25.45
Eegsignal5	1	0.7052	112.48	0.00016	0.00012	24.03	30.61	24.79	22.14
	2	0.8784	112.58	0.00003	0.00001	27.91	21.46	28.67	31.38
	3	0.7134	116.79	0.00008	0.00027	25.47	22.87	26.23	23.63
Rata-rata		0.7168	113.00	0.00031	0.00045	25.81	24.99	26.48	25.66

Pada saat sinyal diberikan intensitas *noise* sebesar 30 dB, masih terlihat bahwa *filter* LMS memiliki waktu komputasi yang jauh lebih singkat dibandingkan *filter* RLS. Berbeda dengan hasil yang ditunjukkan pada Tabel 1 dan Tabel 2, pada saat sinyal diberikan intensitas *noise* 30 dB, kinerja LMS bisa dikatakan lebih baik jika ditinjau dari parameter MSE yang lebih kecil, dan SNR serta PSNR yang lebih baik dibandingkan RLS.

Dari tiga skenario diatas, secara keseluruhan terlihat bahwa *filter* LMS memiliki kelebihan pada waktu komputasi yang lebih singkat, dengan rata-rata berada pada 0.7 detik, tetapi kehandalan sistem dari sisi parameter MSE, SNR dan PSNR masih berada dibawah RLS untuk intensitas *noise* yang rendah. Besarnya parameter SNR dan PSNR pada *filter* RLS cenderung lebih stabil, berada pada kisaran 24.06 dB sampai dengan 24.99 dB untuk parameter SNR, dan 24.73 dB sampai dengan 25.66 dB untuk parameter PSNR. Hal berbeda terjadi pada *denoising* dengan menggunakan *filter* LMS, terjadi perubahan SNR yang signifikan dari 16.14 dB pada *noise* 10 dB, 21.09 dB untuk *noise* sebesar 20 dB dan 25.81 dB untuk intensitas *noise* sebesar 30 dB.

4. Kesimpulan

Dari data hasil pengujian, dapat disimpulkan bahwa adaptif *filtering* dengan algoritma *Recursive Least Square* (RLS) dan *Least Mean Square* (LMS) mampu mereduksi *noise* (*denoising*) pada sinyal EEG dengan baik. *Filter* LMS memiliki kelebihan pada waktu komputasinya yang singkat, tetapi kehandalan sistem dari sisi parameter MSE, SNR dan PSNR masih berada dibawah RLS untuk intensitas *noise* yang rendah. Besarnya parameter SNR dan PSNR pada *filter* RLS cenderung lebih stabil (tidak mengalami perubahan signifikan) pada intensitas *noise* 10 dB, 20 dB dan 30 db. Hal berbeda terjadi pada *denoising* dengan menggunakan *filter* LMS, terjadi perubahan yang signifikan (menjadi lebih baik) pada besarnya parameter SNR dan PSNR untuk intensitas *noise* yang semakin tinggi. Mempertimbangkan dari segi waktu komputasi yang lebih cepat, besarnya MSE, SNR dan PSNR yang lebih baik, maka dapat disimpulkan bahwa *filter* LMS memiliki performansi yang lebih unggul dibandingkan dengan RLS, terutama pada intensitas *noise* yang semakin besar.

Referensi

- [1] S. Islam, A. M. El-hajj, H. Alawieh, Z. Dawy, N. Abbas, and J. El-imad, "Biomedical Signal Processing and Control EEG mobility artifact removal for ambulatory epileptic seizure prediction applications," *Biomed. Signal Process. Control*, vol. 55, p. 101638, 2020.

- [2] N. Bajaj, J. Requena, F. Bellotti, R. Berta, and A. De Gloria, "Biomedical Signal Processing and Control Automatic and tunable algorithm for EEG artifact removal using wavelet decomposition with applications in predictive modeling during auditory tasks," *Biomed. Signal Process. Control*, vol. 55, p. 101624, 2020.
- [3] C. J. Jeba and G. Suganthi, "Biomedical Signal Processing and Control An efficient denoising of impulse noise from MRI using adaptive switching modified decision based unsymmetric trimmed median filter," *Biomed. Signal Process. Control*, vol. 55, p. 101657, 2020.
- [4] N. K. Muhsin, "Noise Removal of ECG Signal Using Recursive Least Square Algorithms," *Al-Khwarizmi Eng. J.*, vol. 7, no. 1, pp. 13–21, 2011.
- [5] X. Chen, X. Xu, A. Liu, M. J. McKeown, and Z. J. Wang, "The Use of Multivariate EMD and CCA for Denoising Muscle Artifacts from Few Channel EEG Recordings," *IEEE Trans. Instrumentation Meas.*, vol. 67, no. 2, pp. 359–370, 2018.
- [6] E. Estrada, H. Nazeran, G. Sierra, F. Ebrahimi, and S. K. Setarehdan, "Wavelet-based EEG Denoising for Automatic Sleep Stage Classification," in *21st International Conference on Electrical Communications and Computers*, 2011, pp. 295–298.
- [7] P. Gajbhiye, R. K. Tripathy, A. Bhattacharyya, and R. B. Pachori, "Novel Approaches for the Removal of Motion Artifact from EEG Recordings," *IEEE Sens. J.*, vol. 1748, pp. 1–10, 2019.
- [8] G. Kaushik, H. P. Sinha, and L. Dewan, "Biomedical Signals Analysis by DWT Signal Denoising With Neural Networks," *J. Theor. Appl. Inf. Technol.*, vol. 62, no. 1, pp. 184–198, 2014.
- [9] S. H. Sardouie, M. B. Shamsollahi, L. Albera, and I. Merlet, "Denoising of ictal EEG data using semi-blind source separation methods based on time-frequency priors," *IEEE J. Biomed. Heal. Informatics*, vol. 2194, no. c, pp. 1–9, 2014.
- [10] K. Islam and A. Rastegarnia, "Probability Mapping Based Artifact Detection and Wavelet Denoising based Artifact Removal from Scalp EEG for BCI Applications," in *2019 IEEE 4th International Conference on Computer and Communication Systems (ICCCS)*, 2019, pp. 243–247.
- [11] Harender and R. K. Sharma, "EEG Signal Denoising based on Wavelet Transform," in *International Conference on Electronics, Communication and Aerospace Technology ICECA 2017 EEG*, 2017, pp. 758–761.
- [12] A. C. M. F. S. R. M. U. Ahmed, "A study of recursive least squares (RLS) adaptive filter algorithm in noise removal from ECG signals," in *2015 International Conference on Informatics, Electronics & Vision (ICIEV)*, 2015, pp. 1–6.
- [13] V. Roy and S. Shukla, "Mth Order FIR Filtering for EEG denoising using Adaptive recursive Least Squares Squares Algorithm," in *2015 International Conference on Computational Intelligence and Communication Networks*, 2015, pp. 1–4.
- [14] J. Dhiman, S. Ahmad, and K. Gulia, "Comparison between Adaptive filter Algorithms (LMS , NLMS and RLS)," in *International Journal of Science, Engineering and Technology Research (IJSETR)*, 2013, vol. 2, no. 5, pp. 1100–1103.
- [15] S. Arunkumar, P. Parthiban, and S. A. Kumar, "Implementation of Least Mean Square Algorithm For Sinusoidal and Audio Denoising Using FPGA," *Int. J. Adv. Res. Electr. Electron. Instrum. Eng.*, vol. 2, no. 12, pp. 5843–5850, 2013.
- [16] F. Ali, P. Rawat, and S. Malvia, "Comparative Analysis and Survey of LMS and RLS Adaptive Algorithms," *Int. J. Comput. Appl.*, vol. 161, no. 3, pp. 26–29, 2017.