

Pembersihan Artefak EOG dari Sinyal EEG menggunakan *Denoising Autoencoder*

HASBIAN FAUZY PERDHANA, HASBALLAH ZAKARIA

Institut Teknologi Bandung, Indonesia
Email: dhasbian@students.itb.ac.id

Received 24 Februari 2022 | *Revised* 19 Maret 2022 | *Accepted* 18 April 2022

ABSTRAK

Elektroensefalografi (EEG) adalah teknik perekaman yang merekam aktivitas elektrik pada otak menggunakan elektroda yang ditempelkan pada kulit kepala. Artefak elektrookulografi (EOG) adalah salah satu artefak yang kerap muncul pada perekaman EEG dikarenakan pergerakan mata dan menyebabkan sinyal EEG berubah bentuk. Untuk membersihkan EEG, artefak perlu dibuang dengan tetap menjaga informasi penting dari EEG. Pada penelitian ini kami mendeteksi artefak EOG menggunakan Independent Component Analysis (ICA) dan deteksi puncak, dan untuk rekonstruksi sinyal EEG kami menggunakan Denoising Autoencoder (DAE). Pada penelitian ini kami meneliti model DAE apakah dapat merekonstruksi sinyal EEG dari artefak EOG. Metode pendeteksian artefak mendapatkan 85% sensitivitas dan 83% Positive Predictive Value (PPV) pada dataset sekunder dan 82% sensitivitas pada dataset primer. Model DAE dilatih dengan validasi silang 10 lipat dan mendapatkan rerata mean squared error (MSE) $0,007 \pm 0,008$. Penelitian ini membuktikan kemampuan DAE untuk merekonstruksi sinyal EEG dengan masukan segmen sinyal EEG terkontaminasi artefak EOG.

Kata kunci: EEG, Artefak EOG, Denoising Autoencoder

ABSTRACT

The Electroencephalography (EEG) is a recording technique to record electrical activity on the brain using electrodes attached to the head scalp. Electrooculography (EOG) is one of the artifacts that are prone to appear on EEG due to eye movement and cause EEG signals to deform. To fix the EEG signal, we need to remove artifacts while conserving EEG information. In this research, we detect EOG artifactual signal using Independent Component Analysis (ICA) and peak detection and used a generative model Denoising Autoencoder (DAE) to reconstruct clean EEG by using EEG artifact-corrupted signal. Our artifact detection method scores 85% sensitivity and 83% Positive Predictive Value on the secondary dataset and 82% sensitivity on the primary dataset. We train the DAE model with 10-fold cross-validation and got 0.007 ± 0.008 Mean Squared Error (MSE). We demonstrated DAE on its ability to generate a clean EEG segment by feeding it contaminated EEG segment.

Keywords: EEG, Eye movement artifact, Denoising Autoencoder

1. PENDAHULUAN

Elektroensefalografi (EEG) merupakan teknik perekaman elektrofisiologi non-invasif yang merekam aktivitas elektrik pada otak dengan menempelkan elektroda pada permukaan kepala. EEG digunakan untuk keperluan klinis, eksperimen laboratorium, dan pemantauan Kesehatan pasien **(Jiang, dkk, 2019)**. Meskipun perekaman EEG intensinya untuk merekam aktivitas elektrik dari otak, terkadang aktivitas elektrik dari organ lain seperti mata ikut terekam dalam perekaman EEG. Aktivitas elektrik dari gerakan mata yang ikut terekam dalam perekaman EEG disebut artefak **(Islam, dkk, 2016)**. Teknik pembuangan artefak awalnya dilakukan secara manual oleh ahli. Sinyal referensi EOG digunakan untuk dijadikan pembanding dengan sinyal EEG. Namun teknik ini dilakukan secara kualitatif dan sangat bergantung pada kemampuan individu yang berbeda-beda setiap orangnya. Karena itu pengembangan teknik untuk pembersihan artefak dengan cara otomatis mulai berkembang.

Secara umum teknik pembersihan sinyal EEG dari artefak EOG terbagi menjadi dua tahapan, tahapan pertama adalah pendeteksian artefak, tahapan kedua adalah koreksi sinyal EEG. Metode yang umum digunakan untuk mendeteksi artefak salah satunya adalah dengan pendekatan dekomposisi seperti *Independent Component Analysis* (ICA) **(Issa & Juhasz, 2019)** **(Winkler, dkk, 2015)**, *Variational Mode Decomposition* (VMD) **(Saini, dkk, 2020)**. Metode dekomposisi mengurai sinyal menjadi beberapa jumlah sinyal yang menyusun sinyal awal, sinyal-sinyal atau komponen yang diurai kemudian dievaluasi dan dipilih mana yang merupakan artefak dan mana yang bukan. Metode deteksi artefak lainnya seperti deteksi pencilan **(Saba-Sadiya, dkk, 2021)** juga dikembangkan dan menghasilkan hasil yang cukup signifikan.

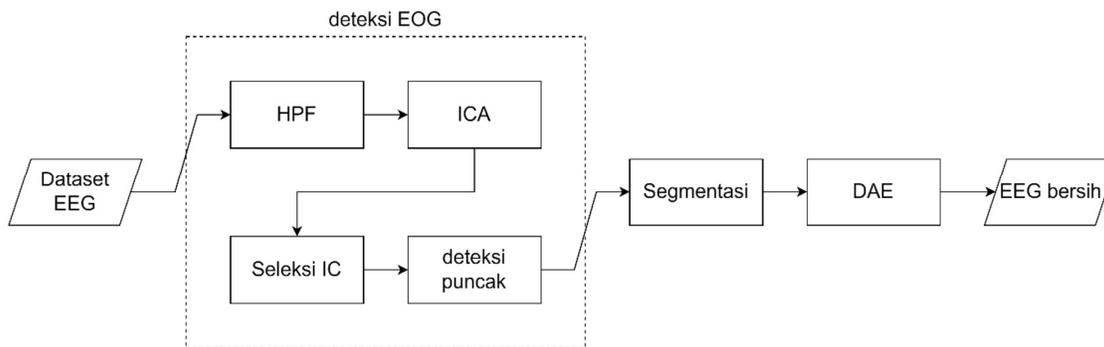
Metode koreksi sinyal EEG juga beragam, namun umumnya jika teknik deteksinya menggunakan pendekatan dekomposisi, teknik koreksinya menggunakan pendekatan rekonstruksi, inversi dari proses dekomposisi. Setelah komponen artefak dipilih dan dibuang, sisa komponen-komponen independen lainnya direkonstruksi menjadi sinyal EEG **(Issa & Juhasz, 2019)** **(Saini, dkk, 2020)**. Walaupun begitu, teknik rekonstruksi tidak terikat pada teknik dekomposisi artefaknya, **(Issa & Juhasz, 2019)** melakukan hibrida teknik inversi ICA dan rekonstruksi *wavelet*. Sedangkan **(Saba-Sadiya, dkk, 2021)** menggunakan *Autoencoder* (AE) **(Bank, dkk, 2020)** untuk merekonstruksi sinyal EEG.

AE merupakan salah satu model generatif, disebut generatif karena model dapat menghasilkan data berupa sinyal **(Fotiadou & Vullings, 2020)** ataupun gambar **(Lee, dkk, 2018)**. Generatif model digunakan untuk beberapa tujuan salah satunya untuk meningkatkan atau menurunkan resolusi sinyal **(Hartmann, dkk, 2018)** **(Luo, dkk, 2020)**, augmentasi data **(Hwang, dkk, 2019)** **(Jiao, dkk, 2020)**, dan tujuan lainnya **(Hu, dkk, 2015)** **(Nejedly, dkk, 2019)**. Turunan AE dengan peruntukan membersihkan derau disebut *Denoising AE* (DAE), DAE telah terbukti berhasil membersihkan derau dari data EKG **(Fotiadou & Vullings, 2020)** dan membersihkan foto dari hujan **(Lee, dkk, 2018)**. Pada penelitian ini kami menggunakan DAE untuk merekonstruksi sinyal EEG yang terkontaminasi artefak EOG.

Pada penelitian ini kami mengadopsi metode **(Issa & Juhasz, 2019)** dalam pendeteksian EOG dengan sedikit modifikasi. Kami menggunakan ICA untuk mengekstraksi komponen artefak EOG dan mendeteksi setiap artefak di dalam sinyal dengan deteksi puncak. Setelah puncak terdeteksi, sinyal disegmentasi di sekitar puncak dan direkonstruksi menggunakan DAE.

2. METODE

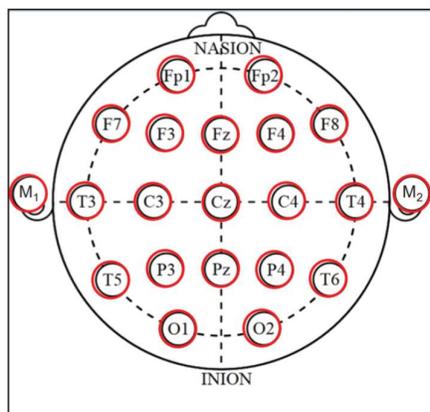
Alur pembersihan artefak dari *dataset* terkontaminasi hingga dibersihkan dapat dilihat pada Gambar 1. *High Pass Filter* (HPF), ICA, seleksi IC, hingga deteksi puncak kami golongkan sebagai metode deteksi EOG. Setelah itu segmentasi sinyal dari puncak-puncak yang diperoleh, kemudian segmen tersebut dikoreksi menggunakan DAE dan segmen baru digunakan untuk menggantikan segmen sebelumnya.



Gambar 1. Diagram Blok Sistem

2.1 Dataset

Kami menggunakan dua *dataset* pada penelitian ini, *dataset* primer dan *dataset* sekunder. *Dataset* primer diperoleh dari penelitian lain yang diambil dari rumah sakit Hasan Sadikin (RSHS). Sedangkan *dataset* sekunder diperoleh dari *dataset* Mendeley yang dapat diakses secara terbuka pada tautan berikut <https://www.mendeley.com/catalogue/18d3ba04-402b-3c65-a393-00a81d470311/> (Klados & Bamidis, 2016). *Dataset* sekunder digunakan untuk melatih model sedangkan *dataset* primer untuk menguji model dan metode yang dikembangkan. *Dataset* sekunder berisi 54 *dataset* yang diperoleh dari 27 subjek dengan panjang perekaman 30 detik dan frekuensi sampling 200 Hz dan telah diterapkan *Band Pass Filter* (BPF) di frekuensi potong 0,5-40 Hz dan *notch filter* di frekuensi 50 Hz. Data direkam dengan spesifikasi standar internasional sembilan belas kanal (FP1, FP2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, Fz, Cz, Pz) dan tata letak 10-20 (Morley, dkk, 2016). Ilustrasi dapat dilihat pada Gambar 2.



Gambar 2. Ilustrasi Peletakan 19 Kanal EEG dengan Tata Letak 10-20 (Morley, dkk, 2016)

Dataset ini merupakan data semi simulasi, di mana sinyal EEG yang terkontaminasi artefak merupakan hasil simulasi dari sinyal EEG bersih yang dikontaminasi sinyal EOG. Kontaminasi artefak EOG dilakukan menggunakan Persamaan (1) (**Elbert, dkk, 1985**).

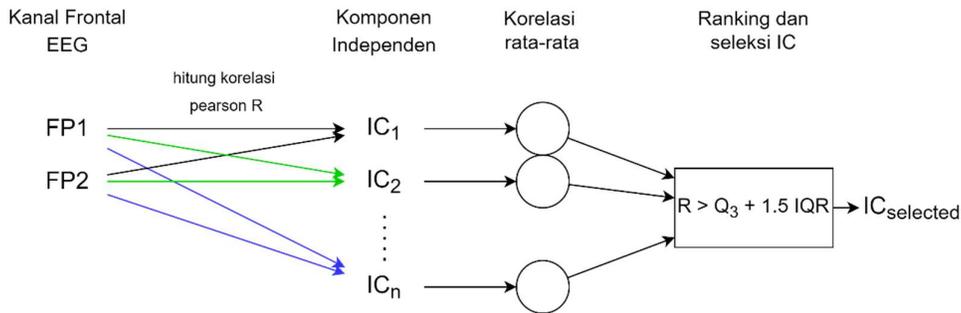
$$Contaminated\ EEG_{i,j} = Pure\ EEG_{i,j} + a_j VEOG + b_j HEOG \tag{1}$$

Dimana *Contaminated EEG_{i,j}* diperoleh dari *Pure EEG_{i,j}* EEG tanpa artefak ditambahkan dengan *a_jVEOG* kanal vertikal EOG dan *b_jHEOG* kanal horizontal EOG. *a_j* dan *b_j* merupakan koefisien kontaminasi yang diperoleh dari eksperimen. Terdapat dua sesi dalam perekaman *dataset* ini, sesi pertama perekaman EEG dengan mata tertutup, dan sesi kedua perekaman EEG dan EOG dengan mata terbuka. Nilai *a_j* dan *b_j* diperoleh dari regresi linier amplitudo EEG dengan EOG pada sesi kedua.

Dataset primer kami peroleh dari 27 subjek pasien demensia akibat stroke. Pada penelitian ini kami hanya fokus dalam mendeteksi artefak saja, dan *dataset* ini dilengkapi dengan anotasi aktivitas kedipan atau gerakan mata. Penyesuaian yang dilakukan pada *dataset* primer hanyalah penyesuaian frekuensi sampling dari 250 Hz menjadi 200 Hz.

2.2 Deteksi Artefak

Data EEG mula-mula diterapkan HPF untuk meningkatkan performansi ICA dalam mengekstraksi komponen-komponen yang saling independen (**Winkler, dkk, 2011**). HPF dilakukan pada frekuensi potong 0,1 Hz menggunakan filter *butterworth* orde 4 menggunakan fungsi *signal.butter*. Kemudian sinyal EEG sembilan belas kanal ditransformasikan oleh ICA menjadi sembilan belas *Independent Component (IC)* menggunakan *sklearn.decomposition.FastICA*.



Gambar 3. Alur Seleksi IC Otomatis

Kami mengembangkan pemilihan IC otomatis menggunakan korelasi silang pearson yang dihitung antara IC dengan kanal frontal EEG FP1 dan FP2. Nilai korelasi tersebut kemudian dirata-ratakan berdasarkan IC, diurutkan dan dilihat distribusinya. Apabila nilai korelasi tertinggi memenuhi syarat Persamaan (4), maka IC tersebut dikatakan sebagai IC artefak.

$$R_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \tag{2}$$

$$\bar{R}_j = \frac{1}{K} \sum_{i=1}^K |R_{ij}|, j = 1,2, \dots N \tag{3}$$

$$R_j \text{ adalah EOG, jika } \bar{R}_j > Q_3(R) + 1.5 * IQR(R), j = 1,2, \dots N \tag{4}$$

Korelasi silang pearson $R_{X,Y}$ dihitung dari kovarians $Cov(X,Y)$ antara IC X dan kanal frontal EEG Y dibagi dengan standar deviasi Persamaan (2). Rata-rata nilai korelasi dihitung pada Persamaan (3) dengan i adalah kanal frontal EEG dan j adalah IC. Kemudian IC dengan nilai korelasi tertinggi dijadikan komponen artefak apabila memenuhi Persamaan (4) dimana $Q_3(R)$ adalah kuartil atas dan $IQR(R)$ adalah *interquartile range*.

Setelah diperoleh komponen artefak, dilakukan pendeteksian puncak. Pada penelitian ini digunakan *envelop* atas untuk memastikan gelombang EOG yang memiliki polaritas negatif ikut terdeteksi. Deteksi puncak mengikuti Persamaan (5).

$$P = \{m_k \mid |Y_i(m_k)| > 2 \cdot E\{|Y_i|\}\} \text{ dan } t(Y_i(m_k)) - t(Y_i(m_{k-1})) \geq 0,5 \text{ detik} \quad (5)$$

Dimana m_k adalah puncak pada komponen Y_i . $E\{|Y_i|\}$ adalah nilai ekspektasi komponen Y_i , t adalah waktu dimana puncak itu muncul.

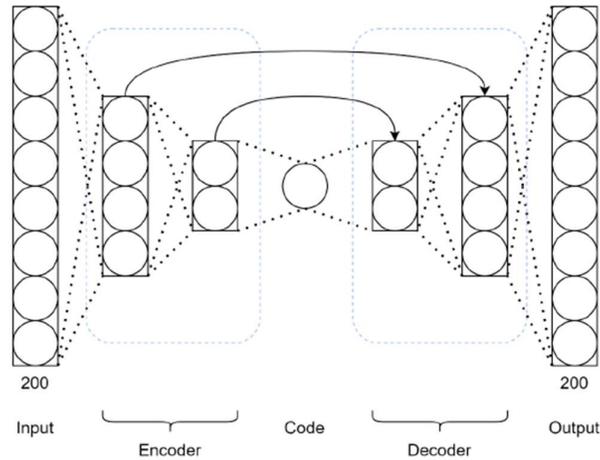
Setelah puncak-puncak diperoleh dilakukan segmentasi di sekitar puncak 0,5 detik sebelum puncak dan 0,5 detik setelah puncak. Pada penelitian ini kami mengambil panjang segmen artefak sepanjang 1 detik. Segmen kemudian distandarisasi dan dikumpulkan.

2.3 *Denoising Autoencoder* (DAE)

Model DAE pada penelitian ini didesain dengan struktur seperti pada Gambar 5 dengan detail seperti Gambar 4. DAE disusun oleh *encoder* dan *decoder* dan dihubungkan melalui sambungan langsung secara simetris pada *hidden layer*.

	Layer	Input size	Output size
Encoder	Input layer	(None, 200)	(None, 200)
	Dense	(None, 200)	(None, 150)
	LeakyReLU	(None, 150)	(None, 150)
	BatchNormalization	(None, 150)	(None, 150)
	Dense	(None, 150)	(None, 150)
	LeakyReLU	(None, 150)	(None, 150)
	BatchNormalization	(None, 150)	(None, 150)
	Dense	(None, 150)	(None, 20)
	LeakyReLU	(None, 20)	(None, 20)
Decoder	BatchNormalization	(None, 20)	(None, 20)
	Dense	(None, 20)	(None, 150)
	Add	[(None, 150), (None, 150)]	(None, 150)
	LeakyReLU	(None, 150)	(None, 150)
	BatchNormalization	(None, 150)	(None, 150)
	Dense	(None, 150)	(None, 150)
	Add	[(None, 150), (None, 150)]	(None, 150)
	LeakyReLU	(None, 150)	(None, 150)
	BatchNormalization	(None, 150)	(None, 150)
Dense	(None, 150)	(None, 200)	

Gambar 4. Arsitektur DAE



Gambar 5. Struktur model DAE

Model dilatih dengan validasi silang lima lipatan dan menggunakan *loss Mean Squared Error* (MSE) dan dioptimasi menggunakan *RMSprop* dengan *learning rate* 0,001.

2.4 Metrik

Untuk mengukur performa deteksi artefak EOG kami menggunakan sensitivitas (*Se*) dan *Positive Predictive Value* (PPV) perhitungan *Se* dan PPV dapat dilihat pada Persamaan (6) dan Persamaan (7).

$$Se = \frac{TP}{TP+} \quad (6)$$

$$PPV = \frac{TP}{TP+FP} \quad (7)$$

$$P \text{ adalah } TP \text{ jika, } |P - P'| \leq 0,75 \text{ detik} \quad (8)$$

$$P \text{ adalah } FP \text{ jika, } |P - P'| > 0,75 \text{ detik} \quad (9)$$

$$P' \text{ adalah } TP \text{ jika, } |P - P'| > 0,75 \text{ detik} \quad (10)$$

TP, FP, dan FN adalah singkatan dari *true positive*, *false positive*, dan *false negative*. Katakanlah P adalah puncak yang dideteksi metode, dan P' adalah puncak sebenarnya. Suatu puncak P dikategorikan TP jika jarak antara P dengan P' kurang dari 0,75 detik (Persamaan (8)), Namun jika di luar rentang 0,75 detik, maka P dikategorikan sebagai FP (Persamaan (9)). Sedangkan untuk mengukur FN kami menggunakan Persamaan (10), P' yang tidak terdeteksi akan dikategorikan sebagai FN.

Pada *dataset* sekunder, kami menggunakan kanal EOG sebagai pembandingan dan validasi puncak EOG pada IC yang terpilih sebagai komponen artefak. Sehingga kami memperoleh TP, FP dan FN. Namun pada *dataset* primer, karena kami hanya memiliki anotasi artefak EOG pada sebagian sinyal, kami hanya dapat mengukur TP dan FN.

Untuk mengukur performa model DAE dan hasil rekonstruksi artefaknya, kami menggunakan rerata *loss* dari validasi silang yang digambarkan pada Gambar 6 dan *Root Mean Squared Error* (RMSE) pada Persamaan (11).



Gambar 6. Validasi Silang Lima Lipat

Validasi silang dilakukan di mana pada setiap lipatnya, model dilatih sebanyak dua ratus perulangan. Dan kami melakukan pelatihan model secara terpisah dengan jumlah seribu perulangan untuk mengevaluasi perkembangan hasil sinyal yang direkonstruksi model DAE menggunakan RMSE.

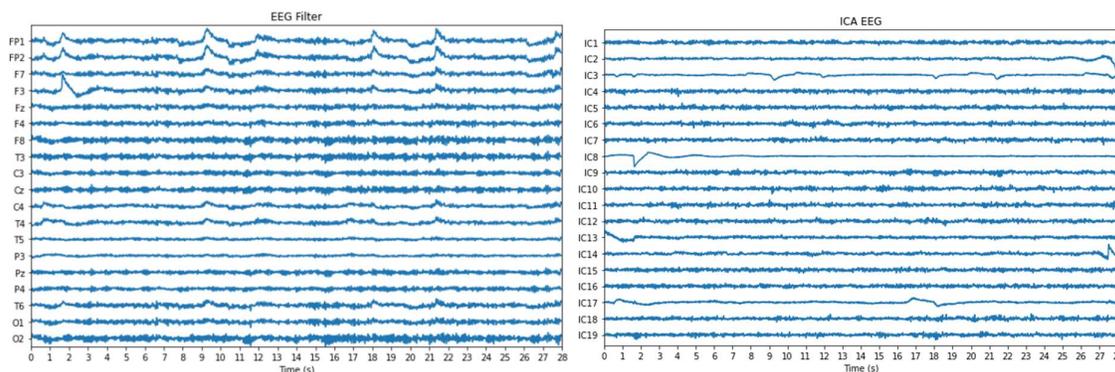
$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (r'(n) - x(n))^2} \tag{11}$$

Di mana $r'(n)$ adalah segmen hasil rekonstruksi DAE, dan $x(n)$ adalah segmen *ground truth* EEG dari *dataset*.

3. HASIL DAN PEMBAHASAN

3.1 Deteksi Puncak

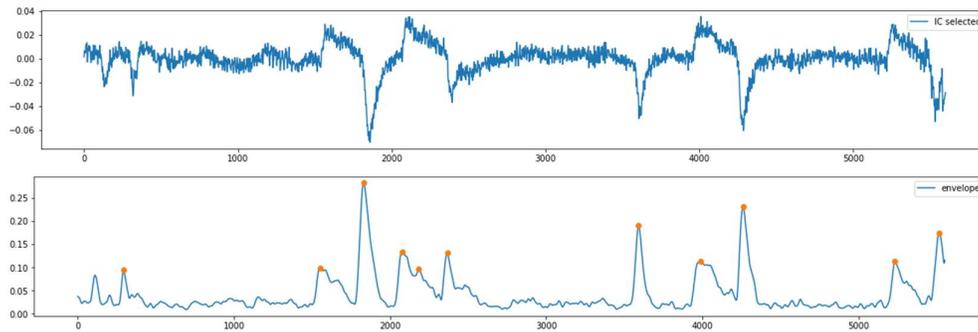
Pada bab ini kami memperlihatkan gambar salah satu data untuk mendemonstrasikan hasil metode yang kami kembangkan. Pada Gambar 7 terlihat hasil HPF dan hasil transformasi ICA.



Gambar 7. Hasil HPF (Kiri) dan ICA (Kanan)

Secara visual dapat terlihat komponen-komponen ICA sangat berbeda antara satu dengan lainnya. Kemudian IC diseleksi otomatis dan hasilnya IC3 yang terpilih pada data ini. Dapat dilihat dari Gambar 8 bahwa sinyal EOG memiliki polaritas yang berbalik dibandingkan dengan

data EEG. Hal ini umum terjadi pada transformasi ICA dikarenakan algoritmanya. Kemudian pada gambar dapat dilihat hasil *envelop* dari IC3 dan deteksi puncaknya.



Gambar 8. IC Terpilih adalah IC3 (Atas). Hasil *Envelop* IC3 dengan Puncak-Puncak yang Terdeteksi (Bawah). Sumbu Vertikal adalah *Arbitrary Unit* (A.U.) Hasil Proses Normalisasi, Sumbu Horizontal Data Poin

Berdasarkan metode pendeteksian artefak EOG tersebut, didapatkan total puncak yang terdeteksi dari seluruh *dataset* sekunder ada sebanyak 475 puncak, sedangkan total puncak sebenarnya pada seluruh *dataset* dari observasi manual ada sebanyak 497. 409 puncak terdeteksi dengan benar atau masuk kategori TP, sehingga didapatkan sensitivitas 0,85 dan PPV 0,83.

Pengujian pada *dataset* primer juga dilakukan dengan cara yang sama. Dari 94 anotasi artefak EOG, 77 puncak terdeteksi dengan benar sehingga diperoleh sensitivitas 0,82.

3.2 Rekonstruksi EEG

Hasil validasi silang dapat dilihat di Tabel 1, dari pelatihan sebanyak dua ratus perulangan diperoleh rata-rata MSE 0,007 dengan standar deviasi 0,008.

Tabel 1. Validasi Silang Sepuluh Lipat Pelatihan DAE

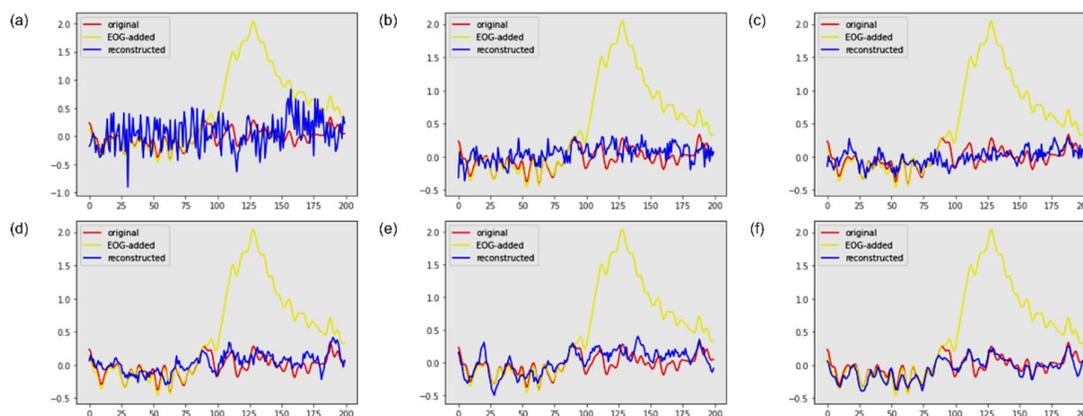
Lipatan	MSE
Lipat-1	0.028
Lipat-2	0.012
Lipat-3	0.007
Lipat-4	0.004
Lipat-5	0.004
Lipat-6	0.003
Lipat-7	0.003
Lipat-8	0.002
Lipat-9	0.002
Lipat-10	0.002
Rata-rata	0.007±0.008

Tabel 2. Perbandingan RMSE Metode DAE dengan Metode Lain

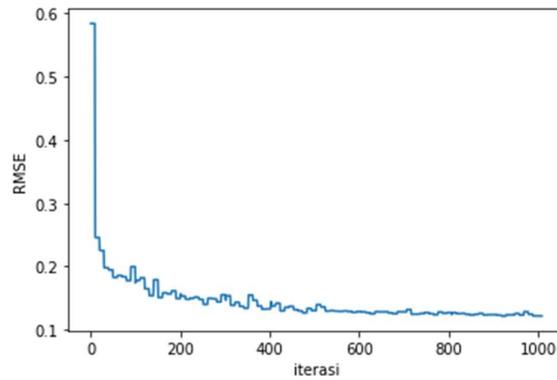
Dataset, Kanal	EEG terkontaminasi	EEG yang dibersihkan			
		Reject IC	W-ICA	F Issa	DAE
Dataset 1, FP1	33.9	16.3	12.6	7.9	16.1
Dataset 1, FP8	13.7	9.4	7.3	3.2	12.7
Dataset 9, FP1	30.8	30.8	9.2	3.2	16.5

Kami membandingkan metode kami dengan metode lainnya yang sudah dilakukan pada penelitian sebelumnya. Pada penelitian sebelumnya oleh **(Issa & Juhasz, 2019)** mereka mengukur RMSE satu kanal penuh antara sinyal yang direkonstruksi dengan sinyal bersih *ground truth*. Hasilnya kami dapati metode kami memberikan nilai RMSE yang lebih rendah dibandingkan dengan sinyal yang terkontaminasi, namun masih lebih tinggi dari metode rekonstruksi lainnya. Hal ini menyatakan metode kami berhasil menurunkan RMSE pada sinyal yang terkontaminasi namun bukanlah pendekatan yang paling ideal untuk mengembalikan sinyal EEG bersih.

Perkembangan pelatihan model DAE dapat dilihat pada Gambar 9. Model dievaluasi dengan menghitung RMSE pada setiap perulangan, grafik penurunan RMSE pada setiap perulangan pelatihan DAE dapat dilihat di Gambar 10.

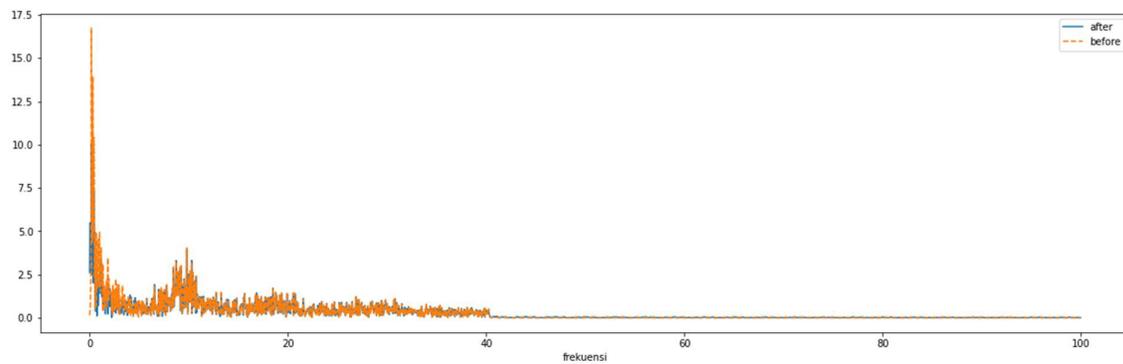


Gambar 9. Perbandingan antara Sinyal EEG Rekonstruksi DAE (Biru), Sinyal EEG Terkontaminasi Artefak (Kuning), Dan Sinyal EEG Tanpa Kontaminasi Artefak (Merah) pada Iterasi 1, 4, 8, 16, 32, 64 (A-F). Sumbu Vertikal Adalah Arbitrary Unit (A.U.) Hasil Proses Normalisasi, dan Sumbu Horizontal Data Poin



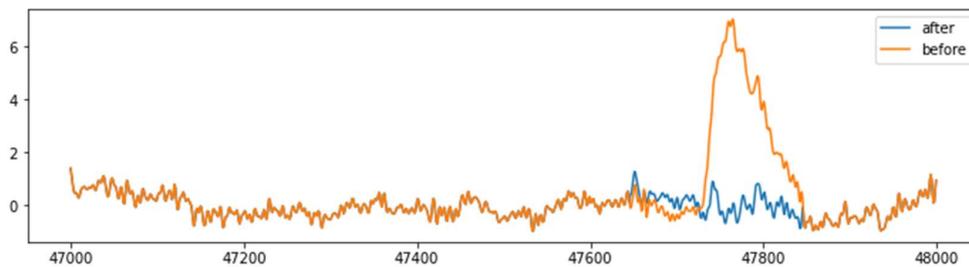
Gambar 10. Grafik Nilai RMSE antara Sinyal EEG Hasil Rekonstruksi dengan Sinyal EEG *Ground Truth* di setiap Iterasi

Untuk memastikan bahwa artefak EOG telah dibersihkan kami mentransformasikan sinyal EEG menggunakan FFT untuk melihat apakah sinyal dengan frekuensi rendah sudah teredam. Grafik perbandingan FFT sinyal EEG hasil rekonstruksi dengan *ground truth* dapat dilihat pada Gambar 11.

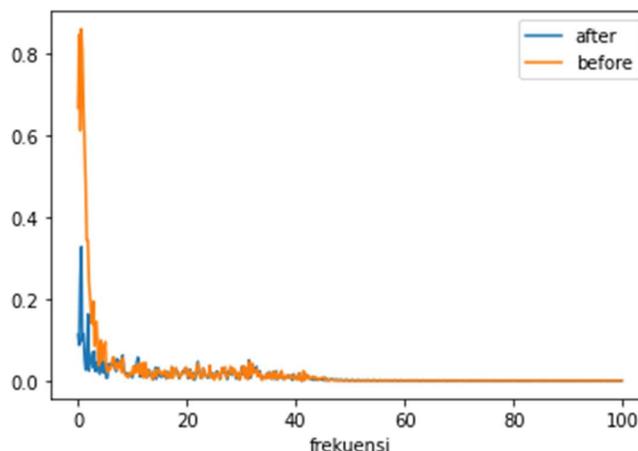


Gambar 11. Perbandingan FFT antara Sinyal Hasil Rekonstruksi DAE dengan Sinyal *Ground Truth*. Sumbu Vertikal Adalah Arbitrary Unit (A.U.) Hasil Proses Normalisasi

Hasil Perbandingan sinyal EEG hasil rekonstruksi DAE dan transformasi FFT pada *dataset* primer menunjukkan hasil yang serupa secara visual dengan data sekunder. Hasilnya dapat dilihat pada Gambar 12 dan Gambar 13.



Gambar 12. Perbandingan FFT antara Sinyal Hasil Rekonstruksi DAE dengan Sinyal *Ground Truth*. Sumbu Vertikal Adalah Arbitrary Unit (A.U.) Hasil Proses Normalisasi, Sumbu Horizontal Data Point



Gambar 13. Perbandingan FFT antara Sinyal Hasil Rekonstruksi DAE dengan Sinyal *Ground Truth*. Sumbu Vertikal Adalah Arbitrary Unit (A.U.) Hasil Proses Normalisasi

4. KESIMPULAN

Pendeteksian dan rekonstruksi sinyal EEG dari gangguan artefak EOG dapat dilakukan dengan baik oleh DAE. Pada data sekunder diperoleh sensitivitas sebesar 0,85 yang artinya menurut sudut pandang sinyal *ground truth*, dari 497 puncak EOG, 85% di antaranya terdeteksi dengan benar. Sedangkan menurut sudut pandang, metode yang dikembangkan pada penelitian ini, dari total 475 puncak artefak yang dideteksi, 83% diantaranya terdeteksi dengan benar. Sedangkan pada *dataset* primer diperoleh sensitivitas 0,82.

Dari pelatihan DAE kami memperoleh rata-rata MSE dari validasi silang sebesar $0,007 \pm 0,008$. Kami mengukur RMSE pada segmen yang sama tiap perulangan pelatihan.

Berdasarkan hasil tersebut kami menyimpulkan bahwa metode deteksi EOG kami berhasil mendeteksi dengan baik, selain itu DAE dapat dengan baik merekonstruksi sinyal EEG yang telah terkontaminasi artefak EOG. Namun jika dibandingkan dengan metode lain, metode kami yang hanya merekonstruksi segmen yang terkontaminasi artefak EOG ternyata bukanlah metode yang paling ideal untuk mengembalikan sinyal EEG yang terkontaminasi artefak EOG.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih kepada **(Klados & Bamidis, 2016)** yang telah mempublikasikan *dataset* mereka secara terbuka yang kami gunakan sebagai *dataset* sekunder. Kami juga mengucapkan terima kasih kepada **(Hadiyoso, dkk, 2021)** yang telah mengizinkan kami untuk menggunakan *dataset* EEG sehingga kami gunakan sebagai *dataset* primer.

DAFTAR RUJUKAN

- Bank, D., Koenigstein, N., & Giryas, R. (2020). *Autoencoders*. <http://arxiv.org/abs/2003.05991>
- Elbert, T., Lutzenberger, W., Rockstroh, B., & Birbaumer, N. (1985). Removal of ocular artifacts

- from the EEG - A biophysical approach to the EOG. *Electroencephalography and Clinical Neurophysiology*, 60(5), 455–463. [https://doi.org/10.1016/0013-4694\(85\)91020-X](https://doi.org/10.1016/0013-4694(85)91020-X)
- Fotiadou, E., & Vullings, R. (2020). Multi-Channel Fetal ECG Denoising With Deep Convolutional Neural Networks. *Frontiers in Pediatrics*, 8. <https://doi.org/10.3389/fped.2020.00508>
- Hadiyoso, S., Zakaria, H., Mengko, T. L. E. R., & Ong, P. A. (2021). *Preliminary Study of EEG Characterization Using Power Spectral Analysis in Post-stroke Patients with Cognitive Impairment*, (pp. 579–592). https://doi.org/10.1007/978-981-33-6926-9_51
- Hartmann, K. G., Schirrmester, R. T., & Ball, T. (2018). *EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals*. <http://arxiv.org/abs/1806.01875>
- Hu, J., Wang, C. sheng, Wu, M., Du, Y. xiao, He, Y., & She, J. (2015). Removal of EOG and EMG artifacts from EEG using combination of functional link neural network and adaptive neural fuzzy inference system. *Neurocomputing*, 151(P1), 278–287. <https://doi.org/10.1016/j.neucom.2014.09.040>
- Hwang, S., Hong, K., Son, G., & Byun, H. (2019). EZSL-GAN: EEG-based Zero-Shot Learning approach using a Generative Adversarial Network. *7th International Winter Conference on Brain-Computer Interface, BCI 2019*, (pp. 1–4). <https://doi.org/10.1109/IWW-BCI.2019.8737322>
- Islam, M. K., Rastegarnia, A., & Yang, Z. (2016). Les méthodes de détection et de rejet d'artefact de l'EEG de scalp : revue de littérature. *Neurophysiologie Clinique*, 46(4–5), 287–305. <https://doi.org/10.1016/j.neucli.2016.07.002>
- Issa, M. F., & Juhasz, Z. (2019). Improved EOG artifact removal using wavelet enhanced independent component analysis. *Brain Sciences*, 9(12). <https://doi.org/10.3390/brainsci9120355>
- Jiang, X., Bian, G. Bin, & Tian, Z. (2019). Removal of artifacts from EEG signals: A review. *Sensors (Switzerland)*, 19(5), 1–18. <https://doi.org/10.3390/s19050987>
- Jiao, Y., Deng, Y., Luo, Y., & Lu, B. L. (2020). Driver sleepiness detection from EEG and EOG signals using GAN and LSTM networks. *Neurocomputing*, 408, 100–111. <https://doi.org/10.1016/j.neucom.2019.05.108>
- Klados, M. A., & Bamidis, P. D. (2016). A semi-simulated EEG/EOG dataset for the comparison of EOG artifact rejection techniques. *Data in Brief*, 8, 1004–1006. <https://doi.org/10.1016/j.dib.2016.06.032>
- Lee, D., Choi, S., & Kim, H.-J. (2018). Performance evaluation of image denoising developed using convolutional denoising autoencoders in chest radiography. *Nuclear Instruments*

- and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 884, 97–104. <https://doi.org/10.1016/j.nima.2017.12.050>
- Luo, T. J., Fan, Y., Chen, L., Guo, G., & Zhou, C. (2020). EEG Signal Reconstruction Using a Generative Adversarial Network With Wasserstein Distance and Temporal-Spatial-Frequency Loss. *Frontiers in Neuroinformatics*, 14. <https://doi.org/10.3389/fninf.2020.00015>
- Morley, A., Hill, L., & Kaditis, A. G. (2016). 10-20 System EEG Placement. *European Respiratory Society*, 34. http://en.wikipedia.org/wiki/10-20_system_%28EEG%29
- Nejedly, P., Cimbalnik, J., Klimes, P., Plesinger, F., Halamek, J., Kremen, V., Viscor, I., Brinkmann, B. H., Pail, M., Brazdil, M., Worrell, G., & Jurak, P. (2019). Intracerebral EEG Artifact Identification Using Convolutional Neural Networks. *Neuroinformatics*, 17(2), 225–234. <https://doi.org/10.1007/s12021-018-9397-6>
- Saba-Sadiya, S., Chantland, E., Alhanai, T., Liu, T., & Ghassemi, M. M. (2021). Unsupervised EEG Artifact Detection and Correction. *Frontiers in Digital Health*, 2, 1–11. <https://doi.org/10.3389/fdgth.2020.608920>
- Saini, M., Payal, & Satija, U. (2020). An Effective and Robust Framework for Ocular Artifact Removal From Single-Channel EEG Signal Based on Variational Mode Decomposition. *IEEE Sensors Journal*, 20(1), 369–376. <https://doi.org/10.1109/JSEN.2019.2942153>
- Winkler, I., Debener, S., Muller, K.-R., & Tangermann, M. (2015). On the influence of high-pass filtering on ICA-based artifact reduction in EEG-ERP. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pp. 4101–4105). <https://doi.org/10.1109/EMBC.2015.7319296>
- Winkler, I., Haufe, S., & Tangermann, M. (2011). Automatic Classification of Artifactual ICA-Components for Artifact Removal in EEG Signals. *Behavioral and Brain Functions*, 7(1), 30. <https://doi.org/10.1186/1744-9081-7-30>