

Klasifikasi Gangguan Tidur REM Behaviour Disorder Berdasarkan Sinyal EEG Menggunakan Machine Learning

Alvi Norma Utami

Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Negeri Surabaya

alviutami16030214028@mhs.unesa.ac.id

Abstrak—REM Behaviour Disorder (RBD) merupakan gangguan tidur yang ditandai dengan hilangnya atonia otot normal (hilangnya kelumpuhan) selama tidur Rapid Eye Movement (REM) berlangsung, dimana penderita bertindak berdasarkan mimpi yang dapat mengakibatkan cedera fisik pada individu atau pasangan tidur mereka. REM merupakan tahap tidur dengan ciri-ciri terhentinya pergerakan bola mata, menurunnya suhu tubuh, melambatnya detak jantung dan tidak adanya aktifitas otot pada beberapa bagian tubuh. Salah satu metode yang digunakan untuk mendeteksi RBD adalah Elektroensefalografi (EEG). EEG merupakan suatu metode merekam atau menangkap aktivitas elektrik di otak. Dataset yang digunakan bersumber dari PhysioNet.org yang terdiri dari 2 kelas yaitu kelas normal dan kelas RBD yang diambil dari 26 subyek dengan 6 subyek normal dan 20 subyek RBD. Penelitian ini dilakukan untuk mengklasifikasikan gangguan tidur RBD berdasarkan sinyal EEG menggunakan algoritma ELM serta diharapkan dapat menentukan algoritma terbaik dalam pengklasifikasian gangguan tidur RBD menggunakan algoritma ELM yang akan dikomparasikan dengan algoritma SVM dan backpropagation berdasarkan sinyal EEG dari segi nilai akurasi yang dihasilkan dan juga waktu yang dibutuhkan untuk membuat model dalam proses klasifikasi algoritma. Klasifikasi gangguan tidur RBD berdasarkan sinyal EEG diawali dengan pra-pemrosesan data, ekstraksi fitur dan klasifikasi. Pra pemrosesan data meliputi pembagian sinyal per 30 detik dan *smoothing* data. Proses ekstraksi ciri menggunakan Transformasi Wavelet Diskrit. Proses klasifikasi RBD berdasarkan sinyal EEG menggunakan algoritma Extreme Learning Machine (ELM) dengan fungsi aktivasi sigmoid biner. Sebelum proses pelatihan pada algoritma ELM, terlebih dahulu dilakukan undersampling untuk mengatasi ketidakseimbangan jumlah kelas. Evaluasi hasil klasifikasi dilakukan dengan *k-fold cross validation*. Hasil klasifikasi gangguan tidur RBD berdasarkan sinyal EEG menggunakan algoritma ELM menunjukkan bahwa algoritma ELM bisa mengklasifikasikan gangguan tidur RBD dengan non RBD berdasarkan sinyal EEG dengan nilai rata-rata akurasi sebesar mencapai $70.71\% \pm 5.44$. Hasil komparasi menyatakan bahwa algoritma backpropagation memiliki rata-rata akurasi terbaik dalam pengklasifikasian RBD berdasarkan sinyal EEG yaitu mencapai $83.81\% \pm 1.40$. Namun berdasarkan komputasi waktu, algoritma ELM lebih unggul dalam kecepatan proses klasifikasi RBD berdasarkan sinyal EEG yaitu mencapai 0.04 ± 0.06 detik dibandingkan algoritma Support Vector Machine (SVM) dan backpropagation

Kata Kunci—Gangguan Tidur, REM Behaviour Disorder, EEG, Extreme Learning Machine, Wavelet

I. PENDAHULUAN

Tidur merupakan cara alami manusia untuk mengistirahatkan tubuh, memulihkan energi, membangun sel-sel baru serta perbaikan sel-sel tubuh yang tidak sempurna [1]. Dalam kondisi tidur, terdapat dua tahap yaitu Rapid Eye Movement (REM) dan Nonrapid Eye Movement (NREM), dimana NREM merupakan tahap awal dalam tidur ringan dengan ciri-ciri terhentinya pergerakan bola mata, menurunnya suhu tubuh, melambatnya detak jantung dan tidak adanya aktifitas otot pada beberapa bagian tubuh. Sedangkan REM merupakan tahap dengan ciri-ciri cepatnya pergerakan bola mata, kekuatan otot hilang serta mimpi yang tampak nyata [2]. Gangguan tidur dapat berdampak pada kualitas tidur yang terganggu serta dapat menurunkan kualitas hidup manusia [1]. Dimana orang yang memiliki gangguan tidur dapat mengakibatkan penurunan konsentrasi, daya tahan tubuh melemah, dan juga memicu berbagai penyakit berbahaya seperti kanker, stroke dan lain-lain [2].

Salah satu gangguan tidur yang berbahaya adalah REM Behaviour Disorder (RBD). RBD adalah parasomnia yang ditandai dengan hilangnya atonia otot normal (hilangnya

kelumpuhan) selama tidur REM berlangsung, dimana orang tersebut bertindak berdasarkan mimpi yang dapat mengakibatkan cedera fisik individu dan pasangan tidur mereka [3]. Ciri khas dari RBD adalah pasien akan mewujudkan mimpi mereka menggunakan gerakan dan vokalisasi. Hal ini dapat membuat pasangan tidur mereka mengetahui apa yang terjadi dalam mimpi pasien RBD ini, contohnya ketika mimpi yang terjadi yaitu berusaha untuk mengusir seekor anjing maka perilaku pasien RBD yang akan terjadi yaitu menendang kaki dan memaki dengan keras pada saat tidur [4]. RBD sendiri merupakan gangguan yang dapat berkembang menjadi beberapa penyakit seperti parkinson, Dementia with Lewy Bodies (DLB), atau Multiple System Atrophy (MSA) [5], sehingga melakukan diagnosis parasomnia dini sangat penting guna dapat mengontrol dampak dari gangguan tidur ini.

Kriteria diagnosis untuk RBD diberikan oleh International Classification of Sleep Disorder (ICSD-3) menunjukkan bahwa pemeriksaan RBD hanya dapat dibuat dengan bantuan polisomnografi. Dalam hal ini, salah satu polisomnografi yang dapat digunakan adalah Elektroensefalografi (EEG). EEG merupakan suatu metode merekam atau menangkap aktivitas elektrik di otak [6]. Sinyal otak yang biasa disebut sinyal EEG merupakan sinyal yang timbul akibat adanya aktivitas listrik yang terjadi di permukaan otak [7]. Beberapa gangguan lain seperti non-REM parasomnia (sleep walking, sleep terrors), obstructive sleep apnea dan gangguan disasosiatif memiliki kondisi yang hampir sama dengan RBD yaitu dimana pasien akan menunjukkan gerakan tidur yang berlebihan dan perilaku yang berpotensi menuju kekerasan. Karena terdapatnya kesamaan di antara kondisi dari beberapa gangguan diatas, maka peran polisomnografi sangatlah penting dalam mendiagnosa RBD atau bukan [8].

Penelitian terdahulu terkait klasifikasi RBD menggunakan polisomnografi seperti pada penelitian Ruffini, dkk (2016) dalam penggunaan algoritma Echo State Networks (ESN) yang termasuk salah satu kelas dari Recurrent Neural Network (RNN) untuk mengklasifikasi RBD menggunakan sinyal EEG yang menghasilkan akurasi sebesar 85% [9], juga penelitian Ruffini, dkk (2019) dalam pengklasifikasian menggunakan sinyal EEG dengan algoritma Deep Convolutional Neural Network (DCNN) yang menghasilkan akurasi tertinggi sebesar 79% dan dengan algoritma pembandingan yaitu RNN yang menghasilkan akurasi tertinggi sebesar 81% [10], serta penelitian yang dilakukan oleh Cooray, Andreotti, Symmonds, Hu, & Vos (2019) dalam penggunaan algoritma Random Forest (RF) untuk mengklasifikasi RBD berdasarkan sinyal EEG, EOG dan EMG yang menghasilkan akurasi tertinggi sebesar 96% ketika menggunakan anotasi tahapan tidur secara manual dan akurasi tertinggi sebesar 92% ketika menggunakan anotasi tahapan tidur secara otomatis [11]. Penelitian terdahulu masih belum terdapat pengklasifikasian RBD menggunakan algoritma ELM, sehingga dalam penelitian ini, klasifikasi gangguan tidur RBD dilakukan dengan algoritma Extreme Learning Machine (ELM). ELM adalah metode jaringan syaraf tiruan feedforward dengan Single Hidden Layer Feedforward Neural Networks (SLFNs), dimana metode ELM ini dapat digunakan untuk mengatasi kelemahan dalam hal kecepatan pembelajaran [12]. Untuk mengetahui kinerja klasifikasi algoritma ELM dengan algoritma lainnya, maka akan dikomparasikan dengan algoritma SVM dan backpropagation.

Tujuan dari penelitian ini yaitu mengklasifikasikan gangguan tidur RBD berdasarkan sinyal EEG menggunakan algoritma ELM serta diharapkan dapat menentukan algoritma terbaik dalam pengklasifikasian gangguan tidur RBD menggunakan algoritma ELM yang akan dikomparasikan dengan algoritma SVM dan backpropagation berdasarkan sinyal EEG dari segi nilai akurasi yang dihasilkan dan juga waktu yang dibutuhkan untuk membuat model dalam proses klasifikasi algoritma. Dataset yang digunakan pada penelitian ini bersumber dari PhysioNet.org [25][26]. Dataset ini terdiri dari data sinyal EEG RBD dan data sinyal EEG normal yang berasal dari 26 subyek, dengan 6 subyek normal dan 20 subyek RBD.

II. METODE

Pada bagian ini diulas tentang proses yang digunakan dalam klasifikasi gangguan tidur RBD yang terdiri dari pra-pemrosesan, ekstraksi fitur dan klasifikasi. Untuk lebih detailnya sebagai berikut.

A. Pra-Pemrosesan Data

Proses dalam tahapan ini yaitu proses pemilihan channel dari rekaman EEG, pembagian sinyal per 30 detik dan *smoothing*. Pada rekaman EEG terdapat beberapa *channel* yaitu FP1-F3, F3-C3, C3-P3, P3-O1, FP2-F4, F4-C4, C4-P4, P4-O2. Dari *channel-channel* tersebut dilakukan pemilihan *channel* dengan memilih satu *channel* yang mewakili yaitu FP2-F4. Pemilihan FP2-F4 dikarenakan FP (frontopolar cortex) atau korteks prefrontal anterior/rostral, merupakan daerah yang memiliki peran penting pada kesadaran manusia dalam pengolahan kognitif yang sangat berguna bagi tingkah laku manusia [15]. Sedangkan F (Lobus Frontal) merupakan pusat kendali otak, fungsi intelektual, aktivitas motorik, dan pengendalian emosi [16]. Pembagian sinyal per 30 detik bertujuan guna mengurangi *resources* yang diperlukan untuk proses komputasi klasifikasi gangguan tidur RBD. Setiap pembagian 30 detik, menghasilkan data sebanyak 15.360, sehingga total matrik dataset berukuran 4.576×15.360 . *Smoothing* bertujuan agar data tidak memiliki rentang yang tidak sama. *Smoothing* data menggunakan metode z-score pada persamaan 1.

$$Z = \frac{(x-\mu)}{\sigma} \quad (1)$$

Dengan Z merupakan hasil *smoothing* data, μ merupakan mean kolom, σ merupakan standard deviasi kolom serta x merupakan data masukan. Hasil *smoothing* data ini yang akan digunakan sebagai data masukan untuk proses ekstraksi ciri.

B. Proses Ekstraksi Ciri dengan Transformasi Wavelet Diskrit (DWT)

Transformasi wavelet merupakan transformasi yang dimanfaatkan untuk menganalisis sinyal bergerak guna mendapatkan informasi spektrum frekuensi dan waktunya secara bersamaan. Fungsi wavelet ialah untuk memperoleh koefisien wavelet. *Mother wavelet* serta koefisien pada rentang interval sinyal wavelet akan dievaluasi dengan ditranslasi (perpindahan) dan dilatasi (penskalaan) untuk lebar yang berbeda dan dilakukan perulangan sepanjang skala waktu [17].

Transformasi wavelet dapat dibagi menjadi dua yaitu Transformasi Wavelet Kontinu (CWT) dan Transformasi Wavelet Diskrit (DWT). CWT merupakan penjumlahan seluruh spektrum sinyal dikalikan dengan *mother wavelet* yang terkompresi dan ditranslasi. Banyaknya koefisien transformasi wavelet yang dihasilkan oleh CWT, menyebabkan data yang dihasilkan menjadi berlebihan (redundansi), sehingga untuk menyelesaikan masalah ini digunakan DWT. Pengimplementasian CWT dianggap lebih sulit dibandingkan dengan DWT. Prinsip dasar dari DWT yaitu dengan teknik pemfilteran digital dan operasi *sub-sampling*, dihasilkan cara untuk memperoleh gambaran waktu dan skala dari sebuah sinyal [18]. Proses pembagian sinyal menjadi frekuensi tinggi yang menghasilkan komponen detail (cD) dan frekuensi rendah yang menghasilkan komponen aproksimasi (cA) disebut dekomposisi wavelet [17].


Dalam penelitian ini *mother wavelet* yang digunakan yaitu *daubechies 4* (db4). Penelitian (Arif & Djamal, 2014) [19] mengenai db4 dalam klasifikasi sinyal EEG terhadap kondisi kelelahan menggunakan wavelet, terbukti dapat meningkatkan akurasi pengenalan hingga 67% [20]. Wavelet cocok digunakan untuk sinyal yang bersifat *non stationary* yaitu sinyal yang memiliki amplitudo berubah-ubah [17]. Sifat sinyal EEG sendiri juga *non stationary* [21], sehingga bentuk *mother wavelet* Db4 cocok untuk proses ekstraksi ini. Proses dekomposisi wavelet dilakukan hingga 6 level. Setiap level akan diambil koefisien aproksimasi dan nilai statistika koefisien detail yang meliputi mean, minimal, maximal dan standart deviasi pada level tersebut dan level sebelumnya.

C. Proses Klasifikasi dengan *Extreme Learning Machine* (ELM)

Sebelum proses pelatihan, terlebih dahulu dilakukan undersampling untuk mengatasi kondisi data antar kelas yang tidak berimbang. Metode undersampling yang dipilih yaitu undersampling acak. Menurut Erna & Romi (2015) undersampling acak dilakukan dengan menghitung selisih antara kelas mayoritas dan minoritas lalu dilakukan penghapusan kelas mayoritas secara acak kemudian dilakukannya kembali seperti proses awal secara berulang hingga jumlah kelas mayoritas sama dengan kelas minoritas [22].

ELM adalah metode jaringan syaraf tiruan feedforward dengan Single Hidden Layer Feedforward Neural Networks (SLFNs). Parameter bobot masukan dan bias ditentukan secara acak, inilah penyebab mengapa ELM mempunyai *learning speed* yang cepat [12].

Tiga lapisan penyusun jaringan ELM yaitu lapisan masukan, lapisan tersembunyi dan lapisan keluaran. Bobot masukan pada setiap *node*/simpul mempunyai nilai yang berbeda



guna menghubungkan lapisan masukan kepada simpul tersembunyi (*hidden node*), kemudian seluruh simpul tersembunyi terhubung ke semua simpul keluaran [23]. Sebagai gambaran arsitektur jaringan ELM dapat dilihat pada Gambar 1.

Gambar 1. Arsitektur Jaringan Extreme Learning Machine

Model matematis dari metode ELM berbeda dengan jaringan feedforward lainnya, hal ini dikarenakan model dari ELM lebih mudah dan efisien. Untuk N jumlah pasangan masukan dan target keluaran yang berbeda (x_i, t_i) , dengan $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ dan $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, standar SLFNs dengan jumlah simpul tersembunyi sebanyak $\tilde{N}$ dan fungsi aktivasi $g(x)$ dapat dimodelkan secara matematis pada persamaan 2 [12]:

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j \quad j = 1, 2, \dots, N \quad (2)$$

Dimana $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ ialah vektor bobot yang menjadi penghubung antara simpul masukan dan simpul tersembunyi ke- i . $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$ ialah vektor bobot yang menjadi penghubung antara simpul tersembunyi ke- i dan simpul keluaran. b_i merupakan *threshold* dari simpul tersembunyi ke- i . lalu $w_i \cdot x_j$ adalah *inner product* dari w_i dan x_j .

SLFNs standar dengan $\tilde{N}$ adalah simpul tersembunyi dan fungsi aktivasi $g(x)$ dapat diperkirakan N sampel ini dengan tingkat eror 0 yang artinya $\sum_{j=1}^N ||o_j - t_j|| = 0$, sehingga terdapat β_i , w_i dan b_i sedemikian hingga

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, 2, \dots, N \quad (3)$$

Persamaan 3 dituliskan secara sederhana seperti pada persamaan 4 :

$$H\beta = T \quad (4)$$

$$\text{Dimana } H = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + \mathbf{b}_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_1 + \mathbf{b}_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + \mathbf{b}_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_N + \mathbf{b}_{\tilde{N}}) \end{bmatrix} \quad (5)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix} \text{ dan } \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} \quad (6)$$

H pada persamaan 5 adalah matrik keluaran lapisan tersembunyi dari jaringan syaraf. $g(\mathbf{w}_1 \cdot \mathbf{x}_1 + \mathbf{b}_1)$ menunjukkan keluaran dari simpul tersembunyi yang berhubungan dengan masukan $\mathbf{x}_j$. $\boldsymbol{\beta}$ ialah matrik dari bobot keluaran dan $\mathbf{T}$ ialah matrik dari target [12].

Salah satu permasalahan yang sering ditemui ialah jumlah sampel data latih berbeda yang digunakan jauh lebih besar dibandingkan dengan jumlah simpul tersembunyi, sehingga H adalah matriks non-persegi dan solusi kuadrat terkecil dari sistem linier tersebut dapat memperoleh persamaan keluaran bobot $\boldsymbol{\beta}$ seperti pada persamaan 7 [24] :

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T} \quad (7)$$

Dimana $\mathbf{H}^+$ merupakan Moore-Penrose generalized invers dari matriks H.

Proses pelatihan klasifikasi algoritma ELM secara simple memiliki 3 tahap [24] : misalnya diperoleh sebuah *training set* = $\{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbf{R}^n, \mathbf{t}_i \in \mathbf{R}^m, i = 1, \dots, n\}$, $g(\mathbf{x})$ merupakan fungsi aktivasi dan $\tilde{N}$ merupakan jumlah simpul tersembunyi,

1. Menetapkan bobot masukan $\mathbf{w}_i$ dan bias $\mathbf{b}_i, i = 1, \dots, \tilde{N}$.
2. Menghitung matrik keluaran H darilapisan tersembunyi.
3. Menghitung bobot dari keluaran $\boldsymbol{\beta}$ menggunakan persamaan 7.

Dimana $\mathbf{T} = [\mathbf{t}_1, \dots, \mathbf{t}_n]^T$, $\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$ atau $\mathbf{H}^+ = \mathbf{H}^T (\mathbf{H}^T \mathbf{H})^{-1}$

Untuk menghitung lapisan keluaran Y digunakan persamaan 8:

$$\mathbf{Y} = \mathbf{H}^T \boldsymbol{\beta} \quad (8)$$

Pada penelitian ini penggunaan banyaknya simpul tersembunyi sebanyak 10, 50, 100, 500 dan 1000. Fungsi aktivasi sigmoid biner dipilih karena untuk keluaran dari fungsi tersebut memiliki interval 0 sampai 1. Matrik bobot dan bias dipilih secara acak. Penentuan elemen matrik bobot umumnya ditentukan pada interval $(-\gamma, \gamma)$. Pada penelitian ini menggunakan pemilihan elemen bobot pada interval $(-1, 1)$. Penentuan elemen matrik bias dipilih secara acak dengan nilai yang kecil pada interval $(0, 1)$.

III. HASIL DAN PEMBAHASAN

Bagian ini berisi tentang dataset, hasil dan pembahasan eksperimen yang telah dilakukan. Untuk lebih detailnya sebagai berikut.

A. Dataset

Dalam penelitian ini, dataset bersumber dari PhysioNet.org [25][26]. Dataset yang digunakan terdiri dari data sinyal EEG RBD dan data sinyal EEG normal yang berasal dari 26 subyek, dengan 6 subyek normal dan 20 subyek RBD, dari usia 23 sampai 82 tahun, dengan subyek perempuan sebanyak 6 orang dan laki-laki sebanyak 20 orang. *Channel* yang digunakan sesuai dengan sistem 10-20 internasional (FP1-F3, F3-C3, C3-P3, P3-O1 dan/atau FP2-F4, F4-C4, C4-P4, P4-O2). Dataset memiliki frekuensi sebesar 512 Hz per *channel*. Masing-masing dataset memiliki panjang durasi yang berbeda-beda. Dalam penelitian ini kelas normal disimbolkan dengan 0 sedangkan kelas RBD disimbolkan dengan 1.

B. Proses Evaluasi hasil klasifikasi

a). Validasi silang k-fold

Sebelum melalui proses klasifikasi, dilakukan validasi silang terlebih dahulu. Validasi silang merupakan metode statistik guna mengevaluasi dan membandingkan algoritma dengan membagi dua bagian pada data yaitu data uji dan data latih, dimana pembagian data

latih bertujuan guna melatih model sedangkan data uji bertujuan guna memvalidasi model [17]. Validasi silang yang dipilih di penelitian ini adalah validasi silang k-fold. Validasi silang k-fold merupakan sebuah metode yang menggunakan keseluruhan data yang ada sebagai data latih dan k partisi $U_1, U_2, \dots, U_k$ dengan masing-masing data uji, seluruh data dipartisi menjadi sebanyak partisi mempunyai jumlah yang sama. Kemudian, proses pengujian dan pelatihan dilakukan sebanyak k iterasi. Pada iterasi ke- i partisi U_i menjadi data uji dan sisanya menjadi data latih [17]. Pada penelitian ini menggunakan validasi silang 49-fold.

b). Pengukuran Hasil Klasifikasi

Dalam penelitian, untuk mengetahui tingkat performa pada suatu algoritma dengan data yang digunakan, dibutuhkan tahap pengukuran hasil klasifikasi. Pada penelitian ini, alat ukur performa algoritma menggunakan *confusion matrix*. *Confusion matrix* adalah sebuah perhitungan dengan dilakukannya perbandingan antara hasil klasifikasi sesuai data yang sesungguhnya dengan jumlah data keseluruhan. Tingkat akurasi inilah yang digunakan sebagai acuan terkait performa algoritma klasifikasi tersebut [27].

Akurasi merupakan perhitungan dengan dilakukannya perbandingan antara jumlah data yang diklasifikasikan secara benar dengan jumlah keseluruhan data [28]. Tingginya nilai akurasi menunjukkan bahwa sistem memiliki kinerja yang baik. Nilai Akurasi dapat dilakukan pada persamaan 9 :

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

Dimana TP (*True Positive*) ialah jumlah data kelas RBD yang terklasifikasi dengan benar pada kelas RBD, FP (*False Positive*) ialah jumlah data kelas normal yang terklasifikasi dengan benar pada kelas RBD, FN (*False Negative*) ialah jumlah data kelas RBD yang terklasifikasi dengan benar pada kelas normal dan TN (*True Negative*) ialah jumlah data kelas normal yang terklasifikasi dengan benar pada kelas normal.

Sensitivitas merupakan perhitungan dengan dilakukannya perbandingan antara jumlah data di kelas positif yang diklasifikasikan secara benar ke kelas positif TP dengan jumlah data yang seharusnya dikelas positif [28]. Sensitivitas dilakukan pada persamaan 10 :

$$Sensitivitas = \frac{TP}{TP+FN} \quad (10)$$

Spesifisitas merupakan perhitungan dengan dilakukannya perbandingan antara jumlah data di kelas negatif yang diklasifikasikan ke kelas negatif TN dengan jumlah data yang seharusnya dikelas negatif [28]. Spesifisitas dilakukan pada persamaan 11:

$$Spesifisitas = \frac{TN}{FP+TN} \quad (11)$$

Geometri mean (G-mean) merupakan perhitungan yang bertujuan untuk mengevaluasi kinerja algoritma klasifikasi yang pada umumnya sering digunakan pada permasalahan kelas dataset yang tidak seimbang. G-mean digunakan untuk mengetahui akurasi keseluruhan dari akurasi kelas minoritas dan mayoritas [29]. G-mean dilakukan pada persamaan 12 :


$$G - mean = \sqrt{sensitivitas * spesifisitas} \quad (12)$$

C. Hasil Eksperimen dengan Algoritma ELM

Pada penelitian ini dilakukan uji coba dataset dengan parameter hasil ekstraksi ciri wavelet db4 level 1 sampai 6 dan parameter banyaknya simpul tersembunyi sebanyak 10, 50, 100, 500 dan 1000. Hasil rata-rata akurasi, sensitivitas, spesifisitas dan g-mean pada setiap level ekstraksi ciri menggunakan algoritma ELM dengan validasi silang 49-fold dan fungsi aktivasi sigmoid biner ditunjukkan pada Tabel 1.


Tabel 1. Hasil eksperimen menggunakan algoritma ELM

Level Ekstraksi Ciri	Nilai Rata-Rata Akurasi (%)	Nilai Rata-Rata Sensitivitas (%)	Nilai Rata-Rata Spesifisitas (%)	Nilai Rata-Rata G-mean (%)
1	67.50 ± 3.44	63.57 ± 8.89	70.00 ± 9.31	67.15 ± 3.31
2	65.36 ± 2.03	64.29 ± 2.53	66.43 ± 4.79	65.28 ± 2.00
3	66.43 ± 2.93	63.57 ± 5.87	69.29 ± 4.07	66.26 ± 2.97
4	65.71 ± 0.80	72.86 ± 6.96	58.57 ± 6.49	65.05 ± 0.96
5	67.50 ± 1.49	65.71 ± 8.97	69.29 ± 8.60	67.03 ± 1.59
6	70.71 ± 5.44	69.29 ± 8.22	72.14 ± 8.14	70.49 ± 5.44



Gambar 1. Grafik waktu pelatihan menggunakan algoritma ELM

Waktu yang diperlukan pada proses pelatihan klasifikasi menggunakan algoritma ELM ditunjukkan pada gambar 1. Waktu tercepat yaitu 0.0313 detik yang dicapai ketika ekstraksi ciri level 5 dan level 6 dengan banyaknya simpul tersembunyi sebesar 10. Sedangkan waktu terlama yaitu 11.578 detik yang dicapai ketika ekstraksi ciri level 1 dengan banyaknya simpul tersembunyi sebesar 1000.



Gambar 2. Grafik waktu pengujian menggunakan algoritma ELM

Waktu yang diperlukan pada proses pengujian klasifikasi menggunakan algoritma ELM ditunjukkan pada gambar 2. Waktu tercepat yaitu 0 detik yang dicapai ketika simpul tersembunyi sebesar 10 pada setiap level ekstraksi ciri, simpul tersembunyi sebesar 50 pada


level ekstraksi ciri 6 dan simpul tersembunyi sebesar 100 pada level ekstraksi ciri 5 dan 6. Sedangkan waktu terlama yaitu 0.2344 detik yang dicapai ketika ekstraksi ciri level 1 dengan banyaknya simpul tersembunyi sebesar 1000.

D. Hasil Eksperimen dengan algoritma *Support Vector Machine* (SVM)

Pada penelitian ini, dataset sinyal EEG dilakukan perbandingan dengan menggunakan algoritma SVM. Klasifikasi menggunakan algoritma SVM dilakukan uji coba dengan beberapa parameter yaitu parameter hasil ekstraksi ciri wavelet db4 level 1 sampai 6, parameter epsilon (ϵ) yaitu 10^{-6} , 10^{-9} dan 10^{-12} serta parameter C yaitu 1,3 dan 6. Parameter C pada algoritma ini menunjukkan nilai batas ambang. Parameter epsilon menunjukkan level akurasi dari fungsi aproksimasi yang mempunyai pengaruh terhadap pemakaian *support vector*. Hasil rata-rata akurasi, sensitivitas, spesifisitas dan g-mean pada setiap level ekstraksi ciri menggunakan algoritma SVM dengan validasi silang 49-fold dan fungsi kernel linier ditunjukkan pada Tabel 2.

Tabel 2. Hasil eksperimen menggunakan algoritma SVM


Level Ekstraksi Ciri	Nilai Rata-Rata Akurasi (%)	Nilai Rata-Rata Sensitivitas (%)	Nilai Rata-Rata Spesifisitas (%)	Nilai Rata-Rata G-mean (%)
1	53.32 ± 0.82	51.65 ± 6.14	54.99 ± 3.32	53.03 ± 1.13
2	55.90 ± 1.05	52.45 ± 6.78	59.35 ± 5.29	55.50 ± 1.39
3	56.43 ± 1.12	59.01 ± 4.30	53.79 ± 5.27	56.19 ± 1.32
4	60.74 ± 2.04	56.12 ± 7.68	65.37 ± 4.59	60.29 ± 2.53
5	65.84 ± 1.94	64.27 ± 1.87	67.40 ± 2.90	65.80 ± 1.94
6	77.27 ± 1.02	77.82 ± 2.92	76.67 ± 1.27	77.22 ± 1.05



Gambar 3. Grafik waktu pelatihan menggunakan algoritma SVM

Waktu yang diperlukan pada proses pelatihan klasifikasi algoritma SVM ditunjukkan pada gambar 3. Waktu tercepat yaitu 1.49 detik yang dicapai ketika ekstraksi ciri level 6

dengan nilai epsilon 10^{-6} serta $C = 1$. Sedangkan waktu terlama yaitu 14077.60 detik yang dicapai ketika ekstraksi ciri level 1 dengan nilai epsilon 10^{-12} serta $C = 6$.



Gambar 4. Grafik waktu pengujian menggunakan algoritma SVM


Waktu yang diperlukan pada proses pengujian klasifikasi menggunakan algoritma ELM ditunjukkan pada gambar 4. Waktu tercepat yaitu 0.31 detik yang dicapai ketika ekstraksi ciri level 6 dengan nilai epsilon 10^{-6} serta $C = 6$. Sedangkan waktu terlama yaitu 37.21 detik yang dicapai ketika ekstraksi ciri level 1 dengan nilai epsilon 10^{-12} serta $C = 6$.

E. Hasil Eksperimen dengan algoritma Backpropagation

Pada penelitian ini, dataset sinyal EEG juga dilakukan perbandingan menggunakan algoritma backpropagation. Klasifikasi menggunakan algoritma backpropagation dilakukan uji coba dengan beberapa parameter yaitu parameter hasil ekstraksi ciri wavelet db4 level 1 sampai 6, parameter lapisan tersembunyi sebanyak 10, 50 dan 100 serta parameter *learning rate* dengan nilai 0.3, 0.6 dan 0.9. Hasil rata-rata akurasi, sensitivitas, spesifisitas dan g-mean pada setiap level ekstraksi ciri menggunakan backpropagation dengan validasi silang 49-fold dan maksimum epoch sebesar 500 ditunjukkan pada tabel 3.


Tabel 3. Hasil eksperimen menggunakan algoritma backpropagation

Level Ekstraksi Ciri	Nilai Rata-Rata Akurasi (%)	Nilai Rata-Rata Sensitivitas (%)	Nilai Rata-Rata Spesifisitas (%)	Nilai Rata-Rata G-mean (%)
1	73.16 ± 1.65	76.19 ± 2.15	60.18 ± 6.67	67.61 ± 3.74
2	76.07 ± 2.27	78.94 ± 2.26	65.39 ± 5.32	71.80 ± 3.42
3	77.71 ± 1.16	79.76 ± 1.89	71.07 ± 7.95	75.17 ± 3.62
4	77.01 ± 1.29	78.89 ± 1.49	69.37 ± 5.13	73.93 ± 2.72
5	77.59 ± 1.18	80.09 ± 2.18	68.80 ± 3.14	74.20 ± 1.43
6	83.81 ± 1.40	86.31 ± 2.28	77.11 ± 3.39	81.55 ± 1.75



Gambar 5. Grafik waktu pelatihan menggunakan algoritma backpropagation

Waktu yang diperlukan pada proses pelatihan klasifikasi menggunakan algoritma backpropagation ditunjukkan pada gambar 5. Waktu tercepat yaitu 8.335 detik yang dicapai ketika ekstraksi ciri level 6 dengan *learning rate* yaitu 0.6 di lapisan tersembunyi sebanyak 10. Sedangkan waktu terlama yaitu 473.859 detik yang dicapai ketika ekstraksi ciri level 1 dengan *learning rate* 0.9 di lapisan tersembunyi sebanyak 100.



Gambar 6. Grafik waktu pengujian menggunakan algoritma backpropagation

Waktu yang diperlukan pada proses pengujian klasifikasi menggunakan algoritma ELM ditunjukkan pada gambar 6. Waktu tercepat yaitu 0.0469 detik yang dicapai ketika ekstraksi ciri level 4 dengan *learning rate* yaitu 0.6 dan 0.9 di lapisan tersembunyi sebanyak 50, ekstraksi ciri level 5 dengan *learning rate* yaitu 0.6 di lapisan tersembunyi sebanyak 10

serta ekstraksi ciri level 6 dengan *learning rate* yaitu 0.3 di lapisan tersembunyi sebanyak 50. Sedangkan waktu terlama yaitu 0.5313 detik yang dicapai ketika ekstraksi ciri level 1 dengan *learning rate* 0.3 di lapisan tersembunyi sebanyak 100.

F. Komparasi algoritma ELM, SVM dan Backpropagation

Tabel perbandingan rata-rata akurasi dan waktu antara algoritma ELM, SVM dan backpropagation ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan algoritma ELM, SVM dan Backpropagation

Algoritma	Level Ekstraksi Ciri	Nilai Rata-Rata Akurasi (%)	Nilai Rata-Rata Waktu Pembuatan Model (s)	Nilai Rata-Rata Waktu Pengujian (s)
ELM	1	67.50 ± 3.44	3.55 ± 4.81	0.10 ± 0.09
	2	65.36 ± 2.03	2.62 ± 3.84	0.08 ± 0.08
	3	66.43 ± 2.93	2.18 ± 3.36	0.07 ± 0.08
	4	65.71 ± 0.80	1.96 ± 3.17	0.06 ± 0.05
	5	67.50 ± 1.49	1.77 ± 2.86	0.05 ± 0.05
	6	70.71 ± 5.44	1.62 ± 2.77	0.04 ± 0.06
SVM	1	53.39 ± 0.84	3491.53 ± 4537.21	15.60 ± 8.45
	2	55.90 ± 1.05	1075.79 ± 1360.09	8.71 ± 3.56
	3	56.43 ± 1.12	243.76 ± 215.41	4.74 ± 1.66
	4	60.74 ± 2.04	76.99 ± 62.82	3.08 ± 1.99
	5	65.84 ± 1.94	21.66 ± 17.22	1.34 ± 0.62
	6	77.27 ± 1.02	7.80 ± 7.15	0.85 ± 0.77
Backpropagation	1	73.16 ± 1.65	346.90 ± 121.92	0.33 ± 0.16
	2	76.07 ± 2.27	164.79 ± 70.19	0.16 ± 0.07
	3	77.71 ± 1.16	88.40 ± 39.54	0.11 ± 0.04
	4	77.01 ± 1.29	51.84 ± 23.90	0.09 ± 0.03
	5	77.59 ± 1.18	31.24 ± 16.52	0.07 ± 0.02
	6	83.81 ± 1.40	21.36 ± 11.55	0.07 ± 0.02

Berdasarkan tabel 4. dapat dilihat bahwa nilai rata-rata akurasi terbaik setiap level dicapai ketika dataset sinyal EEG diklasifikasikan menggunakan algoritma backpropagation. Sedangkan nilai rata-rata waktu pelatihan dan waktu pengujian tercepat dicapai ketika dataset sinyal EEG diklasifikasikan menggunakan algoritma ELM.

G. Analisis Hasil

Penelitian ini dilakukan klasifikasi RBD berdasarkan sinyal EEG menggunakan algoritma ELM dengan parameter level ekstraksi ciri dan banyaknya simpul tersembunyi. Hasil klasifikasi ELM dengan akurasi tertinggi dalam bentuk *confusion matrix* ditunjukkan pada Tabel 5.

Tabel 5. *Confusion Matrix* ELM level ekstraksi ciri 6 dengan Simpul Tersembunyi 500

Kelas	RBD	Normal
RBD	23	7
Normal	5	21

Berdasarkan Tabel 5. Menunjukkan bahwa algoritma ELM dapat mengklasifikasikan gangguan tidur RBD dengan non RBD atau normal berdasarkan sinyal EEG. Hasil

eksperimen menggunakan algoritma ELM menunjukkan akurasi tertinggi berada pada level ekstraksi ciri 6 dengan nilai rata-rata akurasi sebesar $70.71\% \pm 5.44$, hal ini dikarenakan semakin tinggi level ekstraksi ciri maka semakin tinggi pula data akan di ekstraksi lebih detail atau lebih mewakili ciri dari data ekstraksi sebelumnya. Semakin tinggi level ekstraksi ciri, banyak fitur data akan lebih sedikit dibandingkan dengan data sebelumnya. Sinyal EEG yang diekstraksi pada level 2 menghasilkan banyak fitur setengah dari data yang diekstraksi pada level 1.

ELM mempunyai kemampuan klasifikasi yang baik, hal ini dapat dibuktikan dengan cepatnya waktu dalam proses pelatihan maupun pengujian klasifikasi. Waktu pada proses klasifikasi dipengaruhi oleh banyaknya fitur data, artinya semakin tinggi level ekstraksi ciri maka akan sedikit waktu yang diperlukan. Selain fitur data, banyaknya hidden node juga berpengaruh terhadap waktu klasifikasi. Banyaknya simpul tersembunyi menentukan banyaknya penghubung yang terbentuk antara lapisan masukan dan lapisan keluaran yang digunakan untuk memproses fitur data sehingga semakin banyak simpul tersembunyi maka semakin lama pula waktu yang dibutuhkan. Pada penelitian ini banyaknya simpul tersembunyi tidak berpengaruh signifikan terhadap akurasi, hal ini disebabkan karena pengaruh masukan bobot dan bias yang diinisialisasi secara acak, sehingga semakin banyak simpul tersembunyi maka semakin banyak penghubung yang terbentuk sehingga akan semakin banyak hasil yang bisa didapatkan. Dataset yang telah digunakan dalam penelitian ini, juga digunakan oleh penelitian [11] yang menggunakan algoritma Random Forest (RF) untuk mengklasifikasi RBD dan menghasilkan akurasi tertinggi mencapai 96%, jika dibandingkan dengan penggunaan algoritma ELM yang menghasilkan nilai rata-rata akurasi sebesar $70.71\% \pm 5.44$ menunjukkan juga bahwa ELM mempunyai kemampuan klasifikasi yang cukup baik.

Untuk mengetahui kinerja klasifikasi algoritma ELM dengan algoritma lainnya, dilakukan komparasi dengan algoritma SVM dan backpropagation. Hasil komparasi menyatakan akurasi terbaik didapatkan menggunakan algoritma backpropagation dengan nilai rata-rata akurasi tertinggi yaitu $83.81\% \pm 1.40$ yang dicapai ketika level ekstraksi ciri 6 dibandingkan dengan algoritma ELM dengan nilai rata-rata akurasi tertinggi yaitu $70.71\% \pm 5.44$ yang dicapai ketika level ekstraksi ciri 6. Hal ini sesuai dengan penelitian [30] dan [31] yang membuktikan bahwa algoritma backpropagation memiliki kinerja akurasi terbaik dibandingkan algoritma ELM. Namun berdasarkan kecepatan waktu yang digunakan dalam proses klasifikasi RBD berdasarkan sinyal EEG, algoritma ELM jauh lebih unggul dikarenakan menghasilkan waktu klasifikasi tercepat, hal ini relevan dengan penelitian [12] yang mengatakan bahwa ELM mempunyai *learning speed* yang cepat dikarenakan ELM tidak memerlukan iterasi dalam melakukan pelatihan dan penentuan elemen masukan bobot dan bias yang dilakukan secara acak sehingga waktu yang diperlukan dalam proses klasifikasi berjalan dengan singkat. Sedangkan algoritma SVM menghasilkan rata-rata akurasi yang terendah serta mempunyai waktu komputasi yang paling lama dibandingkan ELM dan backpropagation.

IV. KESIMPULAN

Klasifikasi gangguan tidur RBD berdasarkan sinyal EEG diawali dengan pra-pemrosesan data, ekstraksi fitur dan klasifikasi. pra pemrosesan data meliputi pembagian sinyal per 30 detik dan *smoothing* data. Proses ekstraksi ciri menggunakan Transformasi Wavelet Diskrit (DWT). Pada penelitian ini ekstraksi ciri dilakukan pada level 1-6. Proses klasifikasi RBD berdasarkan sinyal EEG menggunakan algoritma ELM dengan fungsi aktivasi yaitu fungsi sigmoid biner. Sebelum proses pelatihan pada algoritma ELM, terlebih dahulu dilakukan undersampling untuk mengatasi ketidakseimbangan jumlah kelas.

ELM merupakan jaringan syaraf tiruan single hidden layer feedforward neural networks (SLFNs) dengan masukan bobot serta bias yang ditentukan secara acak. Tiga layer penyusun jaringan ELM yaitu layer masukan, layer *hidden* dan layer keluaran. Bobot

masuk ke setiap *node* mempunyai nilai yang berbeda guna menghubungkan layer masukan ke *hidden node*, kemudian seluruh *hidden node* terhubung ke semua *node* keluaran. Pada penelitian ini banyaknya *hidden node* dilakukan sebanyak 10, 50, 100, 500 dan 1000.

Hasil klasifikasi gangguan tidur RBD berdasarkan sinyal EEG menggunakan algoritma ELM menunjukkan bahwa algoritma ELM bisa mengklasifikasikan gangguan tidur RBD dengan non RBD berdasarkan sinyal EEG dengan nilai rata-rata akurasi sebesar $70.71\% \pm 5.44$ yang dicapai pada saat level ekstraksi ciri 6. Hasil komparasi algoritma ELM dengan algoritma SVM dan backpropagation dalam pengklasifikasian gangguan tidur RBD berdasarkan sinyal EEG menunjukkan bahwa algoritma backpropagation memiliki rata-rata akurasi terbaik yaitu mencapai $83.81\% \pm 1.40$ yang dicapai ketika level ekstraksi ciri 6. Namun berdasarkan waktu yang dibutuhkan dalam pembuatan model, algoritma ELM lebih unggul dalam kecepatan proses klasifikasi RBD berdasarkan sinyal EEG yaitu mencapai 1.62 ± 2.77 detik ketika level ekstraksi ciri 6 dibandingkan algoritma SVM dan backpropagation.

REFERENSI

- [1] Indrawati, L., & Nuryanti, L. (2018). Hubungan Posisi Tidur dengan Kualitas Tidur Pasien Congestive Heart Failure. *Jurnal Kesehatan Budi Luhur Cimahi, Volume 11 Nomor 2*.
- [2] Yulia, M., Anita, & Miranda, C. (2019). Klasifikasi Sinyal EEG dengan Stimulasi Aromatik Menggunakan Metode Support Vector Machine. *Jurnal Ilmu Komputer dan Bisnis, Volume 10, Nomor 1, Mei 2019*.
- [3] Sunwoo, J.-S., Lee, S., Kim, J.-H., Lim, J.-A., Kim, T.-J., Byun, J.-I., . . . Jung, K.-Y. (2017). Altered Functional Connectivity in Idiopathic Rapid Eye Movement Sleep Behavior Disorder: A restin-State EEG Study. *SLEEP, Vol. 40, No. 6*.
- [4] Hogl, B., & Stefani, A. (2017). REM Sleep Behavior Disorder (RBD) Update on Diagnosis and Treatment. *Somnologi, Volume 21, Supplement 1, pp 1-8*.
- [5] Clinic, M. (2018). *Mayo Clinic*. Diambil kembali dari Mayo Clinic: <https://www.mayoclinic.org/diseases-conditions/rem-sleep-behavior-disorder/symptoms-causes/syc-20352920>.
- [6] Pramartaningthya, E. K., & M., M. S. (2017). Optimasi Daya Spektral Pada Sinyal Lemah Electroencephalography (EEG) dengan Metode Algoritma Genetik. *Multitek Indonesia Jurnal Ilmiah, Vol. 11, No. 2, Desember 2017*.
- [7] Fauzan, A. D., Lailiyya, N., Kusumandari, D. E., & Suratman, F. Y. (2019). Analisa Pengaruh Rangsangan Aromaterapi Lavender dan Kayu Cendana Terhadap Kualitas Tidur Berbasis Gelombang EEG. *Jurnal TEKTRIKA, Vol. 4, No. 1*.
- [8] Arnaldi, D., Antelmi, E., St. Louis, E., Postuma, R., & Arnulf, I. (2017). Idiopathic REM Sleep Behavior Disorder and Neurodegenerative risk : to tell or not to tell to the patient? how to minimize the risk? *Sleep Medicine Reviews, Volume 36, 82-95*.
- [9] Ruffini, G., Ibanez, D., Castellano, M., Dunne, S., & Soria-Frisch, A. (2016). EEG-driven RNN Classification for Prognosis of Neurodegeneration in At-Risk Patients. *International Conference on Artificial Neural Networks 2016* (pp. 306-313). Springer Link.
- [10] Ruffini, G., Ibanez, D., Castellano, M., Dubreuil-Vail, L., Soria-Frisch, A., Postuma, R., . . . Montplaisir, J. (2019). Deep Learning With EEG Spectrograms in Rapid Eye Movement Behavior Disorder. *Frontiers in Neurology, 10:806*.
- [11] Cooray, N., Andreotti, F., Symmonds, M., Hu, M., & Vos, M. (2019). Detection of REM Sleep Behaviour Disorder by Automated Polysomnography Analysis. *Clinical Neurophysiology, Volume 130, Issue 4, 505-514*.

- [12] Fikriya, Z. A., Irawan, M. I., & Soetrisno. (2017). Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. *Jurnal Sains dan Seni ITS Vol. 6, No. 1*, 2337-3520.
- [13] Irawan, D. P., Cholissodin, I., & Santoso, E. (2018). Klasifikasi Risiko Gagal Ginjal Kronis Menggunakan Extreme Learning Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer. Vol. 2, No. 11*, 5220-5228.
- [14] Waskito, S. B., Cholissodin, I., & Santoso, E. (2019). Implementasi Algoritma Extreme Learning Machine (ELM) untuk Klasifikasi Penanganan Human Papilloma Virus (HPV). *Jurnal Pengembangan Teknologi Informai dan Ilmu Komputer. Vol. 3, No. 1*, 84-89.
- [15] Raposo, A., Vicens, L., Clithero, J. A., Dobbins, I. G., & Huettel, S. A. (2011). Contributions of frontopolar cortex to judgments about self, others and relations. *Social Cognitive and Affective Neuroscience*, 6(3), 260-269.
- [16] Lusiawati, I. (2017). Pengembangan Otak Dan Optimalisasi Sumber Daya Manusia. *Jurnal TEDC, 11(2)*, 162-171.
- [17] Wulandari, I. N., & Juniati, D. (2017). Penerapan Dimensi Fraktal Untuk Klasifikasi Laras Pada Musik Gamelan. *Jurnal Ilmiah Matematika, Volume 3 No.6*.
- [18] Hasanah, N., Muljono, A. B., & Suksmadana, I. B. (2018). Penentuan Lokasi Gangguan Hubung Singkat Pada Saluran Transmisi 150 KV Berbasis Transformasi Wavelet. *Dielektrika, Vol. 5, No. 1*, 42-47.
- [19] Arif, A., & Djamal, E. (2014). Klasifikasi Tingkat Kelelahan Berdasarkan Sinyal Electroencephalogram (EEG) Menggunakan Jaringan Syaraf Tiruan Backpropagation. *SNIJA Unjani*.
- [20] Ekayama, R., Djamal, E., & Komarudin, A. (2016). Identifikasi Kondisi Rileks dari Sinyal EEG menggunakan Wavelet dan Learning Vector Quantization. *Prosiding SNST ke-7 Fakultas Teknik Universitas Wahid Hasyim Semarang*.
- [21] Karmila, R., Djamal, E., & Nursantika, D. (2016). Identifikasi Tingkat Konsentrasi dari Sinyal EEG Wavelet dan Adaptive Backpropagation. *SNATi 2016*.
- [22] Irawan, E., & Wahono, R. S. (2015). Penggunaan random under sampling untuk penanganan ketidakseimbangan kelas pada prediksi cacat software berbasis neural network. *IlmuKomputer. com Journal of Software Engineering, 1(2)*, 92-100.
- [23] Sugianto, N. A., Cholissodin, I., & Widodo, A. W. (2018). Klasifikasi Keminatan Menggunakan Algoritme Extreme Learning Machine dan Particle Swarm Optimization untuk Seleksi Fitur (Studi Kasus : Program Studi Teknik Informatika Filkom UB). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 2, No.5*, 1856-1865.
- [24] Prakoso, E. C., Wisesty, U. N., & Jondri. (2016). Klasifikasi Keadaan Mata Berdasarkan Sinyal EEG Menggunakan Extreme Learning Machines. *Ind. Journal on Computing. Vol. 1, Issue 2*, 97-116.
- [25] *physionet.org*. (2012). Dipetik 10 Desember, 2019, dari *physio.net*: <https://physionet.org/content/capslpdb/1.0.0/>
- [26] MG Terzano, L Parrino, A Sherieri, R Chervin, S Chokroverty, C Guilleminault, M Hirshkowitz, M Mahowald, H Moldofsky, A Rosa, R Thomas, A Walters. Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (CAP) in human sleep. *Sleep Med* 2001 Nov; 2(6):537-553.
- [27] Indrayanti, Sugianti, D., & Karomi, M. A. (2017). Peningkatan akurasi Algoritma KNN dengan Seleksi Fitur Gain Ratio untuk Klasifikasi Penyakit Diabetes Mellitus. *IC-Tech Volume XII No. 2*.
- [28] Khadijah, & Kusumaningrum, R. (2019). Ensemble Classifier untuk Klasifikasi Kanker Payudara. *IT Journal Research and Development (ITJRD), Vol.4, No.1*, 61-71.
- [29] Pristyanto, Y. (2019). Penerapan Metode Ensemble Untuk Meningkatkan Kinerja Algoritme Klasifikasi Pada Imbalanced Dataset. *Jurnal Teknoinfo, 13(1)*, 11-16.

- [30] Kom, O. P. B. S., & Ronaldo, R. (2019). Perbandingan Metode Extreme Learning Machine Dan Backpropagation Untuk Mengklasifikasi Phising Webssites. *Journal of Informatics Engineering Research and Technology*, 1(1).
- [31] Irawan, M. I., & Imah, E. M. (2015). Study Comparison Backpropagation, Support Vector Machine, and Extreme Learning Machine for Bioinformatics Data. *Jurnal Ilmu Komputer dan Informasi*, 8(1), 53-59.