

IMPLEMENTASI ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM PADA SISTEM DETEKSI KELELAHAN MENTAL BERBASIS SINYAL ELECTROENCEPHALOGRAM

Teguh Surya Darma Santoso¹, Edita Rosana Widasari^{*2}

^{1,2}Universitas Brawijaya, Malang

Email: ¹teguhsurya.santoso@gmail.com, ²editarosanaaw@ub.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 22 Juni 2024, diterima untuk diterbitkan: 17 Juni 2025)

Abstrak

Kelelahan mental merupakan fenomena umum pada pelajar dan pekerja yang ditandai dengan penurunan energi, motivasi, kemampuan kognitif dan lainnya. Jika tidak segera ditangani, maka dapat menyebabkan berbagai gangguan kesehatan fisik maupun mental dan meningkatkan resiko kecelakaan. Psikolog mengidentifikasi kelelahan mental melalui pengukuran secara subjektif dengan kuesioner atau pengukuran secara kognitif dengan tes kognitif. Namun, proses tersebut memerlukan waktu yang lama dan hasil pengukuran cenderung bersifat subjektif, rentan terhadap kesalahan dan kurang valid untuk pasien yang terbiasa dengan aktivitas kognitif. Oleh karena itu, penelitian ini mengusulkan implementasi metode *Adaptive Neuro-Fuzzy Inference System* pada sistem deteksi kelelahan mental berbasis sinyal *electroencephalogram* satu kanal untuk meningkatkan keakuratan diagnosis, efisiensi waktu dan kenyamanan pengguna. Sistem menggunakan metode normalisasi *min-max*, segmentasi, dekomposisi *Discrete Wavelet Transform*, dan ekstraksi fitur *Power Percentage*, *Standard Deviation*, *Mean Absolute Value* dari sinyal *theta*. Sistem dikemas dalam aplikasi *Graphical User Interface* berbasis MATLAB sehingga dapat menampilkan keluaran berupa grafik sinyal *theta*, nilai-nilai ekstraksi fitur, dan hasil diagnosis pada laptop pengguna. Sistem ini menghasilkan akurasi klasifikasi sebesar 90% dan rata-rata waktu komputasi mencapai 0,45 detik. Sistem ini dapat diandalkan dan digunakan sebagai alat *validator* tambahan untuk psikolog dalam mendiagnosis kelelahan mental.

Kata kunci: ANFIS, EEG, Kelelahan Mental, Sistem Deteksi

IMPLEMENTATION OF THE ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM FOR MENTAL FATIGUE DETECTION SYSTEM BASED ON ELECTROENCEPHALOGRAM SIGNALS

Abstract

Mental fatigue is a common phenomenon in students and workers characterized by decreased energy, motivation, cognitive ability and more. If left untreated, it can lead to various physical and mental health problems and increase the risk of accidents. Psychologists identify mental fatigue through subjective measurements with questionnaires or cognitive measurements with cognitive tests. However, the process takes a long time and the measurement results tend to be subjective, prone to errors and less valid for patients who are accustomed to cognitive activities. Therefore, this study proposes the implementation of the *Adaptive Neuro-Fuzzy Inference System* method on a single-channel *electroencephalogram* signal-based mental fatigue detection system to improve diagnosis accuracy, time efficiency and user convenience. The system uses *min-max* normalization, segmentation, *Discrete Wavelet Transform* decomposition, and *Power Percentage*, *Standard Deviation*, *Mean Absolute Value* feature extraction methods from *theta* signals. The system is packaged in a MATLAB-based *Graphical User Interface* application so that it can display output in the form of *theta* signal graphs, feature extraction values, and diagnosis results on the user's laptop. The system produced a classification accuracy of 90% and an average computation time reached 0.45 seconds. The system is reliable and can be used as an additional *validator* tool for psychologists in diagnosing mental fatigue.

Keywords: ANFIS, Detection System, EEG, Mental Fatigue

1. PENDAHULUAN

Kelelahan mental merupakan fenomena umum yang terjadi pada kalangan pelajar dan pekerja. Hal

ini dapat disebabkan oleh lama durasi aktivitas yang memerlukan konsentrasi dan kemampuan kognitif yang tinggi seperti belajar dan bekerja. Gejala dari kelelahan mental dapat ditandai dengan penurunan

energi, motivasi, dan kemampuan kognitif secara signifikan. Salah satu istilah lain untuk kondisi kelelahan mental yang sering digunakan adalah *burnout* (Levine, 2020). Menurut survei kerja dan kesejahteraan dari American Psychological Association 2021 yang diikuti oleh 1.501 orang dewasa Amerika Serikat, menyatakan bahwa 79% pekerja mengalami stres terkait pekerjaan dan hampir 3 dari 5 pekerja tersebut mengalami dampak negatif dari stres yaitu terjadinya gejala kelelahan mental atau *burnout* (Abramson, 2022). Selain itu, riset mandiri dari Laboratorium Manajemen Psikologi Universitas Gajah Mada menunjukkan bahwa tingkat *academic burnout* yang dialami oleh mahasiswa kluster Sosio-Humaniora UGM angkatan 2019 – 2021 mencapai tingkat sedang dengan rata-rata 59,36% dan dari tiga komponen *academic burnout*, kelelahan (*exhaustion*) yang mengacu pada keadaan kelelahan intens akibat tuntutan pekerjaan yang berlebihan berada dalam kategori tertinggi yang dialami oleh 73,12% partisipan (LM Psikologi UGM, 2021). Jika kondisi ini tidak segera ditangani, maka dapat menimbulkan dampak negatif pada kesehatan fisik dan mental seperti sakit kepala, depresi, insomnia, kecemasan berlebih, parkinson, penyakit jantung, diabetes, stroke dan peningkatan risiko kecelakaan fatal dalam pekerjaan yang membutuhkan kewaspadaan tinggi seperti dokter bedah, pilot atau pengemudi. (Setiawan, et al., 2019; Yaacob, et al., 2023).

Kelelahan mental dapat diidentifikasi oleh psikolog dengan melalui beberapa tahapan meliputi pemeriksaan fisik, wawancara, hingga pengukuran secara subjektif dengan kuesioner seperti *Swedish Occupational Fatigue Inventory* (SOFI), *NASA Task Load Index* (NASA-TLX), dan sebagainya atau pengukuran secara kognitif melalui berbagai jenis tes kognitif. Namun, keseluruhan tahapan ini memerlukan waktu yang lama dan hasil dari pengukuran ini juga cenderung bersifat subjektif, rentan terhadap kesalahan dan kurang valid untuk pasien yang terbiasa dengan tes atau aktivitas kognitif (Setiawan, et al., 2019; Yaacob, et al., 2023). Oleh karena itu, untuk mengatasi hal tersebut, maka dapat menggunakan pengukuran secara fisiologis sebagai alat *validator* tambahan dalam mengidentifikasi kelelahan mental.

Pengukuran secara fisiologis merupakan metode untuk mengukur aktivitas yang terjadi dalam tubuh manusia dan dapat diamati pada berbagai parameter seperti denyut jantung melalui *electrocardiography* (ECG), gerakan bola mata melalui *electrooculography* (EOG), dan aktivitas listrik otak melalui *electroencephalography* (EEG). Pendekatan yang terbukti paling objektif dan akurat dalam mendeteksi kelelahan mental adalah pengukuran berbasis sinyal EEG (Wang, et al., 2023). Penelitian yang dilakukan oleh Tran, et al. (2020) menunjukkan bahwa aktivitas gelombang otak theta mengalami peningkatan yang valid dan konsisten

pada kondisi lelah mental di korteks otak *frontal*, *central*, dan *posterior* sehingga cocok untuk digunakan sebagai *biomarker* saraf yang handal untuk sistem deteksi kelelahan mental.

Penelitian *Brain Computer Interface* (BCI) berbasis sinyal EEG untuk mendeteksi kelelahan mental telah banyak dilakukan salah satunya dilakukan oleh Setiawan, et al. (2019) yang menghasilkan akurasi klasifikasi mencapai 95,8% menggunakan fitur *Power Percentage* (PP) dan algoritma klasifikasi *Relevance Vector Machine* (RVM). Meskipun memiliki nilai akurasi tinggi, penelitian ini menggunakan sinyal EEG banyak kanal yang masih memiliki beberapa kendala diantaranya kompleksitas komputasi yang tinggi sehingga sulit untuk diterapkan dalam sistem dan cenderung menyebabkan rasa tidak nyaman bagi penggunaannya (Hendrawan, 2021). Selain itu, penelitian ini juga belum mengembangkan sebuah sistem atau aplikasi yang dapat digunakan langsung oleh psikolog.

Penelitian dari Hendrawan (2021) melakukan pendekatan berbeda dengan menggunakan sinyal EEG satu kanal untuk deteksi kelelahan mental menghasilkan akurasi klasifikasi mencapai 78,13% menggunakan fitur *Mean Absolute Value* (MAV), *Average Power* (AVP), *Standard Deviation* (SD) dan algoritma klasifikasi *Linear Discriminant Analysis* (LDA). Dalam penelitian ini, dibuktikan bahwa metode segmentasi sinyal pada sinyal EEG satu kanal dan penerapan metode dekomposisi *Discrete Wavelet Transform* (DWT) dapat memberi informasi lebih beragam dan detail mengenai ciri kondisi kelelahan mental sehingga dapat menghasilkan akurasi klasifikasi lebih tinggi pada sinyal EEG yang bersumber dari satu kanal. Namun, penelitian ini belum melakukan pengembangan sistem atau aplikasi yang dapat digunakan oleh psikolog.

Adaptive Neuro-Fuzzy Inference System (ANFIS) merupakan kombinasi algoritma jaringan saraf tiruan dan sistem inferensi *fuzzy* sehingga memiliki keunggulan dari kedua sistem dalam melakukan klasifikasi. ANFIS telah digunakan dalam beberapa penelitian BCI berbasis sinyal EEG diantaranya, penelitian yang dilakukan oleh Oktiana, et al. (2023) untuk klasifikasi empat jenis emosi manusia (senang, netral, takut, sedih) yang menghasilkan akurasi pelatihan mencapai 98,92% dan akurasi pengujian mencapai 98,79%. Selain itu, penelitian oleh Novitasari, et al. (2019) untuk klasifikasi epilepsi dalam dua kelas (*Normal - Epilepsy*) menghasilkan akurasi mencapai 100% dan klasifikasi ke dalam tiga kelas (*Normal - Not Seizure Epilepsy - Epilepsy*) menghasilkan akurasi mencapai 89,33%. Berdasarkan hal tersebut, metode ANFIS menunjukkan performa klasifikasi yang sangat baik sehingga diharapkan dapat meningkatkan tingkat akurasi klasifikasi dalam sistem deteksi kelelahan mental berbasis sinyal EEG. Oleh karena itu, penelitian ini mengusulkan penerapan metode *Adaptive Neuro-Fuzzy Inference System* pada sistem

deteksi kelelahan mental berbasis sinyal *electroencephalogram* satu kanal untuk meningkatkan tingkat akurasi, efisiensi waktu komputasi dan memberikan kemudahan serta kenyamanan bagi psikolog maupun pasien.

2. DASAR TEORI

2.1. Electroencephalography

Electroencephalography (EEG) merupakan metode non-invasif yang dapat mengukur dan merekam aktivitas listrik otak menggunakan elektroda yang ditempelkan pada kulit kepala (Khakim & Kusrohmaniah, 2021). Aktivitas listrik otak dihasilkan oleh sel-sel neuron di otak. Pengukuran dengan EEG lebih objektif dan akurat dari pengukuran dengan EOG atau ECG dalam mendiagnosis kondisi kelelahan mental (Wang et al., 2023). Hasil pengukuran EEG direpresentasikan dalam bentuk grafik sinyal dalam domain waktu yang disebut *electroencephalogram*. Pada grafik tersebut, sumbu x mewakili waktu dan sumbu y mewakili amplitudo. Terdapat lima jenis gelombang otak EEG yang dikategorikan berdasarkan rentang frekuensi yang dapat dilihat pada Tabel 1.

Tabel 1. Jenis Gelombang Otak

Jenis Gelombang	Rentang Frekuensi (Hz)
Delta (δ)	0.5 – 4
Theta (θ)	4 – 8
Alpha (α)	8 – 13
Beta (β)	13 – 30
Gamma (γ)	>30

2.2. Normalisasi Min-Max

Normalisasi *Min-Max* digunakan untuk menyederhanakan proses kalkulasi dengan cara menyeragamkan rentang amplitudo sinyal EEG tanpa mengubah bentuk dan informasi yang terkandung dalam sinyal tersebut (Hendrawan, 2021). Dalam penelitian ini, hasil normalisasi sinyal EEG berada dalam rentang maksimal dan minimal amplitudo yaitu 1 hingga -1. Normalisasi *min-max* dihitung menggunakan Persamaan (1).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} * (A - B) + B \quad (1)$$

Dimana variabel x adalah sinyal EEG, x_{min} adalah nilai minimum sinyal, x_{max} adalah nilai maksimum sinyal, A adalah batas atas amplitudo dan B adalah batas bawah amplitudo.

2.2. Segmentasi

Segmentasi sinyal merupakan pemisahan gelombang sinyal utuh menjadi beberapa bagian sinyal berdasarkan interval waktu tertentu. Penerapan segmentasi pada gelombang sinyal EEG satu kanal dapat memberikan informasi yang lebih beragam dan

detail, sehingga ciri kondisi kelelahan mental dapat dikarakterisasi dengan baik (Hendrawan, 2021).

2.5. Dekomposisi Discrete Wavelet Transform

Discrete Wavelet Transform (DWT) merupakan teknik dekomposisi yang dapat digunakan untuk menganalisis sinyal EEG dalam domain waktu dan frekuensi. Hal ini dikarenakan sinyal EEG merupakan sinyal *non-stasioner*, yang dimana memiliki perubahan frekuensi dalam tiap satuan waktu (Oktriana, et al., 2023). Penggunaan metode DWT dapat meningkatkan akurasi klasifikasi sinyal EEG satu kanal karena informasi mengenai ciri kelelahan mental dapat lebih mudah ditemukan dalam domain waktu-frekuensi (Hendrawan, 2021). DWT menggunakan teknik *multi-resolution analysis* yang bekerja dengan membagi sinyal masukan menjadi komponen sinyal frekuensi tinggi yaitu *detail* (D) dan sinyal frekuensi rendah yaitu *approximation* (A) menggunakan filter *low-pass* dan *high-pass*. Fungsi *wavelet* DWT yang digunakan dalam penelitian ini adalah *daubechies* (db) dengan tipe db4. Tipe ini dipilih karena karakteristik skala yang serupa dengan sinyal EEG serta terbukti menghasilkan akurasi terbaik dalam klasifikasi sinyal EEG satu kanal menggunakan gelombang hasil dekomposisi DWT db4 dibandingkan dengan tipe db5 atau db6 (Hendrawan, 2021). Ilustrasi dekomposisi sinyal EEG 512 Hertz (Hz) dengan Discrete Wavelet Transform dapat dilihat pada Gambar 1.

2.4. Ekstraksi Fitur Mean Absolute Value, Standard Deviation, Power Percentage

Pada penelitian ini, fitur dalam domain waktu yaitu *Mean Absolute Value* (MAV) dan *Standard Deviation* (SD) dari sinyal theta digunakan karena nilai-nilai fitur tersebut menunjukkan perbedaan kondisi normal dan kelelahan mental yang signifikan (Tyas, Wibawa, Purnomo, 2020). Fitur MAV dan SD dapat dihitung dengan Persamaan (3) dan (4).


$$\mu = \frac{1}{T} \sum_{i=1}^T \chi_i \quad (2)$$

$$MAV = \frac{1}{T} \sum_{i=1}^T |\chi_i| \quad (3)$$

$$SD = \sqrt{\frac{1}{T-1} \sum_{i=1}^T (\chi_i - \mu)^2} \quad (4)$$

Keterangan:

- χ_i = gelombang sinyal segmen ke-i.
- T = panjang sinyal segmen atau jumlah data.
- μ = rata-rata dari sinyal segmen ke-i.



Gambar 1. Dekomposisi Discrete Wavelet Transform 512 Hz

Selain itu, fitur dalam domain frekuensi yaitu *Power Percentage* (PP) juga mampu untuk membedakan kondisi normal dan kelelahan mental (Setiawan, et al., 2019). PP dapat dihitung dengan Persamaan (5).

$$PP_{\theta} = \frac{\sum_{f=f_1}^{f_2} S(f)}{\sum_{f=f_1}^{f_2} S(f)}, f_{\theta} \in [4, 8] \quad (5)$$

Dimana f_1 adalah batas bawah frekuensi dan f_2 adalah batas atas frekuensi. $S(f)$ mewakili nilai *Power Spectral Density* (PSD) yang diperoleh menggunakan metode *welch* pada frekuensi θ (f_{θ}) dari sinyal EEG pada domain waktu. Dalam penelitian ini, gelombang otak yang digunakan adalah gelombang theta yang dinotasikan dengan PP_{θ} .

2.5. Klasifikasi Adaptive Neuro-Fuzzy Inference System

Adaptive Neuro-Fuzzy Inference System (ANFIS) merupakan algoritma kombinasi dari jaringan saraf tiruan dan sistem logika fuzzy metode Takagi-Sugeno-Kang (TSK) yang dikembangkan oleh J.S. Roger Jang pada tahun 1993 (Chopra, et al., 2021). ANFIS memiliki keunggulan dari masing-masing metode sehingga diharapkan dapat menghasilkan klasifikasi yang lebih akurat dengan kemampuan pembelajaran dan pengambilan keputusan berdasarkan data historis, seperti jaringan saraf tiruan dan juga dapat menangani data yang ambigu atau tidak lengkap, seperti sistem inferensi fuzzy (Oktriana, et al., 2023). Kelebihan dari ANFIS diantaranya yaitu kemampuan adaptif yang otomatis, kapasitas belajar yang cepat, kemampuan generalisasi yang tinggi dan mampu mengenali data yang bersifat *non-linear* (Chopra, et al., 2021). Aturan IF-THEN untuk 3 input dalam sistem Takagi-Sugeno adalah sebagai berikut.

Rule 1 : IF x is A_1 , y is B_1 , z is C_1 , THEN f_1

$$= p_1x + q_1y + r_1z + s_1$$

Rule 2 : IF x is A_2 , y is B_2 , z is C_2 , THEN f_2

$$= p_2x + q_2y + r_2z + s_2$$

Rule 3 : IF x is A_3 , y is B_3 , z is C_3 , THEN f_3

$$= p_3x + q_3y + r_3z + s_3$$

Dimana x, y, z merupakan himpunan *crisp*; A_i, B_i, C_i merupakan label linguistik; p_i, q_i, r_i merupakan parameter konsekuensi; f_1, f_2, f_3 merupakan output dari *membership function* fuzzy.

Berdasarkan Gambar 2, stuktur ANFIS terdiri dari 5 lapisan yang menyerupai struktur jaringan saraf tiruan. Berikut penjelasan dari tiap lapisan ANFIS (Chopra, et al., 2021).

Lapisan 1:

Lapisan ini disebut lapisan fuzzifikasi. Fungsi dari lapisan ini yaitu mengkonversi nilai *crisp* menjadi nilai *fuzzy* dengan menggunakan fungsi keanggotaan. Node dihitung dengan Persamaan (6).

$$O_i^1 = \begin{cases} \mu_{A_i}(x), & \forall i = 1, 2, \\ \mu_{B_{i-2}}(x), & \forall i = 3, 4, \\ \mu_{C_{i-4}}(x), & \forall i = 5, 6, \end{cases} \quad (6)$$

Dimana μ merupakan fungsi keanggotaan (*membership function*). Terdapat berbagai fungsi keanggotaan diantaranya *gaussian*, *trapezoidal*, *triangular* dan lainnya. Fungsi keanggotaan *gaussian* dengan Persamaan (7) merupakan pilihan yang optimum (Chopra, et al., 2021).

$$f(x) = a \cdot \exp \left\{ -\frac{(x-b)^2}{2c^2} \right\} \quad (7)$$

Parameter a, b, c merupakan kumpulan parameter premis yang membentuk fungsi keanggotaan.

Lapisan 2:

Lapisan ini disebut lapisan aturan atau *rule layer*. Fungsi dari lapisan ini yaitu menentukan *firing strength* (w_i) atau bobot neuron dari aturan dengan menggunakan nilai fungsi keanggotaan dalam lapisan fuzzifikasi. Node dihitung dengan Persamaan (8).


$$O_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(x) \cdot \mu_{C_i}(x) \quad (8)$$

Lapisan 3:


Lapisan ini disebut lapisan normalisasi. Fungsi dari lapisan ini yaitu pembobotan ulang neuron dan dinormalisasi dengan jumlah bobot semua neuron pada lapisan ini. Node dihitung dengan Persamaan (9).

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum w_i}, \forall i = 1, 2, 3. \quad (9)$$

Dimana $\bar{w}_i$ adalah bobot neuron yang telah dinormalisasi.



Gambar 2. Stuktur ANFIS



Gambar 3. Diagram Blok Sistem

Lapisan 4:

Lapisan ini disebut lapisan defuzzifikasi yang setiap node merupakan node adaptif dan mengandung parameter konsekuen. Lapisan ini berfungsi untuk menkonversi nilai *fuzzy* ke nilai *crisp* kembali dengan Persamaan (10).

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i z + s_i) \quad (10)$$

Dimana p , q , dan r adalah parameter konsekuen. Jumlah parameter konsekuen dari tiap aturan yaitu lebih dari satu jumlah masukan.

Lapisan 5:

Lapisan ini disebut *summation layer*. Lapisan keluaran ini direpresentasikan dalam satu node tetap yang merupakan hasil akumulasi dari semua masukan. Node dapat dihitung dengan Persamaan (11).

$$O_i^5 = f(x, y, z) = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i} \quad (11)$$

ANFIS menggunakan proses pembelajaran *hybrid*, yang dimana parameter diperbarui melalui dua arah dan menggunakan dua algoritma optimasi yang berbeda untuk meminimalisir kesalahan dan mengoptimasi performa ANFIS. Pada arah maju (*forward pass*), parameter premis bernilai tetap dan masukan akan merambat maju ke dalam ANFIS hingga lapisan 4, dimana parameter konsekuen akan diperbarui di lapisan tersebut dengan metode *Least Square Estimation* (LSE) dan keluaran akhir akan dihitung. Saat hasil akhir telah dihitung, arah mundur (*backward pass*) dimulai, dimana sinyal error akan


merambat mundur kembali ke lapisan 1 dan parameter premis akan diperbarui dengan metode *gradient descent*.

3. METODE

3.1. Gambaran Umum Sistem

Keseluruhan sistem meliputi hubungan perangkat keras dan pemrosesan dalam perangkat lunak dapat dilihat dalam bentuk diagram blok pada Gambar 3.

Perangkat keras yang digunakan dalam sistem terdiri dari dua perangkat, yaitu laptop dan Neurosky Mindwave Mobile 2. Masukan dari sistem yaitu berupa akuisisi data sinyal EEG yang dilakukan menggunakan Neurosky Mindwave Mobile 2. Data tersebut akan diproses dengan perangkat laptop. Setiap data sinyal mentah EEG diproses melalui beberapa metode pra-pemrosesan yaitu normalisasi *min-max*, segmentasi dan dekomposisi *discrete wavelet transform*. Kemudian, proses dilanjutkan dengan ekstraksi fitur dalam domain waktu-frekuensi dari sinyal *theta* yaitu *power percentage*, *mean absolute value*, dan *standard deviation*. Nilai fitur dari *dataset* latih diperuntukkan untuk pembuatan model yang didapatkan dari proses pelatihan ANFIS sehingga model tersebut dapat digunakan dalam pengujian. Hasil dari proses klasifikasi kelelahan mental menggunakan metode ANFIS akan ditampilkan pada aplikasi *graphical user interface* (GUI) berbasis MATLAB.



Gambar 4. Teknik Pengumpulan Data

3.2. Teknik Pengumpulan Data

Pengumpulan data dilakukan secara langsung dengan jumlah subjek sebanyak 20 orang yang terdiri dari 10 laki-laki dan 10 perempuan dengan rentang usia 21 hingga 22 tahun. Teknik pengumpulan data dalam penelitian ini terdiri dari tiga tahap yaitu pra-induksi, induksi, dan pasca induksi yang dapat dilihat pada Gambar 4.

Tahap pra-induksi dilakukan untuk mendapatkan data subjek normal. Pada tahap ini, subjek melakukan tiga aktivitas yaitu pengisian kuesioner *Swedish Occupational Fatigue Inventory* (SOFI), perekaman data sinyal EEG selama 5 menit dan tes stroop. Selama perekaman sinyal EEG, subjek diminta untuk menutup mata, rileks dan meminimalisir gerakan guna mengurangi derau pada sinyal EEG yang dapat disebabkan oleh gerakan mata maupun tubuh. Hasil kuesioner SOFI dan rata-rata *response time* (RT) tes stroop diolah untuk memvalidasi kondisi normal subjek.

Pada tahap induksi, subjek diberikan stimulus untuk memicu kondisi kelelahan mental berupa tes pauli. Subjek diminta untuk mengerjakan tes pauli selama 30 menit tanpa jeda istirahat. Tes stroop yang dilakukan sebelum dan sesudah tes aritmatika seperti tes pauli dapat memicu penurunan fokus sehingga gejala kelelahan mental dapat lebih dirasakan oleh subjek (Setiawan, et al., 2019).

Pada tahap pasca induksi, subjek diminta untuk melakukan tiga aktivitas yang sama pada tahap pra-induksi dengan urutan terbalik.

induksi sedangkan label kelas lelah diberikan pada data yang direkam saat tahap pasca induksi.

4. PERANCANGAN DAN IMPLEMENTASI

4.1. Perancangan Perangkat Keras

Dalam penelitian ini, perangkat keras yang digunakan dalam sistem terdiri dari *headset* EEG Neurosky Mindwave Mobile 2 dan laptop. Neurosky Mindwave Mobile 2 digunakan sebagai alat untuk mengakuisisi sinyal EEG secara langsung. Hasil dari akuisisi sinyal tersebut dapat dikirim ke perangkat lain seperti laptop atau *smartphone* yang memiliki aplikasi eegID dengan cara menghubungkan *headset* dan perangkat tersebut secara *wireless* melalui Bluetooth. Data sinyal EEG yang telah dikirim dapat diproses menggunakan laptop mulai dari pra-pemrosesan, ekstraksi fitur, pelatihan algoritma klasifikasi hingga pengujian pada aplikasi GUI. Hasil pengolahan data dan klasifikasi akan ditampilkan dalam aplikasi GUI berbasis MATLAB di laptop. Perancangan perangkat keras dalam bentuk diagram skematik dapat dilihat pada Gambar 5.

4.2. Perancangan Perangkat Lunak


Perancangan perangkat lunak utama sistem meliputi tujuh proses yaitu baca data, normalisasi *min-max*, segmentasi, dekomposisi DWT, ekstraksi fitur, klasifikasi ANFIS dan implementasi aplikasi GUI MATLAB yang dapat dilihat pada Gambar 6.



Gambar 5. Diagram Skematik Sistem

Pada tahap ini, subjek diasumsikan dalam kondisi kelelahan mental setelah menjalani proses induksi. Hasil dari kuesioner SOFI dan rata-rata dari *response time* (RT) tes stroop diolah untuk memvalidasi kondisi lelah subjek.

Berdasarkan hasil pengolahan data kuesioner SOFI dan tes stroop, didapatkan kenaikan total skor kuesioner SOFI dan RT tes stroop dari tahap pra-induksi dan tahap pasca induksi. Hal ini menandakan adanya indikasi kelelahan bagi subjek setelah menjalani tahap induksi, sehingga label kelas normal diberikan pada data yang direkam saat tahap pra-



Gambar 6. Diagram Alir Perancangan Perangkat Lunak

Proses dimulai dengan memasukkan data sinyal EEG berekstensi *comma-separated values* (CSV) dalam sistem. Sistem akan memuat program baca data sinyal mentah EEG dalam satuan volt dan melakukan pra-pemrosesan pada sinyal meliputi program normalisasi *min-max* dan segmentasi 60 detik. Proses segmentasi terhadap data dari 20 subjek menghasilkan 200 data sinyal hasil segmentasi yang terdiri dari 100 data kelas normal dan 100 data kelas lelah. Kemudian, proses dekomposisi DWT dilakukan untuk mendapatkan gelombang frekuensi *gamma*, *beta*, *alpha*, *theta* dan *delta*. Gelombang frekuensi *theta* tersebut akan diproses lebih lanjut dengan program ekstraksi fitur sehingga sistem akan mendapatkan nilai fitur MAV dan SD dalam domain waktu serta fitur PP dalam domain frekuensi. Fitur yang telah didapatkan tersebut digunakan dalam proses klasifikasi ANFIS sebagai ciri kelas normal dan lelah. Proses klasifikasi ANFIS dibagi menjadi proses pelatihan dan proses pengujian. Proses pelatihan menggunakan data latih sebanyak 160 data dan proses pengujian menggunakan data uji sebanyak 40 data. Parameter klasifikasi ANFIS yang digunakan yaitu fungsi keanggotaan *gaussian* dan metode optimasi *hybrid*. Kemudian, keluaran dari sistem berupa grafik sinyal *theta*, nilai ketiga fitur, hasil diagnosis, dan waktu komputasi akan ditampilkan dalam aplikasi GUI berbasis MATLAB.

4.3. Implementasi Sistem


Implementasi sistem terdiri dari dua bagian yaitu implementasi perangkat keras yang dapat dilihat pada Gambar 4 dan implementasi perangkat lunak yang dapat dilihat pada Gambar 5.

Gambar 7(a) menunjukkan keseluruhan sistem meliputi laptop dan *headset* EEG Neurosky Mindwave Mobile 2. Gambar 7(b) menunjukkan penggunaan Neurosky Mindwave Mobile 2 pada subjek, dimana elektroda pada *sensor arm* ditempelkan pada dahi kiri dan *ground* pada *ear clip* dijepitkan pada telinga kiri subjek.



Gambar 7. Implementasi Perangkat Keras:
(a) Keseluruhan perangkat, (b) Penggunaan headset EEG Neurosky Mindwave Mobile 2

Implementasi perangkat lunak dikemas dalam bentuk aplikasi *Graphical User Interface* berbasis MATLAB sehingga sistem dapat dijalankan dengan menggunakan laptop atau komputer pribadi yang memiliki *compiler* MATLAB. Tampilan aplikasi dapat dilihat pada Gambar 8.



Gambar 8. Implementasi Perangkat Lunak

Pada Gambar 8, dapat dilihat sistem memiliki beragam fitur yang dapat digunakan untuk memudahkan psikolog dalam menggunakan sistem. Fitur-fitur pada aplikasi dapat dilihat pada Tabel 2.

Tabel 2. Fitur dalam Aplikasi GUI

Fitur
Menerima masukan berupa file (*.csv) dengan tombol <i>Browse</i>
Memproses sinyal segmen menit pertama dengan tombol <i>Plot Segment 1</i>
Memproses sinyal segmen menit kedua dengan tombol <i>Plot Segment 2</i>
Memproses sinyal segmen menit ketiga dengan tombol <i>Plot Segment 3</i>
Memproses sinyal segmen menit keempat dengan tombol <i>Plot Segment 4</i>
Memproses sinyal segmen menit kelima dengan tombol <i>Plot Segment 5</i>
Menampilkan grafik sinyal <i>theta</i> pada kolom <i>EEG signal display (theta)</i>
Menampilkan nilai-nilai hasil ekstraksi fitur pada kolom <i>Feature Extraction</i>
Menampilkan hasil diagnosis kelelahan mental pada kolom <i>Fatigue Diagnosis</i>
Menampilkan waktu komputasi sistem pada kolom <i>Computing time (s)</i>
Menghapus masukan dan keluaran sistem dengan tombol <i>Reset</i>

5. HASIL DAN PEMBAHASAN

Hasil didapatkan dengan 3 pengujian yang telah dilakukan, yaitu pengujian akuisisi data dengan headset EEG Neurosky Mindwave Mobile 2, pengujian klasifikasi kelelahan mental dengan metode ANFIS, dan pengujian waktu komputasi sistem. Pengujian akuisisi data dengan headset EEG Neurosky Mindwave Mobile 2 dilakukan untuk mengetahui apakah alat EEG yang digunakan dapat merekam sinyal EEG sesuai dengan spesifikasi frekuensi sampling yang dimiliki *headset* yaitu 512 Hertz (Hz). Hal ini dilakukan untuk mencegah kerusakan atau kehilangan data saat perekaman. Perhitungan jumlah data dilakukan dengan Persamaan (12).

$$\text{Jumlah data} = \text{frequency sampling} \times \text{detik} \quad (12)$$

$$\text{Jumlah data} = 512 \times (60 \times 5) = 153.600 \text{ data}$$

Tabel 3. Hasil Pengujian Akuisisi Data

Jumlah Data Hasil Perekaman	Jumlah Data Hasil Perhitungan	Kesesuaian
153.605	153.600	Sesuai
153.607	153.600	Sesuai
153.615	153.600	Sesuai
153.610	153.600	Sesuai
153.608	153.600	Sesuai
153.608	153.600	Sesuai
153.621	153.600	Sesuai
153.612	153.600	Sesuai
153.613	153.600	Sesuai
153.611	153.600	Sesuai
Persentase Kesesuaian		100%

Pada hasil pengujian akuisisi data dalam Tabel 3, kesesuaian diperoleh dengan kondisi jumlah data hasil perekaman EEG memiliki nilai lebih sama dengan jumlah data hasil perhitungan manual sehingga dapat disimpulkan bahwa semua data hasil perekaman EEG menggunakan Neurosky Mindwave Mobile 2 tersebut sesuai dan dapat digunakan untuk sistem.

Selanjutnya adalah pengujian tingkat akurasi pada sistem yang dilakukan untuk mengetahui performa model ANFIS dalam melakukan klasifikasi sinyal. Pengujian dilakukan pada 40 data uji, terdiri dari 20 data kelas normal dan 20 data kelas lelah. Hasil pengujian dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pengujian Klasifikasi

Keterangan	Kelas	
	Normal	Fatigue
Sesuai	17	19
Tidak sesuai	3	1
Total		40
Akurasi		90%

Dari hasil pengujian tersebut, diketahui bahwa kesesuaian hasil prediksi sistem terhadap kelas data aktual berjumlah 36 dari 40 data uji. Oleh karena itu, didapatkan tingkat akurasi klasifikasi klasifikasi kelelahan mental sebesar 90%.

Pengujian waktu komputasi pada sistem dilakukan untuk mengetahui rata-rata waktu yang diperlukan sistem dalam melakukan klasifikasi dari proses memasukkan data sinyal segmentasi hingga menampilkan hasil klasifikasi. Pengujian ini dilakukan pada 40 data uji. Hasil pengujian dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pengujian Waktu Komputasi

Subjek	Segment	Waktu Komputasi (detik)
1A	1	0,6193242
	2	0,5676265
	3	0,5489932
	4	0,5709807
	5	0,5692042
1B	1	0,3453384
	2	0,3236220
	3	0,3570499
	4	0,3465582
	5	0,3443737
2A	1	0,3963284
	2	0,4663149
	3	0,5394073
	4	0,4462208

Subjek	Segment	Waktu Komputasi (detik)
2B	5	0,4725238
	1	0,3702016
	2	0,3369516
	3	0,4045199
	4	0,3370274
3A	5	0,3342612
	1	0,4053628
	2	0,4133977
	3	0,3508204
	4	0,5134681
3B	5	0,3408427
	1	0,3752712
	2	0,3431513
	3	0,3396467
	4	0,3388389
4A	5	0,3895315
	1	0,4185681
	2	0,5427245
	3	0,5199967
	4	0,5434281
4B	5	0,4551691
	1	0,4482938
	2	0,4376360
	3	0,4165901
	4	0,4321714
Rata-rata waktu komputasi		0,4281

Pada kolom subjek dalam Tabel 5, terdapat kode angka yang merujuk pada tiap individu subjek dan kode huruf yang merujuk pada kelas data yaitu huruf "A" untuk data kelas normal dan huruf "B" untuk data kelas lelah. Berdasarkan perhitungan rata-rata waktu komputasi dalam pengujian waktu komputasi sistem, didapatkan rata-rata waktu komputasi sistem yaitu 0,42 detik.

6. KESIMPULAN

Berdasarkan pengujian yang telah dilakukan, diperoleh kesimpulan bahwa *headset* EEG Neurosky Mindwave Mobile 2 mampu merekam sinyal EEG dengan baik dibuktikan pada jumlah data hasil perekaman dalam durasi waktu 5 menit. Performa akurasi klasifikasi metode ANFIS pada sistem deteksi kelelahan mental berbasis sinyal EEG satu kanal mencapai akurasi sebesar 90% dengan rata-rata waktu komputasi yaitu 0,42 detik untuk 40 data uji. Hasil tersebut mengindikasikan sistem dapat mendeteksi kelelahan mental dengan baik dan cepat. Sistem yang dikemas dalam bentuk aplikasi GUI berbasis MATLAB juga dapat beroperasi dengan baik sehingga sistem dapat digunakan oleh psikolog melalui laptop atau komputer.

Saran untuk pengembangan penelitian lebih lanjut yaitu penambahan jumlah *dataset* yang lebih bervariasi sehingga sistem dapat mengklasifikasikan kondisi kelelahan mental dengan lebih akurat.

DAFTAR PUSTAKA

ABRAMSON, A., 2022, 1 Januari. Burnout and stress are everywhere. American Psychological Association.

- <https://www.apa.org/monitor/2022/01/special-burnout-stress>
- CHOPRA, S., DHIMAN, G., SHARMA, A., SHABAZ, M., SHUKLA, P., & ARORA, M., 2021. Taxonomy of Adaptive Neuro-Fuzzy Inference System in Modern Engineering Sciences. *Computational Intelligence and Neuroscience*, 2021. <https://doi.org/10.1155/2021/6455592>.
- HENDRAWAN, M. A. 2021. *Mental Fatigue Detection Using Single-Channel Eeg*. In *Jurnal Sistem Informasi Dan Bisnis Cerdas (SIBC)* (Vol. 14, Issue 2).
- KHAKIM, Z., & KUSROHMANIAH, S., 2021. Dasar - Dasar Electroencephalography (EEG) bagi Riset Psikologi. *Buletin Psikologi*, 29(1), 92. <https://doi.org/10.22146/buletinpsikologi.52328>
- LEVINE, D., 2020. Tips for overcoming mental exhaustion. *US News & World Report*. <https://health.usnews.com/health-care/patient-advice/articles/overcoming-mental-exhaustion-tips>
- SETIAWAN, A., WIBAWA, A. D., PANE, E. S., & PURNOMO, M. H., 2019, Maret. EEG-based mental fatigue detection using cognitive tests and RVM classification. In *2019 International Conference of Artificial Intelligence and Information Technology (ICAIIIT)* (pp. 180-185). IEEE.
- NOVITASARI, D. C., SUWANTO, B. M., & ASYHAR, A. H., 2019. Classification of EEG Signals using Fast Fourier Transform (FFT) and Adaptive Neuro-Fuzzy Inference System (ANFIS). *Jurnal Matematika MANTIK*, 5(1), 35-44.
- TRAN, Y., CRAIG, A., CRAIG, R., CHAI, R., & NGUYEN, H., 2020. The influence of mental fatigue on brain activity: Evidence from a systematic review with meta-analyses. In *Psychophysiology* (Vol. 57, Issue 5). Blackwell Publishing Inc. <https://doi.org/10.1111/psyp.13554>
- LM PSIKOLOGI UGM., 2021. Laporan Hasil Riset Mandiri Tingkat Academic Burnout Mahasiswa Klaster Sosio-Humaniora UGM: Meningkatkan Kesadaran akan Urgensi Fenomena Academic Burnout. *LM Psikologi UGM*. <https://lm.psikologi.ugm.ac.id/2021/12/laporan-hasil-riset-mandiri-tingkat-academic-burnout-mahasiswa-klaster-sosio-humaniora-ugm-meningkatkan-kesadaran-akan-urgensi-fenomena-academic-burnout/>
- YAACOB, H., HOSSAIN, F., SHARI, S., KHARE, S. K., OOI, C. P., & ACHARYA, U. R., 2023. Application of Artificial Intelligence Techniques for Brain-Computer Interface in Mental Fatigue Detection: A Systematic Review (2011-2022). *IEEE Access*, 11, 74736-74758. <https://doi.org/10.1109/ACCESS.2023.3296382>.
- WANG, F., WAN, Y., LI, M., HUANG, H., LI, L., HOU, X., PAN, J., WEN, Z., & LI, J., 2023. Recent Advances in Fatigue Detection Algorithm Based on EEG. *Intelligent Automation & Soft Computing*, 35(3), 3573-3586. <https://doi.org/10.32604/iasc.2023.029698>.

Halaman ini sengaja dikosongkan