

## Deskripsi Umum :

### Model Klasifikasi Tahapan Tidur Dari Gelombang Otak Dengan Algoritma Random Forest

*Abstract— Sleep occupies a significant part of human life and is a vital component of an individual's health. Lack of sleep may cause health issues, influence mood, and interfere with cognitive performance. Polysomnography (PSG) is a multi-parameter examination that records the brain and body's basic physical and electrical activities. PSG is a technique for examining various parameters that can be used to diagnose sleep disorders or better understand brainwaves. The sleep stages are essential parts of activity during sleep, and they are divided into cyclic stages in humans. The three main sleep cycle stages are awake, non-REM (NREM) sleep, rapid eye movement (REM) sleep, and sleep stage correlate with brainwaves. The visual process of sleep stage classification is time-consuming, subjective, and costly. The automatic classification algorithm was developed to improve the performance and the efficiency of the sleep stage classification. In this model, we focused on implementing artificial intelligence for brainwaves analysis to improve the classification model. We already executed the high-dimensional features calculated by fast Fourier transform (FFT) from single- or multi-channel brainwaves for the features extraction. Then we continued the process using the Random Forest model for the classification model to improve the evaluation performance for 6- to 2-class classification against the Sleep-EDF dataset.*

*Keywords—brainwaves, classification algorithm, Fast Fourier Transform (FFT), sleep stages, random forest*


**Abstrak –** Tidur menempati bagian penting dari kehidupan manusia dan merupakan komponen penting dari kesehatan individu. Kurang tidur dapat menyebabkan masalah kesehatan, mempengaruhi suasana hati, dan mengganggu kinerja kognitif. Polisomnografi (PSG) adalah pemeriksaan multi-parameter yang merekam aktivitas fisik dan listrik dasar otak dan tubuh. PSG adalah teknik untuk memeriksa berbagai parameter yang dapat digunakan untuk mendiagnosis gangguan tidur atau lebih memahami gelombang otak. Tahapan tidur adalah bagian penting dari aktivitas selama tidur, dan mereka dibagi menjadi tahap siklik pada manusia. Tiga tahap siklus tidur utama adalah terjaga (awake), tidur non-REM (*Non-Rapid Eye Movement*), tidur gerakan mata cepat (*Rapid Eye Movement*). Oleh sebab itu, tahapan tidur berkorelasi dengan gelombang otak. Proses visual klasifikasi tahapan tidur memakan waktu, subjektif, dan mahal. Algoritma klasifikasi otomatis dikembangkan untuk meningkatkan kinerja dan efisiensi klasifikasi tahapan tidur. Dalam model ini, kami menekankan pada pembuatan model algoritma klasifikasi dengan penerapan kecerdasan buatan untuk analisis gelombang otak guna meningkatkan model klasifikasi. Kami telah mengeksekusi fitur dimensi tinggi yang dihitung dengan *Fast Fourier Transform* (FFT) dari gelombang otak saluran tunggal atau saluran multi untuk ekstraksi fitur. Selanjutnya kami menggunakan algoritma Random Forest untuk memperbaiki kinerja algoritma klasifikasi guna meningkatkan kinerja evaluasi untuk klasifikasi 2 hingga 6 kelas tahapan tidur dengan menggunakan dataset Sleep-EDF.

**Kata Kunci – gelombang otak, algoritma klasifikasi, *Fast Fourier Transform*, Tahapan Tidur, *Random Forest***

## **Pendahuluan**

Tidur adalah kondisi sistem saraf tertentu dengan karakteristik dan fase aktivitas otak yang terlihat. Meskipun tidur dianggap oleh banyak orang sebagai proses pasif dan konstan, tidur memang merupakan kondisi kerja. Ada sepertiga dihabiskan untuk tidur selama hidup manusia. Kekurangan tidur dapat menyebabkan masalah kesehatan, suasana hati dan perilaku kognitif[1]. Aktivitas fisik spesifik otak harus dicatat untuk studi tidur. Tes multi-parameter, yang dikenal sebagai Polisomnografi (PSG), biasanya digunakan untuk tujuan ini. PSG dilakukan menggunakan perangkat elektronik yang dilengkapi untuk memantau beberapa parameter fisiologis selama tidur dengan merekam sinyal elektrofisiologis yang sesuai, misalnya: dari otak melalui *Electroencephalogram* (EEG), dari mata melalui *Electrooculogram* (EOG), dari otot rangka melalui *Electromyogram* (EMG) dan dari jantung melalui *Elektrokardiogram* (EKG)[2].

Gambar 1 merupakan sistem standar yang digunakan untuk mengukur sinyal EEG, disebut sistem 10-20, di mana jumlah minimum elektroda yang digunakan adalah 21. Metode ini mengatur penempatan fisik dan penunjukan elektroda pada kulit kepala. Kepala dibagi menjadi beberapa bagian dari bagian-bagian penting tengkorak sehingga semua area otak cukup tertutup. Label 10-20 menunjukkan bahwa jarak sebenarnya antara elektroda tetangga adalah 10% atau 20% dari jarak dari nasion (sisi depan kepala/ anterior) ke inion (sisi belakang kepala/ posterior) antara telinga dan hidung di mana titik elektroda dipilih. Umumnya, elektroda yang ditandai dengan angka genap ditempatkan di sisi kanan kepala dan yang ditandai dengan angka ganjil di sisi kiri. Elektroda juga ditandai dengan huruf untuk mewakili lokasinya relatif terhadap divisi anatomi otak: F (frontal), C (central), T (temporal), P (parietal), dan O (occipital), Fp (Frontal pole). Sebuah subscript z digunakan untuk menandai elektroda garis tengah sebagai nol. Sinyal listrik di otak ditentukan dengan mengukur perbedaan aktivitas listrik antara dua elektroda selama periode waktu tertentu. Saat merambat, sinyal secara bertahap meluruh dengan jarak dari sumbernya. Akhirnya, sinyal telah meluruh ke titik di mana mendapatkan pengukuran yang tepat hanya dari salah satu kombinasi paralel elektroda[3].



**Gambar 1.** Penempatan elektroda pengukuran electroencephalogram (EEG)[3]

Tidur manusia terdiri dari tahapan siklus, dan tahapan tidur adalah bagian penting dari aktivitas selama tidur. Tiga tahap utama dari siklus tidur adalah terjaga, tidur non-REM (*Non Rapid Eye Movement*), dan tidur gerakan mata cepat (*Non Rapid Eye Movement*). Apabila tidak adanya salah satu dari tahapan ini atau kelebihan yang lain dapat menyebabkan diagnosis berbagai kondisi mulai dari apnea tidur, hipersomnia, insomnia, atau berbicara sambil tidur. [4]. Ada dua standar yang diakui untuk menafsirkan tahapan tidur berdasarkan rekaman tidur: kriteria *Rechtschaffen dan Kales* (R&K) dan kriteria *American Academy of Sleep Medicine* (AASM). Rekomendasi R&K mengklasifikasikan tidur menjadi tujuh tahap terpisah: bangun/terjaga, S1/mengantuk, S2/tidur ringan, S3/tidur nyenyak, S4/tidur nyenyak atau gelombang, REM dan MT/waktu gerakan.[5]. Kriteria AASM adalah versi modifikasi dari kriteria R&K. Beberapa perbedaan antara kriteria AASM dan R&K adalah sebagai berikut: [5], [6]:


1. Tahapan NREM dalam kriteria R&K (S1, S2, S3, dan S4) disebut sebagai tahapan N1, N2, dan N3 dalam kriteria AASM.
2. Pada kriteria AASM, tidur dalam / *deep sleep* (N3) merupakan kombinasi tahapan S3 dan S4 dari kriteria R&K.
3. Waktu gerakan (*Movement Time*) dihilangkan sebagai tahap tidur dalam kriteria AASM.

Teknisi atau operator secara tradisional menafsirkan dan secara manual menandai tahapan tidur. Dengan demikian, prosesnya memakan waktu dan mahal serta bergantung pada manusia. Karena memakan waktu, memakan waktu, dan proses yang besar, tidak tepat bagi ahli manusia untuk menulis set data tahap tidur EEG yang besar[7]. Untuk mencapai presisi yang lebih baik, perlu untuk mengembangkan penilaian fase tidur. Penelitian sebelumnya telah dilakukan dengan metode yang berbeda pada klasifikasi tahapan tidur otomatis[6],[8]–[12].

Keperluan pencatatan tidur secara otomatis, maka diperlukan metode klasifikasi tahapan tidur secara otomatis. Sementara berbagai macam pengklasifikasi otomatis tersedia, masih belum jelas pengklasifikasi mana yang paling baik diterapkan dalam kasus ini. Alasan di balik ini adalah fakta bahwa metode penilaian tidur secara manual sangat subjektif dan bervariasi antar dokter juga. Upaya sebelumnya pada klasifikasi otomatis tahap tidur didasarkan pada rekaman EEG saluran tunggal dan multichannel dan berbagai penanda fisiologis lainnya. Ronzhina dkk. menggambarkan skema berbasis EEG saluran tunggal yang memanfaatkan jaringan saraf tiruan yang digabungkan dengan analisis densitas spektrum daya dari rekaman EEG [13]. Zhu dkk. menganalisis sembilan fitur dari rekaman EEG saluran tunggal dan menerapkan teknik kecerdasan buatan yang disebut sebagai *Support Vector Machine* (SVM) untuk melakukan klasifikasi [14]. Kinerja klasifikasi tinggi telah dilaporkan oleh Huang dengan menerapkan transformasi Fourier waktu singkat ke perekaman dua saluran sinyal EEG dahi dan mesin vektor yang relevan [15]. Selain itu, Aboalayon et al. telah melakukan tinjauan komprehensif sistem klasifikasi tahap tidur otomatis (AASC), yang mencakup survei teknik pemrosesan termasuk pra-pemrosesan, ekstraksi fitur, pemilihan fitur, pengurangan dimensi, dan klasifikasi. Studi ini mengevaluasi metode AASC terhadap database sleep-EDF berdasarkan rekaman EEG saluran tunggal dan luar biasa karena telah memilih 10 detik untuk analisisnya. Performa model mereka mencapai akurasi tertinggi dibandingkan dengan hasil sebelumnya [6]. Braun dkk. telah menerapkan fitur Fast Fourier Transform (FFT) dimensi rendah pada database sleep-EDF dengan penggunaan delapan fitur statistik dari saluran EEG Pz-Oz. Kinerja klasifikasi telah mencapai akurasi 90,9%, 91,8%, 92,4%, 94,3%, dan 97,1% untuk semua tahap tidur 6 hingga 2 keadaan [15]. Selain itu, Delimayanti telah menunjukkan bahwa memanfaatkan sepenuhnya ribuan fitur FFT yang diekstraksi dari sinyal EEG saluran tunggal dan multi-saluran dalam kombinasi dengan pemilihan fitur sederhana adalah cara yang efektif untuk meningkatkan kinerja klasifikasi tahap tidur otomatis. Dalam eksperimennya pada klasifikasi kelas 6 hingga 2 terhadap set data Sleep-EDF, metodenya mengungguli metode terbaru dan lanjutan lainnya. [9].

Hasil penelitian yang telah dilakukan adalah model algoritma klasifikasi tahapan tidur dengan menggunakan algoritma FFT (*Fast Fourier Transform*) untuk fitur ekstraksi dan algoritma Random Forest. Ekstraksi fitur statistik yang luar biasa dari sinyal EEG diperlukan untuk melakukan klasifikasi tahap tidur secara efisien. Secara umum, sinyal EEG sangat kompleks dan non-linear, sehingga lebih baik menggunakan model non-linear [16]. Dalam penelitian ini, Fast Fourier Transform (FFT) digunakan untuk mengekstrak fitur sinyal EEG

untuk klasifikasi tahap tidur. Oleh karena itu, nilai dari data deret waktu tertentu sebagai data urutan numerik diubah menjadi himpunan berhingga dari domain frekuensi. Kemudian, untuk mendekonstruksi sinyal menjadi sekuens sinyal EEG tersegmentasi, kami membaginya menjadi interval waktu yang sama yang disebut epoch. Panjang setiap epoch diatur ke setiap 30 detik sinyal EEG. Dengan demikian, zaman kemudian diproses menggunakan analisis frekuensi di mana spektrum frekuensi dihasilkan menggunakan FFT. Kami menggunakan FFT untuk mengubah sinyal dari aslinya, sinyal domain waktu menjadi representasi dalam sinyal domain frekuensi dan sebaliknya[17]. Metode FFT menggunakan teknik matematika untuk analisis data EEG. FFT diterapkan pada setiap epoch dan gambar 2 direpresentasikan dalam bentuk sinyal domain waktu dan sinyal domain frekuensi.



**Gambar 2.** Sinyal otak dalam domain waktu dan domain frekuensi

Studi sebelumnya telah menunjukkan bahwa FFT adalah alat yang menjanjikan untuk pemrosesan sinyal stasioner di hampir semua metode lain yang tersedia dalam aplikasi waktu nyata, dan ini lebih sesuai untuk bentuk gelombang sinus seperti pada sinyal EEG. menikmati keuntungan kecepatan. Namun, kelemahannya adalah tidak memiliki estimasi spektral yang sangat baik dan tidak dapat digunakan untuk analisis sinyal EEG pendek [18].

*Random Forest (RF)* adalah metode klasifikasi gabungan baru. Dibandingkan dengan pendekatan klasifikasi lain yang cukup baik, seperti metode Neural Network (NN) dan metode SVM, metode ini mengungkapkan keunggulan komputasi yang cepat, akurasi tinggi, kemampuan anti-noise yang sangat baik, dan menghindari *overfitting*. Oleh karena itu, telah banyak digunakan dalam klasifikasi bioinformatika. RF terdiri dari sejumlah besar pohon keputusan yang memilih fitur pemisahannya dari subset sampel bootstrap dari fitur  $p$  di setiap simpul internal. Pohon-pohon tersebut dibangun melalui metodologi *Classification And*

*Regression Tree (CART)* tanpa pemangkasan. Prediksi akhir ditentukan oleh suara mayoritas dari prediksi ensemble. Untuk menurunkan waktu komputasi dan menemukan fitur terbaik untuk membedakan antara tiga tahap tidur yang diinginkan, semua fitur diperiksa menggunakan fitur penting *Out-Of-Bag* (OOB). Observasi OOB adalah sampel dari data pelatihan yang akhirnya tidak digunakan dalam pelatihan karena pengambilan sampel data secara acak. Kepentingan fitur OOB dihitung menggunakan pengklasifikasi hutan acak dengan 100 pohon dan dengan semua fitur diambil sampelnya di setiap node. Pengamatan OOB kemudian digunakan untuk menghitung pentingnya semua fitur dan hanya fitur yang paling penting yang tersisa dalam algoritma akhir. Pelatihan algoritma tahapan tidur otomatis kemudian dilakukan pada 204 fitur yang diekstraksi dengan kepentingan tertinggi. Nilai ini dipilih berdasarkan trial and error[19]. Hasil riset telah menunjukkan bahwa model klasifikasi gelombang otak dengan ekstraksi fitur menggunakan FFT dan model klasifikasi dengan algoritma Random Forest telah memberikan hasil evaluasi yang lebih baik dari hasil riset sebelumnya dengan menggunakan dataset Sleep-EDF-2013[20].

	2 Class	3 Class	4 Class	5 Class	6 Class
FFT_4001	98.26%	94.87%	94.23%	94.42%	91.74%
FFT_4002	98.09%	94.52%	93.64%	93.04%	90.81%
FFT_4011	98.43%	95.43%	94.47%	92.58%	92.01%
FFT_4012	97.93%	94.28%	91.96%	91.40%	90.80%
FFT_4021	98.54%	94.04%	92.01%	92.30%	91.76%
FFT_4022	98.26%	94.74%	92.85%	91.22%	89.73%
FFT_4031	99.26%	97.62%	95.85%	94.79%	94.79%
FFT_4032	98.79%	96.60%	95.20%	94.69%	93.15%
FFT_4041	97.08%	89.92%	88.95%	88.71%	88.71%
FFT_4042	97.45%	93.44%	90.82%	90.21%	89.99%
FFT_4051	98.60%	96.14%	95.11%	95.30%	94.31%
FFT_4052	97.86%	92.87%	91.58%	91.01%	90.05%
FFT_4061	98.95%	95.78%	95.52%	95.02%	94.51%
FFT_4062	98.62%	95.83%	95.23%	94.17%	93.04%
FFT_4071	98.90%	96.01%	94.38%	93.70%	91.74%
FFT_4072	98.66%	94.62%	94.73%	94.87%	93.00%
FFT_4081	97.60%	93.49%	92.09%	91.99%	89.56%
FFT_4082	97.15%	92.86%	90.55%	90.32%	89.10%
FFT_4091	98.35%	93.35%	91.58%	91.58%	89.31%
FFT_4092	96.67%	92.37%	88.60%	87.92%	87.23%
FFT_4101	97.28%	92.13%	92.57%	92.39%	92.39%
FFT_4102	98.39%	94.26%	93.46%	93.00%	93.00%

FFT_4111	98.60%	94.55%	92.66%	92.50%	91.06%
FFT_4112	99.32%	97.70%	94.28%	94.50%	93.78%
FFT_4121	97.28%	92.66%	91.84%	91.14%	89.39%
FFT_4122	97.01%	91.37%	90.87%	89.22%	87.49%
FFT_4131	99.25%	94.10%	94.53%	94.21%	91.93%
FFT_4141	97.97%	96.55%	95.36%	95.32%	91.84%
FFT_4142	97.44%	95.93%	95.67%	95.24%	92.75%
FFT_4151	98.62%	95.45%	94.27%	94.19%	90.63%
FFT_4152	99.20%	95.21%	94.16%	93.81%	90.10%
FFT_4161	96.57%	92.79%	90.35%	90.35%	87.60%
FFT_4162	96.91%	94.11%	90.29%	90.00%	89.05%
FFT_4171	96.43%	94.89%	92.16%	91.86%	88.65%
FFT_4172	93.93%	89.49%	85.11%	83.53%	81.47%
FFT_4181	98.44%	94.56%	93.25%	92.63%	90.02%
FFT_4182	98.10%	94.09%	92.89%	92.79%	89.37%
FFT_4191	96.90%	91.45%	89.11%	87.38%	86.05%
FFT_4192	95.55%	92.59%	90.17%	90.06%	89.75%
FFT_7011	89.28%	84.15%	76.28%	73.35%	69.50%
FFT_7022	95.35%	84.43%	77.02%	77.77%	72.37%
FFT_7041	94.44%	74.89%	61.28%	57.11%	57.31%
FFT_7052	93.91%	83.95%	82.78%	80.94%	78.53%
FFT_7061	96.04%	84.53%	82.35%	82.35%	82.35%
FFT_7071	92.94%	85.51%	81.37%	77.95%	73.32%
FFT_7082	94.63%	83.46%	79.27%	77.55%	77.55%
FFT_7092	94.15%	80.39%	75.41%	74.65%	74.65%
FFT_7101	95.39%	88.38%	81.76%	79.36%	73.89%
FFT_7112	96.83%	86.30%	85.07%	83.43%	78.93%
FFT_7121	96.50%	88.50%	83.34%	83.34%	75.44%
FFT_7132	94.84%	85.33%	78.39%	76.75%	73.94%
FFT_7141	95.21%	84.73%	80.77%	77.74%	73.31%
FFT_7151	87.95%	72.11%	49.27%	44.37%	38.68%
FFT_7162	88.26%	80.67%	75.61%	73.08%	64.37%
FFT_7171	94.81%	87.86%	84.65%	79.67%	74.59%
FFT_7182	95.25%	68.87%	61.83%	54.90%	54.70%
FFT_7192	98.07%	90.44%	86.90%	85.82%	79.06%
FFT_7201	98.16%	83.62%	73.63%	66.14%	66.36%
FFT_7212	93.27%	83.37%	80.50%	78.51%	75.64%
FFT_7221	93.71%	78.22%	78.99%	77.63%	77.63%
FFT_7241	97.36%	73.94%	69.63%	65.22%	65.42%

## REFERENCES

- [1] C. S. McCrae *et al.*, “Efficacy of brief behavioral treatment for insomnia in older adults: examination of sleep, mood, and cognitive outcomes,” *Sleep Med.*, vol. 51, pp. 153–166, Nov. 2018, doi: 10.1016/j.sleep.2018.05.018.
- [2] N. Giannakeas, “EEG-Based Automatic Sleep Stage Classification,” *Biomed. J. Sci. Tech. Res.*, vol. 7, no. 4, Aug. 2018, doi: 10.26717/BJSTR.2018.07.001535.
- [3] E. Kaniusas, “Fundamentals of Biosignals,” in *Biomedical Signals and Sensors I: Linking Physiological Phenomena and Biosignals*, E. Kaniusas, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 1–26. doi: 10.1007/978-3-642-24843-6\_1.
- [4] S. Chokroverty, Ed., *Sleep Disorders Medicine: Basic Science, Technical Considerations and Clinical Aspects*. New York, NY: Springer New York, 2017. doi: 10.1007/978-1-4939-6578-6.
- [5] S. Taran, P. C. Sharma, and V. Bajaj, “Automatic sleep stages classification using optimize flexible analytic wavelet transform,” *Knowl.-Based Syst.*, vol. 192, p. 105367, Mar. 2020, doi: 10.1016/j.knosys.2019.105367.
- [6] K. Aboalayon, M. Faezipour, W. Almuhammadi, and S. Moslehpour, “Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation,” *Entropy*, vol. 18, no. 9, p. 272, Aug. 2016, doi: 10.3390/e18090272.
- [7] T. Nakamura, V. Goverdovsky, M. J. Morrell, and D. P. Mandic, “Automatic Sleep Monitoring Using Ear-EEG,” *IEEE J. Transl. Eng. Health Med.*, vol. 5, pp. 1–8, 2017, doi: 10.1109/JTEHM.2017.2702558.
- [8] O. Yildirim, U. Baloglu, and U. Acharya, “A Deep Learning Model for Automated Sleep Stages Classification Using PSG Signals,” *Int. J. Environ. Res. Public Health*, vol. 16, no. 4, p. 599, Feb. 2019, doi: 10.3390/ijerph16040599.
- [9] M. K. Delimayanti *et al.*, “Classification of Brainwaves for Sleep Stages by High-Dimensional FFT Features from EEG Signals,” *Appl. Sci.*, vol. 10, no. 5, p. 1797, Mar. 2020, doi: 10.3390/app10051797.
- [10] A. R. Hassan and M. I. H. Bhuiyan, “A decision support system for automatic sleep staging from EEG signals using tunable Q-factor wavelet transform and spectral features,” *J. Neurosci. Methods*, vol. 271, pp. 107–118, Sep. 2016, doi: 10.1016/j.jneumeth.2016.07.012.
- [11] A. R. Hassan and A. Subasi, “A decision support system for automated identification of sleep stages from single-channel EEG signals,” *Knowl.-Based Syst.*, vol. 128, pp. 115–124, Jul. 2017, doi: 10.1016/j.knosys.2017.05.005.
- [12] A. R. Hassan and M. I. H. Bhuiyan, “An automated method for sleep staging from EEG signals using normal inverse Gaussian parameters and adaptive boosting,” *Neurocomputing*, vol. 219, pp. 76–87, Jan. 2017, doi: 10.1016/j.neucom.2016.09.011.
- [13] R. G. Norman, I. Pal, C. Stewart, J. A. Walsleben, and D. M. Rapoport, “Interobserver Agreement Among Sleep Scorers From Different Centers in a Large Dataset,” *Sleep*, vol. 23, no. 7, pp. 1–8, Oct. 2000, doi: 10.1093/sleep/23.7.1e.
- [14] A. Supratak, H. Dong, C. Wu, and Y. Guo, “DeepSleepNet: a Model for Automatic Sleep Stage Scoring based on Raw Single-Channel EEG,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, no. 11, pp. 1998–2008, Nov. 2017, doi: 10.1109/TNSRE.2017.2721116.
- [15] M. Ronzhina, O. Janoušek, J. Kolářová, M. Nováková, P. Honzík, and I. Provazník, “Sleep scoring using artificial neural networks,” *Sleep Med. Rev.*, vol. 16, no. 3, pp. 251–263, Jun. 2012, doi: 10.1016/j.smr.2011.06.003.
- [16] S. K. T. Hwa, M. H. A. Hijazi, A. Bade, R. Yaakob, and M. S. Jeffree, *IAES Int. J. Artif. Intell.*, vol. 8, no. 4, pp. 429–435, 2019, doi: 10.11591/ijai.v8.i4.pp429-435.



- [17] H. J. Nussbaumer, "The Fast Fourier Transform," in *Fast Fourier Transform and Convolution Algorithms*, H. J. Nussbaumer, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 1981, pp. 80–111. doi: 10.1007/978-3-662-00551-4\_4.
- [18] A. S. Al-Fahoum and A. A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains," *ISRN Neurosci.*, vol. 2014, p. 730218, Feb. 2014, doi: 10.1155/2014/730218.
- [19] L. Breiman, "Random Forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [20] B. Kemp, A. H. Zwinderman, B. Tuk, H. A. C. Kamphuisen, and J. J. L. Obery, "Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG," *IEEE Trans. Biomed. Eng.*, vol. 47, no. 9, pp. 1185–1194, Sep. 2000, doi: 10.1109/10.867928.