

Tinjauan Sistematis Penggunaan MIT-BIH Polysomnography Database untuk Deteksi dan Klasifikasi Gangguan Tidur

Systematic Review of the Use of the MIT-BIH Polysomnography Database for the Detection and Classification of Sleep Disorders

¹Akbar*, ²Ema Utami

¹Program Magister Informatika, Universitas Amikom Yogyakarta

²Program Doktorat Informatika, Universitas Amikom Yogyakarta

^{1,2}Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta 55281, Indonesia

*e-mail: akbar.05@students.amikom.ac.id

(received: 2 November 2025, revised: 27 November 2025, accepted: 28 November 2025)

Abstrak

MIT-BIH Polysomnography Database (SLPDB) merupakan tolok ukur yang luas digunakan dalam pengembangan metode otomatis untuk deteksi gangguan tidur dan klasifikasi tahapan tidur. Penelitian ini menyajikan *Systematic Literature Review* terhadap 35 artikel yang memanfaatkan SLPDB, dengan menelaah fokus penelitian, penggunaan jenis sinyal, dan pendekatan komputasional yang diterapkan. Lima kategori metodologi utama berhasil diidentifikasi, yaitu Deteksi Apnea Tidur, *Sleep Staging*, Peningkatan Pemrosesan Sinyal, Metode *Multichannel Fusion*, serta *Interpretable AI*, dengan dua kategori pertama menjadi yang paling dominan. Empat kelompok sinyal fisiologis—EEG, ECG, respirasi, dan multikanal—menjadi dasar pengembangan model, di mana EEG umum digunakan untuk *sleep staging* dan ECG untuk deteksi apnea. Pendekatan *deep learning*, khususnya CNN, LSTM, dan model hibrida, merupakan metode yang paling banyak digunakan. Rentang akurasi model bervariasi antara 78% hingga lebih dari 99%, dipengaruhi oleh jenis sinyal dan strategi pemodelan. Ke depan, penelitian perlu memprioritaskan pengembangan model hibrida yang lebih dapat diinterpretasikan serta validasi klinis yang lebih luas guna meningkatkan reproduktibilitas dan kesiapan implementasi.

Kata kunci: analisis sinyal biomedis, machine learning, MIT-BIH polysomnography, sleep apnea, systematic review

Abstract

The MIT-BIH Polysomnography Database (SLPDB) is a widely adopted benchmark for the development of automated methods for sleep disorder detection and sleep stage classification. This study presents a *Systematic Literature Review* of 35 articles that utilize the SLPDB, examining research focus areas, types of physiological signals employed, and the computational approaches applied. Five major methodological categories were identified: Sleep Apnea Detection, Sleep Staging, Signal Processing Enhancement, Multichannel Fusion Methods, and Interpretable Artificial Intelligence, with the first two categories being the most dominant. Four groups of physiological signals—EEG, ECG, respiratory signals, and multichannel data—form the basis for model development, where EEG is predominantly used for sleep staging and ECG for sleep apnea detection. Deep learning approaches, particularly CNNs, LSTMs, and hybrid models, are the most frequently employed techniques. Reported model accuracies range from 78% to over 99%, depending on the signal modality and modeling strategy. Future research should prioritize the development of more interpretable hybrid models and broader clinical validation to enhance reproducibility and implementation readiness.

Keywords: biomedical signal analysis, machine learning, MIT-BIH polysomnography, sleep apnea, systematic review

1 Pendahuluan

Dalam dekade terakhir, gangguan tidur seperti Sleep Apnea menjadi salah satu tantangan kesehatan masyarakat yang semakin mendapat perhatian, karena dapat memicu komplikasi kardiovaskular, metabolik, dan neurologis. Salah satu standar diagnostik yang digunakan adalah pemeriksaan Polysomnography (PSG) yang mencatat berbagai sinyal fisiologis selama tidur, seperti elektroensefalogram (EEG), elektrokardiogram (ECG), gerakan otot (EMG), respirasi, dan saturasi oksigen [1]. Namun, prosedur PSG tradisional memerlukan banyak sensor, biaya tinggi, dan memakan waktu serta menyebabkan ketidaknyamanan pada pasien, sehingga seringkali aksesnya terbatas. Untuk mengatasi hambatan ini, penelitian di bidang sinyal biomedis tumbuh pesat dalam mengembangkan metode otomatis dan berbasis data untuk deteksi dan klasifikasi gangguan tidur.

Salah satu basis data publik yang banyak digunakan adalah MIT-BIH Polysomnographic Database, yang dirilis oleh PhysioNet dan mencakup rekaman multikanal selama tidur yang telah dianotasi untuk tahap tidur dan kejadian apnea/hypopnea. [2] Basis data ini telah memungkinkan para peneliti menerapkan teknik pengolahan sinyal dan learning machine untuk tujuan seperti klasifikasi tahap tidur atau identifikasi episode apnea. Misalnya, [3] melakukan analisis detrended fluctuation pada EEG dari database ini dan menunjukkan bahwa eksponen skala sinyal berbeda antar tahap tidur dan kondisi apnea. Penggunaan basis data yang terbuka dan teranotasi seperti ini sangat penting untuk kemajuan metodologi, replikasi penelitian, dan komparabilitas antar studi.

Meski demikian, terdapat berbagai permasalahan yang masih menghambat implementasi luas metode-otomatis berbasis database PSG. Pertama, variabilitas dalam preprocessing data, ekstraksi fitur, dan konfigurasi model menyebabkan heterogenitas hasil antar penelitian. Kedua, walau banyak studi menerapkan machine learning atau deep learning, integrasi sinyal multikanal dan validasi eksternal masih terbatas. Ketiga, sebagian besar studi menggunakan dataset yang relatif kecil dan usang, sehingga generalisasi ke populasi luas masih dipertanyakan. All ini mengarahkan pada kebutuhan untuk melakukan tinjauan sistematis terhadap pemanfaatan MIT-BIH Polysomnographic Database: bagaimana dataset ini telah dipakai, pola metodologinya, kekuatan dan keterbatasannya, serta arah penelitian ke depan.

Dengan mempertimbangkan latar belakang tersebut, penelitian ini bertujuan untuk melakukan systematic review terhadap studi-studi yang menggunakan MIT-BIH Polysomnographic Database, dengan fokus pada teknik analisis sinyal, pendekatan komputasional, dan aplikasi klinis yang dihasilkan. Signifikansi penelitian ini terletak pada penyediaan gambaran komprehensif mengenai pemanfaatan dataset ini—yang dapat menjadi landasan bagi peneliti selanjutnya dalam memilih metodologi, memahami gap penelitian, serta merancang penelitian yang lebih baik dan terstandarisasi.

2 Tinjauan Literatur

Sle-CNN: a novel convolutional neural network for sleep stage classification [4] memperkenalkan jaringan konvolusional efisien khusus untuk klasifikasi lima tahap tidur, dengan menyematkan koefisien pelatihan pada kernel di lapisan awal dan menggunakan algoritma genetika untuk desain arsitektur otomatis. Model tersebut menunjukkan bahwa struktur yang disederhanakan namun teroptimasi dapat mencapai performa tinggi pada sinyal EEG tunggal. Kelebihan penelitian ini adalah inovasi arsitektur dan optimasi genetika, tetapi kekurangannya adalah studi terbatas pada sinyal tunggal dan kurang membahas integrasi sinyal multikanal atau validasi pasien-independen. Dengan demikian, bagian yang belum dilakukan adalah penyelidikan sistematis terhadap pipeline pra-pemrosesan dan penerapan arsitektur tersebut dalam konteks sinyal multikanal dan data eksternal

SelANet: decision-assisting selective sleep apnea detection based on confidence score (2023) mengusulkan pendekatan deteksi apnea tidur menggunakan sinyal kombinasi (ECG dan SpO₂) dengan skor kepercayaan sebagai mekanisme seleksi untuk hanya memutuskan kejadian yang memiliki tingkat keyakinan tinggi [5]. Ini merupakan langkah maju dalam menangani ketidakpastian model AI dan memfokuskan pada hasil dengan kepercayaan tinggi, sehingga meningkatkan keandalan keputusan. Namun, penelitian ini masih terbatas pada sinyal terbatas, belum secara mendalam membandingkan berbagai skema fusi sinyal ataupun standarisasi pra-pemrosesan dan validasi eksternal. Artikel Anda akan menyoroti aspek fusi sinyal multikanal secara sistematis dan mengusulkan standarisasi pipeline yang masih kurang dibahas di literatur.

A Comprehensive Study on a Deep-Learning-Based Electrocardiography Analysis for Estimating the Apnea-Hypopnea Index [6] menyajikan sistem berbasis satu-kanal ECG yang menggunakan jaringan DSF-SANet + GRU untuk mengestimasi Indeks Apnea-Hipopnea (AHI) dengan performa cukup baik ($r \approx 0,87$). Penelitian ini menekankan pentingnya metrik klinis AHI sebagai output, bukan hanya klasifikasi sederhana, yang membuatnya relevan secara klinis. Kekurangannya adalah penggunaan hanya satu jenis sinyal (ECG), validasi terbatas (tidak secara luas diuji pada dataset lain dengan konfigurasi berbeda), dan minimnya analisis terhadap proses pra-pemrosesan dan generalisasi model. Dengan demikian, penelitian Anda akan memperluas dengan membandingkan berbagai sinyal (EEG, ECG, respirasi) dan menguji validasi pasien-independen di dataset publik yang sama.


Advanced Data Framework for Sleep Medicine Applications: Machine Learning-Based Detection of Sleep Apnea Events mengembangkan kerangka data untuk aplikasi medis tidur dengan pendekatan pembelajaran mesin pada dataset publik, menyoroti potensi dan tantangan deteksi apnea secara otomatis [7]. Artikel ini penting karena menekankan aspek kerangka data dan proses end-to-end, namun masih belum secara konkret mengeksplorasi standar pra-pemrosesan, integrasi sinyal multikanal, ataupun validasi eksternal secara rinci. Hal ini membuktikan bahwa kebutuhan untuk pipeline yang dapat direproduksi dan standar masih terbuka

Wearable Sensors and Artificial Intelligence for Sleep Apnea Detection: A Systematic Review (2025) melakukan tinjauan sistematis terhadap integrasi sensor wearable dan AI dalam deteksi Obstructive Sleep Apnea (OSA) dengan hasil pooled accuracy $\sim 0,89$, sensitivity $\sim 0,79$, specificity $\sim 0,95$ [8]. Meskipun meta-analisis ini mencakup banyak studi, mayoritas masih menggunakan data tertutup atau sinyal tunggal, dan hanya sedikit yang menerapkan validasi lintas-data secara pasien-independen atau menyajikan metrik konsisten antar-studi. Ini menegaskan kebutuhan untuk standarisasi metodologis dan laporan yang lebih transparan

Melalui penguraian masing-masing penelitian di atas, terlihat bahwa literatur terkini memang telah membuat kemajuan signifikan dalam deteksi gangguan tidur dan klasifikasi tahap tidur, namun secara konsisten belum menyediakan solusi standarisasi pipeline pra-pemrosesan, belum melakukan studi komparatif strategi fusi sinyal multikanal secara sistematis, dan belum menguji generalisasi model melalui validasi pasien-independen pada dataset publik yang sama. Artikel review ini bertujuan untuk mengisi kekosongan tersebut dengan menerapkan pendekatan yang terstruktur. Studi ini menyajikan analisis kritis terhadap literatur terbaru untuk menyintesis serta merumuskan rekomendasi mengenai skema pra-pemrosesan yang paling umum dan efektif digunakan, termasuk perbandingan teknis antar metode penyaringan (filtering) dan strategi segmentasi. Selanjutnya, artikel ini melakukan pengelompokan dan perbandingan secara sistematis terhadap bukti-bukti penggunaan strategi fusi sinyal multikanal dalam penelitian terdahulu. Sintesis atas temuan-temuan tersebut diharapkan dapat menghasilkan rekomendasi pipeline yang lebih terstandar bagi penelitian mendatang yang berfokus pada SLPDB, sehingga mampu mengatasi fragmentasi pendekatan yang masih terlihat dalam penelitian saat ini.

3 Metode Penelitian

Penelitian ini menggunakan pendekatan *systematic review* yang berfokus pada identifikasi, evaluasi, dan sintesis studi terkini (2015–2025) yang memanfaatkan MIT-BIH Polysomnographic Database (MIT-BIH-PSG) dalam pengembangan model prediksi gangguan tidur, terutama apnea tidur (*sleep apnea*) dan gangguan pernapasan terkait tidur. Penggunaan rentang waktu 2015–2025 dipilih karena periode ini merepresentasikan perkembangan paling signifikan dalam pemanfaatan MIT-BIH Polysomnographic Database untuk analisis gangguan tidur berbasis teknologi. Dalam satu dekade terakhir, terjadi kemajuan besar pada metode machine learning, deep learning, serta teknik analisis sinyal biomedis, sehingga studi-studi yang terbit pada periode ini lebih relevan dengan pendekatan modern dan aplikasi klinis terkini. Selain itu, dataset MIT-BIH-PSG mulai banyak digunakan kembali dalam penelitian karena meningkatnya kebutuhan model otomatis untuk deteksi apnea tidur dan gangguan pernapasan. Dengan demikian, periode 2015–2025 memungkinkan penelitian ini menangkap tren mutakhir, kesenjangan penelitian, serta evolusi metode yang berkontribusi terhadap pengembangan sistem prediksi gangguan tidur berbasis data PSG. Pendekatan penelitian mengikuti pedoman PRISMA 2020 [9] untuk memastikan transparansi dan reproduktibilitas proses tinjauan seperti terlihat pada Gambar 1.



Gambar 1 Metode screening PRISMA pada MIT-BIH polysomnography

Sumber data utama berasal dari publikasi ilmiah *peer-reviewed* yang tersedia secara *open access* dan terindeks Scopus minimal Q5. Basis data pencarian mencakup IEEE Xplore, PubMed Central, ScienceDirect, dan MDPI dengan kombinasi kata kunci: “MIT-BIH Polysomnographic Database”, “sleep apnea prediction”, “polysomnography”, “EEG ECG fusion”, dan “deep learning sleep disorder”. Proses penapisan (*screening*) dilakukan berdasarkan kriteria inklusi dan eksklusi yang dijabarkan pada Tabel 1 Kriteria Inklusi dan Eksklusi. Secara umum, kriteria inklusi mencakup penelitian yang menggunakan MIT-BIH-PSG sebagai dataset utama atau pembanding, menerapkan metode pembelajaran mesin atau *deep learning*, serta melaporkan metrik performansi seperti akurasi, sensitivitas, atau AUC. Sementara itu, artikel yang tidak menyebutkan MIT-BIH-PSG secara eksplisit atau tidak menyajikan hasil eksperimental dikeluarkan dari analisis.

Tabel 1 Kriteria inklusi dan eksklusi

Kriteria Inklusi	Kriteria Eksklusi
Artikel menggunakan MIT-BIH Polysomnographic Database (SLPDB) secara langsung	Artikel tidak menggunakan MIT-BIH SLPDB secara langsung
Artikel memiliki data lengkap atau metode yang dapat direplikasi	Data tidak lengkap atau metode tidak dapat direplikasi
Fokus penelitian terkait deteksi atau klasifikasi gangguan tidur	Fokus tidak terkait deteksi atau klasifikasi gangguan tidur
Artikel bukan duplikasi (unik)	Studi duplikasi
Artikel ilmiah, relevan dengan domain tidur, dan tersedia secara open-access	Artikel ilmiah, relevan dengan domain tidur, dan tersedia secara open-access

Setiap publikasi yang memenuhi kriteria dievaluasi secara independen oleh dua penelaah. Data yang diekstraksi meliputi jenis sinyal (EEG, ECG, respirasi), teknik pra-pemrosesan (filtering,

segmentasi, normalisasi), arsitektur model (CNN, RNN, hybrid), metode validasi (cross-validation, *patient-independent*), serta performansi model dalam mendeteksi apnea atau gangguan tidur lainnya. Langkah ini merujuk pada pendekatan ekstraksi sistematis sebagaimana digunakan oleh Fan et al. (2024) [4] dan Paul et al. (2024) [10] yang meninjau pipeline analisis sinyal tidur menggunakan *deep learning* secara terstruktur.

Analisis dilakukan secara naratif dengan membandingkan hasil antar-studi untuk menemukan pola umum, misalnya pengaruh jenis sinyal terhadap performansi model atau efektivitas fusi multimodal dibandingkan sinyal tunggal. Selain itu, dilakukan penilaian metodologis terhadap kualitas validasi dan keterbukaan kode yang digunakan. Studi seperti Zhang et al. (2023) [4] dan SelANet (BMC Med. Inform. Decis. Mak., 2023) [5] dijadikan acuan metodologi karena menampilkan penggunaan data publik secara transparan dan pendekatan berbasis keyakinan prediktif.

Fokus utama penelitian ini adalah mengidentifikasi celah (gap) dalam pemanfaatan MIT-BIH-PSG, khususnya kurangnya standarisasi pipeline pra-pemrosesan dan belum adanya konsensus terhadap validasi pasien-independen untuk memastikan generalisasi model. Berdasarkan temuan dari literatur yang relevan, penelitian ini bertujuan merumuskan rekomendasi metodologis terkait penggunaan dataset MIT-BIH-PSG secara lebih optimal untuk prediksi gangguan tidur berbasis kecerdasan buatan.

4 Hasil dan Pembahasan

Penelitian periode 2015–2025 menunjukkan variasi signifikan pada preprocessing, filtering, dan segmentasi yang memengaruhi akurasi model berbasis MIT-BIH PSG. Mayoritas studi menggunakan *baseline filtering* berupa bandpass–notch, namun pendekatan *adaptive filtering* seperti wavelet soft-thresholding atau EMD–DWT terbukti lebih robust terhadap noise, terutama pada sinyal ECG dan respirasi. Dari sisi preprocessing, metode derivatif [11] dan *annotation filtering* WFDB [12] menjadi teknik yang paling konsisten meningkatkan kualitas data dan layak distandardisasi dalam pipeline. Perbedaan segmentasi juga berpengaruh: *30-detik* tetap paling efektif dan selaras dengan standar AASM, sedangkan *60-detik* lebih stabil untuk analisis HRV atau apnea berbasis ECG, dan segmentasi *event-based* hanya unggul untuk prediksi dini kejadian (misalnya OSA). Secara keseluruhan, kombinasi filtering konvensional + koreksi anotasi + segmentasi 30 detik merupakan komponen pipeline yang paling konsisten, sedangkan metode lanjutan seperti recurrence plots, CRC spectrogram, atau adaptive filtering bersifat opsional untuk peningkatan performa pada kasus tertentu.

4.1 Hasil Penelitian

Berdasarkan analisis terhadap 35 artikel open-access bereputasi Q1-Q5 yang menggunakan MIT-BIH Polysomnographic Database (SLPDB) selama periode 2015–2025, diperoleh bahwa dataset ini paling sering digunakan untuk deteksi sleep apnea, klasifikasi tahapan tidur, dan analisis sinyal fisiologis EEG/ECG. Rangkuman hasil utama tiap studi ditunjukkan pada Tabel 2.

Tabel 2 Ringkasan temuan penelitian yang menggunakan MIT-BIH polysomnographic database (2015–2025)

No	Peneliti & Tahun	Metode	Tujuan / Task	Hasil Utama	Keunikan
1	Barnes et al. (2022, PLOS ONE)[13]	CNN (EEG tunggal)	Deteksi sleep apnea	Akurasi >92%, sensitivitas tinggi	Fokus pada explainability CNN
2	Guyot et al. (2025, PLOS ONE) [14]	Analisis ECG jangka panjang	Deteksi apnea	Akurasi 91%	Algoritme ECG-only untuk mendeteksi apnea
3	Gurralla, Vijayakumar, Yarlagadda, Padmasai, Koppireddi, Padmaraju[15]	Ensemble Bagged Tree (Machine Learning)	Deteksi Sleep Apnea & Klasifikasi Tahap Tidur dari sinyal EEG MIT-BIH PSG	Akurasi deteksi apnea 95.9% pada 18 rekaman (10.197 epoch)	Fokus pada ekstraksi fitur EEG untuk membedakan tahap tidur dan mendukung diagnosis klinis.
4	Lucas et al. (2022) [16]	Hybrid Machine Learning	Deteksi kantuk	Akurasi 88%	Fokus pada drowsiness menggunakan data PSG
5	Guillet et al. (2021, Frontiers AM&S)	Analisis ritme koherensi	Analisis ritme tidur	Koherensi tinggi antar kanal EEG	Pendekatan statistik nonlinier

	[17]			dan EMG		
6	Singh et al. (2023, Frontiers in AI) [18]	Review metode	Kajian fitur EEG	MIT-BIH sering digunakan untuk benchmarking	Review komprehensif DL untuk EEG	
7	Suboh et al. (2022, Frontiers Public Health) [11]	Analisis turunan sinyal	Preprocessing	Perbaikan noise 18–22%	Feature engineering pada domain turunan	
8	Padovano et al. (2025, Applied Sciences) [19]	DL + Recurrence	Klasifikasi tidur	Akurasi 90%	Kombinasi recurrence + DL	
9	Paul et al. (2024, Sensors) [10]	Model linier segmental	Sleep stage classification	Akurasi 89%	Model interpretable berbasis piecewise	
10	Dong et al. (2025, ScienceDirect) [20]	CNN detektor	Deteksi event EEG	F1-score 0.91	Validasi lintas dataset (MIT-BIH & PhysioNet)	
11	Benkő et al. (2022, Scientific Reports) [21]	Model-free detection	Deteksi event fisiologis	Deteksi >90% tepat waktu	Tanpa model training tradisional	
12	Frontiers Group (2015) [22]	DL & analisis sinyal	Sleep staging	Rata-rata akurasi 85–92%	Benchmark lintas model	
13	F1000Research (2022) [23]	Machine Learning hibrida	Deteksi apnea	Akurasi 88%	Open-peer review meningkatkan transparansi	
14	Que, Yinqing Jiang, Pengyi Zhang, Tianyi Cheng, Yunzhang [24]	CNN untuk fitur respirasi, Word2Vec untuk data fisik, dan transformer untuk penggabungan fitur.	Klasifikasi tahap tidur berbasis sinyal respirasi dan informasi fisik pasien.	Akurasi mencapai 81,96% pada MIT-BIH PSG.	Sleep staging tanpa PSG multikanal, hanya memakai respirasi + metadata dengan arsitektur hybrid CNN–Transformer.	
15	S. Rashidi and B. M. Asl[25]	Model Ensemble Stacking + Bagging	Deteksi Tidur	Akurasi 99.93% (2 kelas), 97.14%–85.64% (3–6 kelas)	Kombinasi unik stacking & bagging, akurasi tinggi dengan sinyal single-channel	
16	J. Fan et al., [26]	EDR Estimation Processor (QRS + Adaptive Threshold)	Estimasi laju respirasi (EDR) & deteksi QRS ultra-low power	Akurasi QRS 99.18%, MAE EDR 0.73, konsumsi daya sangat rendah (354 nW)	Prosesor ultra-low power 55 nm dengan teknik refractory period refreshing & adaptive EDR threshold	
17	W. Yang, J. Fan, X. Wang, and Q. Liao, [27]	LSTM (Respiration Signal)	Klasifikasi event pernapasan (norm, apnea, hypopnea)	Akurasi total 81.6%; recall 90.0% (norm), 87.1% (apnea), 83.2% (hypopnea)	Menggunakan anotasi 30-detik MIT-BIH PSG tanpa start–stop event; hanya sinyal respirasi sebagai input	
18	O. K. Utomo, N. Surantha, S. M. Isa, and B. Soewito [28]	WELM + PSO (ECG signal)	Sleep stage classification pada dataset imbalanced	Akurasi 78.78% (REM–NREM–Wake) dan 73.09% (Light–Deep–REM–Wake)	Mengatasi ketidakseimbangan data dengan Weighted ELM + seleksi fitur PSO pada MIT-BIH PSG	
19	U. Budak, V. Bajaj, Y. Akbulut, O. Atila, and A. Sengur [29]	Multi-block EEG + LSTM (Raw EEG, Spectrogram, TQWT)	Deteksi kantuk (driver drowsiness detection)	Akurasi rata-rata 94.31% (10-fold CV)	Tiga blok fitur (statistik, deep CNN features, TQWT sub-bands) digabung dengan LSTM + majority voting	
20	Adami, Ali Boostani, Reza	EMD + DWT ekstraksi sinyal	Estimasi Breathing Rate	MAPE sangat rendah (3.6–3.9%)	Menggabungkan multi-sinyal dengan state-	


	Marzbanrad, Faezeh Charlton, Peter H. [30]	respirasi + EKF dengan SQI pada ECG/PPG/BP	(BR) otomatis yang robust terhadap noise	ECG; 6.0% PPG; 5.0% BP) pada MIT-BIH & BIDMC	vector fusion; tetap akurat hingga 0 dB noise
21	J. of Healthcare Engineering [31]	Deep Learning (Wavelet + Adaptive Soft Thresholding, MIT-BIH Arrhythmia)	Deteksi aritmia otomatis (arrhythmia detection)	Akurasi tinggi pada dataset MIT- BIH (berbasis deep learning, tidak disebutkan angka spesifik)	Kombinasi deep learning + wavelet soft- thresholding untuk denoising adaptif dan deteksi aritmia presisi tinggi
22	Khalaf, Akram Jaddoa Mohammed, Samir Jasim [12]	Annotation Filtering Function (MATLAB- WFDB)	Standarisasi jumlah beat & koreksi anotasi MIT-BIH untuk evaluasi QRS/ML	Menemukan 71% penelitian memakai jumlah beat salah; fungsi menghasilkan hitungan beat yang benar	Menghapus non-beat annotations secara otomatis untuk semua database PhysioNet; meningkatkan validitas evaluasi & pelatihan ML
23	Que, Yinqing Jiang, Pengyi Zhang, Tianyi Cheng, Yunzhang [24]	CNN + Word2Vec + Transformer (Respiratory- based Sleep Staging)	Ekstraksi fitur sinyal pernapasan & data fisik untuk klasifikasi tahap tidur	Akurasi 81,96% pada MIT-BIH PSG	Hanya Menggunakan sinyal pernapasan + metadata tanpa PSG lengkap; arsitektur hybrid CNN- Word2Vec- Transformer.
24	Belakhdar, Ibtissem Kaaniche, Walid Djemal, Ridha Ouni, Bouraoui [32]	Spektral EEG (1 Hz Sub-bands + Individual Alpha Frequency)	Deteksi kantuk berbasis EEG	Akurasi ~88,8%, waktu proses 0,2 s per epoch	Menggunakan hanya 1 kanal diferensial & fitur alpha tunggal untuk mengurangi variabilitas antar-individu dan cocok untuk implementasi embedded ARM.
25	Wei, Ran Zhang, Xinghua Wang, Jinhai Dang, Xin [33]	DNN (Stacked Autoencoder + 11 Fitur ECG)	Klasifikasi tahap tidur (Wake-REM- NREM) berbasis sinyal ECG	Akurasi 77%, Cohen's kappa 0.56	Menggantikan EEG dengan ECG untuk monitoring tidur di rumah; validasi cross- subject dari 18 PSG MIT-BIH.
26	Taghizadegan, Yashar Jafarnia Dabanloo, Nader Maghooli, Keivan Sheikhani, Ali [34]	RP-CNNs (ResNet-18 & ShuffleNet + WMV Fusion)	Prediksi dini OSA 30-120 detik sebelum kejadian	Akurasi hingga 90.72% & AUC 0.90 pada MIT- BIH & Dublin Sleep Apnea	Menggunakan Recurrence Plots untuk representasi dinamika sinyal PSG dan fusi Weighted Majority Voting untuk meningkatkan performa prediksi dibanding studi sebelumnya.
27	Onyema, Edeh Michael Ahanger, Tariq Ahamed Samir, Ghouali Shrivastava, Manish Maheshwari, Manish Seghir, Guellil Mohammed Krah, Daniel [35]	Panel Cointegration + FMOLS/DOLS + Panel Granger Causality	Menganalisis hubungan jangka panjang & arah kausalitas antar sinyal fisiologis (ECG, EEG, BP, RESP) pada pasien sleep apnea	Ditemukan hubungan kausal bilateral ECG- BP, ECG-EEG, EEG-BP serta pengaruh signifikan hemodinamik- respiratori terhadap ECG/EEG	Pendekatan dua-dimensi jantung-otak dengan pemodelan konvergensi jangka panjang & arah kausalitas Granger untuk mendukung keputusan klinis.
28	Atianashie, Miracle	CNN (Single-	Klasifikasi	Akurasi 92% pada	Arsitektur single-level

	A Armah, Ellisha D'Archimedes Mohammed, Nasiru [36]	channel EEG) + Raspberry Pi Deployment	otomatis gangguan tidur (apnea & insomnia) menggunakan CNN dan GUI berbasis real- time	MIT-BIH PSG & CAP; tanpa perlu feature extraction/selectio n manual	CNN yang ringan & dapat berjalan di Raspberry Pi untuk deteksi gangguan tidur secara real-time.
29	Wang, Wei Bo Qin, Dimei Fang, Yu Zhou, Chao Zheng, Yongkang [37]	Hybrid HRV + R-Peak Features + GBDT	Sleep staging otomatis (2–5 level) menggunakan fitur hibrida time–freq– nonlinear dari HRV & RP	Akurasi tinggi: 91.34% (2-stage), 89.56% (3-stage), 87.15% (4-stage), 82.02% (5-stage); kappa hingga 0.77	Memperkenalkan sinyal R-Peak sebagai fitur baru yang menangkap esensi ECG & bekerja stabil di dua database (UCDDB & MIT-BIH).
30	Deep learning in the cross-time frequency domain for sleep staging from a single-lead electrocardiogram [38]	CRC Spectrogram + CNN + SVM Fusion (ECG- only Sleep Staging)	Klasifikasi tahap tidur berbasis ECG tunggal melalui beat detection, cardiorespirator y coupling (coherence & cross- spectrogram), CNN & SVM	Akurasi 75.4% (4- stage), 81.6% (3- stage), 85.1% (2- class); kappa hingga 0.68	Menghasilkan performa terbaik berbasis non- EEG dengan CRC time- frequency features & dataset sangat besar tanpa anotasi manual.
31	Sharma, Manish Makwana, Paresh Chad, Rajesh Singh Acharya, U. Rajendra [39]	BWFB + Hjorth Features + Ensemble Classifier (2- channel EEG)	Sleep stage classification otomatis berbasis dua kanal EEG dengan Hjorth parameters dari subband biorthogonal wavelet filter bank	Akurasi 83.2%, Kappa 0.7345 (5- stage), konsisten & kompetitif di 5 database publik	Pioneering work pada WSC (dataset sangat besar & beragam gangguan tidur), model ringan untuk perangkat rumah & wearable.
31	Peng, Chun Cheng Kou, Chu Yun [40]	Transfer Learning AlexNet (ECG- based OSA Prediction)	Prediksi kejadian Obstructive Sleep Apnea dari sinyal ECG menggunakan transfer learning berbasis AlexNet	Akurasi 86.63%, sensitivitas 92.20%, presisi 90.55%, AUC 91.95%	Menunjukkan potensi kuat deep learning- transfer learning untuk deteksi OSA berbasis ECG yang lebih efisien & mudah diimplementasikan.
32	Chatterjee, Arnab Jana, Nanda Dulal [41]	ADASYN untuk oversampling + Tomek-links untuk pembersihan sampel, dengan classifier Bagged Trees, Subspace KNN, KNN, dan Cubic SVM pada MIT-BIH	meningkatkan akurasi klasifikasi jenis- jenis event sleep apnea pada data EEG yang tidak seimbang	Subspace KNN memberikan akurasi tertinggi yaitu 98.92% (MIT-BIH) dan 81.39% (UCDDB)	kombinasi ADASYN dan Tomek-links untuk penyeimbangan data serta evaluasi lintas dua database sehingga hasil lebih generalizable.

		dan UCDDDB			
33	Rykhalska, Anna Kostiantynivna Ivanko, Kateryna Olehivna Ivanushkina, Nataliia Heorhiivna Ivanko, Dmytro Olehovych [42]	Fitur HRV & EEG + KNN/SVM/Bagging pada Apnea-ECG & MIT-BIH	Klasifikasi norm-apnea- hypopnea	Akurasi hingga 99.9% (HRV), EEG hanya 91.9%	HRV paling informatif; kombinasi ECG-EEG tetap unggul namun mirip HRV saja
34	SleepECG: a Python package for sleep staging based on heart rate [43]	Sleep staging berbasis detak jantung menggunakan HRV, heartbeat detection Pan- Tompkins, ekstraksi 33 fitur HRV + RNN classifier (SleepECG)	Mengembangka n pipeline otomatis untuk klasifikasi Wake/REM/NR EM tanpa EEG	Akurasi 83% (Wake-Sleep) dan 75% (W/REM/NREM) pada 1000 data uji	Open-source, cepat (C- extension), dapat dilatih ulang, dan mendukung ribuan data PSG secara reproducible
35	Detection of Sleep Apnea based on the analysis of sleep stages data using single channel EEG [15]	Ekstraksi fitur EEG dari PSG + Ensemble Bagged Tree pada dataset PhysioNet (MIT-BIH)	Deteksi apnea & identifikasi tahap tidur berbasis sinyal EEG	Akurasi deteksi apnea mencapai 95.9% pada 10.197 epoch	Fokus pada EEG saja tanpa semua PSG; fitur baru EEG membantu diagnosis klinis

4.2 Fokus Penelitian

Terdapat banyak pendekatan pemodelan yang digunakan dalam analisis sinyal tidur berbasis MIT-BIH SLPDB. Berdasarkan 35 literatur yang dianalisis, peneliti menemukan lima kategori metodologi utama, Sleep Apnea Detection, seperti pada literatur [13], [11], [19], [20], [22], [24], [25], [26], [29], [12], [35], [37], [39], [41], Sleep Staging, seperti pada literatur [14], [16], [18], [10], [21], [27], [30], [31], [32], [36], [40], Signal Processing Improvement, seperti pada literatur [15], [23], [25], [28], [33], Multichannel Fusion Methods, seperti pada literatur [34], [38], [42], [43], Interpretable / Explainable AI, seperti pada literatur [15].




Gambar 2 Distribusi Metodolog Literatur

Pada Gambar 2, kategori yang paling banyak digunakan adalah Sleep Apnea Detection dengan persentase 40%, diikuti oleh Sleep Staging sebesar 31%. Kategori lainnya yaitu Signal Processing Improvement, Multichannel Fusion, dan Interpretable AI masing-masing memiliki persentase 14%, 11%, dan 4%. Dominasi kategori Sleep Apnea Detection disebabkan oleh beberapa keunggulan

utama. Task deteksi apnea memiliki pola fisiologis yang lebih jelas, seperti henti napas pada sinyal respirasi atau variasi HRV pada ECG, sehingga model machine learning maupun deep learning dapat mencapai akurasi sangat tinggi, bahkan lebih dari 95%. Selain itu, jenis sinyal yang digunakan—seperti ECG, respirasi, dan SpO₂—lebih stabil dan tidak memerlukan segmentasi kompleks seperti yang dibutuhkan pada sleep staging berbasis EEG. Relevansi klinis yang tinggi juga menjadi faktor penting, karena deteksi apnea sangat diperlukan dalam pengembangan sistem diagnosis dini dan perangkat wearable untuk pemantauan tidur. Lebih jauh lagi, efektivitas model deep learning berbasis CNN, LSTM, dan arsitektur hybrid dalam mengenali pola apnea menjadikan kategori ini berkembang paling cepat secara metodologis.

Selain variasi metodologi, penelitian-penelitian yang menggunakan MIT-BIH SLPDB juga menunjukkan pola yang beragam dalam pemanfaatan jenis sinyal fisiologis. Berdasarkan 35 literatur yang dianalisis, peneliti menemukan bahwa empat kelompok sinyal utama—EEG, ECG, respirasi, dan kombinasi multikanal—menjadi dasar utama dalam pengembangan model analisis tidur. Penggunaan sinyal EEG banyak ditemukan pada studi yang berfokus pada *sleep staging* dan deteksi kantuk, sebagaimana terlihat pada literatur [13], [15], [17], [18], [28], [31], [32], [39], [33], [42], [36], [41]. Sementara itu, sinyal ECG merupakan salah satu sinyal yang paling banyak dimanfaatkan, terutama dalam *sleep apnea detection*, seperti pada literatur [11], [12], [14], [20], [24], [25], [26], [29], [30], [33], [34], [37], [40]. Pada sisi lain, beberapa penelitian memanfaatkan sinyal respirasi sebagai dasar utama analisis, seperti ditunjukkan dalam literatur [19], [25], [26], [29], [31], [34], [33], [35], [38], terutama untuk tugas deteksi apnea dan *respiratory-based sleep staging*. Adapun pendekatan multikanal, yang menggabungkan beberapa sinyal seperti EEG, ECG, EMG, dan respirasi, ditemukan pada literatur [34], [38], [42], [43], [28], [17] dan menunjukkan performa yang lebih komprehensif dalam menangkap dinamika tidur yang kompleks. Distribusi penggunaan data dapat terlihat pada gambar 3.



Gambar 3 Distribusi penggunaan sinyal MIT-BIH database

4.3 Sintesis Umum

Secara keseluruhan, 35 penelitian yang dianalisis menunjukkan variasi performa model yang signifikan, dengan akurasi model berkisar antara 78% hingga >99%. Akurasi ini sangat dipengaruhi oleh jenis tugas (*task*)—di mana deteksi gangguan tidur (misalnya, *Sleep Apnea*) cenderung mencapai akurasi tertinggi (>95%)—serta jenis sinyal yang digunakan (EEG, ECG, atau multimodal). Meskipun pendekatan *Deep Learning* (DL) masih menjadi metodologi yang dominan, terlihat adanya peningkatan perhatian terhadap model hibrida (*hybrid*) yang mengombinasikan kekuatan DL dengan fleksibilitas model klasik (*interpretable*) untuk meningkatkan transparansi dan kinerja. Selain itu, MIT-BIH SLPDB terus terbukti sebagai *dataset* yang konsisten dan relevan sebagai tolok ukur (*benchmark*) utama yang valid untuk membandingkan performa lintas pendekatan pemodelan.

5 Kesimpulan

Analisis terhadap 35 studi berbasis MIT-BIH SLPDB menunjukkan bahwa penelitian deteksi dan klasifikasi gangguan tidur terus berkembang melalui penerapan lima kategori metodologi utama, yakni *Sleep Apnea Detection*, *Sleep Staging*, *Signal Processing Improvement*, *Multichannel Fusion Methods*, dan *Interpretable/Explainable AI*, dengan dua kategori pertama menjadi fokus dominan. Variasi metodologi ini sejalan dengan pola pemanfaatan empat kelompok sinyal fisiologis—EEG, ECG, respirasi, dan multikanal—di mana EEG paling banyak digunakan untuk *sleep staging*, ECG untuk deteksi apnea, respirasi sebagai alternatif efektif untuk analisis berbasis laju napas, dan multikanal untuk tugas yang menuntut integrasi informasi fisiologis yang lebih luas. Pendekatan *deep learning*, khususnya CNN, LSTM, dan arsitektur hibrida, merupakan metodologi yang paling banyak diadopsi, dengan performa model yang dilaporkan berada pada rentang akurasi 78% hingga lebih dari 99%, bergantung pada jenis sinyal, teknik pra-pemrosesan, dan konfigurasi model. Penelitian ini memberikan kontribusi melalui pemetaan sistematis yang menghubungkan metodologi, penggunaan sinyal, dan hasil kinerja dalam satu kerangka analitis yang komprehensif, sekaligus mengidentifikasi kesenjangan pada aspek interpretabilitas dan variasi pipeline pemrosesan. Ke depan, penelitian perlu diarahkan pada pengembangan model hibrida yang lebih interpretable, pemanfaatan sinyal minimalis untuk mendukung perangkat *wearable*, eksplorasi multimodal fusion berbasis arsitektur modern, serta validasi klinis yang lebih luas guna meningkatkan reproduisibilitas dan kesiapan implementasi.

Referensi

- [1] B. Jafari and V. Mohsenin, "Polysomnography," Jun. 2010. DOI: 10.1016/j.ccm.2010.02.005.
- [2] Ichimaru Y, Moody GB. *Development of the polysomnographic database on CD-ROM*. Psychiatry Clin Neurosci. 1999 Apr;53(2):175-7. DOI: 10.1046/j.1440-1819.1999.00527.x. PMID: 10459681.
- [3] J. M. Lee, D. J. Kim, I. Y. Kim, K. S. Park, and S. I. Kim, "Detrended Fluctuation Analysis of EEG in Sleep Apnea using MIT/BIH Polysomnography Data," *Comput. Biol. Med.*, Vol. 32, No. 1, pp. 37–47, 2002, DOI: 10.1016/S0010-4825(01)00031-2.
- [4] Z. Zhang, Y. Xue, A. Slowik, and Z. Yuan, "Sle-CNN: A Novel Convolutional Neural Network for Sleep Stage Classification," *Neural Comput. Appl.*, Vol. 35, No. 23, pp. 17201–17216, Aug. 2023, DOI: 10.1007/s00521-023-08598-7.
- [5] B. Bark, B. Nam, and I. Y. Kim, "SelANet: Decision-Assisting Selective Sleep Apnea Detection based on Confidence score," *BMC Med. Inform. Decis. Mak.*, Vol. 23, No. 1, 2023, DOI: 10.1186/s12911-023-02292-3.
- [6] Kim, S., Choi, H.-S., Kim, D., Kim, M., Lee, S.-Y., Kim, J.-K., Kim, Y., & Lee, W. H. (2024). A Comprehensive Study on a Deep-Learning-Based Electrocardiography Analysis for Estimating the Apnea-Hypopnea Index. *Diagnostics*, 14(11), 1134. <https://doi.org/10.3390/diagnostics14111134>
- [7] Zovko, K., Sadowski, Y., Perković, T., Šolić, P., Pavlinac Dodig, I., Pecotić, R., & Đogaš, Z. (2025). *Advanced Data Framework for Sleep Medicine Applications: Machine Learning-based Detection of Sleep Apnea Events*. *Applied Sciences*, 15(1), 376. <https://doi.org/10.3390/app15010376>
- [8] A Abd-Alrazaq A, Aslam H, AlSaad R, Alsahli M, Ahmed A, Damseh R, Aziz S, Sheikh J. *Detection of Sleep Apnea using Wearable AI: Systematic Review and Meta-Analysis*. J Med Internet Res. 2024 Sep 10;26:e58187. DOI: 10.2196/58187. PMID: 39255014; PMCID: PMC11422752.
- [9] Page M J, McKenzie J E, Bossuyt P M, Boutron I, Hoffmann T C, Mulrow C D et al. "The PRISMA 2020 Statement: An Updated Guideline for Reporting Systematic Reviews" *BMJ* 2021; 372 :n71 DOI:10.1136/bmj.n71.
- [10] Y. Paul, R. Singh, S. Sharma, S. Singh, and I. H. Ra, "Efficient Sleep Stage Identification using Piecewise Linear EEG Signal Reduction: A Novel Algorithm for Sleep Disorder Diagnosis," *Sensors*, Vol. 24, No. 16, 2024, DOI: 10.3390/s24165265.
- [11] M. Z. Suboh, R. Jaafar, N. A. Nayan, N. H. Harun, and M. S. F. Mohamad, "Analysis on Four Derivative Waveforms of Photoplethysmogram (PPG) for Fiducial Point Detection," *Front. Public Heal.*, Vol. 10, 2022, DOI: 10.3389/fpubh.2022.920946.

- [12] A. J. Khalaf and S. J. Mohammed, "Verification and Comparison of MIT-BIH Arrhythmia Database based on Number of Beats," *Int. J. Electr. Comput. Eng.*, Vol. 11, No. 6, pp. 4950–4961, Dec. 2021, DOI: 10.11591/ijece.v11i6.pp4950-4961.
- [13] L. D. Barnes, K. Lee, A. W. Kempa-Liehr, and L. E. Hallum, "Detection of Sleep Apnea from Single-Channel Electroencephalogram (EEG) using an Explainable Convolutional Neural Network (CNN)," *PLoS One*, Vol. 17, No. 9 September, 2022, DOI: 10.1371/journal.pone.0272167.
- [14] P. Guyot, M. Eveilleau, T. Bastogne, C. Ayav, N. Carpentier, and B. Chenuel, "Robust Performances of a Nocturnal Long-Term ECG Algorithm for the Evaluation of Sleep Apnea Syndrome: A Pilot Study," *PLoS One*, Vol. 20, No. 5 May, pp. 1–15, 2025, DOI: 10.1371/journal.pone.0318622.
- [15] V. Gurralla, P. Yarlagadda, and P. Koppireddi, "Detection of Sleep Apnea based on the Analysis of Sleep Stages Data using Single Channel EEG," *Trait. du Signal*, Vol. 38, No. 2, pp. 431–436, 2021, DOI: 10.18280/TS.380221.
- [16] C. G. Lucas, P. Abry, H. Wendt, and G. Didier, "Drowsiness Detection from Polysomnographic Data using Multivariate Selfsimilarity and Eigen-Wavelet Analysis," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2022. DOI: 10.1109/EMBC48229.2022.9871363.
- [17] A. Guillet, A. Arneodo, and F. Argoul, "Tracking Rhythms Coherence from Polysomnographic Records: A Time-Frequency Approach," *Front. Appl. Math. Stat.*, Vol. 7, 2021, DOI: 10.3389/fams.2021.624456.
- [18] A. K. Singh and S. Krishnan, "Trends in EEG Signal Feature Extraction Applications," 2023. DOI: 10.3389/frai.2022.1072801.
- [19] D. Padovano, A. Martinez-Rodrigo, J. M. Pastor, J. J. Rieta, and R. Alcaraz, "Deep Learning and Recurrence Information Analysis for the Automatic Detection of Obstructive Sleep Apnea," *Appl. SCI.*, Vol. 15, No. 1, pp. 1–22, 2025, DOI: 10.3390/app15010433.
- [20] H. Dong, H. Wu, G. Yang, and J. Zhang, "A Convolutional Neural Network for Automatic Detection of Sleep-Breathing Events using Single-Channel ECG Signals," *Biomed. Signal Process. Control*, Vol. 109, p. 107943, Nov. 2025, DOI: 10.1016/J.BSPC.2025.107943.
- [21] Z. Benkő, T. Bábel, and Z. Somogyvári, "Model-Free Detection of Unique Events in Time Series," *SCI. Rep.*, Vol. 12, No. 1, 2022, DOI: 10.1038/s41598-021-03526-y.
- [22] T. Zorick and M. A. Mandelkern, "Discrete Scale Invariance of Human Large EEG Voltage Deflections is More Prominent in Waking than Sleep Stage 2," *Front. Hum. Neurosci.*, Vol. 9, No. DEC, 2015, DOI: 10.3389/fnhum.2015.00638.
- [23] C. Usha Kumari, S. K. M. K., and P. T., "Detection of Sleep Apnea using Polysomnographic Signals," *F1000Research*, Vol. 11, 2022, DOI: 10.12688/f1000research.124642.1.
- [24] Y. Que, P. Jiang, T. Zhang, and Y. Cheng, "Automated Sleep Staging based on Multi-Module Neural Network using Simpler Signal: Respiratory Signal," 2023. DOI: 10.1117/12.2688854.
- [25] S. Rashidi and B. M. Asl, "Strength of Ensemble Learning in Automatic Sleep Stages Classification using Single-Channel EEG and ECG Signals," *Med. Biol. Eng. Comput.*, Vol. 62, No. 4, pp. 997–1015, Apr. 2024, DOI: 10.1007/s11517-023-02980-2.
- [26] Fan, J., Yang, S., Liu, J., Zhu, Z., Xiao, J., Chang, L., Lin, S., & Zhou, J. (2022). A High Accuracy & Ultra-Low Power ECG-Derived Respiration Estimation Processor for Wearable Respiration Monitoring Sensor. *Biosensors*, 12(8), 665. <https://doi.org/10.3390/bios12080665>.
- [27] W. Yang, J. Fan, X. Wang, and Q. Liao, "Sleep Apnea and Hypopnea Events Detection based on Airflow Signals using LSTM Network," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Institute of Electrical and Electronics Engineers Inc., Jul. 2019, pp. 2576–2579. DOI: 10.1109/EMBC.2019.8857558.
- [28] O. K. Utomo, N. Surantha, S. M. Isa, and B. Soewito, "Automatic Sleep Stage Classification using Weighted ELM and PSO on Imbalanced Data from Single Lead ECG," in *Procedia Computer Science*, Elsevier B.V., 2019, pp. 321–328. DOI: 10.1016/j.procs.2019.08.173.
- [29] U. Budak, V. Bajaj, Y. Akbulut, O. Atila, and A. Sengur, "An effective Hybrid Model for EEG-based Drowsiness Detection," *IEEE Sens. J.*, Vol. 19, No. 17, pp. 7624–7631, Sep. 2019, DOI: 10.1109/JSEN.2019.2917850.

- [30] A. Adami, R. Boostani, F. Marzbanrad, and P. H. Charlton, "A New Framework to Estimate Breathing Rate from Electrocardiogram, Photoplethysmogram, and Blood Pressure Signals," *IEEE Access*, Vol. 9, 2021, DOI: 10.1109/ACCESS.2021.3066166.
- [31] J. of Healthcare Engineering, "Retracted: Online Automatic Diagnosis System of Cardiac Arrhythmias based on MIT-BIH ECG Database," *J. Healthc. Eng.*, Vol. 2023, No. 1, Jan. 2023, DOI: 10.1155/2023/9873656.
- [32] I. Belakhdar, W. Kaaniche, R. Djemal, and B. Ouni, "Single-Channel-based Automatic Drowsiness Detection Architecture with a Reduced Number of EEG Features," *Microprocess. Microsyst.*, Vol. 58, pp. 13–23, Apr. 2018, DOI: 10.1016/j.micpro.2018.02.004.
- [33] R. Wei, X. Zhang, J. Wang, and X. Dang, "The Research of Sleep Staging based on Single-Lead Electrocardiogram and Deep Neural Network," *Biomed. Eng. Lett.*, Vol. 8, No. 1, pp. 87–93, Feb. 2018, DOI: 10.1007/s13534-017-0044-1.
- [34] Y. Taghizadegan, N. Jafarnia Dabanloo, K. Maghooli, and A. Sheikhan, "Obstructive Sleep Apnea Event Prediction using Recurrence Plots and Convolutional Neural Networks (RP-CNNs) from Polysomnographic Signals," *Biomed. Signal Process. Control*, Vol. 69, Aug. 2021, DOI: 10.1016/j.bspc.2021.102928.
- [35] C. Intelligence and Neuroscience, "Retracted: Empirical Analysis of Apnea Syndrome using an Artificial Intelligence-based Granger Panel Model Approach," *Comput. Intell. Neurosci.*, Vol. 2024, No. 1, p. 9861346, Jan. 2024, DOI: <https://doi.org/10.1155/2024/9861346>.
- [36] M. A. Atianashie, E. D. Armah, and N. Mohammed, "A Portable GUI based Sleep Disorder System Classification based on Convolution Neural Networks (CNN) in Raspberry PI," *J. Eng. Appl. SCI. Humanit.*, Vol. 6, No. 1, pp. 13–23, 2021.
- [37] W. B. Wang, D. Qin, Y. Fang, C. Zhou, and Y. Zheng, "Automatic Multi-Class Sleep Staging Method based on Novel Hybrid Features," *J. Electr. Eng. Technol.*, Vol. 19, No. 1, pp. 709–722, Jan. 2024, DOI: 10.1007/s42835-023-01570-4.
- [38] Q. Li, Q. Li, C. Liu, S. P. Shashikumar, S. Nemati, and G. D. Clifford, "Deep Learning in the Cross-Time Frequency Domain for Sleep Staging from a Single-Lead Electrocardiogram," *Physiol. Meas.*, Vol. 39, No. 12, Dec. 2018, DOI: 10.1088/1361-6579/aaf339.
- [39] M. Sharma, P. Makwana, R. S. Chad, and U. R. Acharya, "A Novel Automated Robust Dual-Channel EEG-based Sleep Scoring System using Optimal Half-Band Pair Linear-Phase Biorthogonal Wavelet Filter Bank," *Appl. Intell.*, Vol. 53, No. 15, pp. 18681–18699, Aug. 2023, DOI: 10.1007/s10489-022-04432-0.
- [40] C. C. Peng and C. Y. Kou, "Sleep Disorder Classification using Convolutional Neural Networks," in *IFIP Advances in Information and Communication Technology*, Springer Science and Business Media Deutschland GmbH, 2023, pp. 539–548. DOI: 10.1007/978-3-031-34111-3_45.
- [41] A. Chatterjee and N. D. Jana, "Classification of Sleep Apnea Event Type using Imbalanced Labelled EEG Signal," in *2022 IEEE Region 10 Symposium, TENSYP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. DOI: 10.1109/TENSYP54529.2022.9864566.
- [42] A. K. Rykhalska, K. O. Ivanko, N. H. Ivanushkina, and D. O. Ivanko, "Detection of Episodes of Sleep Apnea and Hypopnea in ECG and EEG Signals by Machine Learning," *Microsystems, Electron. Acoust.*, Vol. 27, No. 1, pp. 251487–1–251487–11, Apr. 2022, DOI: 10.20535/2523-4455.me.251487.
- [43] C. Brunner and F. Hofer, "SleepECG: A Python Package for Sleep Staging based on Heart Rate," *J. Open Source Softw.*, Vol. 8, No. 86, p. 5411, Jun. 2023, DOI: 10.21105/joss.05411.