



طبقه بندی مرحله خواب بر اساس EDR و HRV حاصل از ECG

محمدرضا یوسفی نجف‌آبادی^۱، محمد البهادلی^۲

^۱دانشکده مهندسی برق، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران
^۲شرکت برق منطقه‌ای اصفهان، اصفهان، ایران

چکیده: این مقاله به تشخیص و طبقه‌بندی مراحل خواب بر اساس سیگنال ECG^۱ با استفاده از الگوریتم‌های یادگیری ماشین می‌پردازد. مراحل خواب شامل بیداری، مراحل خواب REM^۲ و NREM^۳ هستند که هر کدام ویژگی‌ها و الگوهای خاص خود را دارند. در این مطالعه، از دو ویژگی مهم در تحلیل سیگنال ECG استفاده شده است، شامل تنفس مشتق شده از ECG (EDR^۴) و تنوع ضربان قلبی (HRV^۵).

با استفاده از ویژگی‌های استخراج شده از سیگنال ECG و با استفاده از مدل‌های طبقه‌بندی مناسب، می‌توان مراحل خواب را به طور صحیح تشخیص داد. در این مقاله، از یک روش ترکیبی استفاده شده است که ترکیبی از الگوریتم‌های استخراج ویژگی و الگوریتم طبقه‌بندی است. این روش ترکیبی بهبود قابل توجهی در دقت و قابلیت تعمیم‌پذیری مدل طبقه‌بندی ارائه می‌دهد.

نتایج آزمایشات بر روی مجموعه داده‌های واقعی نشان می‌دهد که دقت طبقه‌بندی برای تشخیص دو حالت خواب و بیدار برابر با ۸۱.۴٪ و دقت طبقه‌بندی برای تشخیص مراحل خواب REM و NREM برابر با ۷۴.۶٪ است. این نتایج نشان می‌دهد که روش ارائه شده قابلیت تشخیص و طبقه‌بندی مراحل خواب را بهبود بخشیده است.

واژگان کلیدی: تشخیص مرحله خواب، الکتروکاردیوگرام، تنفس ناشی از ECG، تغییرات ضربان قلب، ماشین بردار پشتیبانی

^۱ Electrocardiogram

^۲ Rapid Eye Movement

^۳ Non-Rapid Eye Movement

^۴ ECG-derived respiration

^۵ Heart Rate Variability



۱- مقدمه

تشخیص و طبقه‌بندی مراحل خواب، به عنوان یک مسئله مهم در زمینه پزشکی و علوم بهداشتی، اهمیت ویژه‌ای دارد. مراحل خواب شامل مرحله بیداری، مراحل خواب غیر REM و مراحل خواب REM هستند [2] و هر کدام ویژگی‌های خاص خود را دارند. در این مقاله، ما به طور خاص به تشخیص و طبقه‌بندی مراحل خواب بر اساس سیگنال الکتروکاردیوگرافی (ECG) تک لید می‌پردازیم.

برای انجام این کار، از دو ویژگی مهم در تحلیل سیگنال ECG استفاده می‌کنیم. اولین ویژگی، تنفس مشتق شده از ECG است که اطلاعات مرتبط با تنفس فرد را در سیگنال ECG بازتاب می‌دهد [7]. دومین ویژگی، تنوع ضربان قلبی است که میزان تغییرات زمانی بین ضربان‌های قلب را نشان می‌دهد و اطلاعاتی راجع به فعالیت عصبی-عضلانی و اتونومیک سیستم قلبی را در اختیار ما قرار می‌دهد [10].

برای طبقه‌بندی مراحل خواب، از روش‌های پردازش سیگنال و یادگیری ماشین استفاده می‌شود. این الگوریتم‌های یادگیری ماشین، با استفاده از ویژگی‌های استخراج شده از سیگنال ECG و با استفاده از مدل‌های طبقه‌بندی مناسب، قادر به تشخیص صحیح مراحل خواب هستند [1]. در این مقاله، از یک روش ترکیبی استفاده می‌شود که ترکیبی از الگوریتم‌های استخراج ویژگی و الگوریتم طبقه‌بندی است. این روش ترکیبی، با استفاده از ترکیب بهینه این دو مرحله، دقت و قابلیت تعمیم‌پذیری مدل طبقه‌بندی را بهبود می‌بخشد.

در نتیجه، این مقاله به بررسی وضعیت تشخیص و طبقه‌بندی مراحل خواب بر اساس سیگنال ECG می‌پردازد و رویکردهای نوینی را برای ارتقای دقت و کارایی این فرآیند ارائه می‌دهد. همچنین، نتایج آزمایشات و تحلیل‌های انجام شده بر روی مجموعه داده‌های واقعی، تأیید می‌کند که روش ارائه شده قابلیت تشخیص و طبقه‌بندی مراحل خواب از اهمیت ویژه‌ای برخوردار است. مراحل خواب شامل مرحله بیداری، مراحل خواب NREM و مراحل خواب REM هستند [5]. در این مقاله، به طور خاص به تشخیص مراحل خواب بر اساس سیگنال ECG (الکتروکاردیوگرافی) تک لید پرداخته شده است. بر اساس این مقاله، از دو ویژگی مهم در تحلیل سیگنال ECG، یعنی تنفس مشتق شده از (EDR) و تنوع ضربان قلبی (HRV) استفاده می‌شود. الگوریتم‌های یادگیری ماشین، با استفاده از ویژگی‌های استخراج شده از سیگنال ECG و مدل‌های طبقه‌بندی مناسب، قادر به تشخیص صحیح مراحل خواب هستند [6]. در این مقاله، از یک روش ترکیبی استفاده شده که ترکیبی از الگوریتم‌های استخراج ویژگی و الگوریتم طبقه‌بندی است.

تشخیص و طبقه‌بندی مراحل خواب اهمیت زیادی در زمینه علوم پزشکی دارد. مراحل خواب شامل بیداری، مراحل خواب غیر REM و مراحل خواب REM هستند [8]. در این مقاله، به ویژه به تشخیص مراحل خواب بر اساس سیگنال ECG تک لید می‌پردازیم. از دو ویژگی اصلی در تحلیل سیگنال ECG، یعنی تنفس مشتق شده از ECG و تنوع ضربان قلبی استفاده می‌کنیم. از روش‌های پردازش سیگنال و یادگیری ماشین برای طبقه‌بندی مراحل خواب استفاده می‌کنیم. الگوریتم‌های یادگیری ماشین، با استفاده از ویژگی‌های استخراج شده از سیگنال ECG و با استفاده از مدل‌های طبقه‌بندی مناسب، قادر به تشخیص صحیح مراحل خواب هستند [9]. در این مقاله، از یک روش ترکیبی استفاده می‌کنیم که ترکیبی از الگوریتم‌های استخراج ویژگی و الگوریتم طبقه‌بندی است.

۲- بررسی کارهای مرتبط

در این بخش، کارهای قبلی مرتبط با طبقه‌بندی مراحل خواب و استفاده از روش‌های متنوع مورد بررسی و ارزیابی قرار می‌گیرند. از جمله این کارها می‌توان به استفاده از روش‌های سنتی مانند ماشین بردار پشتیبان، شبکه‌های عصبی عمیق، روش‌های پردازش سیگنال و الگوی ECOC اشاره کرد. تریپاتی و همکاران [4] با بررسی سیگنال‌های ECG، استخراج HRV سیگنال، تخمین PSD و طبقه‌بندی بر اساس هوش مصنوعی از طریق طبقه‌بندی‌کننده‌های یادگیری ماشین ترکیبی حساسیت، خصوصیت و دقت به ترتیب به مقدار ۹۶.۰٪، ۹۴.۰٪ و ۹۶.۰٪ را بدست آوردند. همچنین شاران و همکاران [7] با استخراج HRV و EDR از سیگنال ECG با روش رگرسیون



لجستیک طبقه‌بندی کردند که به دقت معادل ۸۰٪ دست یافتند. میتسوکورا و همکاران [10] در یک مطالعه با استفاده از استخراج فقط HRV از سیگنال ECG به طبقه‌بندی با دقت ۶۶٪ رسیدند. سان و همکاران [12] با استخراج سیگنال EDR از سیگنال ECG با استفاده از شبکه عصبی پیچشی در طبقه‌بندی NREM, REM, wake به مقدار $\kappa = 0.76$ دست یافتند.

۳- پایگاه داده

پایگاه داده استفاده شده در این مقاله از مجموعه داده MIT-BIH Polysomnographic استفاده شده که شامل ۱۸ PSG است، هر سابقه شامل ضبط ECG, EEG، سیگنال تنفس و سیگنال فشار خون است. سوابق شامل افراد سالم (دو فرد) و بیماران مبتلا به سندرم خواب آپنه (۱۶ فرد) هستند، با میانگین سن 42 ± 7 ، میانگین وزن 119 ± 24 و فرکانس نمونه برداری ۲۵۰ هرتز. هر سابقه بین ۱۵۴ تا ۷۸۰ برچسب دارد که مراحل خواب را به REM, NREM و بیداری نشان می‌دهد. در این مطالعه، از تمام قطعات نشان داده شده موجود در هر ۱۸ سابقه داده ECG استفاده شده، که به ۳۰ ثانیه یا ۷۵۰۰ نمونه تقسیم شده‌اند [11].


لینک دانلود این پایگاه داده <https://physionet.org/content/slpdb/1.0.0> است [11].

۴- پیش‌پردازش


برای پیش‌پردازش ابتدا سیگنال از یک فیلتر notch با $w_0 = 0.4$ و پهنای باند -3 dB ($bw = 0.4$) ثانیه عبور داده شده است. در مرحله بعد تبدیل موجک ۶ با سطح ۱۰ بر سیگنال فیلتر شده اعمال شد. سپس سیگنال با سطح ۸ این تبدیل، بازسازی شده و baseline سیگنال با استفاده از آن حذف شده است. شکل ۱ روند فرایند حذف baseline در سیگنال را نشان می‌دهد. در مرحله بعد با استفاده از الگوریتم Pan-Tompkins برای بدست آوردن R-peaks استفاده شده است. این نقاط برای استخراج سیگنال‌های HRV و EDR لازم است. پس از فیلتر کردن سیگنال و حذف baseline آن، R-peaks بدست آمده که در شکل ۲ نمایش داده شده است. در این شکل R-peaks بر روی سیگنال اصلی قرار گرفته شده است. نقاط ستاره‌ای شکل R-peaks بدست آمده هستند.

در مرحله بعد EDR و HRV سیگنال محاسبه می‌شود. سیگنال HRV به تغییرات زمانی بین دو ضربان قلب متوالی در سیگنال ECG اشاره دارد. یعنی فاصله زمانی بین ضربان‌های قلب، که معمولاً با دقت بالایی اندازه‌گیری می‌شود. سیگنال HRV معمولاً به عنوان یک معیار برای ارزیابی و تحلیل فعالیت عصبی اتونوم در سیستم قلبی-عروقی استفاده می‌شود. برای استخراج سیگنال HRV، نقاط R در سیگنال ECG شناسایی می‌شوند و فواصل زمانی بین ضربان‌های قلب محاسبه می‌شود.


سیگنال EDR (Electrodermal Response) یا پاسخ الکتروگالوانیکی نیز به تغییرات هدایت الکتریکی پوست در پاسخ به تحریکات خارجی اشاره دارد. تحریکات مختلف می‌توانند باعث تغییر در هدایت الکتریکی پوست شوند، مانند استرس، تنش عاطفی، واکنش به وقوع رویدادها و غیره. اندازه‌گیری EDR می‌تواند نشان‌دهنده واکنش‌های فیزیولوژیکی و عاطفی فرد در مواجهه با رویدادها و شرایط مختلف باشد. برای استخراج سیگنال EDR، معمولاً از سیگنال هدایت الکتریکی استفاده می‌شود. سیگنال HRV و EDR از سیگنال ECG استخراج می‌شوند با شناسایی نقاط R در سیگنال ECG و محاسبه فواصل زمانی بین ضربان‌های قلب برای HRV و از سیگنال هدایت الکتریکی پوست برای EDR. شکل ۳ سیگنال EDR را نشان می‌دهد.



شکل ۱: فرایند حذف baseline. قسمت اول؛ سیگنال خام. قسمت دوم؛ baseline استخراج شده. قسمت سوم؛ نمایش سیگنال خام و baseline استخراج شده در یک نمودار. قسمت چهارم؛ سیگنال با baseline حذف شده



شکل ۲: R-peaks بدست آمده روی سیگنال اصلی



شکل ۳: نمونه سیگنال EDR

از این پارامترهای بدست آمده برای استخراج ویژگی که در بخش بعد به آن پرداخته شده استفاده می‌شود.

۵- استخراج ویژگی

ویژگی‌های استخراج شده به دو دسته ویژگی‌های حوزه زمان و ویژگی‌های حوزه فرکانس تقسیم می‌شوند. این ویژگی‌ها از پارامترهای EDR و HRV بدست آمده در بخش قبل استخراج شده‌اند. ویژگی‌های حوزه زمان شامل مقدار حداکثر، مقدار حداقل، میانگین، میانه، انحراف معیار، Skewness, Kurtosis، پارامترهای Hjorth شامل activity, mobility, complexity، آنتروپی نمونه‌ای (Sample Entropy)، آنتروپی تقریبی (Approximate Entropy)، آنتروپی جایگشت (Permutation Entropy) می‌شود. این ویژگی‌ها از هر دو پارامتر EDR و HRV بدست آمده است. پارامترهای Hjorth، مجموعه‌ای از پارامترهای استخراج شده از سیگنال‌های زمانی هستند که برای مطالعه و تحلیل سیستم‌های عصبی استفاده می‌شوند. این پارامترها توسط بیوفیزیکدان دانمارکی بنام بریان هیورت (Brian Hjorth) پیشنهاد شده‌اند و به منظور کمی‌سازی ویژگی‌های سیگنال‌های عصبی و ارتباط آنها با ویژگی‌های فیزیولوژیکی مورد استفاده قرار می‌گیرند. مجموعه پارامترهای Hjorth شامل سه پارامتر است که عبارتند از: Activity (فعالیت): پارامتر فعالیت نشان‌دهنده میزان انرژی و فعالیت کلی سیگنال است. این پارامتر با محاسبه واریانس سیگنال تعریف می‌شود. Mobility (حرکت): پارامتر حرکت نشان‌دهنده میزان تغییرات فرکانسی سیگنال است و به عنوان نسبت واریانس فرکانسی به فعالیت محاسبه می‌شود. Complexity (پیچیدگی): پارامتر پیچیدگی نشان‌دهنده رفتار غیرخطی سیگنال و تغییرات آن در طول زمان است. این پارامتر با محاسبه نسبت واریانس حرکت به حرکت قبلی محاسبه می‌شود.

برای استخراج ویژگی‌های حوزه فرکانس، چگالی طیف توان (PSD) سیگنال‌های EDR و HRV با استفاده از روش ولج (Welch) با استفاده از پنجره‌بندی همینگ (Hamming) با ۵۰٪ همپوشانی بدست آمده است. در سیگنال HRV، PSD می‌تواند برای ارزیابی فعالیت‌های سمپاتیک و پاراسمپاتیک استفاده شود. جزئیات فرکانس بالا (Hf) در بازه ۰.۱۵ تا ۰.۴ هرتز فعالیت پاراسمپاتیک یا واگال که با آریتمی سینوسی تنفسی مرتبط است را شبیه‌سازی می‌کند. جزئیات فرکانس پایین (Lf) که شامل بازه ۰.۰۴ تا ۰.۱۵ هرتز است، هم نشان‌دهنده عملکردهای سمپاتیک و پاراسمپاتیک در قلب است و در بالای ۰.۱ هرتز، سیستم عصبی سمپاتیک به نظر نمی‌رسد تأثیر



زیادی بر ریتم‌ها داشته باشد، اما سیستم پاراسمپاتیک می‌تواند تا ۰.۰۵ هرتز بر ریتم قلب اثر بگذارد. باند VLF با فرکانس‌هایی در بازه ۰.۰۳۳ تا ۰.۰۴ هرتز، نیز برای تحلیل فرکانسی HRV استخراج شده است. چندین ویژگی استخراج شده از باندهای فرکانسی LF، HF و VLF هر دو HRV و EDR عبارتند از: مساحت زیر باندهای فرکانسی (aHF و aLF، aVLF)، مجموع مساحت زیر (aTotal PSD)، نسبت مساحت باند فرکانسی به مساحت کل سیگنال (pHF و pLF، pVLF)، مساحت نرمال شده LF و HF ($HF_n = HF/(LF + HF)$) و ($LF_n = LF/(LF + HF)$)، نسبت LF به HF، و نقاط اوج فرکانسی باندها (peakVLF، peakLF، peakHF).

این ویژگی‌ها عبارتند از aVLF، aLF، aHF، pVLF، pLF، pHF، LF_n، HF_n، LF_HF_ratio، peakVLF، peakLF، peakHF. ویژگی‌های بدست آمده برای طبقه‌بندی استفاده شده است که در بخش بعد به آن پرداخته خواهد شد.

۶- طبقه‌بندی

در این مقاله، برای طبقه‌بندی مراحل خواب از روش ماشین بردار پشتیبان (SVM) استفاده شده است. ابتدا مجموعه داده به صورت تصادفی به دو زیرمجموعه، یعنی مجموعه آموزش (۸۰٪ از کل مجموعه داده) و مجموعه آزمایش (۲۰٪ از کل مجموعه داده) تقسیم شده است.

برای تشخیص و طبقه‌بندی مراحل بیداری (Wake)، REM و NREM (WRN) و همچنین مقایسه بین بیداری و خواب (WS)، از ماشین بردار پشتیبان چندکلاسه (SVM^1) با استفاده از افزونه‌ی کدگذاری خروجی تصحیح خطا (ECOC) استفاده شده است. این افزونه که به عنوان الگوی SVM استفاده می‌شود، به منظور ایجاد ساختار طبقه‌بندی استفاده شده است. روش SVM با استفاده از الگوی ECOC برای طبقه‌بندی مراحل خواب به کار گرفته شده است. این روش به ویژگی‌های استخراج شده از سیگنال ECG و با استفاده از مجموعه آموزش، یادگیری می‌کند و سپس بر روی مجموعه آزمایش اعمال می‌شود تا دقت طبقه‌بندی مورد ارزیابی قرار گیرد. با استفاده از روش SVM و افزونه ECOC، مراحل بیداری، REM و NREM و همچنین مقایسه بین بیداری و خواب به صورت دقیق تشخیص داده می‌شوند. این روش با استفاده از مدل SVM و ساختار طبقه‌بندی ECOC، قادر است الگوهای خاص و ویژگی‌های مراحل خواب را تشخیص داده و دقت طبقه‌بندی را بهبود بخشد.

۷- نتایج


نتایج حاصل از طبقه‌بندی‌های انجام شده در این مقاله در ادامه آورده شده است. شکل ۴ نتایج طبقه‌بندی بیداری و خواب (WS) را به صورت یک ماتریس سردرگمی نشان می‌دهد. در این ماتریس، محور افقی نشان دهنده برچسب‌های واقعی مراحل خواب (بیداری و خواب) و محور عمودی نشان دهنده برچسب‌های پیش‌بینی شده توسط مدل طبقه‌بندی است. اعداد در داخل هر خانه این ماتریس نشان دهنده تعداد نمونه‌هایی است که به درستی یا به اشتباه طبقه‌بندی شده‌اند. همچنین، شکل ۵ نتایج طبقه‌بندی مراحل بیداری (Wake)، REM و NREM (WRN) را نیز به صورت یک ماتریس سردرگمی نمایش می‌دهد. در این ماتریس، محور افقی نشان دهنده برچسب‌های واقعی مراحل خواب (بیداری، REM و NREM) و محور عمودی نشان دهنده برچسب‌های پیش‌بینی شده توسط مدل است.

۸- بحث و نتیجه‌گیری


در این مقاله به بررسی و تحلیل نتایج حاصل از طبقه‌بندی مراحل خواب و ارزیابی کارایی روش پیشنهادی می‌پردازد. در این قسمت، نتایج به دست آمده از طبقه‌بندی مراحل خواب با استفاده از روش ماشین بردار پشتیبان (SVM) با افزونه‌ی کدگذاری خروجی تصحیح

¹ Support Vector Machine

خطا (ECOC) مورد بررسی و تجزیه و تحلیل قرار می‌گیرند. نتایج نشان می‌دهند که روش پیشنهادی با دقت بالا می‌تواند مراحل بیداری و خواب را به طور دقیق تشخیص دهد. ماتریس سردرگمی نشان می‌دهد که تعداد زیادی از نمونه‌ها به درستی طبقه‌بندی شده‌اند. این نتایج نشان می‌دهند که مدل SVM با استفاده از الگوی ECOC قادر است تا الگوهای مختلف مراحل خواب را به خوبی تشخیص داده و دقت طبقه‌بندی را بهبود دهد. علاوه بر این، نتایج طبقه‌بندی مراحل بیداری (Wake)، REM، و NREM (WRN) نیز نشان می‌دهند که روش پیشنهادی عملکرد مناسبی در تشخیص این مراحل دارد. مدل SVM با استفاده از الگوی ECOC قادر است به طور جامع مراحل بیداری، REM و NREM را تشخیص داده و نتایج قابل قبولی را به ارمغان آورد.



شکل ۴: ماتریس سردرگمی خواب و بیداری



شکل ۵: ماتریس سردرگمی بیداری و REM و NREM



مراجع

- [1] A. Rahimi, A. Safari and M. Mohebbi, "Sleep Stage Classification Based on ECG-Derived Respiration and Heart Rate Variability of Single-Lead ECG Signal," *2019 26th National and 4th International Iranian Conference on Biomedical Engineering (ICBME)*, Tehran, Iran, 2019, pp. 158-163, doi: 10.1109/ICBME49163.2019.9030391.
- [2] E. Eldele et al., "An Attention-Based Deep Learning Approach for Sleep Stage Classification With Single-Channel EEG," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29. Institute of Electrical and Electronics Engineers (IEEE), pp. 809–818, 2021. doi: 10.1109/tnsre.2021.3076234.
- [3] M. Tang et al., "Deep adaptation network for subject-specific sleep stage classification based on a single-lead ECG," *Biomedical Signal Processing and Control*, vol. 75. Elsevier BV, p. 103548, May 2022. doi: 10.1016/j.bspc.2022.103548.
- [4] P. Tripathi et al., "Ensemble Computational Intelligent for Insomnia Sleep Stage Detection via the Sleep ECG Signal," in *IEEE Access*, vol. 10, pp. 108710-108721, 2022, doi: 10.1109/ACCESS.2022.3212120.
- [5] R. Zhao, Y. Xia, and Q. Wang, "Dual-modal and multi-scale deep neural networks for sleep staging using EEG and ECG signals," *Biomedical Signal Processing and Control*, vol. 66. Elsevier BV, p. 102455, Apr. 2021. doi: 10.1016/j.bspc.2021.102455.
- [6] E. Urtnasan, J.-U. Park, E. Y. Joo, and K.-J. Lee, "Deep Convolutional Recurrent Model for Automatic Scoring Sleep Stages Based on Single-Lead ECG Signal," *Diagnostics*, vol. 12, no. 5. MDPI AG, p. 1235, May 15, 2022. doi: 10.3390/diagnostics12051235.
- [7] R. V. Sharan, "ECG-Derived Respiration for Sleep-Wake Stage Classification," *2021 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)*, Kota Kinabalu, Malaysia, 2021, pp. 1-4, doi: 10.1109/IICAET51634.2021.9573596.
- [8] U. Erdenebayar, Y. Kim, J.-U. Park, S. Lee, and K.-J. Lee, "Automatic Classification of Sleep Stage from an ECG Signal Using a Gated-Recurrent Unit," *INTERNATIONAL JOURNAL of FUZZY LOGIC and INTELLIGENT SYSTEMS*, vol. 20, no. 3. Korean Institute of Intelligent Systems, pp. 181–187, Sep. 30, 2020. doi: 10.5391/ijfis.2020.20.3.181.
- [9] F. Bozkurt, M. K. Uçar, C. Bilgin, and A. Zengin, "Sleep–wake stage detection with single channel ECG and hybrid machine learning model in patients with obstructive sleep apnea," *Physical and Engineering Sciences in Medicine*, vol. 44, no. 1. Springer Science and Business Media LLC, pp. 63–77, Jan. 04, 2021. doi: 10.1007/s13246-020-00953-5.
- [10] Y. Mitsukura, K. Fukunaga, M. Yasui, and M. Mimura, "Sleep stage detection using only heart rate," *Health Informatics Journal*, vol. 26, no. 1. SAGE Publications, pp. 376–387, Feb. 19, 2019. doi: 10.1177/1460458219827349.
- [11] Y. Ichimaru and G. B. Moody, "MIT-BIH Polysomnographic Database." *physionet.org*, 1992. doi: 10.13026/C23K5S.
- [12] H. Sun et al., "Sleep staging from electrocardiography and respiration with deep learning," *Sleep*, vol. 43, no. 7. Oxford University Press (OUP), Dec. 21, 2019. doi: 10.1093/sleep/zsz306.