

A Lightweight Convolutional Neural Network for Efficient Automatic Sleep Stage Classification Using Single-Channel EEG Spectrograms with Real-Time Application Capabilities

Behzadi, Hossein¹ / Kalantari, Mohammad Hossein² / Adl, Mohamad Taghi^{3*}

¹ - B.Sc. Student, Computer Department, Faculty of Electrical & Computer Engineering, Noshirvani University of Technology, Babol, Iran

² - M.Sc. Student, Computer Department, Faculty of Electrical & Computer Engineering, Noshirvani University of Technology, Babol, Iran

³ - Assistant Professor, Computer Department, Faculty of Electrical & Computer Engineering, Noshirvani University of Technology, Babol, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2026.2084373.2019

Received: 2-2-2026

Revised: 9-6-2026

Accepted: 14-6-2026

KEYWORDS

Sleep Stage Classification
EEG Spectrogram
Convolutional Neural Network
Single-Channel EEG

ABSTRACT


Accurate analysis and evaluation of sleep, as well as sleep stage classification, play a crucial role in the diagnosis of sleep disorders and diseases and in the assessment of sleep quality and overall quality of life. However, manual annotation of sleep signals is a time-consuming process and its accuracy strongly depends on the expertise of human scorers. In recent years, intelligent methods have been introduced to automate this process; nevertheless, challenges such as class imbalance among sleep stages—particularly for the N1 stage—still remain. In this study, a sleep stage classification approach with reduced computational complexity is proposed, enabling its application in real-time scenarios and sleep monitoring systems with limited computational resources. In the proposed framework, single-channel EEG signals are employed and transformed into a time–frequency representation so that neural patterns can be analyzed in an image-based form. Subsequently, a convolutional neural network is trained to classify sleep stages without relying on expensive or complex hardware. The objective of this design is to achieve an efficient, lightweight, and practically deployable model suitable for real-world applications, without the need for complex architectures or heavy computational resources. Experimental evaluations demonstrate that, despite its compact structure, the proposed model achieves competitive performance in sleep stage classification, reaching an overall accuracy of 85%. Moreover, the model shows better performance in the challenging N1 stage compared to related studies.

***Corresponding Author**

Address: Computer Department, Faculty of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Babol, Iran

E-Mail: m.adl@nit.ac.ir





شبکه عصبی کانولوشنی کم‌هزینه برای طبقه‌بندی خودکار و کارآمد مراحل خواب با استفاده از اسپکتروگرام‌های EEG تک‌کاناله با قابلیت استفاده در کاربردهای بلادرنگ

بهزادی، حسین^۱ / کلانتری، محمد حسین^۲ / عدل، سید محمد تقی^{۳*}

- ^۱ - دانشجوی کارشناسی مهندسی کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی، بابل، ایران
^۲ - دانشجوی کارشناسی ارشد مهندسی کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی، بابل، ایران
^۳ - استادیار، گروه کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی، بابل، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2026.2084373.2019

پذیرش: ۱۴۰۵/۳/۲۴

بازنگری: ۱۴۰۵/۳/۱۹

ثبت در سامانه: ۱۴۰۴/۱۱/۱۳

واژه‌های کلیدی	چکیده
طبقه‌بندی مراحل خواب اسپکتروگرام EEG شبکه عصبی کانولوشنی EEG تک‌کاناله	مطالعه و ارزیابی دقیق خواب، و همچنین طبقه‌بندی مراحل آن نقشی کلیدی در تشخیص اختلالات، بیماری‌ها و بررسی کیفیت زندگی دارد. با توجه به این‌که برچسب‌گذاری دستی سیگنال‌ها، امری زمان‌بر است و دقت آن به مهارت ارزیاب‌ها وابسته است، در سال‌های اخیر روش‌های هوشمند برای خودکارسازی این فرایند معرفی شده‌اند اما همچنان چالش‌هایی مانند نامتوازن بودن تعداد داده‌های مراحل خواب، به ویژه مرحله N1 وجود دارد. در این پژوهش رویکردی با پیچیدگی محاسباتی کمتر برای طبقه‌بندی مراحل خواب ارائه شده که امکان استفاده در کاربردهای بلادرنگ و سامانه‌های پایش خواب با منابع محدود را فراهم می‌کند. در این رویکرد از سیگنال EEG تک‌کاناله و نمایش زمان-فرکانسی آن استفاده شد تا الگوهای مغزی در قالب تصویر، قابل تحلیل شود؛ سپس یک مدل کانولوشنی آموزش داده شد که بتواند بدون نیاز به سخت‌افزارهای پرهزینه و پیچیده، مراحل خواب را طبقه‌بندی کند. هدف این طراحی، دستیابی به مدلی کارآمد، سبک و قابل استفاده در شرایط واقعی و کاربردهای عملی است که میان دقت طبقه‌بندی و پیچیدگی محاسباتی تعادل برقرار کند. ارزیابی‌ها نشان می‌دهد که مدل پیشنهادی با وجود ساختار فشرده، عملکرد بسیار مناسبی در تشخیص مراحل خواب دارد و به دقت کلی حدود ۸۵ درصد دست یافته است، همچنین در مرحله N1 نیز دقت قابل قبولی را در مقایسه با پژوهش‌های مشابه نشان می‌دهد. رویکرد پیشنهادی با تمرکز بر کاهش پیچیدگی محاسباتی و ساده‌سازی ورودی‌ها طراحی شده است.

*نویسنده‌ی مسئول

نشانی: گروه کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی نوشیروانی، بابل، ایران

پست الکترونیک: m.adl@nit.ac.ir



۱- مقدمه

خواب یکی از فرایندهای بنیادین زندگی انسان است که حدود یک سوم از طول عمر هر انسان را به خود اختصاص می‌دهد [۱]. فرایند خواب نقش مهمی در بازیابی انرژی ذهن و جسم، استراحت مغز و به طور کلی حفظ تعادل جسمی و روحی ایفا می‌کند [۲]؛ نشان داده شده که کیفیت خواب تأثیر مستقیمی بر تمرکز، خلق و خو، میزان یادگیری و خلاقیت و حتی عملکرد سیستم ایمنی بدن دارد [۳]. در مقابل، کم‌خوابی و اختلالات خواب باعث افزایش خطر ابتلا به افسردگی، اضطراب و بیماری‌های جسمی مانند دیابت و بیماری‌های قلبی و عروقی می‌شود [۴]. به همین دلیل ارزیابی کیفیت خواب و پایش دقیق الگوهای خواب مانند طبقه‌بندی مراحل خواب، نقشی کلیدی در تشخیص اختلالات دارد که این فرایند به طور معمول به کمک تست خواب^۱ و برچسب‌گذاری دستی سیگنال EEG انجام می‌شود که با وجود دقت بالا، بسیار زمان‌بر و وابسته به متخصصان خواب و ارزیاب‌ها است [۵].

پیشرفت هوش مصنوعی به خصوص روش‌های یادگیری ماشین و یادگیری عمیق باعث شده تحلیل خودکار سیگنال‌های مغزی برای شناسایی مراحل خواب بیش از پیش مورد توجه محققان قرار گیرد [۶]. مدل‌های یادگیری عمیق توانسته‌اند فرایند تشخیص و طبقه‌بندی مراحل خواب را با سرعت بیشتر و وابستگی کمتر به ارزیابی دستی انجام دهند [۷]. از آن‌جا که مراحل مختلف خواب با تغییرات مشخص در باندهای فرکانسی سیگنال EEG همراه هستند، استفاده از نمایش‌های زمان-فرکانس می‌تواند اطلاعات مؤثرتری نسبت به سیگنال خام فراهم کند. اسپکتروگرام با نمایش هم‌زمان تغییرات زمانی و توزیع فرکانسی سیگنال، الگوهایی را برجسته می‌کند که تفکیک مراحل خواب را ساده‌تر می‌سازند. علاوه بر این، تبدیل سیگنال EEG به قالب تصویری، امکان بهره‌گیری مؤثر از مدل‌های یادگیری عمیق کانولوشنی را در تحلیل خودکار مراحل خواب فراهم می‌کند. با این حال این موضوع همچنان با چند چالش جدی رو به رو است که از مهمترین آن‌ها می‌توان به نامتوازن بودن کلاس‌های خواب، به ویژه مرحله N1 که دارای نمونه‌های کمتری است اشاره کرد [۸].

در مطالعات اخیر، روش‌های مختلفی برای دسته‌بندی مراحل خواب پیشنهاد شده است [۹]؛ از مدل‌های کلاسیک یادگیری ماشین مانند بردار پشتیبان^۲ و جنگل تصادفی^۳ که بر پایه استخراج دستی ویژگی‌ها کار می‌کنند، تا مدل‌های یادگیری

عمیق کانولوشنی که توانایی استخراج خودکار الگوهای پیچیده‌تر را دارند. با این‌که روش‌های کلاسیک از نظر تفسیرپذیری دارای برتری هستند - به این معنا که نقش هر ویژگی ورودی در تصمیم نهایی مدل قابل ردیابی و تحلیل است - اما وابستگی شدید این روش‌ها به مهندسی ویژگی و همچنین افت دقت آن‌ها در مجموعه داده‌های بزرگ یا نامتوازن، کارایی‌شان را محدود می‌کند [۵]. در مقابل، مدل‌های یادگیری عمیق با بهره‌گیری از ساختارهای کانولوشنی قادر به استخراج خودکار الگوهای پیچیده‌تری از داده هستند و معمولاً دقت بالاتری ارائه می‌دهند، اما این بهبود کارایی اغلب با افزایش پیچیدگی مدل، اتکا به ورودی‌های چندکاناله و نیاز به منابع سخت‌افزاری بیشتر برای آموزش همراه است [۱۰].


با توجه به چالش‌های مورد اشاره، این پژوهش به دنبال ارائه مدلی با پیچیدگی و نیاز پردازشی کمتر و قابل استفاده در شرایط عملی مانند کاربردهای بلندمدت برای طبقه‌بندی مراحل خواب است، مدلی تک‌کاناله که بدون تکیه بر ورودی‌های متعدد یا معماری‌های سنگین، بتواند دقتی قابل قبول ارائه دهد. از این‌رو، سهم اصلی این پژوهش طراحی و ارزیابی یک چارچوب کاربردمحور و سبک برای طبقه‌بندی مراحل خواب است. در این چارچوب، ساده‌سازی ورودی با استفاده از اسپکتروگرام خاکستری تک‌کاناله، کاهش ابعاد تصویر، استفاده از معماری کانولوشنی فشرده و به‌کارگیری وزن‌دهی کلاس‌ها برای کاهش اثر عدم توازن داده‌ها به‌صورت هم‌زمان مورد توجه قرار گرفته است. هدف از این طراحی، دستیابی به مصالحه‌ای عملی میان دقت طبقه‌بندی و هزینه محاسباتی است؛ به‌گونه‌ای که مدل ضمن حفظ عملکرد قابل قبول، از نظر سادگی پیاده‌سازی، زمان پردازش و نیاز به منابع سخت‌افزاری برای کاربردهای نزدیک به بلندمدت مناسب باشد. در ادامه مقاله، ابتدا ادبیات موضوع و پژوهش‌های پیشین در زمینه طبقه‌بندی مراحل خواب ارائه می‌شود، سپس داده‌های به کار رفته و مراحل آماده‌سازی آن شرح داده می‌شود و در بخش بعد، معماری مدل و تنظیمات آموزش معرفی شده و در انتها نتایج و ارزیابی‌های مدل و شاخص‌های آن ارائه و مورد بحث قرار می‌گیرند.

۲- ادبیات موضوع

طبقه‌بندی مراحل خواب از گذشته یکی از موضوعات مهم در مطالعات خواب بوده و نخستین استاندارد رسمی برای طبقه‌بندی مراحل خواب در سال ۱۹۶۸ با نام R&K^۴ ارائه

³ Random Forest⁴ Rechtschaffen & Kales¹ PSG (Polysomnography)² SVM

مدل‌های یادگیری عمیق کانولوشنی را فراهم می‌کند که در استخراج خودکار الگوهای پیچیده عملکرد موفقی دارند [۷].



شکل (۱) محل قرارگیری الکترودهای EEG. کانال Fpz-Cz نمایانگر نواحی پیشانی-مرکزی و کانال Pz-Oz نمایانگر نواحی پس‌سری سر است که در تحلیل مراحل مختلف خواب کاربرد دارند.

در همین راستا می‌توان مطالعات طبقه‌بندی مراحل خواب که اخیراً انجام شده است را به دو گروه اصلی تقسیم کرد. گروه اول روش‌هایی هستند که بر استخراج دستی ویژگی‌ها از سیگنال EEG تاکید دارند. در این بخش معمولاً ابتدا ویژگی‌های زمانی، فرکانسی یا زمانی-فرکانسی استخراج شده و سپس با استفاده از الگوریتم‌های پایه یادگیری ماشین مدل آموزش داده می‌شود. برای نمونه، در مطالعه Aboalayon و همکاران [۵]، ویژگی‌های حوزه زمان-فرکانس استخراج و با استفاده از الگوریتم‌های کلاسیک یادگیری ماشین مانند SVM و KNN طبقه‌بندی انجام شده است. همچنین در پژوهش Singh در سال ۲۰۲۴ [۴]، مجموعه‌ای از ویژگی‌های آماری و انرژی باند‌های فرکانسی را محاسبه و سپس یک مدل طبقه‌بندی جنگل تصادفی برای تعیین مراحل خواب به کار گرفته شده است. در این مدل‌ها علی‌رغم این‌که پژوهشگران و متخصصان به علت روشن بودن اهمیت هر ویژگی، قابلیت تفسیر و بررسی بهتری دارند، اما مدل‌های آموزش دیده شده در تکرارپذیری و مقیاس‌پذیری محدود است و بین مجموعه داده‌های دیگر معمولاً به خوبی عمل نمی‌کند [۵].

در مرورهای جدیدتر نیز تأکید شده است که روش‌های یادگیری عمیق، به دلیل توانایی استخراج خودکار ویژگی از سیگنال‌های فیزیولوژیک، به یکی از رویکردهای اصلی در طبقه‌بندی خودکار

شد که در آن خواب به پنج مرحله اصلی تقسیم می‌شود؛ ابتدا مرحله بیداری یا Wake، سپس ۴ مرحله میانی با نام‌گذاری S1 تا S4 و در انتها مرحله حرکات مداوم چشم^۵ [۱]. تجربه نشان داده مراحل S3 و S4 که به خواب عمیق اختصاص داشتند، چندان مرز عمیق و قابل تفسیری ندارد. برای رفع این موضوع انجمن پزشکی خواب آمریکا^۶ در سال ۲۰۰۷ استاندارد جدیدی ارائه داد که در آن مراحل S3 و S4 با یکدیگر ادغام شده و N3 نام گرفتند تا تشخیص خواب عمیق ساده‌تر شود. بر اساس این استاندارد طبقه‌بندی و برجسب‌گذاری خواب بر روی ایپوک‌های ۳۰ ثانیه‌ای انجام شده و هر ایپوک به یکی از پنج کلاس استاندارد N1، N2، N3، Wake یا REM دسته‌بندی می‌شود [۱۱].

در مطالعات مرتبط با تحلیل خواب، معمولاً از کانال‌های مختلف سیگنال EEG استفاده می‌شود که از میان آن‌ها، کانال‌های Fpz-Cz و Pz-Oz کاربرد بیشتری دارند. همان‌طور که در شکل (۱) دیده می‌شود، کانال Fpz-Cz که نواحی پیشانی و مرکزی سر را پوشش می‌دهد، اغلب برای تحلیل مراحل خواب سبک مورد استفاده قرار می‌گیرد، در حالی که کانال Pz-Oz که نواحی پس‌سری را شامل می‌شود، برای تشخیص حرکات چشم و به‌ویژه مرحله REM مناسب‌تر است [۱۲]. انتخاب کانال مناسب نقش مهمی در کیفیت تشخیص مراحل خواب دارد و می‌تواند بر دقت و پایداری مدل‌های طبقه‌بندی تأثیرگذار باشد.

از آنجا که مراحل مختلف خواب با تغییرات مشخصی در باند‌های فرکانسی سیگنال EEG همراه هستند، استفاده از نمایش‌های زمان-فرکانس به عنوان ابزاری مؤثر برای تحلیل این تغییرات مورد توجه قرار گرفته است. اسپکتروگرام یکی از رایج‌ترین روش‌ها است که با نمایش هم‌زمان تغییرات زمانی و توزیع فرکانسی سیگنال، الگوهایی را برجسته می‌کند که در سیگنال خام به‌سادگی قابل مشاهده نیستند. به این صورت که اگر سیگنال خام تنها یک خط دارای نوسان است، اسپکتروگرام این خط را به یک نمایش تصویری زمان-فرکانس تبدیل می‌کند که در آن تغییرات دامنه و توزیع انرژی سیگنال در بازه‌های مختلف زمانی و فرکانسی به‌صورت شدت رنگ نمایش داده می‌شوند؛ بدین ترتیب، الگوهای ریتمیک و ساختارهای پنهان سیگنال به شکلی مفهومی و قابل تمایز در تصویر بازنمایی شده و فرآیند تفکیک مراحل خواب ساده‌تر می‌گردد. علاوه بر این، تبدیل سیگنال EEG به قالب تصویری، امکان استفاده مؤثر از

⁶ AASM

⁵ REM (Rapid Eye Movement)

میان داده‌ها دارد عملکرد بهتری دارند اما به علت ورودی‌های چند ایپوکی معمولاً پیچیدگی‌های شبکه عصبی و زمان آموزش و محاسبات آن‌را افزایش می‌دهد [۷]، [۸]. در کنار مدل‌های دنباله‌محور، بخشی از پژوهش‌های اخیر بر کاهش تعداد کانال‌ها و طراحی مدل‌های سبک‌تر تمرکز کرده‌اند. برای نمونه، TinySleepNet [۱۴] با هدف طبقه‌بندی مراحل خواب بر اساس EEG خام تک‌کاناله و کاهش منابع موردنیاز آموزش معرفی شد. همچنین مدل SleepSatelightFTC [۱۲] با تمرکز بر EEG تک‌کاناله، سبک‌بودن و تفسیرپذیری ارائه شده است. این دسته از مطالعات نشان می‌دهند که کاهش پیچیدگی ورودی و معماری، در صورت طراحی مناسب، می‌تواند برای کاربردهای عملی و سامانه‌های قابل حمل اهمیت زیادی داشته باشد. در مجموع، اگرچه رویکردهای یادگیری عمیق و به‌ویژه مدل‌های دنباله‌محور عملکرد قابل توجهی در طبقه‌بندی مراحل خواب ارائه داده‌اند، اما استفاده از ورودی‌های چندکاناله، پردازش چندایپوکی و لایه‌های بازگشتی یا توجه‌محور می‌تواند پیچیدگی معماری و هزینه پردازش را افزایش دهد. از این‌رو، در بسیاری از کاربردهای عملی، ایجاد تعادل میان دقت طبقه‌بندی و سادگی پیاده‌سازی اهمیت ویژه‌ای دارد.

با وجود کاربرد گسترده اسپکتروگرام و شبکه‌های کانولوشنی در پژوهش‌های پیشین، بسیاری از روش‌های موجود یا از ورودی‌های چندکاناله استفاده می‌کنند، یا برای بهبود کارایی به معماری‌های دنباله‌محور، چندایپوکی و پیچیده‌تر متکی هستند. در مقابل، تمرکز پژوهش حاضر بر بررسی این پرسش است که تا چه حد می‌توان با یک ورودی EEG تک‌کاناله، نمایش خاکستری فشرده و یک CNN سبک، با وجود کاهش پیچیدگی محاسباتی، عملکرد قابل قبول را حفظ کرد. بنابراین، تمایز اصلی روش پیشنهادی در ترکیب کنترل‌شده این ساده‌سازی‌ها و ارزیابی آن در قالب یک چارچوب با پیچیدگی کم‌تر برای کاربردهای عملی است.

۳- طرح و روش پیشنهادی

در این پژوهش از مجموعه‌داده عمومی Sleep-EDF Expanded [۱۵] استفاده شد که یکی از پایگاه‌های داده استاندارد و در دسترس عموم برای مطالعات طبقه‌بندی مراحل خواب است. با توجه به هدف اصلی پژوهش، یعنی طراحی یک مدل سبک برای یادگیری الگوی خواب طبیعی، تنها داده‌های بخش Sleep Cassette این مجموعه‌داده مورد استفاده قرار گرفتند. این بخش شامل رکوردهای PSG مربوط به ۷۸ فرد

مراحل خواب تبدیل شده‌اند. با این حال، این مطالعات نشان می‌دهند که انتخاب نوع سیگنال ورودی، شیوه نمایش داده، معماری شبکه و نحوه برخورد با نامتوازن بودن کلاس‌ها همچنان از عوامل تعیین‌کننده در کارکرد نهایی مدل هستند [۶].

گروه دوم که بر یادگیری عمیق تمرکز دارد، فرایند استخراج ویژگی درون خود مدل اتفاق می‌افتد و به صورت واضح نمی‌توان مشخص کرد که هر ویژگی به چه دلایلی اهمیت پیدا کرده و از چه بخشی از سیگنال تاثیر پذیرفته است. شبکه‌های عصبی به ویژه مدل‌های کانولوشنی^۷، می‌توانند الگوهای پیچیده‌تری را از داده خام بدون مهندسی دستی یاد بگیرند و خروجی‌های پایدارتری ارائه دهند. در پژوهش SleepEEGNet که توسط Mousavi و همکاران ارائه شده [۷]، از ساختارهای مبتنی بر Seq2Seq برای تحلیل وابستگی‌های زمانی میان ایپوک‌های پیایی استفاده شده و نشان داده شده است که مدل‌های دنباله‌محور می‌توانند الگوهای خواب را به خوبی یاد بگیرند. ادامه این مسیر، مدل‌های جدیدتری نیز با تمرکز بر یادگیری وابستگی زمانی میان ایپوک‌ها پیشنهاد شده‌اند. برای نمونه، شبکه ESSN با هدف ارائه یک ساختار کارآمد برای مدل‌سازی توالی خواب معرفی شده و تلاش می‌کند میان استفاده از اطلاعات زمینه‌ای ایپوک‌های مجاور و کاهش پیچیدگی محاسباتی تعادل برقرار کند [۱۰]. همچنین Yildirim [۲] در یک پژوهش دیگر از شبکه‌های کانولوشنی عمیق برای طبقه‌بندی مراحل خواب استفاده کرده و حالت‌های مختلفی از ورودی، شامل سیگنال‌های EEG، EOG و ترکیب آنها را بررسی کرده است. استفاده از سیگنال‌های بیشتر می‌تواند اطلاعات مکمل بیشتری در اختیار مدل قرار دهد، اما هزینه محاسباتی و سخت‌افزاری را نیز افزایش می‌دهد [۲].

همان‌طور که پیش‌تر اشاره شد، از جمله رویکردهای پرکاربرد در این حوزه، رویکردهای مبتنی بر اسپکتروگرام هستند، از جمله پژوهش Li و همکاران [۱۳] در سال ۲۰۲۲ که در آن، هر ایپوک سیگنال به یک تصویر زمان-فرکانسی تبدیل شده تا مراحل خواب به صورت دیداری قابل تفکیک شوند؛ سپس سیگنال‌ها به نرخ نمونه برداری خاصی (۶۴ هرتز) هم‌نرخ‌سازی شده و بخش‌های بدون اطلاعات آن‌ها حذف می‌شوند [۱۳]. گروهی دیگر از پژوهش‌گران نیز تلاش کرده‌اند با مدل‌های دنباله‌محور برای وابستگی زمانی بین ایپوک‌ها اهمیت بالاتری قائل شوند و طبق گزارشات این نوع مدل‌ها به ویژه برای تشخیص مراحل محلی مانند N1 که تعداد نمونه‌های کمتری را در

^۷ CNN

داده‌ها با نسبت ۷۰٪، ۱۵٪ و ۱۵٪ به ترتیب به مجموعه‌های آموزش، اعتبارسنجی و آزمون اختصاص داده شدند. با توجه به وجود ۷۸ فرد سالم در مجموعه داده مورد استفاده، این تقسیم‌بندی شامل ۵۶ فرد در مجموعه آموزش، ۱۱ فرد در مجموعه اعتبارسنجی و ۱۱ فرد در مجموعه آزمون بود. این نوع تقسیم‌بندی باعث می‌شود ارزیابی مدل واقع‌بینانه‌تر بوده و احتمال نشت اطلاعات میان مجموعه‌ها کاهش یابد.

از میان سیگنال‌های موجود نیز کانال Fpz-Cz به عنوان کانال اصلی ورودی انتخاب شد زیرا هم از نظر تاثیر بر طبقه بندی و هم از نظر سازگاری و تکرارپذیری، منطقی ترین گزینه است [۱۲]، [۱۳]. همچنین با محدود کردن ورودی به یک کانال پایدار و متداول، سعی شده تا چارچوبی ارائه شود که در آن، تغییرات ناشی از تفاوت در چیدمان الکترودها یا کیفیت ثبت سیگنال، کمترین تاثیر را بر عملکرد نهایی مدل داشته باشد، در صورتی که پیچیدگی محاسباتی ورودی مدل را متناسب با حاصل ضرب ابعاد تصویر ورودی و تعداد کانال‌ها در نظر بگیریم، تبدیل اسپکتروگرام‌های چندکاناله به نسخه تک‌کاناله موجب کاهش خطی بار محاسباتی ورودی می‌شود. به‌طور مشخص، با کاهش تعداد کانال‌ها از سه به یک، حجم داده ورودی هر نمونه تقریباً به یک‌سوم حالت سه‌کاناله کاهش می‌یابد. این کاهش می‌تواند بار پردازش اولیه و حافظه موردنیاز برای ذخیره و انتقال ورودی‌ها را کمتر کند و از این نظر با هدف طراحی یک چارچوب سبک‌تر سازگار است. علاوه بر کاهش بار محاسباتی، انتخاب ورودی تک‌کاناله و حذف پردازش اضافی با هدف هم‌خوانی بیشتر با سامانه‌های بلادرنگ انجام شده است.

با این حال، استفاده از یک کانال EEG به معنای حذف بخشی از اطلاعات مکمل موجود در کانال‌های دیگر است. برای نمونه، سیگنال‌های EOG یا کانال‌های پس‌سری می‌توانند در تشخیص مرحله REM مفید باشند. در این پژوهش، انتخاب کانال Fpz-Cz با هدف کاهش پیچیدگی ورودی و سازگاری بیشتر با سامانه‌های ساده‌تر پایش خواب انجام شد. بنابراین، رویکرد پیشنهادی جایگزین کامل سامانه‌های چندکاناله بالینی نیست، بلکه یک چارچوب سبک‌تر برای کاربردهایی است که در آن کاهش تعداد کانال‌ها و سادگی پیاده‌سازی اهمیت دارد. پس از جمع‌آوری سیگنال‌ها، هر داده که داده‌های مربوط به خواب یک فرد در طول یک شب است به بازه‌های ۳۰ ثانیه‌ای تقسیم شد که هر بازه یک اپیوک است. در مرحله پیش‌پردازش، ابتدا سیگنال EEG از کانال Fpz-Cz استخراج شد. با توجه به اینکه داده‌های مورد استفاده مربوط به اروپا بوده و نویز برق شهر در این داده‌ها عمدتاً در فرکانس ۵۰ هرتز ظاهر می‌شود،

سالم در بازه سنی ۲۵ تا ۱۰۱ سال است و رکوردهای مربوط به بخش Sleep Telemetry، که شامل شرایط متفاوت ثبت و مداخله دارویی است، در آموزش و ارزیابی مدل وارد نشدند. بنابراین، نسبت افراد سالم و افراد دارای اختلال خواب در داده‌های مورد استفاده این پژوهش به ترتیب ۱۰۰٪ و ۰٪ در نظر گرفته شد.

داده‌ها شامل ۱۵۳ رکورد PSG از افراد سالم است که هر رکورد شامل ثبت سیگنال در یک بازه حدوداً ۲۰ ساعته از یک چرخه روز و شب است. برچسب‌گذاری مراحل خواب توسط متخصصان و در قالب اپیوک‌های ۳۰ ثانیه‌ای انجام شده است. در این پژوهش، پس از حذف برچسب‌های نامعتبر، حرکت و بخش‌های فاقد برچسب قابل استفاده، مراحل خواب در پنج کلاس Wake، N1، N2، N3 و REM در نظر گرفته شدند. مراحل ۳ و ۴ خواب عمیق نیز مطابق استانداردهای رایج به‌صورت کلاس N3 ادغام شدند.

توزیع نسبی اپیوک‌های معتبر در کلاس‌های مختلف مراحل خواب در جدول (۱) گزارش شده است. در این جدول درصد هر کلاس نسبت به کل اپیوک‌های معتبر با هدف ارائه توزیع کلی داده‌ها، گزارش شده است.

جدول (۱) توزیع نسبی اپیوک‌های معتبر در کلاس‌های مختلف مراحل خواب

مرحله خواب	درصد حضور در اپیوک‌های معتبر
Wake	۶۴.۸٪
N1	۵.۲٪
N2	۱۶.۶٪
N3	۷.۱٪
REM	۶.۲٪


همان‌طور که در جدول (۱) مشاهده می‌شود، توزیع کلاس‌ها نامتوازن است و کلاس N1 سهم کمتری نسبت به کلاس‌هایی مانند Wake و N2 دارد. این موضوع یکی از چالش‌های اصلی در طبقه‌بندی مراحل خواب است و به همین دلیل، در آموزش مدل و ارزیابی عملکرد، علاوه بر دقت کلی، از معیارهایی مانند Precision، Recall و F1-Score نیز استفاده شد.

برای جلوگیری از نشت اطلاعات میان مجموعه‌های آموزش، اعتبارسنجی و آزمون، تقسیم داده‌ها به‌صورت subject-wise انجام شد. در این روش، تمام اپیوک‌ها و اسپکتروگرام‌های مربوط به هر فرد فقط در یکی از سه مجموعه قرار گرفتند و هیچ فردی به‌طور مشترک در بیش از یک مجموعه قرار نگرفت.

که در آن ϵ یک مقدار کوچک ثابت برای جلوگیری از بروز مشکل لگاریتم صفر است. برای تولید اسپکتروگرام از تبدیل فوریه کوتاه‌مدت استفاده شد. در این مرحله، پنجره Hann با طول ۲۵۶ نمونه، معادل ۴ ثانیه و همپوشانی ۱۲۸ نمونه، معادل ۲ ثانیه، به کار گرفته شد. با توجه به نرخ نمونه‌برداری ۶۴ هرتز، تفکیک‌پذیری فرکانسی برابر با ۰/۲۵ هرتز بود. پس از محاسبه اسپکتروگرام، تحلیل به بازه فرکانسی ۰/۵ تا ۳۲ هرتز محدود شد تا مؤلفه‌های بسیار کم‌فرکانس و فرکانس‌های خارج از محدوده اصلی فعالیت EEG خواب از ورودی مدل حذف شوند. این محدودسازی فرکانسی، در کنار اعمال فیلتر ۵۰ Notch هرتز در مرحله پیش‌پردازش، با هدف کاهش اثر مؤلفه‌های نویزی و افزایش پایداری نمایش زمان-فرکانس انجام شد. سپس مقادیر اسپکتروگرام به مقیاس لگاریتمی دسی‌بل تبدیل شده و با روش Min-Max در بازه صفر تا یک نرمال‌سازی شدند. در نهایت، هر اسپکتروگرام به صورت تصویر خاکستری تک‌کاناله با ابعاد ثابت ۶۰×۷۶ پیکسل ذخیره شد و به عنوان ورودی شبکه کانولوشنی مورد استفاده قرار گرفت. این نمایش زمان-فرکانس باعث می‌شود مدل به جای وابستگی به نوسانات موضعی سیگنال خام، بر الگوهای پایداری انرژی در بازه‌های زمانی-فرکانسی تمرکز کند. در اسپکتروگرام، محور افقی نشان‌دهنده زمان، محور عمودی بیانگر فرکانس و شدت روشنایی هر پیکسل معرف میزان انرژی لگاریتمی نرمال‌شده سیگنال در آن ناحیه است. در شکل (۳) نمونه تصاویر اسپکتروگرام‌های مراحل مختلف خواب که تصویر نمونه‌هایی از اسپکتروگرام مراحل Wake، N2 و REM هستند، نمایش داده شده است. بخش‌های تیره‌تر نشان دهنده انرژی پایین‌تر و نواحی روشن‌تر نشان دهنده شدت انرژی بیشتر و فعالیت قوی‌تر در آن ناحیه است.

مدل‌های آموزشی مختلفی در پژوهش جاری با تمرکز بر کارایی بالا و پیچیدگی کمتر نسبت به مدل‌های مشابه طراحی و ارزیابی شد و ورودی آن، مجموعه اسپکتروگرام‌های خاکستری تک‌کاناله تولید شده در مراحل قبل با ابعاد ۶۰×۷۶ بود. به جهت کاهش ابعاد، مدل کانولوشنی طراحی شده از سه بلوک کانولوشنی اصلی تشکیل شد که هر بلوک شامل یک لایه کانولوشن دوبعدی با کرنل ۳×۳، فعال‌ساز ReLU و یک لایه Max Pool در انتهای هر کدام از آن‌ها بود. سپس خروجی این سه بلوک به یک بردار به طول ۱۲۸ تبدیل گشته و وارد یک شبکه تمام‌متصل^۹ دارای لایه dropout شد تا از بیش‌برازش جلوگیری شود. در انتها داده‌ها وارد یک لایه

برای کاهش اثر این مؤلفه نویزی، فیلتر ۵۰ Notch هرتز روی سیگنال اعمال شد. سپس برای یکنواخت‌سازی داده‌ها، نرخ نمونه‌برداری تمام رکوردها به ۶۴ هرتز کاهش داده شد. در ادامه، برچسب‌های غیرقابل استفاده، شامل بخش‌های بدون برچسب معتبر و بخش‌های مربوط به حرکت، از فرایند آموزش و ارزیابی حذف شدند. بنابراین، هر ایپوک ۳۰ ثانیه‌ای شامل ۱۹۲۰ نمونه سیگنال بود و به صورت مستقل برای تولید نمایش زمان-فرکانس مورد استفاده قرار گرفت. شکل (۲) نمونه‌هایی از سیگنال‌های ۳۰ ثانیه‌ای کانال Fpz-Cz را در کلاس‌های مختلف خواب نشان می‌دهد.



به منظور استخراج همزمان اطلاعات زمانی و فرکانسی از سیگنال EEG، هر ایپوک ۳۰ ثانیه‌ای به نمایش زمان-فرکانس از نوع اسپکتروگرام تبدیل شده است. اسپکتروگرام در واقع بیانگر توزیع انرژی سیگنال در حوزه فرکانس در طول زمان بوده و از تبدیل فوریه کوتاه‌مدت^۸ به دست می‌آید که به صورت زیر تعریف می‌شود [۱۶]، [۱۷]:

$$S(t, f) = \left| \sum_{n=0}^{N-1} x(n)w(n-t)e^{-j2\pi fn} \right|^2 \quad (1)$$


که در آن $x(n)$ نمونه‌های سیگنال EEG، $w(\cdot)$ تابع پنجره، و $S(t, f)$ چگالی طیفی توان سیگنال در زمان t و فرکانس f است. به منظور کاهش دامنه دینامیکی و افزایش پایداری عددی، مقدار لگاریتمی اسپکتروگرام محاسبه شده و به عنوان ورودی شبکه عصبی کانولوشنی مورد استفاده قرار گرفته است:

$$\hat{S}(t, f) = \log(S(t, f) + \epsilon) \quad (2)$$

⁹ Fully-connected layer

⁸ STFT


پارامترها انجام شد. علاوه بر این، استفاده از لایه Dropout برای کاهش بیش‌برازش و وزن‌دهی کلاس‌ها برای کاهش اثر نامتوازن بودن داده‌ها در فرایند آموزش در نظر گرفته شد. بنابراین، ساده‌سازی معماری در این پژوهش به معنای حذف ظرفیت یادگیری مدل نیست، بلکه تلاشی برای حفظ توان استخراج ویژگی در قالب ساختاری فشرده‌تر و کم‌پارامترتر است. در مدل پیشنهادی، هر ایپوک ۳۰ ثانیه‌ای به صورت مستقل طبقه‌بندی می‌شود و وابستگی زمانی میان ایپوک‌های متوالی به صورت صریح در معماری مدل‌سازی نشده است. این تصمیم با هدف کاهش پیچیدگی معماری، کاهش نیاز به ورودی‌های چندایپوکی و حفظ قابلیت استفاده در سامانه‌های سبک و بلادرنگ اتخاذ شد. با این حال، از آنجا که توالی مراحل خواب دارای ساختار فیزیولوژیک مشخصی است، مدل‌سازی وابستگی زمانی می‌تواند به‌ویژه در تشخیص مراحل گذار مانند N1 مفید باشد. بنابراین، افزودن مؤلفه‌های دنباله‌محور سبک به مدل پیشنهادی می‌تواند به عنوان مسیر توسعه آینده مورد بررسی قرار گیرد.



شکل (۴) دیاگرام مدل پیشنهادی طبقه بندی خواب پژوهش


از آنجایی که یکی از اهداف اصلی در این پژوهش کاهش حجم ورودی و ساده‌سازی مدل بود، در نسخه نهایی از اسپکتروگرام خاکستری تک‌کاناله به جای نمایش رنگی سه‌کاناله استفاده شد. این انتخاب باعث کاهش مستقیم حجم داده ورودی از حالت $3 \times 60 \times 76$ به $1 \times 60 \times 76$ شد؛ بنابراین، تعداد مقادیر ورودی هر نمونه از ۱۳۶۸۰ به ۴۵۶۰ کاهش یافت. در نتیجه، حجم ورودی مدل تقریباً به یک‌سوم حالت سه‌کاناله رسید. این کاهش، همراه

خروجی ۵ کلاسه می‌شوند تا برچسب پیش‌بینی شده آن‌ها مشخص شود. تعداد پارامترهای این مدل به طور تقریبی 0.3 میلیون پارامتر است که در مقایسه با بسیاری از معماری‌های عمیق‌تر یا دنباله‌محور، مقدار کمتری است؛ برای نمونه، مدل 1D-CNN ارائه‌شده توسط Yildirim و همکاران [۲] حدود 0.8 میلیون پارامتر دارد و مدل EEGSNet ارائه‌شده توسط Li و همکاران [۱۳] نیز از پنج بلوک کانولوشنی، شامل مجموعاً ۱۵ لایه کانولوشنی، و بخش Bi-LSTM برای یادگیری وابستگی زمانی استفاده می‌کند. بنابراین، کاهش تعداد کانال ورودی، استفاده از اسپکتروگرام خاکستری تک‌کاناله و حذف مؤلفه‌های دنباله‌محور سنگین، باعث کاهش تعداد پارامترها و ساده‌تر شدن پیاده‌سازی مدل پیشنهادی شده است.



شکل (۱) نمونه تصاویر اسپکتروگرام‌های مراحل مختلف خواب که تصویر (الف) مرحله REM، تصویر (ب) مرحله Wake و تصویر (ج) مرحله N2 را نشان می‌دهند.

با وجود فشرده بودن معماری، طراحی مدل به گونه‌ای انجام شد که استخراج الگوهای محلی زمان-فرکانس در چند سطح انجام گیرد. سه بلوک کانولوشنی متوالی، امکان استخراج تدریجی ویژگی‌های ساده‌تر، مانند تغییرات انرژی در نواحی محدود زمان-فرکانس، و سپس ترکیب آن‌ها در سطوح بالاتر را فراهم می‌کنند. استفاده از کرنل‌های 3×3 نیز با هدف حفظ جزئیات محلی اسپکتروگرام و جلوگیری از افزایش غیرضروری تعداد



شکل (۵) نمودار عملکرد مدل در شاخص‌های مختلف تعیین دقت به تفکیک کلاس‌ها

بررسی عملکرد تفکیکی کلاس‌ها نشان می‌دهد که فشرده بودن مدل باعث افت یکنواخت عملکرد در همه مراحل خواب نشده است؛ با این حال، همانند بسیاری از مطالعات مشابه، کلاس‌های دارای الگوهای گذار یا همپوشانی بیشتر، به‌ویژه N1، همچنان دشوارتر از سایر کلاس‌ها تشخیص داده می‌شوند. این نتیجه نشان می‌دهد که معماری پیشنهادی، با وجود سادگی و کاهش پیچیدگی، همچنان توانسته بخشی از الگوهای متمایزکننده مراحل خواب را از نمایش زمان-فرکانس تک‌کاناله استخراج کند.

در مورد مرحله REM نیز باید توجه داشت که استفاده نکردن از کانال‌های EOG یا کانال‌های پس‌سری می‌تواند بخشی از اطلاعات مرتبط با حرکات چشم را از ورودی مدل حذف کند. با این حال، نتایج تفکیکی شکل (۵) نشان می‌دهد که نمایش زمان-فرکانس کانال Fpz-Cz همچنان اطلاعات کافی برای تشخیص قابل قبول این مرحله در چارچوب پیشنهادی فراهم کرده است.

با توجه به دشواری تشخیص مرحله N1 و نامتوازن بودن آن در اغلب مجموعه داده‌ها، در این پژوهش کارکرد مدل پیشنهادی در این مرحله به طور جداگانه بررسی و با نتایج پژوهش‌های شاخص در این حوزه مقایسه شد. در مدل حاضر، مقدار F1 مربوط به کلاس N1 برابر با ۰/۶۵ به دست آمد که نسبت به بسیاری از مدل‌های دنباله‌محور یا پیچیده‌تر، عملکرد مناسبی را نشان می‌دهد [۷]، [۱۳]. در مدل SleepEEGNet که از ورودی تک‌کاناله و ساختار دنباله‌محور Seq2Seq استفاده می‌کند، مقدار F1 کلاس N1 حدود ۰/۵۲ و همچنین در پژوهش Li و همکاران با استفاده از اسپکتروگرام رنگی و معماری ترکیبی CNN-BiLSTM، عملکرد این کلاس ۰/۵ گزارش شده است.

با استفاده از معماری کانولوشنی فشرده و حذف لایه‌های دنباله‌محور سنگین، چارچوب پیشنهادی را از نظر تعداد پارامترها و بار پردازشی نسبت به مدل‌های پیچیده‌تر مناسب‌تر می‌سازد.

با توجه به عدم توازن قابل توجه میان کلاس‌های مراحل خواب، به‌ویژه مرحله N1، استفاده صرف از معیار دقت کلی (Accuracy) نمی‌تواند ارزیابی دقیقی از کارکرد مدل ارائه دهد. از این‌رو، در این پژوهش علاوه بر دقت، از معیار F1-Score که ترکیبی از دقت و بازخوانی است، برای ارزیابی عملکرد مدل استفاده شده است:

$$Precision = \frac{TP}{TP + FP} \quad (۳)$$

$$Recall = \frac{TP}{TP + FN} \quad (۴)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (۵)$$

که در آن TP، FP و FN به ترتیب نشان‌دهنده تعداد نمونه‌های مثبت صحیح، مثبت ناصحیح و منفی ناصحیح هستند. معیار F1-Score با ایجاد توازن میان دقت و بازخوانی، به‌ویژه برای کلاس‌های کم‌نمونه مانند N1، ارزیابی واقع‌بینانه‌تری از کارکرد مدل ارائه می‌دهد. برای سنجش عملکرد مدل، ارزیابی نهایی بر روی مجموعه‌ی آزمون مستقل انجام شد که به صورت subject-wise از داده‌های آموزش و اعتبارسنجی جدا شده بود، سپس شاخص‌های Precision، Recall و F1-Score برای هر یک از کلاس‌های Wake، N1، N2، N3 و REM محاسبه شدند. نمودار شکل (۵) مقادیر این شاخص‌ها را به تفکیک کلاس‌ها نشان می‌دهد.


همان‌طور که در شکل (۵) مشخص است عملکرد مدل در کلاس‌های مختلف از نظر Precision، Recall و F1-Score قابل قبول بوده و روند نسبتاً پایداری را نشان می‌دهد. همچنین بهترین عملکرد مدل در تشخیص کلاس Wake می‌باشد که با توجه به تفاوت فاحش این حالت فعالیت مغزی با حالات دیگر نتیجه‌ای قابل پیش‌بینی است. مرحله N1 که به علت عدم توازن تعداد داده‌هایش در اکثر مجموعه داده‌ها همیشه باعث چالش مدل‌ها بوده است، در این مدل هم عملکرد پایین‌تری نسبت به سایر کلاس‌ها دارد اما با این حال باز هم مدل در مقایسه با مدل‌های پژوهش‌های مشابه توانسته عملکرد قابل قبولی و حتی بهبودیافته‌ای را نشان دهد.

جدول (۲) مقایسه نوع ورودی، ساختار معماری، پیچیدگی و عملکرد مدل پیشنهادی با چند روش مرتبط

مدل	نوع ورودی	ویژگی ورودی	تعداد لایه‌های CNN	لایه‌ها و اجزای غیر CNN	تعداد کل پارامترها (میلیون)	امتیاز F1 برای کلاس N1
[۷] SleepEEGNet	سیگنال خام	---	8 CONV1D	BiRNN, Seq2Seq, Attention	۲.۶	۰.۵۲
[۱۳] EEGSNet	اسپکتروگرام EEG	رنگی / سه کاناله	15 CONV2D	GAP, 2x BiLSTM, Auxiliary classifier	۰.۶	۰.۴۷ و ۰.۵
[۲] Yildirim et al.	سیگنال خام EEG/PSG	---	10 CONV1D	MaxPool, DropOut, Dense	۰.۸	۰.۲۵
مدل پیشنهادی	اسپکتروگرام EEG	خاکستری / تک‌کاناله	3 CONV2D	BatchNorm, MaxPool, DropOut, Dense	۰.۳	۰.۶۵

(۲) نشان می‌دهد که مدل پیشنهادی در چارچوب هدف اصلی این پژوهش، یعنی کاهش پیچیدگی ورودی و معماری، توانسته میان سادگی مدل و عملکرد طبقه‌بندی تعادل مناسبی برقرار کند. همچنین، از آنجا که مرحله N1 ماهیتی گذار دارد و تعداد نمونه‌های آن در داده‌ها کمتر است، بخشی از دشواری تشخیص این کلاس می‌تواند ناشی از نبود مدل‌سازی صریح وابستگی زمانی میان ایپوک‌های متوالی باشد. با وجود این محدودیت، مدل پیشنهادی با تکیه بر ویژگی‌های زمان-فرکانس هر ایپوک، عملکرد قابل قبولی در این کلاس ارائه کرده است.

برای تحلیل دقیق‌تر، ماتریس درهم‌ریختگی^{۱۰} نیز که در شکل (۶) آمده رسم شد. در این تصویر هر سطر نشان دهنده برچسب واقعی و هر ستون نشان دهنده خروجی پیش‌بینی شده توسط مدل است.



در مجموع، نتایج نشان می‌دهد که مدل پیشنهادی با وجود استفاده از ورودی EEG تک‌کاناله، اسپکتروگرام خاکستری و کاهش ابعاد ورودی و پارامترها، توانسته عملکردی پایدار و قابل مقایسه با روش‌های پیچیده‌تر ارائه دهد. دقت کلی آزمون حدود ۸۵٪ و F1-score نیز نزدیک ۰.۸۵ به دست آمده است

این مقایسه نشان می‌دهد که مدل پیشنهادی با وجود استفاده از ورودی تک‌کاناله و کاهش تعداد پارامتر، توانسته خروجی بهتری در تشخیص مرحله N1 ارائه دهد.

به‌منظور بررسی همزمان عملکرد و پیچیدگی معماری، مدل پیشنهادی با چند روش شاخص در حوزه طبقه‌بندی مراحل خواب مقایسه شد. از آنجا که همه پژوهش‌های پیشین زمان اجرا، مصرف حافظه یا توان مصرفی را به‌صورت یکسان گزارش نکرده‌اند، در این مقاله مقایسه عمدتاً بر اساس نوع ورودی، رنگی یا خاکستری بودن نمایش ورودی، تعداد لایه‌ها یا بلوک‌های کانولوشنی، اجزای غیرکانولوشنی، تعداد پارامترهای قابل آموزش و عملکرد مدل در کلاس دشوار N1 انجام شد. جدول (۲) خلاصه این مقایسه را نشان می‌دهد.

همانطور که در جدول (۲) مشاهده می‌شود، مدل پیشنهادی در مقایسه با روش‌های دنباله‌محور و سنگین‌تر، از ساختاری فشرده‌تر استفاده می‌کند. SleepEEGNet با وجود استفاده از EEG تک‌کاناله، به دلیل بهره‌گیری از ساختار Seq2Seq، BiRNN و Attention دارای پیچیدگی بیشتری نسبت به یک CNN مستقل تک‌ایپوکی است. مدل EEGSNet نیز اگرچه از اسپکتروگرام EEG استفاده می‌کند، اما نمایش ورودی آن به‌صورت RGB بوده و علاوه بر چندین لایه کانولوشنی، از دو لایه Bi-LSTM برای یادگیری وابستگی زمانی میان ایپوک‌ها بهره می‌برد. در مقابل، مدل پیشنهادی با استفاده از اسپکتروگرام خاکستری تک‌کاناله، سه بلوک کانولوشنی و حذف مؤلفه‌های دنباله‌محور سنگین، تعداد پارامترهای کمتری دارد و در عین حال مقدار F1-Score مناسبی برای کلاس دشوار N1 ارائه می‌دهد.

باید توجه داشت که مقایسه مستقیم مدل‌ها به دلیل تفاوت در مجموعه داده، نحوه تقسیم داده‌ها، تعداد کلاس‌ها و تنظیمات ارزیابی، به‌صورت مطلق قابل تفسیر نیست. با این حال، جدول

کلاس‌ها می‌تواند چارچوبی ساده و قابل پیاده‌سازی برای طبقه‌بندی خودکار مراحل خواب فراهم کند. این رویکرد نشان می‌دهد که تمرکز بر سادگی کنترل‌شده می‌تواند به تعادلی مؤثر میان دقت، پایداری و قابلیت پیاده‌سازی عملی منجر شود. چنین رویکردی می‌تواند در مسیر توسعه سامانه‌های قابل حمل، دستگاه‌های پایش خواب بلادرنگ، دستگاه‌های خانگی پایش خواب یا ابزارهای بالینی با منابع محاسباتی محدود، کاربردی و در دسترس باشد. در ادامه مسیر می‌توان با افزودن مؤلفه‌های دنباله‌ای سبک برای مدل‌سازی وابستگی زمانی بین ایپوک‌ها، بهره‌گیری از مجموعه داده‌های بزرگ‌تر و متنوع‌تر، و بررسی تدریجی تأثیر افزودن کانال‌های مکمل EEG یا EOG، عملکرد مدل را به‌ویژه در مراحل دشوارتر یا وابسته‌تر به اطلاعات مکمل، مانند N1 و REM، بهبود داد. همچنین، ارزیابی مدل در شرایط واقعی‌تر و روی داده‌های شامل اختلالات خواب می‌تواند گامی مهم در جهت افزایش تعمیم‌پذیری و آماده‌سازی آن برای کاربردهای بالینی گسترده‌تر باشد.

منابع:

- [1] A. Rechtschaffen and A. Kales, "A manual of standardized terminology, technique and scoring system for sleep stages of human subjects," 1968. Accessed: May 08, 2026. [Online]. Available: <https://api.semanticscholar.org/CorpusID:222384270>
- [2] O. Yildirim, U. B. Baloglu, and U. R. Acharya, "A deep learning model for automated sleep stages classification using PSG signals," *Int. J. Environ. Res. Public Health*, vol. 16, no. 4, Feb. 2019, doi: 10.3390/ijerph16040599.
- [3] M. Gaiduk, Á. Serrano Alarcón, R. Seepold, and N. Martínez Madrid, "Current status and prospects of automatic sleep stages scoring: Review," *Biomed. Eng. Lett.*, vol. 13, no. 3, pp. 247–272, Aug. 2023.
- [4] A. R. Singh, G. Singh, and N. Saluja, "Stages of Sleep: A classification analysed from Electroencephalogram Signals," in *2024 Global Conference on Communications and Information Technologies, GCCIT 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/GCCIT63234.2024.10862361.
- [5] K. Aboalayon, M. Faezipour, W. Almuhammadi, and S. Moslehpour, "Sleep stage classification using EEG signal

که نشان دهنده تعادل مناسب بین بهینه‌سازی‌ها و ساده‌سازی مدل و کیفیت طبقه‌بندی است. در طراحی این مدل تمرکز بر کاهش محاسبات و امکان استفاده عملی مدل با منابع سخت‌افزاری محدود بود که با استفاده از ورودی تک‌کاناله و کاهش ابعاد تصاویر توانست خروجی قابل قبول و قابل استفاده‌ای را ارائه دهد و میان دقت بالاتر و هزینه محاسباتی کمتر به تعادل مناسبی برسد؛ همچنین زمینه مناسبی را در ادامه برای افزودن داده‌ها و پیشرفت مدل مانند افزایش دقت و اضافه کردن اجزای بیشتر را بدون نیاز به تغییر اساسی در مدل فراهم می‌کند.

۴- نتیجه‌گیری

خواب یکی از فرایندهای حیاتی بدن است و ارزیابی دقیق آن نقش مهمی در تشخیص اختلالات، بیماری‌ها و تحلیل کیفیت خواب دارد. اما روش‌های سنتی مبتنی بر برچسب‌گذاری دستی سیگنال‌های EEG زمان‌بر، وابسته به نظر متخصص و همچنین مستعد خطا هستند. در این پژوهش، با هدف ارائه رویکردی با پیچیدگی کمتر، کم‌هزینه و قابل اعتماد برای طبقه‌بندی خودکار مراحل خواب، از تبدیل سیگنال EEG به اسپکتروگرام تک‌کاناله استفاده شد تا اطلاعات اصلی مرحله خواب در قالب تصویر قابل یادگیری و تحلیل برای مدل شبکه عصبی ثبت شود.

معماری پیشنهادی با حذف ورودی چندکاناله، استفاده از اسپکتروگرام خاکستری تک‌کاناله و کاهش تعداد پارامترها نسبت به معماری‌های دنباله‌محور و چندبخشی، به مدلی فشرده‌تر و ساده‌تر برای پیاده‌سازی تبدیل شد. با وجود این ساده‌سازی، کارایی مدل در کلاس‌های اصلی خواب پایدار بوده و در تشخیص مرحله N1 نیز، مطابق مقایسه ارائه شده در جدول (۲)، نتایجی قابل مقایسه یا بهتر از برخی مدل‌های پیچیده‌تر ارائه داد. با این حال، یکی از محدودیت‌های مدل پیشنهادی، بررسی مستقل هر ایپوک و عدم مدل‌سازی صریح وابستگی زمانی میان ایپوک‌های متوالی است. از این رو، در کارهای آینده می‌توان از مؤلفه‌های دنباله‌محور سبک، مانند واحدهای بازگشتی کم‌حجم یا پنجره‌های کوتاه از ایپوک‌های مجاور، استفاده کرد تا بدون افزایش شدید پیچیدگی، تشخیص مراحل گذار و کلاس‌های دشوارتر مانند N1 بهبود یابد.

نتایج این پژوهش نشان داد که اگرچه استفاده از اسپکتروگرام و CNN به‌تنهایی رویکردی شناخته‌شده در ادبیات موضوع است، اما ترکیب هدفمند اسپکتروگرام خاکستری تک‌کاناله، کاهش ابعاد ورودی، معماری کانولوشنی فشرده و وزن‌دهی

Based on Raw Single-Channel EEG,” in *Proceedings of the 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2020, pp. 641–644. doi: 10.1109/EMBC44109.2020.9176741.

[15] 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, 2000, doi: 10.1109/10.867928.

[16] A. V Oppenheim and R. W. Schaffer, *Discrete-Time Signal Processing*, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2010.

[17] A. V Oppenheim, A. S. Willsky, and S. H. Nawab, *Signals and Systems*, 2nd ed. Upper Saddle River, NJ, USA: Prentice Hall, 1997.

analysis: A comprehensive survey and new investigation,” *Entropy (Basel)*, vol. 18, no. 9, p. 272, Aug. 2016.

[6] P. Liu *et al.*, “Automatic sleep stage classification using deep learning: signals, data representation, and neural networks,” *Artif. Intell. Rev.*, vol. 57, no. 11, Nov. 2024, doi: 10.1007/s10462-024-10926-9.

[7] S. Mousavi, F. Afghah, and U. R. Acharya, “SleepEEGNet: Automated sleep stage scoring with sequence to sequence deep learning approach,” *PLoS One*, vol. 14, no. 5, p. e0216456, May 2019.

[8] G. N. Sundar, D. Narmadha, A. A. Anton Jone, K. M. Sagayam, H. Dang, and M. Pomplun, “Automated sleep stage classification in sleep apnoea using convolutional neural networks,” *Inform. Med. Unlocked*, vol. 26, no. 100724, p. 100724, 2021.

[9] O. Tsinalis, P. M. Matthews, and Y. Guo, “Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders,” *Ann. Biomed. Eng.*, vol. 44, no. 5, pp. 1587–1597, May 2016, doi: 10.1007/s10439-015-1444-y.

[10] Y. Chen, Y. Lv, X. Sun, M. Poluektov, Y. Zhang, and T. Penzel, “ESSN: An efficient sleep sequence network for automatic sleep staging,” *IEEE J. Biomed. Health Inform.*, vol. 28, no. 12, pp. 7447–7456, Dec. 2024, doi: 10.1109/JBHI.2024.3443340.

[11] C. Iber, S. Ancoli-Israel, A. L. Chesson, and S. F. Quan, *The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications*. Westchester, IL, USA: American Academy of Sleep Medicine, 2007.

[12] A. Ito and T. Tanaka, “SleepSatelightFTC: A lightweight and interpretable deep learning model for single-channel EEG-based sleep stage classification,” Aug. 2024. doi: 10.1101/2024.08.02.606301.

[13] C. Li, Y. Qi, X. Ding, J. Zhao, T. Sang, and M. Lee, “A Deep Learning Method Approach for Sleep Stage Classification with EEG Spectrogram,” *Int. J. Environ. Res. Public Health*, vol. 19, no. 10, May 2022, doi: 10.3390/ijerph19106322.

[14] A. Supratak and Y. Guo, “TinySleepNet: An Efficient Deep Learning Model for Sleep Stage Scoring