Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
DOI: 10.22034/jscit.2025.521511.2121
Volume 14, Number 3, Autumn 2025, pp. 21-33
Received: 05/07/2025, Revised: 09/12/2025, Accepted: 09/16/2025

Modeling Sleep Quality in the Elderly Using the Pittsburgh Sleep Quality Index Based on Non-Intrusive Smart Home Sensors

Fatemeh Sadat Lesani[1*], Mohammad Mobalegh Naseri[2]
1- Department of Electrical and Computer Engineering, Qom University of Technology, Qom, Iran.
2*- Department of Electrical and Computer Engineering, Shahab-Danesh University, Qom, Iran.
[1*]lesani@qut.ac.ir, [2]m.naseri72@gmail.com

Corresponding author's address: Fatemeh Sadat Lesani, Department of Electrical and Computer Engineering, Qom, Iran.

Abstract: With the advancement of smart home technologies and their expanding applications in healthcare, monitoring and analyzing elderly sleep patterns has become a critical research area. Sleep, as a fundamental pillar of physical and mental health, requires continuous and accurate assessment. This study leverages data collected from non-intrusive environmental sensors within smart homes to investigate the influence of past sleep quality on current sleep status. A hybrid deep learning model combining CNN and LSTM architectures was employed to analyze these sleep patterns. Sleep quality was quantified using the Pittsburgh Sleep Quality Index (PSQI). Evaluation results demonstrate that the proposed model outperforms conventional approaches in predicting sleep quality. The Mean Squared Error (MSE), Mean Absolute Error (MAE), and Root Mean Squared Error (RMSE) for the CNN-LSTM hybrid model were 0.0006876, 0.02108, and 0.02622, respectively, indicating the model's high effectiveness in recognizing elderly sleep behaviors. Data analysis further revealed that the combination of sleep efficiency and sleep interruptions had the greatest impact on predicting sleep quality. These findings suggest promising applications for intelligent health monitoring systems, especially in elderly care.

Keywords: Artificial Intelligence, Smart Home, Deep learning, Sleep Awake Behavioral Patterns, Pittsburgh Sleep Quality Index.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
شناسه دیجیتال: 10.22034/jscit.2025.521511.2121
جلد ۱۴، شماره ۳، پاییز ۱۴۰۴ صفحه ۲۱-۳۳
دریافت: ۱۴۰۴/۰۲/۱۷، بازنگری: ۱۴۰۴/۰۶/۲۱، پذیرش: ۱۴۰۴/۰۶/۲۵

مدل‌سازی کیفیت خواب سالمندان با استفاده از شاخص کیفیت خواب پیتسبورگ بر اساس حسگرهای غیر مداخله‌گر خانه هوشمند

فاطمه سادات لسانی*[۱]، محمد مبلغ ناصری [۲]،
۱*- استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران.
۲- کارشناسی ارشد بیوانفورماتیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه شهاب دانش قم، قم، ایران.
[1*]lesani@qut.ac.ir, [2]m.naseri72@gmail.com

* نشانی نویسنده مسئول: فاطمه سادات لسانی، قم، بلوار شهید خداکرم، دانشگاه صنعتی قم، دانشکده مهندسی برق و کامپیوتر.

چکیده - باتوجه‌به رشد چشمگیر فناوری خانه‌های هوشمند و کاربردهای گسترده آن در حوزه‌های مختلف، به‌ویژه در زمینه سلامت و مراقبت از سالمندان، پایش و تحلیل الگوهای رفتاری ساکنان به یکی از موضوعات حیاتی و مهم تبدیل شده است. در این میان، خواب به‌عنوان یکی از ارکان اصلی حفظ سلامت جسمی و روانی، نیازمند بررسی دقیق و مداوم است. این پژوهش با تمرکز بر این موضوع، از داده‌های حسگرهای محیطی خانه‌های هوشمند برای تحلیل الگوهای رفتاری افراد در طول خواب و بیداری استفاده کرده و تأثیر کیفیت خواب در روزهای قبل بر کیفیت خواب فعلی را مورد مطالعه قرار داده است. نوآوری اصلی این پژوهش، ارائه یک مدل ترکیبی پیشرفته است که در آن امتیاز خواب با استفاده از شاخص کیفیت خواب پیتسبورگ کمی‌سازی شده و عوامل مؤثر بر آن با به‌کارگیری یک مدل ترکیبی یادگیری عمیق شامل شبکه‌های عصبی CNN و LSTM مدل‌سازی شده است. این رویکرد ترکیبی، امکان تحلیل دقیق‌تر و جامع‌تر الگوهای خواب را فراهم می‌کند. نتایج ارزیابی‌ها نشان می‌دهد که مدل پیشنهادی در مقایسه با روش‌های پیشین، از دقت بالاتری در پیش‌بینی کیفیت خواب برخوردار است. این یافته‌ها گامی مهم در جهت بهبود پایش سلامت افراد، به‌ویژه سالمندان، محسوب می‌شود و می‌تواند به‌عنوان پایه‌ای برای توسعه سیستم‌های هوشمند مراقبت از سلامت در آینده مورداستفاده قرار گیرد.

واژه‌های کلیدی: هوش مصنوعی، خانه‌های هوشمند، یادگیری عمیق، الگوهای رفتاری خواب و بیداری، شاخص کیفیت خواب پیتسبورگ.

۱- مقدمه

با افزایش سن جمعیت، شمار سالمندانی که با بیماری‌های مزمن زندگی می‌کنند رو به رشد است؛ با این حال، بسیاری از آن‌ها ترجیح می‌دهند تا سال‌های پایانی عمر به صورت مستقل زندگی کرده و کنترل امور زندگی و تصمیم‌گیری‌های خود را همچنان در دست داشته باشند [۱]. فناوری‌های کمکی نقش مؤثری در افزایش استقلال بیماران ایفا کرده و وابستگی آن‌ها به دیگران را کاهش می‌دهند. ازاین‌رو، بهره‌گیری از ابزارهای مبتنی بر فناوری و هوش مصنوعی به منظور ارائه خدمات مراقبت از راه دور و انتقال اطلاعات به متخصصان حوزه سلامت، روزبه‌روز در حال گسترش است. فناوری‌های کمکی، به‌ویژه در میان افراد ۶۵ تا ۷۴ سال رشد سریعی را تجربه می‌کنند [۲].

دولت‌ها، مؤسسات و سازمان‌های مختلف سعی دارند تعاریف مختلفی از زندگی مستقل در منزل را برای سالمندان شکل دهند. یکی از مناسب‌ترین راه‌ها در این زمینه استفاده از فناوری خانه هوشمند است. در خانه هوشمند، داده‌ها با کمک حسگرها و

دوربین‌های مختلف جمع‌آوری و ذخیره شده و برای پردازش‌های مختلف و ارائه خدمات بهتر در خصوص بهبود شرایط زندگی انسان‌ها مورداستفاده قرار می‌گیرد [۳]. به بیان دیگر، خانه هوشمند به یک واحد مسکونی معمولی اطلاق می‌شودکه با حسگرها و تجهیزات قابل نظارت فنی امکان زندگی بهینه‌تر را فراهم می‌آورد. خانه هوشمند دارای کاربردهای متعددی، همچون مراقبت از بزرگسالان، سالمندان و بیماران، یادآوری وظایف مختلف و ایجاد هشدارهای متفاوت براساس داده‌های دریافتی از محیط، مانند هشدار افتادن فرد سالمند در خانه می‌باشد. در میان این موارد، خانه‌های هوشمند می‌توانند به طور فوق‌العاده‌ای برای افراد سالمند با انواع زوال عقل بسیار مفید باشند [۴]. به طور خاص، استفاده از حسگرهای کم‌هزینه در معماری خانه‌های هوشمند می‌تواند روش مفیدی برای تشخیص هرگونه رفتار غیرعادی در خانه باشد [۵].

با ثبت روزانه داده‌های مربوط به بیمار، الگوی فعالیت‌های روزمره او در گذر زمان شکل می‌گیرد و ناهنجاری‌ها را می‌توان به‌عنوان انحراف از روند طبیعی زندگی فرد شناسایی کرد [۶]. یکی از مؤلفه‌های کلیدی در تحلیل وضعیت سلامت، کیفیت خواب افراد است که هم تحت تأثیر رفتارهای روزانه قرار دارد و هم می‌تواند بر عملکرد جسمی و روانی در روزهای بعد اثرگذار باشد. ارتباط میان خواب، بیداری و کیفیت زندگی در مطالعات متعددی بررسی شده است [۷]. خانه‌های هوشمند این امکان را فراهم می‌کنند که رفتارهای مرتبط با خواب و بیداری افراد به‌صورت مستمر مورد پایش قرار گیرد.

در حالی که بخش عمده‌ای از پژوهش‌های صورت‌گرفته در این حوزه تاکنون بر تحلیل الگوهای رفتاری به منظور نظارت بر وضعیت سلامت و نیز تشخیص خودکار فعالیت‌های کاربران متمرکز بوده‌اند [۸, ۹]، موضوع خواب و مدل‌سازی رفتار خواب افراد کمتر مورد توجه قرار گرفته است. در حوزه پایش و بهبود خواب، نظارت بر رفتار و کیفیت خواب از یک‌سو، و پیش‌بینی به‌منظور پیشگیری و رفع اختلالات احتمالی از سوی دیگر، هر دو از اهمیت بالایی برخوردارند.

از جمله معدود مطالعاتی که مستقیماً به پیش‌بینی کیفیت خواب بر اساس داده‌های حسگرهای محیطی خانه‌های هوشمند پرداخته‌اند، پژوهش پروفسور کوک و همکاران است[۲۴]. آن‌ها در این مطالعه با بهره‌گیری از مدل‌های سنتی یادگیری ماشین مانند رگرسیون خطی، ماشین بردار پشتیبان، درخت تصمیم و جنگل تصادفی، تلاش کردند کیفیت خواب کاربران را پیش‌بینی کنند. با وجود نوآوری در طراحی چارچوب اولیه، نتایج به‌دست‌آمده با خطای نسبتاً بالا همراه بود؛ به‌عنوان مثال، مدل رگرسیون خطی دارای میانگین خطای مطلق (MAE) برابر با ۱,۹۸ و ریشه میانگین مربع خطا (RMSE) برابر با ۲,۴۱ گزارش شده است. این مقادیر خطا نشان می‌دهند که الگوریتم‌های کلاسیک قادر به درک دقیق وابستگی‌های پیچیده زمانی و غیرخطی میان داده‌ها نیستند و استفاده از روش‌های پیشرفته‌تر، مانند مدل‌های یادگیری عمیق ترکیبی، برای دستیابی به پیش‌بینی دقیق‌تر کیفیت خواب کاملاً ضروری است.

در همین راستا، مقاله حاضر روشی جدید برای مدل‌سازی رفتار خواب افراد در خانه‌های هوشمند ارائه می‌دهد. در این مدل کیفیت خواب فرد در دفعات پیش جهت پیش‌بینی امتیاز کیفیت خواب فرد در شب آینده مورداستفاده قرار می‌گیرد. جهت کمی‌سازی عوامل مؤثر بر کیفیت خواب از شاخص کیفیت خواب پیتسبورگ (PSQI[۱]) [۱۰]و جهت مدل‌سازی رفتار کاربر از روش ترکیبی CNN-LSTM استفاده شده است. نوآوری‌های این مقاله در ادامه آورده شده است:

- استفاده از داده‌های حسگرهای محیطی غیرتهاجمی خانه هوشمند جهت پیش‌بینی کیفیت خواب فرد بر اساس کیفیت خواب‌های پیشین او،
- استفاده از روش کمی‌سازی PSQI جهت محاسبه عوامل مؤثر بر کیفیت خواب فرد،
- بررسی عوامل مختلف مؤثر بر کیفیت خواب مانند مدت‌زمان خواب، کارایی خواب، وقفه‌های حین خواب و ترکیبات مختلف این عوامل بر عملکرد نهایی مدل پیش‌بینی کیفیت خواب مستخرج از داده‌های حسگرهای محیطی خانه هوشمند،
- استفاده از روش ترکیبی CNN-LSTM جهت مدل‌سازی رفتار کاربر.

در بخش دوم از مقاله، به بررسی کارهای پیشین در زمینه رفتار افراد بر اساس الگوهای خواب و بیداری با استفاده از حسگرهای محیطی خانه هوشمند پرداخته شده است. در بخش سوم از مقاله، مدل پیشنهادی توضیح داده شده است. در بخش چهارم، ارزیابی نتایج حاصل از تحقیق ارائه داده شده است و درنهایت در بخش ۵ نتیجه‌گیری نهایی انجام شده است.

۲- مرور ادبیات

در سال‌های اخیر، کیفیت خواب به عنوان یکی از عوامل کلیدی در سلامت جسمی و روانی افراد موردتوجه قرار گرفته است. تحقیقات نشان داده‌اند که رفتارهای حرکتی روزانه مانند خواب، فعالیت بدنی

و زمان‌های بی‌تحرکی می‌توانند به‌عنوان شاخص‌هایی برای ارزیابی وضعیت سلامت عمومی به کار روند [۶, ۱۱-۱۴]. در این زمینه، خانه‌های هوشمند با بهره‌گیری از حسگرهای غیرفعال، امکان جمع‌آوری پیوسته و دقیق داده‌های رفتاری را فراهم کرده‌اند و می‌توانند نقش مؤثری در پایش و تحلیل وضعیت سلامت به‌ویژه برای افراد سالمند یا دارای اختلال شناختی داشته باشند [۱۱].

برخی مطالعات پیشنهاد کرده‌اند که تحلیل یکپارچهٔ داده‌های مربوط به خواب و فعالیت فیزیکی می‌تواند دید بهتری نسبت به‌سلامت فرد ارائه دهد [۱۲-۱۴]. همچنین، چالش‌هایی مانند دقت پایین برخی سنجش‌ها و پیچیدگی تحلیل داده‌های رفتاری در مطالعات اخیر مطرح شده‌اند که ضرورت توسعه روش‌های هوشمند و مبتنی بر یادگیری ماشین را در این حوزه افزایش داده‌اند [۱۵-۱۷].

مطالعات مختلف نشان داده‌اند که کم‌تحرکی و اختلالات خواب از عوامل مهم در افزایش خطر ابتلا به بیماری‌های مزمن و کاهش طول عمر هستند [۶, ۱۲, ۱۳]. سازمان بهداشت جهانی نیز بی‌تحرکی را به‌عنوان یکی از عوامل اصلی خطر در بیماری‌های غیرواگیر معرفی کرده است. در این زمینه، پژوهش‌های متعددی به بررسی رابطه بین خواب، فعالیت فیزیکی و وضعیت سلامتی پرداخته‌اند و اهمیت تحلیل یکپارچه‌ی این رفتارها را مطرح کرده‌اند [۱۲–۱۴].

در سال‌های گذشته، ابزارهایی نظیر شتاب‌سنج‌های پوشیدنی و دستگاه‌های سنجش فعالیت برای جمع‌آوری داده‌های رفتاری استفاده شده‌اند. با این حال، دقت این ابزارها به نوع دستگاه، الگوریتم‌های پردازش، و محل نصب بستگی دارد و ممکن است در شرایط واقعی با نویز و اختلال مواجه شوند [۱۴–۲۰]. علاوه بر این، استفاده از ابزارهای پوشیدنی می‌تواند راحتی فرد را تحت تأثیر قرار داده و رفتار طبیعی روزمره او را تغییر دهد. در مقابل، سیستم‌های خانه هوشمند به‌صورت غیرفعال و بدون نیاز به مداخله مستقیم، داده‌ها را ثبت می‌کنند و از این نظر گزینه‌ای مناسب برای مطالعات بلندمدت و مقیاس‌پذیر محسوب می‌شوند [۲۱, ۲۲].

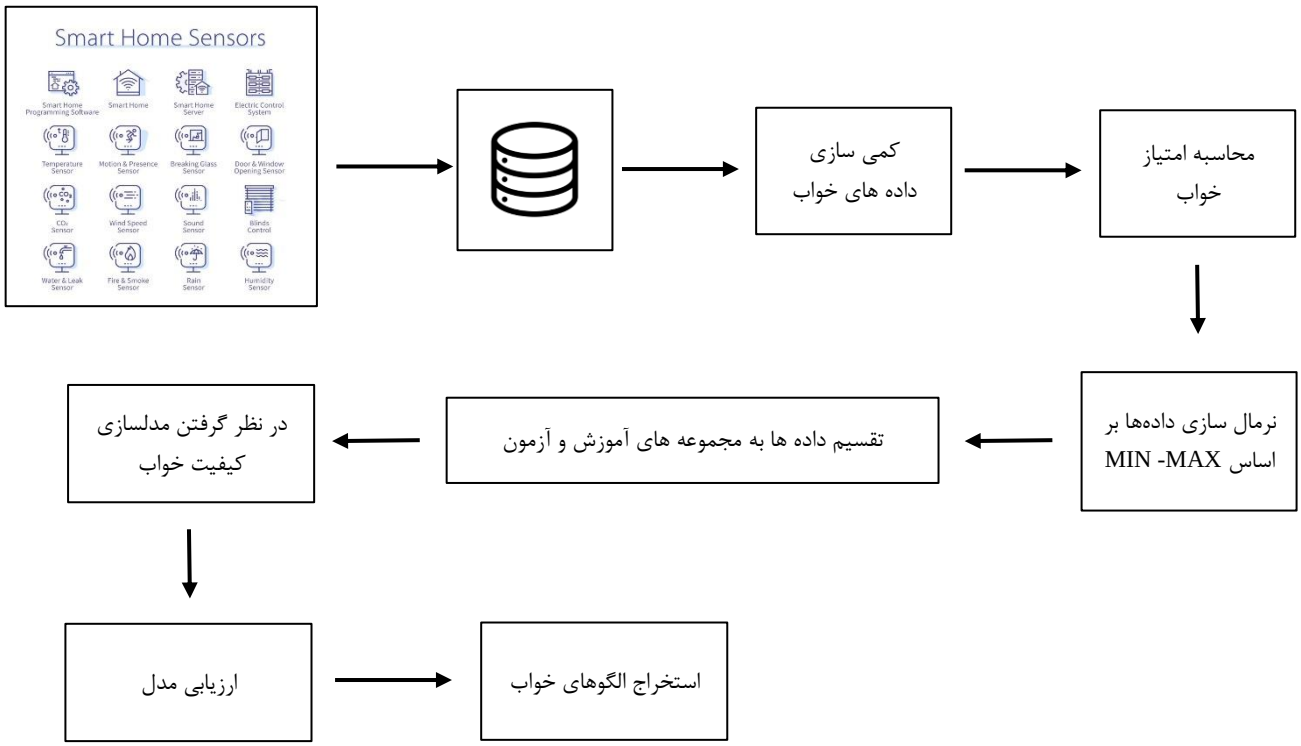
همچنین، در یک مطالعه اولیه با استفاده از داده‌های خانه هوشمند CASAS[۲] تلاش کرده‌اند تا رفتارهای خواب و بیداری افراد را مدل‌سازی و پیش‌بینی کنند. آن‌ها با استفاده از روش‌های سنتی یادگیری ماشین نظیر رگرسیون، ماشین بردار پشتیبان و جنگل تصادفی سعی کردند کیفیت خواب و بیداری را بر اساس داده‌های حسگرها پیش‌بینی کنند. هرچند این مطالعه یکی از اولین گام‌ها در جهت مدل‌سازی داده‌های خواب در محیط واقعی محسوب می‌شود، اما استفاده از الگوریتم‌های سنتی باعث شد که دقت پیش‌بینی در برخی موارد پایین باشد و مدل‌ها نتوانند به‌خوبی وابستگی‌های پیچیده بین داده‌ها را شناسایی کنند [۲۱]. این موضوع نشان‌دهنده نیاز به استفاده از مدل‌های پیشرفته‌تر و قدرتمندتر مانند شبکه‌های عصبی عمیق برای دستیابی به دقت بالاتر در تحلیل و پیش‌بینی کیفیت خواب است.

از سوی دیگر، همان‌طور که در مقالات پیشین نیز اشاره شده است [۱۳, ۲۱, ۲۲]، مدل‌سازی و پیش‌بینی دقیق کیفیت خواب بر اساس داده‌های غیرمداخله‌گر خانه‌های هوشمند، یک حوزه نوظهور و بسیار حیاتی است که تاکنون مطالعات محدودی به آن پرداخته‌اند و بسیاری از چالش‌ها هنوز به‌درستی بررسی نشده‌اند.

در برخی از مطالعات پیشین، نتایج کمی نیز گزارش شده که نشان‌دهنده عملکرد نسبتاً محدود روش‌های سنتی در پیش‌بینی کیفیت خواب می‌باشد. به‌عنوان مثال، در مطالعه [۲۱] که با استفاده از الگوریتم‌های کلاسیک مانند رگرسیون و جنگل تصادفی انجام شد، میانگین خطای پیش‌بینی (MAE) در حدود ۱,۹۸ و RMSE برابر با ۲,۴۱ گزارش شده است. همچنین، در پژوهش دیگری که از روش ماشین بردار پشتیبان استفاده کرده بود، دقت پیش‌بینی پایین‌تر از ۷۵٪ به‌دست آمد [۲۲]. این نتایج نشان می‌دهند که روش‌های کلاسیک در تحلیل داده‌های پیچیده و غیرخطی خواب محدودیت دارند. از این‌رو، استفاده از مدل‌های عمیق مانند CNN-LSTM می‌تواند بهبود معناداری در دقت پیش‌بینی و تحلیل کیفیت خواب ایجاد کند.

با وجود پیشرفت‌های صورت‌گرفته در حوزه تحلیل کیفیت خواب، مرور مطالعات پیشین نشان می‌دهد که چالش‌های متعددی همچنان پابرجا هستند. بسیاری از پژوهش‌ها از ابزارهای پوشیدنی برای جمع‌آوری داده‌ها استفاده کرده‌اند که اگرچه داده‌هایی با جزئیات بالا فراهم می‌کنند، اما برای کاربران به‌ویژه سالمندان، استفاده از آن‌ها ممکن است ناراحت‌کننده یا محدودکننده باشد. همچنین برخی از مطالعات مانند [۲۵] صرفاً بر تشخیص وضعیت خواب/بیداری تمرکز داشته و از تحلیل دقیق کیفیت خواب غافل مانده‌اند. مطالعاتی مانند[۲۶] نیز تنها به طبقه‌بندی دوقسمتی (خواب باکیفیت/بی‌کیفیت) بسنده کرده‌اند که توانایی مدل‌سازی تغییرات جزئی و پیوسته کیفیت خواب را ندارد. همچنین، پژوهش‌هایی که بر داده‌های موبایل متکی هستند[۲۷] ، به دلیل عدم اطمینان از همراه داشتن گوشی توسط سالمندان، با محدودیت‌های عملی روبه‌رو هستند.

از سوی دیگر، در مواردی که از حسگرهای محیطی خانه هوشمند استفاده شده، اغلب مدل‌های سنتی یادگیری ماشین به‌کار رفته‌اند



شکل ۱: روند کلی سامانهٔ پیشنهادی برای پیش‌بینی کیفیت خواب بر اساس چرخه‌های خواب/بیداری و داده‌های حسگرهای غیرمداخله‌گر

که توانایی محدودی در استخراج وابستگی‌های زمانی و غیرخطی در داده‌های خواب دارند.[۲۸] این موارد نشان می‌دهد که همچنان نیاز به مدل‌هایی وجود دارد که ضمن استفاده از داده‌های غیرمداخله‌گر، قادر به تحلیل دقیق‌تر الگوها و تغییرات کیفی خواب باشند.

برهمین اساس، نوآوری اصلی این پژوهش در استفاده از ترکیب مدل‌های عمیق شامل CNN و LSTM برای استخراج خودکار

ویژگی‌ها و درک وابستگی‌های زمانی داده‌های خواب است. برخلاف مطالعات قبلی، در این مقاله قصد داریم نه‌تنها کیفیت خواب را پیش‌بینی کنیم، بلکه تأثیر خواب شب قبل را بر کیفیت خواب شب بعد تحلیل کرده و با بررسی مؤلفه‌های مختلف خواب، به یک مدل دقیق و کاربردی دست یابیم. همچنین تأثیر مولفه‌های موثر بر کیفیت خواب، به صورت تکی و در ترکیب با سایر مولفه‌ها در شاخص PSQI مورد بررسی قرار گرفته است. به علاوه، ترکیب دقیق داده‌های حسگرهای مختلف خانه هوشمند با مدل‌های یادگیری عمیق به‌منظور ارائه راهکار هوشمند برای پایش و بهبود کیفیت خواب افراد، از دیگر نوآوری‌های کلیدی این مطالعه است.

۳- روش پیشنهادی

شکل ۱ معماری کلی مدل پیشنهادی را نمایش می‌دهد. هدف اصلی این مدل، پیش‌بینی کیفیت خواب شب آینده بر اساس الگوهای رفتاری خواب در چرخه‌های پیشین، با استفاده از داده‌های غیرفعال حسگرهای خانه هوشمند است.

در نخستین گام، داده‌های رفتاری از طریق حسگرهای محیطی نصب‌شده در خانه هوشمند (مانند حسگر حرکت، دما، درب و ...)، به‌صورت غیرفعال و بدون مداخله کاربر ثبت می‌شوند. این داده‌ها سپس مورد پیش‌پردازش قرار می‌گیرند که شامل مراحل نرمال‌سازی، حذف نویز، و زمان‌بندی است. پس از آماده‌سازی، داده‌ها به سه مجموعه مستقل شامل داده‌های آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند.

در این پژوهش، برخلاف رویکردهای متداول مبتنی بر بازه‌های زمانی ثابت (مانند ۲۴ ساعت)، از مفهوم چرخه‌های خواب/بیداری برای تحلیل رفتار استفاده شده است. هر چرخه شامل سه بخش اصلی است: بیداری پیش از خواب شبانه، دوره خواب شبانه، و بیداری پس از خواب. این ساختار چرخه‌ای امکان تحلیل دقیق‌تر و واقع‌بینانه‌تری از رفتار خواب فرد را فراهم می‌کند، چرا که مرزهای خواب واقعی را در داده‌های حسگر به‌خوبی بازتاب می‌دهد.

برای محاسبه کیفیت خواب هر چرخه، از شاخص کیفیت خواب پیتسبورگ (PSQI) استفاده شده است که به‌طور معمول شامل ۷ مؤلفه ارزیابی‌کننده ابعاد مختلف خواب است. با توجه به غیرمداخله‌ای بودن جمع‌آوری داده‌ها، تنها سه مؤلفه قابل محاسبه در این مطالعه مورد استفاده قرار گرفته‌اند که توضیحات دقیق علت انتخاب این سه ویژگی در بخش ۳-۳ آورده شده است. این سه مولفه عبارتند از: مدت‌زمان خواب[۳]، کارایی خواب[۴]، و وقفه‌های حین خواب[۵].

بر اساس این سه مؤلفه، برای هر چرخه خواب یک امتیاز تجمیعی به‌عنوان شاخص کیفیت خواب محاسبه می‌شود. شیوه دقیق محاسبه این امتیاز در بخش ۱-۳-۳ تشریح شده است.

در نهایت، برای مدل‌سازی و پیش‌بینی کیفیت خواب، از یک مدل ترکیبی یادگیری عمیق CNN-LSTM استفاده شده است. داده‌های حسگرها در قالب توالی زمانی به شبکه عصبی پیچشی[۶] داده می‌شوند تا الگوهای مکانی و ویژگی‌های رفتاری مرتبط با خواب شناسایی شوند. شبکه عصبی پیچشی قادر است وابستگی‌های محلی در داده‌های حسگر را به‌صورت مؤثر استخراج کند.سپس خروجی CNN به یک شبکه LSTM [۷] وارد می‌شود تا وابستگی‌های زمانی و الگوهای طولی در داده‌ها (از جمله روند تغییر کیفیت خواب در چرخه‌های متوالی) مورد بررسی قرار گیرد. LSTM با توانایی نگهداری حافظه بلندمدت، برای تحلیل توالی‌های رفتاری خواب بسیار مناسب است.

هدف نهایی مدل پیشنهادی، پیش‌بینی کیفیت خواب در چرخه بعدی بر اساس داده‌های چند چرخه گذشته است. این قابلیت پیش‌بینی، امکان شناسایی زودهنگام اختلالات خواب و همچنین ارائه توصیه‌های هوشمند برای بهبود وضعیت خواب فرد را فراهم می‌سازد. چنین امکانی به‌ویژه برای سالمندان و بیماران نیازمند مراقبت، در محیط خانه هوشمند ارزش بالایی دارد. در ادامه، اجزای مختلف مدل پیشنهادی به‌صورت گام‌به‌گام و با جزئیات تشریح شده‌اند.

۳-۱- سابقه خواب

تمرکز اصلی این پژوهش، تحلیل و پیش‌بینی رفتار خواب افراد بر اساس سابقه خواب آن‌ها در شب‌های گذشته است. هدف از این تحلیل، شناسایی الگوها و اختلالات احتمالی خواب است که می‌توانند با مشکلات رفتاری در دوره بیداری نیز همراه باشند. به‌منظور درک بهتر رابطه میان خواب‌های پیشین و کیفیت خواب شب آینده، ابتدا مؤلفه‌های کلیدی خواب مورد بررسی قرار گرفته‌اند. این مؤلفه‌ها در ادامه برای کمی‌سازی کیفیت خواب و محاسبه امتیاز خواب هر چرخه مورد استفاده قرار می‌گیرند.

۳-۲- کمیت خواب در مقابل کیفیت خواب

میزان خواب موردنیاز هر فرد به ویژگی‌های فردی و شرایط بدنی او بستگی دارد. برخی افراد ممکن است با ۵ تا ۶ ساعت خواب احساس شادابی و آرامش داشته باشند، در حالی که برخی دیگر برای دستیابی به این وضعیت، به ۹ تا ۱۰ ساعت خواب نیاز دارند. با این حال، به‌طور معمول ۶ تا ۸ ساعت خواب به‌عنوان بازه رایج خواب در میان بزرگسالان گزارش شده است [۱۳]. هیچ تحقیقی وجود ندارد که مقدار دقیق خواب لازم را پیش‌بینی کند. در واقع مقدار خواب موردنیاز، همان مقداری است که فرد با آن احساس آرامش کند. خواب را می‌توان از جنبه دیگری مورد بررسی قرار داد که همان کیفیت خواب است. ازآنجاکه کیفیت خواب یک معیار ذهنی است، اندازه‌گیری آن به‌شدت دشوار می‌باشد. شاخص کیفیت خواب پیتسبورگ (PSQI) روش مناسبی است که برای این اندازه‌گیری مورد استفاده قرار گرفته است [۲۳].

۳-۳- شاخص کیفیت خواب پیتسبورگ (PSQI)

شاخص PSQI شامل ۱۹ سؤال خود گزارش‌دهی و ۵ سؤال اضافی رتبه‌بندی است. سوالات در هفت دسته طبقه‌بندی شده که با هم ترکیب شده تا نمره PSQI را تشکیل دهند. هر دسته امتیازی بین ۰ تا ۳ دریافت می‌کند. بنابراین امتیاز ترکیبی PSQI دارای حداکثر مقدار ۲۱ است که مقادیر بالاتر نشان دهنده کیفیت خواب بدتر است. هفت دسته اندازه‌گیری شده عبارتند از:

۱) کیفیت خواب ذهنی
۲) تأخیر در خواب
۳) مدت‌زمان خواب
۴) کارایی خواب
۵) وقفه‌های خواب
۶) استفاده از داروهای خواب‌آور
۷) اختلال در عملکرد روزانه

از میان هفت مؤلفه شاخص PSQI، تنها سه مؤلفه قابل استخراج از داده‌های غیرتهاجمی خانه هوشمند هستند. دلایل عدم استفاده از سایر مؤلفه‌ها به شرح زیر است:

دلیل عدم استفاده از مؤلفه اول، یعنی کیفیت خواب ذهنی، این است که این مؤلفه به درک دیدگاه شرکت‌کنندگان از نحوه خوابیدنشان مرتبط است. به‌ویژه، این مؤلفه عمدتاً بر ارزیابی احساس

آرامش در هنگام بیدارشدن متمرکز است و مدت‌زمان واقعی خوابیدن شرکت‌کننده را در نظر نمی‌گیرد. باتوجه به اینکه خانه هوشمند CASAS که در این تحقیق از داده‌های آن استفاده شده است، شرکت‌کنندگان را بدون هیچ‌گونه تعاملی نظارت می‌کند، ازاین‌رو درک شرکت‌کنندگان از کیفیت خوابشان ناشناخته باقی می‌ماند؛ بنابراین، این مؤلفه در نمره‌دهی به خواب لحاظ نشده است.

همچنین دلیل عدم استفاده از مؤلفه ۲ یعنی تأخیر خواب این بود که این مولفه برای بررسی مدت زمانی که شرکت‌کننده پس از رفتن به رختخواب به خواب رفته است، استفاده می‌شود. به عبارت دیگر شرکت‌کننده چقدر قبل از اینکه بتواند به خواب برود، در رختخواب بوده است. خانه هوشمند CASAS یک سیستم غیرتهاجمی است و اطلاعات کافی برای تعیین اینکه آیا یک فرد تنها در رختخواب دراز کشیده یا واقعاً به خواب رفته است ارائه نمی‌دهد. بنابراین، این مولفه در نمره خواب لحاظ نشده است.

یکی دیگر از مؤلفه‌های موجود در PSQI، مؤلفه ۶ یعنی استفاده از داروهای خواب‌آور است. از آنجا که اطلاعات مرتبط با این مؤلفه در مجموعه‌داده‌های CASAS وجود ندارد، بنابراین از آن استفاده نشده است.

عدم استفاده از مؤلفه ۷ یعنی اختلال عملکرد در طی روز به این دلیل است که این مؤلفه برای ارزیابی اینکه آیا شرکت‌کننده در انجام فعالیت‌های روزانه دچار مشکل است یا خیر، طراحی شده است. به‌ویژه، این مؤلفه بررسی می‌کند که آیا شرکت‌کننده در انجام فعالیت‌هایی مانند ۱) رانندگی، ۲) صرف وعده‌غذایی، یا ۳) شرکت در فعالیت‌های اجتماعی با مشکلاتی روبه‌رو می‌شود یا خیر. همچنین ارزیابی می‌کند که آیا شرکت‌کننده در حفظ انگیزه برای انجام وظایف خود در طول روز دچار مشکل است یا خیر. مشابه مؤلفه ۱، خانه هوشمند CASAS هیچ راهی برای تعامل با شرکت‌کنندگان به‌منظور تعیین احساسات آن‌ها در طول روز ندارد. بنابراین، این مؤلفه نیز در محاسبه نمره خواب لحاظ نشده است.

۳-۳-۱- محاسبه امتیاز خواب

در این مقاله برای به‌دست‌آوردن امتیاز خواب از PSQI به‌عنوان مرجع استفاده می‌شود. همچنین متذکر می‌شویم که امتیازات بر اساس اطلاعات جمع‌آوری شده از مجموعه‌داده‌های سیستم خانه هوشمند CASAS ایجاد می‌شود. از میان هفت دسته موجود، در این مقاله تنها سه دسته به‌عنوان شاخص‌های اصلی مورد استفاده قرار می‌گیرند. این تصمیم به دلیل نیاز سایر دسته‌ها به اندازه‌گیری دقیق‌تر و استفاده از حسگرهای مجاورتی اتخاذ شده است. سه دسته انتخابی عبارت‌اند از مؤلفه‌های ۳، ۴ و ۵ که به ترتیب به مدت زمان خواب، کارایی خواب، و وقفه‌های خواب مرتبط هستند.

۳-۳-۲- کارایی خواب (Sleep Efficiency)

کارایی خواب به درصد زمانی که فرد واقعاً در خواب است نسبت به کل مدت زمانی که در رختخواب سپری می‌کند، اشاره دارد. این مقدار با استفاده از فرمول زیر محاسبه می‌شود:

$$\text{کارایی خواب} = \left(\frac{\text{کل مدت حضور در تختخواب}}{\text{کل مدت خواب با در نظر گرفتن ها وقفه}}\right) \times 100$$

در مجموعه‌داده‌های سیستم خانه هوشمند CASAS، این مقدار از طریق داده‌های حسگرهای حرکتی و سایر حسگرهای محیطی که زمان ورود و خروج از بستر را ثبت می‌کنند، به دست می‌آید. مقدار بالاتر از ۸۵٪ معمولاً نشان‌دهنده کیفیت خواب مناسب است، در حالی که مقدار زیر ۷۵٪ ممکن است نشانه مشکلات خواب باشد.

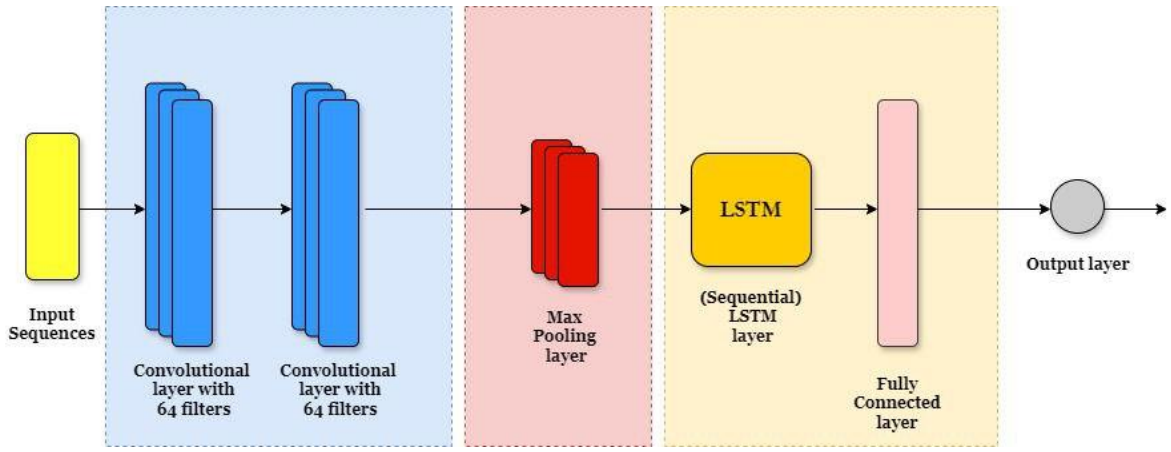
۳-۳-۳- وقفه‌های خواب (Sleep Disturbances)

وقفه‌های خواب شامل هرگونه بیداری کوتاه‌مدت یا طولانی‌مدت در طول شب است. در مجموعه داده CASAS، این پارامتر از طریق حسگرهای حرکتی و تغییر در وضعیت کاربر در هنگام خواب بررسی می‌شود. به عنوان مثال:

- خروج از رختخواب: حسگرهای درب اتاق خواب نشان می‌دهند که فرد نیمه‌شب از تخت خارج شده است، این یک وقفه محسوب می‌شود.
- حرکات غیرعادی: اگر فرد به طور مکرر در تخت غلت بزند و حسگرهای حرکتی اتاق‌خواب آن را ثبت کنند، این نشان‌دهنده اختلال خواب است.

۳-۴- شبکهٔ عصبی ترکیبی CNN-LSTM

مدل CNN-LSTM یک ترکیب از دو مدل شبکه عصبی مصنوعی در یادگیری ماشین است. این مدل دو روش شبکه عصبی پیچشی و شبکه حافظه طولانی کوتاه‌مدت (LSTM) را با هم ترکیب می‌کند. در این مدل، لایه‌های CNN برای استخراج ویژگی‌ها از داده‌های ورودی استفاده می‌شوند، سپس ویژگی‌های استخراج شده به‌عنوان ورودی به لایه‌های LSTM داده می‌شوند تا الگوهای زمانی در داده‌ها شناسایی شود [۲۲]. شکل ۲ نمای کلی مدل ترکیبی CNN-LSTM پیشنهادی را نشان می‌دهد.



شکل ۲: معماری مدل ترکیبی CNN–LSTM برای پیش‌بینی کیفیت خواب.

ورودی مدل به‌صورت توالی‌ای از بردارهای ویژگی با ابعاد $T\times3$ است که سه شاخص «مدت زمان خواب»، «کارایی خواب» و «وقفه‌های خواب» را شامل می‌شود. این داده‌ها ابتدا وارد دو لایه پیچشی یک‌بعدی (Conv1D) با ۶۴ فیلتر و کرنل سایز ۲ می‌شوند تا الگوهای محلی میان ویژگی‌ها در شب‌های متوالی استخراج شوند. سپس یک لایه MaxPooling برای کاهش ابعاد و جلوگیری از بیش‌برازش به‌کار می‌رود. خروجی این بخش به یک لایه LSTM با ۶۴ نورون منتقل می‌شود تا وابستگی‌های زمانی بلندمدت مدل‌سازی گردد. در نهایت، یک لایه تمام‌متصل (Dense) با ۱ نورون خروجی مقدار پیش‌بینی‌شده را به‌صورت عددی پیوسته تولید می‌کند که نشان‌دهنده امتیاز نرمال‌شده کیفیت خواب بر مبنای شاخص PSQI است.

مدل CNN-LSTM از دو بخش اصلی تشکیل شده است: شبکه عصبی پیچشی و شبکه‌های عصبی بازگشتی LSTM. شبکه CNN مسئول استخراج ویژگی‌های مکانی از داده‌های ورودی است. این بخش معمولاً شامل لایه‌های پیچشی و لایه‌های تجمیعی[۸] می‌باشد. لایه‌های پیچشی با اعمال فیلترهایی بر داده‌های ورودی، الگوهای محلی و ویژگی‌های مهم را شناسایی می‌کنند، درحالی‌که لایه‌های تجمیعی با کاهش ابعاد داده، تعداد پارامترها و حجم محاسبات مدل را کاهش می‌دهند. لایه پیچشی به‌عنوان هسته اصلی شبکه CNN شناخته می‌شود که فیلترها را بر داده‌های ورودی اعمال می‌کند تا الگوهای محلی شناسایی شوند.

لایه تجمیعی برای کاهش ابعاد فضایی داده‌های ورودی استفاده می‌شود و تعداد پارامترها و محاسبات مدل را کاهش می‌دهد.

بخش LSTM برای پردازش داده‌های دنباله‌ای (زمانی) با وابستگی‌های بلندمدت طراحی شده است. این بخش شامل سه دروازه اصلی است: دروازه ورودی، دروازه خروجی و دروازه فراموشی.

- دروازه ورودی تعیین می‌کند که چه اطلاعات جدیدی به حافظه (سلول) افزوده شود.
- دروازه خروجی تعیین می‌کند که چه اطلاعاتی از حافظه به خروجی منتقل شود.
- دروازه فراموشی تصمیم می‌گیرد که چه اطلاعاتی از حافظه حذف شود [۲۲].

این ساختار به LSTM اجازه می‌دهد تا وابستگی‌های بلندمدت موجود در داده‌ها را به‌خوبی یاد بگیرد.

در این پژوهش، داده‌های ورودی به مدل ترکیبی CNN-LSTM به‌صورت دنباله‌ای از بردارهای ویژگی استخراج شده از چرخه‌های خواب و بیداری می‌باشد. هر بردار نمایندهٔ یک چرخه‌ی خواب و شامل سه مؤلفه‌ی اصلی بر مبنای شاخص PSQI شامل مدت زمان خواب، کارایی خواب و تعداد وقفه‌های خواب است؛ بنابراین، ابعاد ورودی به شبکه‌ی عصبی پیچشی به صورت یک ماتریس با ابعاد $3\times T$ است که در آن T تعداد چرخه‌های خواب می‌باشد.

شبکه‌های عصبی پیچشی در این تحقیق به منظور استخراج الگوهای مکانی و محلی از دنباله‌های عددی مربوط به مؤلفه‌های خواب طراحی شده‌اند. هر دنباله مربوط به یک چرخه خواب/بیداری است که شامل داده‌های ترتیبی برای چند شب متوالی می‌باشد. شبکه‌های عصبی پیچشی با اعمال فیلترهای ۱-بعدی بر روی این دنباله‌ها، توانایی شناسایی الگوهای محلی مانند روند تغییرات تدریجی یا جهشی در مؤلفه‌های خواب را دارد. به بیان دیگر، شبکه‌ی عصبی پیچشی قادر است تعامل بین مؤلفه‌های خواب (مانند ارتباط میان کارایی خواب و وقفه‌ها در چند شب متوالی) را استخراج کرده و الگوهای تکرارشونده را شناسایی کند. این ویژگی‌ها

به‌خصوص در تشخیص روند کاهش یا افزایش کیفیت خواب طی چند شب اهمیت دارند. خروجی حاصل از شبکه‌ی عصبی پیچشی به لایه‌ی LSTM منتقل می‌شود تا وابستگی‌های زمانی طولانی‌مدت میان چرخه‌های خواب در شب‌های متوالی مدل‌سازی شود.

بدین ترتیب، انتخاب معماری ترکیبی CNN-LSTM باتوجه به ساختار ترتیبی و چندبعدی داده‌ها، رویکردی منطقی و مؤثر در مدل‌سازی رفتار خواب سالمندان در محیط خانه‌ی هوشمند محسوب می‌شود و نتایج تجربی نیز کارایی بالای آن را تأیید می‌کند.

نوع مسئله مورد بررسی در این پژوهش از نوع رگرسیون تک‌متغیره است؛ هدف، پیش‌بینی امتیاز نهایی کیفیت خواب فرد در یک شب خاص بر اساس داده‌های خواب‌های شب‌های قبلی می‌باشد. خروجی مدل یک مقدار عددی پیوسته است که مطابق با امتیاز ترکیبی شاخص PSQI تعریف می‌شود. این مدل به صورت تابع تقریبی طراحی شده که رابطه بین الگوهای خواب قبلی و کیفیت خواب شب آینده را یاد بگیرد. با توجه به ماهیت پیوسته خروجی، از معیارهای رگرسیونی شامل میانگین مربعات خطا (MSE) ، میانگین قدرمطلق خطا (MAE) **و** ریشه میانگین مربعات خطا (RMSE) برای ارزیابی عملکرد مدل استفاده شده است.

۴- ارزیابی نتایج

در این بخش به ارزیابی روش پیشنهادی خواهیم پرداخت. ابتدا، مجموعه‌داده‌ای که برای پیاده‌سازی و انجام آزمایش‌ها مورد استفاده قرار گرفته است، معرفی خواهد شد. پس از معرفی مجموعه‌داده، نتایج حاصل از پیاده‌سازی روش پیشنهادی بررسی خواهد شد. این نتایج شامل تجزیه و تحلیل دقیق عملکرد مدل بر اساس معیارهای ارزیابی مختلف شامل میانگین مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE) و ریشه میانگین مربعات خطا (RMSE) می‌باشد. نتایج به‌دست‌آمده در مقایسه با سایر مدل‌های رایج در این زمینه ارائه خواهد شد تا توانایی و دقت مدل پیشنهادی مشخص گردد. در ادامه، به تفسیر نتایج و ارزیابی کارایی مدل در شناسایی الگوی خواب‌های پیشین و تأثیر آن بر خواب‌های بعدی خواهیم پرداخت. همچنین، عواملی که بر عملکرد مدل تأثیرگذار بوده و چالش‌های موجود در این فرایند بررسی خواهند شد.

۴-۱- مجموعه‌داده

در این پژوهش از مجموعه داده CASAS متعلق به دانشگاه ایالتی واشنگتن[۹] استفاده شده است. این مجموعه داده یکی از منابع معتبر و پرکاربرد در حوزه خانه‌های هوشمند و پایش فعالیت‌های انسانی محسوب می‌شود و به‌طور خاص برای تحلیل الگوهای رفتاری ساکنان در محیط‌های واقعی طراحی شده است. داده‌های این مجموعه از طریق حسگرهای غیرمداخله‌گر مانند حسگرهای حرکتی، درب، فشار و دما در محیط‌های زندگی واقعی جمع‌آوری شده‌اند، بدون آن‌که مزاحمتی برای ساکنین ایجاد کنند.

مجموعه داده CASAS شامل ثبت دقیق زمان‌بندی و نوع رویدادهای رخداده در خانه هوشمند است که امکان تحلیل فعالیت‌های روزمره مانند خواب، بیداری، رفت‌وآمد، و استفاده از فضاهای مختلف خانه را فراهم می‌کند. در این تحقیق، با تمرکز بر بازه‌های زمانی مرتبط با خواب، از داده‌های خام برای استخراج الگوهای خواب و بیداری استفاده شده است.

در این مجموعه داده، داده‌ها از یک فرد بزرگسال داوطلب که به مدت ۳ ماه در خانه هوشمند زندگی می‌کرد جمع‌آوری شده‌اند و شامل ثبت حدود ۹۰ چرخه خواب/بیداری می‌باشد. برای هر چرخه، سه ویژگی اصلی شامل مدت‌زمان خواب، کارایی خواب و وقفه‌های خواب (بر اساس مؤلفه‌های ۳، ۴ و ۵ از شاخص PSQI) استخراج شده است؛ بنابراین، ورودی مدل یک دنباله از بردارهای سه‌بعدی با ابعاد T×3 است که T تعداد چرخه‌های خواب است.

باوجود محدودیت در تعداد داده‌ها، معماری مدل به‌گونه‌ای طراحی شده است که احتمال بیش‌برازش را کاهش دهد. ساختار مدل به‌صورت سبک و کم‌عمق طراحی شده، از Dropout و Weight Decay در آموزش استفاده شده، و تعداد ویژگی‌های ورودی به‌صورت محدود و هدفمند انتخاب شده‌اند. همچنین، استفاده از مدل ترکیبی CNN-LSTM به دلیل توانایی آن در تحلیل وابستگی‌های زمانی و استخراج الگوهای محلی میان ویژگی‌ها در چرخه‌های خواب متوالی، حتی در داده‌های تک فردی، توجیه‌پذیر و مؤثر بوده است.

نوع حسگرهای موجود در این مجموعه‌داده شامل سه دسته اصلی است:

حسگرهای حرکتی (Motion Sensors)،
حسگرهای درب (Door Sensors)،
حسگرهای دما (Temperature Sensors).

بر اساس نوع حسگرهای ثبت‌کننده‌ی رخداد، در مراحل پیش‌پردازش داده‌ها، ویژگی‌های مرتبط با خواب مانند سطح فعالیت در شب، ورود و خروج به اتاق‌خواب، و تغییرات دمای محیط استخراج شده‌اند.

۴-۲- تنظیمات آزمایش

در این بخش، تنظیمات مدل و مقداردهی اولیه هایپرپارامترها برای آموزش مدل پیشنهادی ارائه شده است. این تنظیمات شامل مشخصات مربوط به معماری مدل، مقادیر هایپرپارامترهای کلیدی و فرایند آموزش شبکه می‌باشد. این تنظیمات به نحوی انتخاب شده‌اند که مدل بتواند بهترین عملکرد را در پیش‌بینی کیفیت خواب ارائه دهد. در ادامه، نتایج حاصل از اجرای آزمایش‌ها تحلیل شده و عملکرد مدل با استفاده از معیارهای ارزیابی موردبررسی قرار می‌گیرد. جدول ۱ مقادیر نهایی هایپرپارامترهای مدل پیشنهادی را نشان می‌دهد.

در یادگیری عمیق، هر دوره (Epoch) معادل یک‌بار مشاهده کامل کل داده‌های آموزشی توسط مدل است. این فرایند به مدل اجازه می‌دهد وابستگی‌های درونی داده‌ها را بهتر یاد بگیرد. انتخاب تعداد مناسب دوره‌ها بسیار مهم است؛ زیرا دوره‌های کم ممکن است منجر به کم‌برازش[10] شوند و دوره‌های زیاد خطر بیش‌برازش[11] را افزایش می‌دهند. در این پژوهش با استفاده از اعتبارسنجی، مقدار ۱۰۰ به‌عنوان مقدار بهینه انتخاب شده است.

جدول ۱ مقادیر هایپرپارامترها و تنظیمات تکمیلی مدل پیشنهادی

دسته‌بندی	پارامتر	مقدار
هایپرپارامترهای اصلی	روش بهینه‌سازی (Optimizer)	Adam
	نرخ یادگیری (Learning Rate)	0.0005
	تعداد دوره‌های آموزشی (Epochs)	100
	تابع هزینه (Loss Function)	MSELoss
تنظیمات تکمیلی	کاهش نرخ یادگیری (Learning Rate Decay)	Adam
	Dropout	0.1
	Weight Decay	1e-4

۴-۳- ارزیابی و تحلیل نتایج

در این بخش، عملکرد مدل پیشنهادی ترکیبی CNN-LSTM برای پیش‌بینی کیفیت خواب سالمندان با استفاده از داده‌های استخراج‌شده از حسگرهای خانه هوشمند مورد ارزیابی قرار گرفته است. هدف اصلی این ارزیابی، سنجش دقت مدل و مقایسه آن با مدل‌های یادگیری ماشین کلاسیک و همچنین شبکه‌های عصبی تک‌لایه است تا مشخص شود تا چه میزان معماری پیشنهادی توانایی پیش‌بینی دقیق کیفیت خواب بر اساس الگوهای رفتاری گذشته را داراست.

ساختار مدل پیشنهادی در این پژوهش ترکیبی از شبکه عصبی پیچشی (CNN) و حافظه طولانی - کوتاه‌مدت (LSTM) است که برای پیش‌بینی کیفیت خواب بر اساس داده‌های سری زمانی طراحی شده است. ورودی مدل به‌صورت یک ماتریس با ابعاد $3\times T$ است که در آن T نشان‌دهنده تعداد چرخه‌های خواب و ۳ نشان‌دهنده ویژگی‌های استخراج‌شده از هر چرخه می‌باشد (شامل مدت‌زمان خواب، کارایی خواب و وقفه‌ها).

مدل شامل دو لایه Conv1D با ۶۴ فیلتر و کرنل سایز ۲، یک‌لایه MaxPooling، یک‌لایه LSTM با ۶۴ نورون، و یک‌لایه Fully Connected برای خروجی نهایی است. خروجی مدل یک مقدار عددی پیوسته در بازهٔ [۰،۱] است که امتیاز نرمال‌شده کیفیت خواب را نشان می‌دهد.

داده‌ها شامل ۹۰ چرخه خواب برای یک فرد داوطلب است و به‌صورت سری زمانی به سه بخش تقسیم شده‌اند: ٪۷۰ برای آموزش، ٪۱۵ برای اعتبارسنجی، و ٪۱۵ برای آزمون. داده‌های آزمون و اعتبارسنجی کاملاً جدا از داده‌های آموزش انتخاب شده‌اند. برای جلوگیری از بیش‌برازش، از معماری سبک، Dropout و L2 regularization استفاده شده است.

بر اساس جدول ۲، مدل پیشنهادی با MSE=0.001، MAE=0.021 و RMSE=0.026، عملکرد به‌مراتب بهتری نسبت به سایر مدل‌ها داشته است. در مقایسه با مدل CNN-only که MSE آن برابر ۰،۰۱۶ و MAE آن ۰،۰۹۷ گزارش شده، مشخص است که ترکیب CNN و LSTM توانسته است مزایای هر دو معماری را به‌صورت مکمل ترکیب کرده و ساختاری دقیق‌تر برای شناسایی الگوهای پیچیده خواب ایجاد کند.

از میان مدل‌های کلاسیک، مدل Decision Tree با MSE=0.001 و RMSE=0.037 پس از CNN-LSTM، بهترین عملکرد را ارائه داده است. مدل‌های XGBoost و GBM نیز بادقت نسبتاً مناسب، اما همچنان با فاصله از مدل پیشنهادی، در رده‌های بعدی قرار دارند. همچنین، مدل‌های LSTM-only و CNN-only به دلیل عدم توانایی در تحلیل هم‌زمان وابستگی‌های مکانی و زمانی، خطای بالاتری نسبت به مدل ترکیبی داشته‌اند.

نکته مهم دیگر آن است که مدل پیشنهادی نه‌تنها در معیار MSE، بلکه در دو معیار دیگر یعنی MAE و RMSE نیز عملکرد بهینه‌ای داشته و پایداری پیش‌بینی آن در مراحل مختلف آموزش حفظ شده است.

جدول ۲: نتیجه آزمایشات مدل پیشنهادی جهت بررسی اثر کیفیت خواب‌های قبلی بر خواب بعدی

مدل	MSE	MAE	RMSE
Random Forest [24]	0.009	0.098	0.094
SVM [24]	0.002	0.044	0.044
Linear Regression [24]	0.006	0.078	0.078
Decision Tree [24]	0.001	0.038	0.037
GBM	0.004	0.060	0.064
XGBoost	0.003	0.050	0.057
CNN-only	0.016	0.097	0.126
LSTM-only	0.018	0.118	0.135
مدل پیشنهادی (CNN-LSTM)	**0.001**	**0.021**	**0.026**

شکل ۳ عملکرد مدل پیشنهادی را بر روی داده‌های آموزشی و اعتبارسنجی نشان می‌دهد. نمودار (a) مربوط به MSE، روند کلی کاهش خطا را نشان می‌دهد که در آن مقدار خطا در هر دو مجموعه آموزشی (نمودار قرمز) و اعتبارسنجی (نمودار آبی) در مراحل ابتدایی آموزش، به‌طور قابل توجهی کاهش یافته و به سمت مقادیر بسیار پایین حرکت می‌کند. در نمودار MAE (b)، مشاهده می‌شود که خطای مطلق نیز روند کاهشی مشابهی دارد، اما در برخی نقاط، نوساناتی مشاهده می‌شود که ممکن است نشان‌دهنده حساسیت مدل به تغییرات داده‌ها باشد. نمودار RMSE (c) نیز الگوی مشابهی را منعکس می‌کند و تأیید می‌کند که مدل در طول زمان به تدریج بهبود یافته و با گذشت دوره‌های آموزشی، خطاهای پیش‌بینی کاهش می‌یابد. در مجموع، تمامی نمودارها نشان‌دهنده عملکرد مثبت مدل در یادگیری و توانایی آن در کاهش خطاها بر اساس داده‌های آموزشی و اعتبارسنجی هستند، که حکایت از توانمندی مدل در تعمیم به داده‌های جدید دارد.

مدل پیشنهادی از سه مؤلفه اصلی شامل مدت خواب، کارایی خواب و وقفه‌های خواب استفاده کرده است که در شاخص کیفیت خواب پیتسبورگ (PSQI) به کار رفته‌اند تا پیش‌بینی کیفیت خواب را انجام دهد. به‌منظور بررسی دقیق‌تر تأثیر هر یک از این مؤلفه‌ها بر عملکرد مدل، و همچنین شناسایی بهترین ترکیب از آن‌ها، آزمایش‌های جداگانه‌ای انجام شد. در این آزمایش‌ها، تنها یک مؤلفه در هر بار آموزش مدل استفاده شد تا میزان تأثیر آن بر پیش‌بینی کیفیت خواب ارزیابی شود.

نتایج حاصل از این آزمایش‌ها که در جدول ۳ ارائه شده است، نشان می‌دهد که کارایی خواب بهترین عملکرد را در مقایسه با دو مؤلفه دیگر داشته است. مقدار MAE، MSE و RMSE برای این مؤلفه به ترتیب برابر با ۴,۸۱۷، ۲۵,۹۸۶ و ۵,۰۹۷ است که نسبت به دو مؤلفه دیگر کمترین میزان خطا را دارد. این موضوع نشان می‌دهد که کارایی خواب، شاخص دقیق‌تری برای پیش‌بینی کیفیت خواب است و تأثیر بیشتری بر عملکرد مدل پیشنهادی دارد.

در مقابل، مدت خواب و وقفه‌های خواب عملکرد ضعیف‌تری از خود نشان داده‌اند. مدل مبتنی بر مدت خواب بالاترین میزان خطا را داشته است، به‌طوری‌که مقدار MAE برابر ۶,۴۰۵ و مقدار MSE برابر ۴۲,۲۰۳ است. این نتایج نشان می‌دهد که مدت‌زمان کلی خواب به‌تنهایی نمی‌تواند به طور دقیق کیفیت خواب را پیش‌بینی کند. مدل مبتنی بر وقفه‌های خواب نیز با مقدار MAE برابر ۵,۷۱۴ و MSE برابر ۳۴,۱۴۷ عملکرد بهتری نسبت به مدت خواب داشته است، اما همچنان دقت آن کمتر از کارایی خواب است.

در مجموع، این نتایج نشان می‌دهد که کارایی خواب مهم‌ترین شاخص در پیش‌بینی کیفیت خواب است و می‌تواند به‌عنوان معیار اصلی در مدل‌های آینده برای پیش‌بینی دقیق‌تر کیفیت خواب در نظر گرفته شود.

جدول ۳. بررسی تأثیر عملکرد شاخص‌های مختلف PSQI بر پیش‌بینی کیفیت خواب

شاخص‌های مؤثر در مدل	MAE	MSE	RMSE
مدت خواب	۶,۴۰۵	۴۲,۲۰۳	۶,۴۹۶
کارایی خواب	۴,۸۱۷	۲۵,۹۸۶	۵,۰۹۷
وقفه‌های خواب	۵,۷۱۴	۳۴,۱۴۷	۵,۸۴۳

در آزمایش دوم، ترکیب‌های دوتایی از سه مؤلفه مدت خواب، کارایی خواب و وقفه‌های خواب موردبررسی قرار گرفت تا مشخص شود که کدام ترکیب می‌تواند پیش‌بینی دقیق‌تری از کیفیت خواب ارائه دهد. جدول ۴ نتایج این آزمایش را نمایش می‌دهد.

نتایج جدول ۴ نشان می‌دهند که ترکیب «کارایی خواب + وقفه‌های خواب» در بین ترکیب‌های دوتایی بهترین عملکرد را دارد؛ به‌طوری که کمترین مقدار MAE برابر با ۲۲,۱۹۶، کمترین MSE برابر با ۴,۳۲۸، و کمترین RMSE برابر با ۴,۷۱۱ را به ثبت رسانده است.

در مقابل، ترکیب «مدت خواب + وقفه‌های خواب» ضعیف‌ترین عملکرد را داشته و بیشترین مقدار MAE برابر ۳۴,۰۹۰، MSE برابر ۵,۶۹۱ و RMSE برابر ۵,۸۳۸ را نشان داده است.

همچنین، ترکیب «مدت خواب + کارایی خواب» با مقادیر MAE=29.533، MSE=5.192، و RMSE=5.434 عملکرد متوسطی را نسبت به دو ترکیب دیگر داشته است. به‌طورکلی، نتایج نشان می‌دهد که ترکیب «کارایی خواب + وقفه‌های خواب» بهترین ترکیب دوتایی برای پیش‌بینی کیفیت خواب است. این ترکیب، معیارهای خطای پایین‌تری نسبت به سایر ترکیب‌ها داشته و

می‌تواند نقش مهمی در بهبود دقت مدل پیشنهادی ایفا کند.

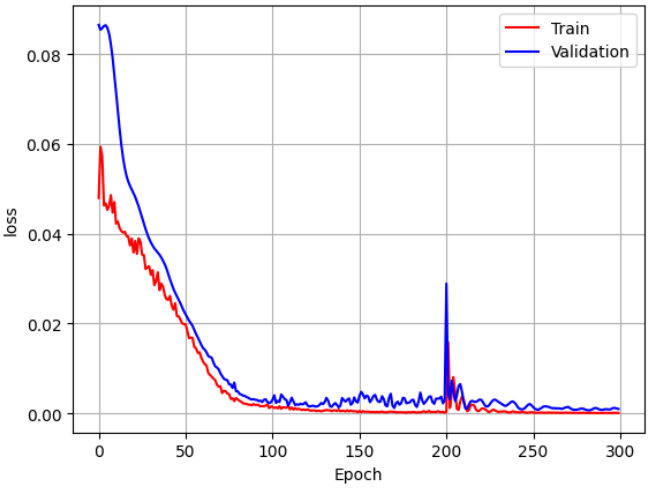
جدول ۴. بررسی تأثیر عملکرد ترکیب دوتایی از شاخص‌های مختلف PSQI بر پیش‌بینی کیفیت خواب

شاخص‌های مؤثر در مدل	MAE	MSE	RMSE
مدت خواب + کارایی خواب	۵,۱۹۲	۲۹,۵۳۳	۵,۴۳۴
مدت خواب + وقفه‌های خواب	۵,۶۹۱	۳۴,۰۹۰	۵,۸۳۸
کارایی خواب + وقفه‌های خواب	۴,۳۲۸	۲۲,۱۹۶	۴,۷۱۱

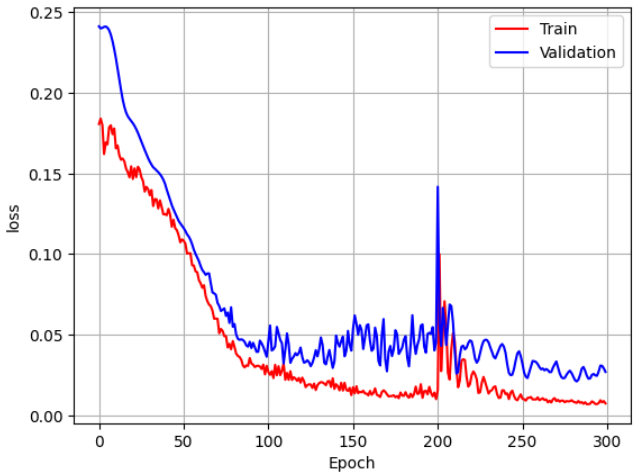
این یافته تأکید می‌کند که ترکیب عوامل چندگانه خواب (به جای تمرکز بر یک عامل) و استفاده از معماری ترکیبی CNN-LSTM برای استخراج الگوهای پیچیده، نقش کلیدی در بهبود عملکرد مدل دارد. این نتایج می‌تواند به‌عنوان پایه‌ای برای توسعه سیستم‌های نظارت بر خواب در خانه‌های هوشمند و بهبود کیفیت زندگی سالمندان مورد استفاده قرار گیرد.

۵- نتیجه‌گیری و کارهای آتی

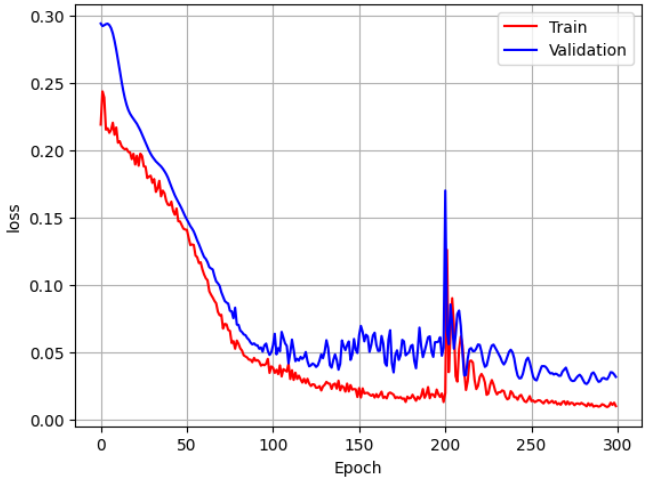
خواب نقش مهمی در زندگی انسان‌ها دارد و بخش اعظمی از سلامت و تندرستی بدن در گرو خواب کافی و مناسب است. در این پژوهش روشی نوآورانه ارائه شد که با استفاده از حسگرهای تعبیه شده در خانه‌های هوشمند رفتار بیداری و خواب افراد حاضر در محیط خانه را مدل‌سازی کرده و برای پیش‌بینی کیفیت خواب سالمندان مورداستفاده قرار می‌دهد. این پژوهش با ارائه یک مدل ترکیبی



(a)MSE



(b)MAE



(c)RMSE

شکل ۳: معیارهای عملکرد مدل پیشنهادی برای ارزیابی تأثیر کیفیت خواب قبلی بر کیفیت خواب افراد در داده‌های آموزشی و اعتبارسنجی

مبتنی بر شبکه‌های عصبی پیچشی (CNN) و حافظه کوتاه‌مدت بلندمدت (LSTM)، موفق به پیش‌بینی کیفیت خواب سالمندان با دقت قابل‌توجهی شده است و نتایج نشان می‌دهد که مدل پیشنهادی با مقادیر خطای بسیار پایین، عملکرد برتری نسبت به روش‌های مرسوم دارد که نشان‌دهنده قابلیت بالای این معماری در پردازش داده‌های پیچیده خواب است.

در این تحقیق، برای ارزیابی جامع کیفیت خواب و کمی‌سازی شاخص‌های مرتبط با آن، از شاخص کیفیت خواب پیتسبورگ استفاده شد که نتایج خوبی در پیش‌بینی کیفیت خواب فرد به دست آورد. سیستم پایش مستمر طراحی شده می‌تواند ارتباط معناداری بین کیفیت خواب کنونی و الگوهای رفتاری روزهای گذشته شناسایی کند. این مدل قابلیت ادغام با سیستم‌های خانه‌های هوشمند مجهز به حسگرهای بیومتریک را دارد تا هشدارهای خودکار برای شناسایی ناهنجاری‌های خواب ایجاد کند، محیط خانه هوشمند را بر اساس الگوهای خواب بهینه‌سازی کند و گزارش‌های تحلیلی پزشکی فراهم آورد.

اگرچه نتایج مدل در یک محیط کنترل‌شده امیدوارکننده بوده است، ولی نیاز به ارزیابی آن در جمعیت‌های بزرگ‌تر با شرایط خواب متنوع‌تر احساس می‌شود. علاوه بر این، توسعه نسخه‌های سبک‌تر این مدل برای اجرا روی سخت‌افزارهای کم‌مصرف خانه‌های هوشمند از اهداف آینده این پژوهش به شمار می‌رود.

مراجع

[1] Roberts, A.W., S.U. Ogunwole, L. Blakeslee, and M.A. Rabe, The population 65 years and older in the United States: 2016. 2018: US Department of Commerce, Economics and Statistics Administration.

[2] Anderson, W.L. and J.M. Wiener, The impact of assistive technologies on formal and informal home care. The Gerontologist, 2015. 55(3): p. 422-433.

[3] Barnay, T. and S. Juin, Does home care for dependent elderly people improve their mental health? Journal of Health Economics, 2016. 45: p. 149-160.

[4] Zahraa Khais Shahid, S.S., Christer Åhlund, Unsupervised Forecasting and Anomaly Detection of ADLs in single-resident elderly smart homes. SAC '23: 38th ACM/SIGAPP Symposium on Applied Computing, 2023.

[5] Demir, E., E. Köseoğlu, R. Sokullu, and B. Şeker, Smart home assistant for ambient assisted living of elderly people with dementia. Procedia computer science, 2017. 113: p. 609-614.

[6] Organization, W.H., Global action plan on physical activity 2018-2030: more active people for a healthier world. 2019: World Health Organization.

[7] Kentaro Matsui , T.Y., Kentaro Nagao , Tomohiro Utsumi , Ayumi Tsuru , Rei Otsuki , Naoko Ayabe , Megumi Hazumi , Masahiro Suzuki, Association of Subjective Quality and Quantity of Sleep with Quality of Life among a General Population. Int J Environ Res Public Health, 2021.

[8] Gao, J., Y. Zhang, Y. Chen, and T. Zhang, Unsupervised Human Activity Recognition Via Large Language Models and Iterative Evolution. ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2024.

[9] Hui Chen , C.G.-V., Kévin Bouchard ,Sébastien Gaboury ,Mélanie Couture ,Nathalie Bier , Sylvain Giroux, Enhancing Human Activity Recognition in Smart Homes with Self-Supervised Learning and Self-Attention Sensors and Communications for the Social Good, 2024.

[10] D J Buysse , C.F.R., T H Monk, S R Berman, D J Kupfer, The Pittsburgh Sleep Quality Index: a new instrument for psychiatric practice and research. Psychiatry Res, 1989.

[11] Morris, M., B. Adair, K. Miller, E. Ozanne, R. Hansen, A. Pearce, N. Santamaria, L. Viegas, M. Long, and C. Said, Smart-home technologies to assist older people to live well at home. Aging Sci, 2013. 1(1): p. 9p.

[12] Troiano, R.P., E. Stamatakis, and F.C. Bull, How can global physical activity surveillance adapt to evolving physical activity guidelines? Needs, challenges and future directions. British journal of sports medicine, 2020. 54(24): p. 1468-1473.

[13] Panel, C.C., N.F. Watson, M.S. Badr, G. Belenky, D.L. Bliwise, O.M. Buxton, D. Buysse, D.F. Dinges, J. Gangwisch, and M.A. Grandner, Recommended amount of sleep for a healthy adult: a joint consensus statement of the American Academy of Sleep Medicine and Sleep Research Society. Journal of Clinical Sleep Medicine, 2015. 11(6): p. 591-592.

[14] Strain, T., K. Wijndaele, M. Pearce, and S. Brage, Considerations for the use of consumer-grade wearables and smartphones in population surveillance of physical activity. Journal for the Measurement of Physical Behaviour, 2022. 5(1): p. 8-14.

[15] Hyde, E.T., J.D. Omura, J.E. Fulton, A. Weldy, and S.A. Carlson, Physical activity surveillance using wearable activity monitors: are US adults willing to share their data? American Journal of Health Promotion, 2020. 34(6): p. 672-676.

[16] Fuller, D., E. Colwell, J. Low, K. Orychock, M.A. Tobin, B. Simango, R. Buote, D. Van Heerden, H. Luan, and K. Cullen, Reliability and validity of commercially available wearable devices for measuring steps, energy expenditure, and heart rate: systematic review. JMIR mHealth and uHealth, 2020. 8(9): p. e18694.

[17] Straiton, N., M. Alharbi, A. Bauman, L. Neubeck, J. Gullick, R. Bhindi, and R. Gallagher, The validity and reliability of consumer-grade activity trackers in older, community-dwelling adults: A systematic review. Maturitas, 2018. 112: p. 85-93.

[18] Scott, H., L. Lack, and N. Lovato, A systematic review of the accuracy of sleep wearable devices for estimating sleep onset. Sleep Medicine Reviews, 2020. 49: p. 101227.

[19] O'Driscoll, R., J. Turicchi, K. Beaulieu, S. Scott, J. Matu, K. Deighton, G. Finlayson, and J. Stubbs, How well do activity monitors estimate energy expenditure? A systematic review and meta-analysis of the validity of current technologies. British Journal of Sports Medicine, 2020. 54(6): p. 332-340.

[20] Evenson, K.R., M.M. Goto, and R.D. Furberg, Systematic review of the validity and reliability of consumer-wearable activity trackers. International Journal of Behavioral Nutrition and Physical Activity, 2015. 12(1): p. 1-22.

[21] Jennifer A Williams , D.J.C., Forecasting Behavior in Smart Homes Based on Sleep and Wake Patterns. Technol Health Care, 2017.

[22] Ronald Mutegeki, D.H., A CNN-LSTM Approach to Human Activity Recognition. Digital Signal Processing and Signal Processing Education Workshop, 2020.

[23] Lovell, K. and C. Liszewski, Summary: Normal Sleep Patterns and Sleep Disorders. Available from learn. chm. msu. edu/neuroed/neurobiology.(Accessed 6thJuly, 2014.), 2015.

[24] Jennifer A Williams , D.J.C., Forecasting Behavior in Smart Homes Based on Sleep and Wake Patterns. Technol Health Care, 2017.

[25] Kasubi, M.D.H.J.W., Predicting of Sleep Behaviour in Smart Homes Based on Multi-residents Using Machine Learning Techniques. SN Computer Science, 2021.

[26] Xiaoping Ma, N.G., Hwee Pink Tan, Identifying Elderly with Poor Sleep Quality using Unobtrusive In-home Sensors for Early Intervention. 2018.

[27] Xiangmao Chang, C.P., Guoliang Xing, Tian Hao, Gang Zhou, iSleep: A Smartphone System for Unobtrusive Sleep Quality Monitoring. ACM Transactions on Sensor Networks, 2020.

[28] Anshika Arora, P.C.M.P.S.B., Analysis of Data from Wearable Sensors for Sleep Quality Estimation and Prediction Using Deep Learning. Arabian Journal for Science and Engineering, 2020.

پاورقی‌ها:

[1] Pittsburgh Sleep Quality Index

[2] Center for Advanced Studies in Adaptive Systems

[3] Sleep Duration

[4] Sleep Efficiency

[5] Sleep Disturbances

[6] Convolutional Neural Network (CNN)

[7] Long Short-Term Memory (LSTM)

[8] Pooling

[9] Washington State University

[10] Underfitting

[11] Overfitting