

## بهینه‌سازی ابرپارامترهای مدل‌های ترکیبی یادگیری عمیق با رویکرد تشخیص آپنه خواب با استفاده از

### الگوریتم‌های هوش جمعی

فرانک فتوحی قزوینی<sup>۱\*</sup>، مریم بدیعی<sup>۲</sup>

<sup>۱</sup>استادیار دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه قم، قم، ایران

<sup>۲</sup>دانشجوی کارشناسی ارشد دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه قم، قم، ایران

#### مقاله پژوهشی

#### چکیده

#### تاریخ دریافت:

۱۴۰۳/۱۰/۲۰

#### تاریخ پذیرش:

۱۴۰۳/۱۱/۲۷

#### کلیدواژه‌ها:

آپنه خواب، بهینه‌سازی گورکن عسل، بهینه‌سازی گرگ خاکستری، شبکه عصبی پیچشی، شبکه عصبی بازگشتی عمیق.

#### نویسنده مسئول:

F-Fotouhi@qom.ac.ir

این مقاله به بررسی کارایی طبقه‌بندهای ترکیبی CNN-DRNN در شناسایی آپنه خواب با استفاده از سیگنال الکتروکاردیوگرام قلب (ECG) پرداخته است. در این مطالعه، مدل‌های مختلف شبکه‌های عصبی کانولوشنی از جمله AlexNet، VGG16، VGG19 و ZFNet در ترکیب با مدل‌های شبکه عصبی بازگشتی عمیق شامل LSTM، GRU و BiLSTM مورد ارزیابی قرار گرفته است. این مدل‌ها با و بدون استفاده از بهینه‌سازهای هوش جمعی گورکن عسل و گرگ خاکستری برای تعیین مقادیر بهینه ابرپارامترها مقایسه شده‌اند. نتایج نشان می‌دهد که مدل ترکیبی AlexNet-GRU پس از اعمال هر دو بهینه‌ساز، بهترین عملکرد را با دقت ۹۵٪، نرخ تشخیص ۹۷/۶۱٪ و F-Score ۹۳/۳۷٪ ارائه کرده است. در این پژوهش، چالش بهینه‌سازی ابرپارامترها در مدل‌های یادگیری عمیق با استفاده از دو بهینه‌ساز گورکن عسل و گرگ خاکستری بررسی شده است. این بهینه‌سازها با الهام از رفتارهای طبیعت، تعامل غیرمستقیم میان عامل‌ها و توزیع هوشمند به حل این چالش کمک می‌کنند. البته، بهینه‌ساز گورکن عسل در مقایسه با گرگ خاکستری در انتخاب مقادیر بهینه ابرپارامترها عملکرد بهتری از خود نشان داده است.

doi : 10.22034/ ABMIR.2025.22637.1087

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.22637.1087) /© 2024. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



## ۱- مقدمه

هایپرپارامترها متکی هستند، توانسته است بهبود قابل توجهی در دقت تشخیص بیماری آپنه خواب ایجاد کند.

در این تحقیق از دو الگوریتم هوش جمعی گورکن عسل<sup>۳</sup> و گرگ خاکستری<sup>۴</sup> برای یافتن ترکیب بهینه‌ای از پارامترها استفاده شده است که موجب افزایش دقت مدل‌های یادگیری عمیق در تشخیص آپنه خواب شده است.

انتخاب این بهینه‌سازها به دلیل توانایی آن‌ها در همگرایی سریع، توازن بین جستجوی محلی و سراسری، انعطاف‌پذیری در تنظیم پارامترها، پایداری در ارائه نتایج بهینه و سازگاری با مسائل پیچیده صورت گرفته است. این ویژگی‌ها باعث می‌شود که این دو الگوریتم برای بهینه‌سازی پارامترهای مدل‌های یادگیری عمیق در کاربردهای مرتبط با پزشکی، مانند تشخیص آپنه خواب، بسیار مناسب باشند.

اصلی‌ترین دستاورد این مقاله، استفاده از دو الگوریتم HB و GW برای بهینه‌سازی ابرپارامترهای الگوریتم‌های یادگیری عمیق ترکیبی از شبکه‌های عصبی کانولوشن<sup>۵</sup> و بازگشتی<sup>۶</sup> با رویکرد افزایش دقت و حساسیت در تشخیص اختلال آپنه خواب است.

در بخش دوم، مروری بر پژوهش‌های پیشین و روش‌های مختلف تشخیص آپنه خواب ارائه می‌شود. بخش سوم و چهارم به معرفی روش پیشنهادی و روش انجام آزمایش اختصاص دارد. نتایج و تحلیل عملکرد مدل در بخش پنجم آورده شده و در نهایت، در بخش ششم نتیجه‌گیری و پیشنهادهای آتی مطرح خواهد شد.

باتوجه به هزینه‌ها و محدودیت‌های روش‌های سنتی تشخیص آپنه خواب و اهمیت شناسایی به‌موقع این بیماری در جلوگیری از عوارض جدی سلامتی، توسعه روش‌های نوین و کارآمد مانند مدل پیشنهادی در این پژوهش که باهدف افزایش دقت تشخیص آپنه خواب با تحلیل سیگنال ECG از طریق ترکیب شبکه‌های CNN و RNN و استفاده از بهینه‌سازهای هوش جمعی برای تنظیم بهینه پارامترهای آن‌ها توسعه‌یافته است، ضروری به نظر می‌رسد. این

بیماری آپنه خواب (ایست تنفسی در خواب) یکی از اختلالات رایج در جامعه انسانی است که به دلیل مسدودشدن مجاری هوایی در هنگام خواب به وقوع می‌پیوندد [۲]. این بیماری در صورت عدم تشخیص و درمان به‌موقع می‌تواند منجر به مشکلات جدی سلامت مانند اختلالات قلبی عروقی، سکته مغزی، دیابت و کاهش بهره‌وری فرد در فعالیت‌های روزمره شود. آپنه خواب به‌طورکلی به سه دسته اصلی تقسیم می‌شود: آپنه خواب انسدادی، آپنه خواب مرکزی و آپنه خواب ترکیبی که روش‌های مختلفی برای شناسایی این بیماری وجود دارد [۲].

روش سنتی و استاندارد تشخیص این بیماری، آزمایش پلی‌سومنوگرافی<sup>۱</sup> است که در آن فعالیت‌های زیستی بدن مانند سیگنال‌های مغزی، حرکت‌های چشم، تنفس و ضربان قلب ثبت می‌شود.

علاوه بر آن، تحلیل سیگنال‌های زیستی؛ مانند الکتروکاردیوگرام<sup>۲</sup> به دلیل غیرتهاجمی بودن و سهولت دسترسی، از روش‌های محبوب محسوب می‌شود. استخراج ویژگی‌های زمانی، فرکانسی و غیرخطی از این سیگنال‌ها می‌تواند تشخیص دقیقی از آپنه خواب ارائه دهد [۶]؛ اما روش‌های سنتی تحلیل سیگنال‌ها ممکن است دقت پایینی داشته و به تحلیل دستی وابسته باشد.

در سال‌های اخیر، فناوری‌های یادگیری ماشین و یادگیری عمیق به‌عنوان راه‌حل‌های نوین برای شناسایی آپنه خواب موردتوجه قرار گرفته‌اند. این فناوری‌ها با ارائه پیش‌بینی‌های سریع و دقیق، امکان تشخیص بلادرنگ و کاهش مخاطرات بیماری را فراهم می‌آورند [۲]. با این حال، انتخاب معماری‌های مناسب و بهینه‌سازی پارامترهای مدل همچنان از چالش‌های کلیدی در این حوزه محسوب می‌شوند.

این پژوهش با ارائه رویکردی نوین در استفاده از الگوریتم‌های هوش جمعی برای تنظیم مقادیر بهینه هایپرپارامترهای مدل‌های یادگیری عمیق، برخلاف روش‌های سنتی که به جستجوی دستی

<sup>5</sup> Convolutional Neural Network

<sup>6</sup> Recurrent Neural Network

<sup>1</sup> Polysomnography (PSG)

<sup>2</sup> Electrocardiogram (ECG)

<sup>3</sup> Honey Badger (HB)

<sup>4</sup> Grey Wolf (GW)

در [۶] اشاره شده است که پرسش‌نامه‌ها، تکنیک‌های پردازش تصویر و روش‌های تجزیه و تحلیل سیگنال، رویکردهای اصلی برای نظارت بر آپنه خواب هستند.

در همین راستا سیگنال‌های فیزیولوژیک مختلفی برای تشخیص آپنه خواب تحلیل شده‌اند که در میان آن‌ها الکتروکاردیوگرام یا ECG امکان بهتری برای پیاده‌سازی در مانیتورهای پوشیدنی و غیرتماسی فراهم می‌کند. این پژوهش با مطالعه عملکرد ۱۴ روش مختلف یادگیری ماشینی و ۱۹ روش مختلف یادگیری عمیق، یک مقایسه دقیق بین مدل‌های مختلف CNN و DRNN ها ارائه داده است.

در [۷] بوسال و همکاران، یک مدل OCNN بر اساس تابع فعال‌سازی ReLU برای حذف مشکل اشباع گرادینان ارائه می‌دهند. این مطالعه همچنین یک تابع فعال‌سازی خطی اصلاح‌شده برای مدل OCNN ارائه می‌کند.

[۱۲] به پیاده‌سازی الگوریتم‌های یادگیری عمیق برای نظارت بر شدت آپنه خواب بر اساس حرکات تنفسی می‌پردازد. این حرکت‌ها با نصب حسگر شتاب‌سنج مناسب بر روی نای ثبت می‌شوند.

در اکثر پژوهش‌های انجام‌شده، شدت آپنه خواب انسدادی با استفاده از شاخص آپنه-هیپوپنه<sup>۳</sup> ارزیابی می‌شود [۱۲]. این شاخص به تعداد متوسط آپنه‌ها و هیپوپنه‌ها در هر ساعت خواب (در هر بازه زمانی) بر روی PSG گفته می‌شود. در شکل (۱) ارتباط این شاخص با شدت آپنه بررسی می‌شود.

شدت آپنه	شاخص آپنه - هیپوپنه (تعداد رویداد در هر ساعت خواب)
نرمال	کمتر از ۵
خفیف	$5 < AHI \leq 15$
متوسط	$15 < AHI \leq 30$
شدید	۳۰ یا بیشتر

شکل (۱): ارتباط بین شدت آپنه و شاخص AHI [۱۲]

روش‌ها با تمرکز بر استفاده از فناوری‌های هوشمند و سیگنال‌های زیستی می‌توانند گامی مؤثر در ارائه راه‌حل‌های بهینه برای بیماران باشند.

## ۲- مروری بر پژوهش‌های پیشین

ناهنجاری‌های هنگام خواب با توجه به اهمیتی که در کیفیت زندگی افراد دارد، در سال‌های اخیر، مورد توجه بسیاری از پژوهشگران در حوزه داده‌کاوی پزشکی بوده است. مهم‌ترین ناهنجاری زمان خواب، آپنه خواب است که تشخیص و پیش‌بینی دقیق آن، یک گام مؤثر برای درمان بیماری و مدیریت عوارض جانبی آن خواهد بود.

عباسی و همکاران، در [۱] بهینه‌ساز MHBA<sup>۱</sup> را به‌عنوان یک نسخه تطبیق‌یافته و اصلاح‌شده از روش HB برای بهینه‌سازی ابرپارامترهای معماری CNN در جهت تشخیص آپنه خواب معرفی می‌کنند. نتایج تجربی روی پایگاه داده ECG نشان می‌دهد که MHBA با دقت ۹۱/۳۱٪، AUC برابر ۹۷/۵٪، تشخیص‌پذیری ۹۳/۶٪ و حساسیت ۹۰/۱٪ بهتر از روش‌های سنتی CNN و یادگیری ماشینی عمل می‌کند.

احمدزاده و همکاران در [۲]، مروری جامع بر فناوری‌های موجود برای اندازه‌گیری پارامترهای حیاتی مرتبط با فیزیولوژی بدن که باعث اختلال در تنفس می‌شود، ارائه می‌دهند.

در این پژوهش، مروری بر فناوری‌های تهاجمی و غیرتهاجمی موجود برای شناسایی پارامترهای خواب، الگوریتم‌های یادگیری ماشینی و روش‌های دقیق تجزیه و تحلیل سیگنال‌های ضبط‌شده انجام شده و پس از استخراج ویژگی‌های دامنه زمانی مختلف مانند تغییرپذیری ضربان قلب و تنفس مشتق از ECG، انواع مختلفی از مدل‌های یادگیری ماشینی مانند SVM، LDA، ANN، رگرسیون حداقل مربعات جزئی و رگرسیون ساده بیز تقویت‌شده برای تشخیص رویدادهای آپنه خواب استفاده شده است.

بهترین دقت و حساسیت توسط ANN ها به دست آمده است اما تأثیر تشخیص‌پذیری در روش رگرسیون ساده تعمیم‌یافته بیز بیشتر از سایر روش‌ها بوده است.

<sup>3</sup> Apnea-Hypopnea Index (AHI)

<sup>1</sup> Modified Honey Badger (MHB)

<sup>2</sup> Octree-based Convolutional Neural Network

امیدوارکننده و مؤثر برای تجهیزات معمولی در جهت سرعت بخشیدن به تشخیص و درمان زود هنگام در نظر گرفته شود.

در [۲۶] پمبو و همکاران، بر روی کارآمدی اجرای طبقه‌بندهای تشخیص آپنه خواب بر اساس سیگنال الکتروکاردیوگرام (ECG) دقیق به دقیقه تمرکز می‌کنند و یک مدل مبتنی بر ECG برای تحلیل دقیق آپنه خواب ارائه می‌دهند که با توجه به نتایج حاصل شده، می‌توان نتیجه گرفت طبقه‌بندهای مختلف رفتارهای متفاوتی برای حل مسئله یکسان دارند.

در [۲۷]، رومرو و سایرین بر روی روش‌های غربالگری OSA بر اساس ثبت صدا در خانه تمرکز می‌کنند و نشانه‌های OSA با ویژگی‌های صوتی خاص مثل خروپف، نفس‌های بلند و عدم وجود نفس (ایست تنفسی) را در نظر می‌گیرند.

سانتاجی و همکاران در [۲۸] نشان می‌دهند که تشخیص مراحل خواب یک روش رایج برای تجزیه و تحلیل خواب است. در این مطالعه الکتروانسفالوگرام (EEG) برای ساخت یک سیستم تشخیص مرحله خواب مستقل استفاده شده است.

در [۲۹] ستیوان و همکاران، یک الگوریتم تشخیص آپنه خواب برای افتراق یک رویداد عادی با آپنه با استفاده از یک چارچوب یادگیری عمیق یک‌بعدی و دوبعدی CNN با تجزیه حالت تجربی از یک سیگنال ECG پیش‌پردازش شده پیشنهاد می‌دهند.

در سال‌های اخیر، روش‌های یادگیری عمیق انقلابی بزرگ در تشخیص آپنه خواب ایجاد کرده است. برخلاف روش‌های مرسوم یادگیری ماشین، روش‌های یادگیری عمیق به استخراج ویژگی خودکار متکی هستند. شبکه‌های عصبی بازگشتی عمیق DRNN و شبکه‌های عصبی CNN دو نوع اصلی از مدل‌های یادگیری عمیق هستند که برای نظارت بر آپنه خواب مورد استفاده قرار گرفته است.

### ۳- روش‌شناسی پژوهش

با توجه به این‌که CNN ها فرصتی بزرگ برای استخراج خودکار ویژگی‌ها و طبقه‌بندی تصاویر، سیگنال‌ها و سایر داده‌های بیولوژیک فراهم کرده است، بعد از انقلاب بزرگ یادگیری عمیق در سال ۲۰۱۸، هر دو نوع شبکه عصبی CNN و RNN به‌عنوان

در [۱۴] حنیف و همکاران، به تجزیه و تحلیل اسکن‌های سه‌بعدی سروصورت باهدف پیش‌بینی شاخص آپنه-هیپوپنه (AHI) می‌پردازند.

کلی و سایرین در [۱۶]، باهدف ارزیابی تشخیص OSA، با استفاده از اندازه‌گیری‌های حرکت فک پایین، ترکیب شده با تحلیل یادگیری ماشین خودکار، در مقایسه با PSG داخل خانه تحقیقاتی انجام داده‌اند.

در [۱۸] مراحل خواب توسط کورکالاین و همکاران، به پنج مرحله مختلف بیداری، حرکت سریع چشم و سه مرحله خواب بدون حرکت سریع چشم دسته‌بندی شده است. این مراحل به صورت دستی برای بازه‌های ۳۰ ثانیه‌ای با استفاده از سیگنال‌های الکتروانسفالوگرافی، الکترواکولوگرام و الکترومایوگرام ضبط شده توسط پلی‌سومنوگرافی به توسعه یک روش خودکار مبتنی بر یادگیری عمیق بازگشتی دقیق برای طبقه‌بندی مراحل خواب در بیماران مشکوک به آپنه خواب انسدادی<sup>۱</sup> پرداخته است.

در [۲۰] لئو و همکاران، در راستای تشخیص ناهنجاری آپنه خواب در کودکان، کارهای مرتبط با تجزیه و تحلیل حرکت را در کودکان کوچک (۳ - ۰ ساله) با استفاده از تکنیک‌های یادگیری ماشین و به کمک داده‌های تصویری و ویدئویی خلاصه می‌کنند. در این مطالعه به‌طور خاص، مشخص می‌شود که بهبود یادگیری عمیق برای استخراج ویژگی حرکت می‌تواند یک مسیر مؤثر برای کشف و بهبود تشخیص ناهنجاری خواب به کمک رایانه باشد.

در [۲۱] لیمبو و سایرین، با توجه به اهمیت دقت در مسائل پزشکی به حل مسائل گرادیان و تغییر کوواریانس داخلی در فرایند تفکیک داده‌های سیگنال ECG پرداخته‌اند.

در [۲۲] لوه و همکاران، یک مدل یادگیری عمیق بر اساس شبکه عصبی کانولوشن یک‌بعدی CNN برای تشخیص الگوی متناوب خواب با استفاده از ثبت EEG استاندارد ارائه می‌دهند.

در [۲۴]، مت اعلام می‌کند با توجه به شدت اختلالات آپنه نوزادی، برای جلوگیری از مرگ یا عواقب مادام‌العمر برای نوزاد، درمان‌های اولیه بلادرنگ لازم است و بررسی سامانه‌های نظارتی مدرن بر اساس راه‌حل‌های پردازش ویدیویی می‌تواند یک جایگزین

<sup>1</sup> Obstructive Sleep Apnea (OSA)

شبکه LSTM, RNN (حافظه کوتاه مدت بلندمدت) و GRU (واحد بازگشتی دردار)، سه گروه مشهور از خانواده شبکه‌های بازگشتی هستند.

مبنای معماری مورد بررسی در این مقاله، بر پایه ترکیب دودسته مدل CNN و DRNN توسعه یافته است [۶]. معماری ترکیبی CNN-DRNN از کارایی CNN ها در استخراج ویژگی و از توانایی DRNN ها در مدل‌سازی الگوی زمانی ویژگی‌های استخراج شده در طول زمان، بهره می‌برد.

### ۲-۳ محاسبات تکاملی و بهینه‌سازی هوشمند در

#### معماری CNN-DRNN

هوش ازدحامی<sup>۱</sup> به رفتار گروهی و هوش جمعی یک مجموعه از موجودات می‌پردازد. جمعیت را می‌توان به صورت مجموعه‌ای سازمان یافته از موجوداتی تعریف کرد که با یکدیگر همکاری می‌کنند. در کاربردهای محاسباتی هوش جمعی از موجوداتی مانند زنبورها، گرگ‌ها، موریانه‌ها، ماهی‌ها، پرندگان یا حتی قطره‌های آب در رودخانه الگوبرداری می‌شود [۱۷].

در این نوع اجتماعات هریک از موجودات ساختار نسبتاً ساده‌ای دارند ولی رفتار گروهی آن‌ها پیچیده به نظر می‌رسد. رفتار گروهی، تنها وابسته به رفتار فردی افراد اجتماع نیست، بلکه به چگونگی همکنشی و تعامل میان افراد نیز وابسته است. همکنشی بین افراد، تجربه افراد درباره محیط را افزایش می‌دهد و مایه پیشرفت اجتماع می‌شود [۱۹].

مکانیسم هوش جمعی را می‌توان به عنوان یک ابزار برای بهینه‌سازی ساختار معماری یادگیری عمیق در بهبود نوع ترکیب، تعداد فیلترهای لایه‌های کانولوشن، تعداد نوروها در لایه‌های مخفی و سایر ابرپارامترها به کار برد.

هوش جمعی برای بهینه‌سازی مدل‌ها نیاز به تعریف تابع هدف دارد. معمول‌ترین تابع هدف معیار خطا است که برای مسائل پیش‌بینی، می‌توان از میانگین خطای مطلق یا مربع خطا و برای مسائل طبقه‌بندی مانند تشخیص آپنه خواب می‌توان از معیارهایی مانند دقت، حساسیت، تشخیص پذیری و F-score استفاده کرد [۱۹].

یک نقطه عطف برای تولید و تغییر مدل‌های یادگیری عمیق ترکیبی برای تشخیص بیماری آپنه خواب به کار گرفته شده است.

یکی از اهداف فرعی این پژوهش، بررسی کارایی طبقه‌بندی آپنه خواب توسط یادگیری عمیق بر اساس مدل‌های ترکیبی متشکل از CNN و DRNN ها است [۶].

در این سناریو، شبکه CNN ویژگی‌های با وضوح بالا را استخراج و DRNN ها تکامل این ویژگی‌ها را در یک دوره زمانی بزرگ‌تر مدل می‌کنند. به منظور ارائه تصویری روشن از روند پیشنهادی، فلوچارت مربوط به تشخیص آپنه خواب با استفاده از یادگیری عمیق در شکل (۲) نمایش داده شده است.

اصلی‌ترین هدف این پژوهش، بهبود کارایی طبقه‌بندی CNN-DRNN با استفاده از دو بهینه‌ساز گورکن عسل و گرگ خاکستری برای انتخاب بهینه ابرپارامترهای موجود در مدل‌های پیشنهادی است.

### ۱-۳ طبقه‌بندی آپنه خواب به وسیله یادگیری عمیق

CNN یک معماری پرکاربرد در یادگیری عمیق است که به طور مستقیم از داده‌ها آموزش می‌بیند و از لایه‌های گره‌ای تشکیل شده است و شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است.

CNN ها داده‌های دارای ساختار شبکه‌ای را پردازش کرده و سپس ویژگی‌های مهم آن‌ها را استخراج می‌کنند. آن‌ها می‌توانند مهم‌ترین ویژگی فیلترها را بیاموزد و چون به پارامترهای زیادی احتیاج ندارد، صرفه‌جویی زیادی در وقت و عملیات آزمون و خطا صورت می‌گیرد.

شبکه عصبی بازگشتی نیز برای پردازش داده‌های سری زمانی و داده‌های ترتیبی مناسب هستند. شبکه‌های عصبی بازگشتی می‌تواند از حافظه داخلی خود برای پردازش دنباله‌ای از ورودی‌ها استفاده کند. در سایر شبکه‌های عصبی، تمام ورودی‌ها از یکدیگر مستقل هستند ولی در شبکه عصبی بازگشتی همه ورودی‌ها با یکدیگر مرتبط هستند.

<sup>1</sup> Swarm Intelligence

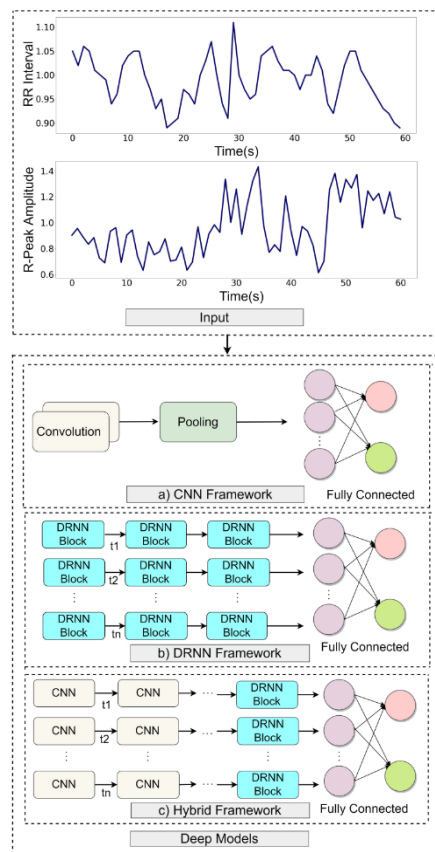
به‌خودی‌خود، دریافتن محل کندوهای عسل ناتوان است ولی با کمک و تعامل با یک پرنده می‌تواند آن‌ها را پیدا کند [۱]. الگوریتم گورکن عسل یک متاهوریستیک<sup>۱</sup> الهام‌گرفته از رفتار گورکن عسل در جستجوی غذا است. این الگوریتم بر اساس دو رفتار اصلی گورکن عسل طراحی شده است: جستجوی غذا در سطح زمین و کاوش زیرزمین. این رفتارها به ترتیب با اکتشاف<sup>۲</sup> و بهره‌برداری<sup>۳</sup> در الگوریتم‌های بهینه‌سازی مرتبط هستند [۱].

فرایند بهینه‌سازی آن شامل مراحل زیر است:

- ۱- تعیین تعداد عامل‌ها به‌عنوان جمعیت اولیه: الگوریتم با مجموعه‌ای از پاسخ‌های اولیه تصادفی آغاز می‌شود (تعریف  $n$  عدد گورکن به‌عنوان اعضای جمعیت گورکن‌ها و مشخص کردن جای آن‌ها).
- ۲- ازدحام<sup>۴</sup> و اکتشاف: با تغییر موقعیت‌ها در فضای جستجو، الگوریتم مناطق مختلف را کاوش می‌کند. نزدیکی گورکن به غذا، تأثیر مهمی در نتیجه دارد، جایی که ازدحام جمعیت زیاد است می‌تواند به هدف نزدیک باشد.
- ۳- تراکم و بهره‌برداری: تراکم، تصادفی بودن متغیر در زمان را مشخص می‌کند و ایجاد یک انتقال یکپارچه از اکتشاف به بهره‌برداری را امکان‌پذیر می‌کند. در واقع پس از یافتن مناطق امیدوارکننده، الگوریتم بر آن‌ها تمرکز کرده و بهینه‌ترین پاسخ‌ها را پیدا می‌کند.
- ۴- فرار از حالت بهینه محلی با توجه به پرچم‌ها: پرچم‌ها به‌عنوان سیگنال‌هایی عمل می‌کنند که نشان می‌دهند آیا عامل (گورکن) در یک بهینه محلی گرفتار شده است یا خیر. اگر گورکن نتواند در چندین تکرار بهبود قابل توجهی در موقعیت خود ایجاد کند (تابع هدف تغییر چشمگیری نداشته باشد)، پرچم مشخص می‌کند که عامل در بهینه محلی گیر افتاده است.

فرار از بهینه محلی یکی از عواملی است که باعث انعطاف‌پذیری و کارایی الگوریتم گورکن عسل در حل مسائل پیچیده بهینه‌سازی می‌شود.

تحقیقات اخیر در حوزه هوش جمعی عملکرد بهتر آن‌ها را در زمینه بهینه‌سازی مسائل نسبت به سایر الگوریتم‌های بهینه‌ساز نشان می‌دهد [۱۹]. روش‌های بهینه‌سازی پارامترهای آموزشی مدل‌های یادگیری عمیق، شامل تغییر نرخ یادگیری اولیه، نوع الگوریتم بهینه‌ساز، تعداد دوره‌های آموزشی، اندازه دسته‌ها یا مینی‌دسته‌ها، تعداد لایه‌های مخفی کاملاً متصل، تعداد و اندازه فیلترهای دسته و کرنل‌ها یا اندازه لایه حداکثر ادغام و سایر موارد می‌گردد.



شکل (۲): ساختار شبکه عصبی عمیق برای تشخیص آینه خواب:

CNN(a)، DRNN(b) و چارچوب ترکیبی (c)

### ۳-۳ الگوریتم بهینه‌ساز گورکن عسل (HBA)

گورکن عسل حیوانی تقریباً مشابه سگ و یک شکارچی باهوش و شجاع است که شکار خود را با تعقیب دائم و با استفاده از حس بویایی تیز خود ردیابی کرده و از طریق حفاری، موقعیت تقریبی هدف خود را تعیین و در نهایت آن را شکار می‌کند. این حیوان

<sup>3</sup> Exploitation  
<sup>4</sup> Intensity

<sup>1</sup> Metaheuristic  
<sup>2</sup> Exploration

۳- شکار: این مرحله مشابه پیدا کردن بهینه‌ترین نقطه یا جواب نهایی است که به صورت خودکار توسط الگوریتم شناسایی و به دست می‌آید.

فرایند بهینه‌سازی در این الگوریتم شامل مراحل زیر است:

۱- جمعیت اولیه: مجموعه‌ای از گرگ‌ها (پاسخ‌ها) در فضای جستجو تولید می‌شوند.

۲- شبیه‌سازی شکار: موقعیت گرگ‌ها بر اساس رفتار سه گرگ برتر (آلفا، بتا و دلتا) و تأثیرپذیری از آن‌ها به‌روزرسانی می‌شود.

۳- اکتشاف و بهره‌برداری: با تغییر موقعیت‌ها، الگوریتم بین جستجوی مناطق جدید (اکتشاف) و تمرکز بر نقاط بهینه (بهره‌برداری) تعادل ایجاد می‌کند.

۴- به‌روزرسانی موقعیت: با استفاده از مدل ریاضی که فاصله و جهت گرگ‌ها نسبت به طعمه را شبیه‌سازی می‌کند، موقعیت‌ها بهینه می‌شوند.

۵- معیار توقف: مشابه HBA، الگوریتم تا برآورده شدن معیار توقف ادامه می‌یابد.

از جمله مزایای بهینه‌ساز گرگ خاکستری نسبت به سایر بهینه‌سازها مانند PSO می‌توان به سادگی، هزینه کم محاسباتی و مناسب بودن آن برای مسائل پیچیده اشاره نمود. همچنین چالش‌هایی مانند امکان به دام افتادن در نقاط کمینه محلی و نیاز به تنظیم دقیق پارامترها محدودیت‌های این بهینه‌ساز است.

### ۳-۵ مجموعه داده

مجموعه داده استفاده‌شده در این پژوهش برای بررسی معماری‌های موردنظر و مقایسه عملکرد آن‌ها دیتاست منبع باز PhysioNet Apnea-ECG version-1.0.0 (AEPD) است [۶].

این مجموعه شامل ۷۰ رکورد مربوط به ۳۲ فرد مختلف است که تقسیم به چهار دسته A, B, C, X می‌شود. ۱۳ نفر با AHI کمتر از ۵ به‌عنوان نرمال و ۱۳ نفر با AHI بزرگ‌تر از ۳۰ در گروه آپنه خواب شدید قرار می‌گیرند. ۶ نفر نیز دارای AHI بین ۵ تا ۳۰ و در دسته آپنه خفیف یا متوسط طبقه‌بندی می‌شوند. نوارهای الکتروکاردیوگرام در فرکانس ۱۰۰ هرتز اندازه‌گیری شده و مدت‌زمان ضبط خواب هر شرکت‌کننده بین ۷ تا ۱۰ ساعت بوده

۵- به‌روزرسانی پاسخ‌ها و تغییر مکان عامل‌ها: موقعیت‌ها با استفاده از یک مدل ریاضی شامل توابع احتمال و الگوریتم‌های جهش و ترکیب، بهبود می‌یابند.

۶- معیار توقف: الگوریتم تا زمانی که معیار توقف (مانند تعداد تکرار یا دقت موردنظر) برآورده شود، ادامه می‌یابد.

این بهینه‌ساز مزایایی مانند توانایی بالا در اکتشاف و بهره‌برداری متوازن و انعطاف‌پذیری در مسائل پیچیده دارد و در مقابل با محدودیت‌هایی مثل نیاز به تنظیم دقیق پارامترها و هزینه محاسباتی بالا در مسائل با ابعاد بزرگ مواجه است.

### ۳-۴ الگوریتم بهینه‌ساز گرگ خاکستری (GWA)

الگوریتم گرگ خاکستری که در سال ۲۰۱۴ توسط پروفسور میرجلیلی و همکاران ایشان ارائه گردیده است، یک الگوریتم فرا ابتکاری است که از ساختار سلسله‌مراتبی و رفتار اجتماعی گرگ‌های خاکستری در هنگام شکار کردن الهام گرفته است. این الگوریتم بر تعامل بین چهار نوع گرگ (آلفا، بتا، دلتا و امگا) متمرکز است که نقش‌های مختلفی در فرایند شکار ایفا می‌کنند [۹]. این الگوریتم مبتنی بر جمعیت فرایند ساده‌ای دارد که به سادگی قابل‌تعمیم به مسائل با ابعاد بزرگ است. گرگ‌های خاکستری به‌عنوان شکارچیان رأس در نظر گرفته می‌شوند که در بالای هرم زنجیره غذایی هستند و ترجیح می‌دهند در گروهی زندگی کنند که به‌طور متوسط ۱۲-۵ عضو دارد. همه اعضای این گروه دارای سلسله‌مراتب تسلط اجتماعی بسیار دقیق هستند و وظایف خاصی را دنبال می‌کنند. این الگوریتم شامل ۳ مرحله اصلی است [۲۳]:

۱- مشاهده شکار، ردیابی و تعقیب آن: در این مرحله، گرگ‌ها شکار را شناسایی کرده و آن را دنبال می‌کنند. این مرحله مشابه فرایند جستجو و شناسایی مناطق خوب و نزدیک به بهترین جواب (محل شکار) برای بهینه‌سازی است.

۲- نزدیک شدن، حلقه زدن به دور شکار و گمراه کردن آن تا زمانی که از حرکت بازماند. این مرحله مشابه فرایند جستجوی دقیق‌تر است که در آن گرگ‌ها به سمت بهترین نقاط حرکت می‌کنند و آن‌ها را بهبود می‌بخشند تا بتوانند بهترین جواب را پیدا کنند.

پیشرفت‌های چشم‌گیری در حل مسائل پیچیده شده‌اند. ترکیب‌های مختلف معماری DRNN شامل BiLSTM، LSTM و GRU با آن‌ها در این مقاله برای تشخیص کارآمد بیماری آپنه، با استفاده از بهینه‌سازهای گورکن عسل و گرگ خاکستری استفاده شده است. نظر به تعداد کم اپیزودهای آپنه در طول زمان خواب نسبت به اپیزودهای عادی در مجموعه داده موردنظر، برای متعادل کردن داده‌ها، از روش اعتبارسنجی متقابل ۵ بخشی استفاده شده است که روشی مؤثر برای متعادل کردن داده‌ها در مجموعه داده‌های نامتعادل است [۶].

اعتبارسنجی متقابل موجب می‌شود مدل‌ها در چند نقطه آموزش دیده و آزمایش شوند و بر روی داده‌های تست بهتر عمل کنند. در هر بخش، ۷۰٪ داده‌ها برای آموزش و ۱۰٪ آن‌ها به‌عنوان یک مجموعه اعتبارسنجی برای یافتن پارامترهای بهینه در نظر گرفته می‌شود. ۲۰٪ داده‌ها نیز برای ارزیابی مدل‌های آموزش دیده بر روی داده‌هایی که در طول آموزش و اعتبارسنجی دیده نشده‌اند، مورد استفاده قرار می‌گیرد.

#### ۴-۱ مقداردهی پارامترها

توسعه و اجرای کدها در محیط Google Colab با ۱۵ گیگابایت GPU RAM و حدود ۱۲ تا ۲۵ گیگابایت CPU RAM به‌عنوان منابع سخت‌افزاری، با استفاده از زبان برنامه‌نویسی پایتون انجام شده است.

زمان اجرای هر مدل با احتساب سایر مراحل مانند پیش‌پردازش سیگنال بین ۴۵ دقیقه تا ۲:۳۰ ساعت متغیر بود. استفاده از TPU در برخی موارد سرعت آموزش را افزایش داد و باعث صرفه‌جویی در زمان اجرا گردید.

نتایج به‌دست‌آمده همراه با کدها از طریق پلتفرم GitHub<sup>۱</sup> در دسترس عموم قرار گرفته است و بررسی دقیق‌تر زمان اجرا و منابع مصرفی از طریق پروفایل Google Colab امکان‌پذیر خواهد بود. با توجه به اینکه هدف هر دو الگوریتم بهینه‌ساز گورکن عسل و گرگ خاکستری بهینه‌سازی پارامترهای کمی نظیر ابرپارامترها است، در تمامی آزمایش‌های انجام‌شده، اندازه جمعیت اولیه ۵۰ و

است. هر دقیقه از نوار قلب این مجموعه داده به‌صورت تنفس نرمال یا نامنظم توسط متخصص خواب برچسب‌گذاری شده است. به‌طور کل این مجموعه شامل اطلاعات ۳۵ شرکت‌کننده است که به علت نویز ناشی از حرکت بیمار، نویز اندازه‌گیری یا اختلال‌های دیگر تنها داده‌های ۳۲ شرکت‌کننده مورد بررسی قرار گرفته است [۶].

#### ۳-۶ پیش‌پردازش

سیگنال ECG برای تطابق با طبقه‌بندی پایه آپنه به بخش‌های ۱ دقیقه‌ای تقسیم می‌شود. البته باید در نظر داشت که فرایند قطعه‌بندی، تأثیر رویداد آپنه قبلی را بر روی بخش فعلی نادیده می‌گیرد.

در بررسی انجام‌شده برای استخراج خودکار ویژگی‌ها از دامنه‌ها و بازه‌های RR (فاصله بین ضربان‌های پی‌درپی قلب) در سیگنال ECG، استفاده می‌شود. چون مطالعات قبلی نشان می‌دهد که اطلاعات بخش مجاور (در مجموع پنج بخش ۱ دقیقه‌ای) برای تشخیص هر تکرار آپنه مهم است، بخش‌های سیگنال ECG برچسب شده با «آپنه خواب» همراه با بخش‌های همسایه برای پردازش استخراج شدند [۶،۱].

ابتدا برای شناسایی قله‌های R در ضربان قلب از روش همیلتون استفاده شد و سپس فاصله بین قله‌های R بر اساس موقعیت آن‌ها محاسبه و مقادیر قله R به‌عنوان دامنه استخراج شد [۱۳]. با توجه به این واقعیت که بازه‌های RR بازیابی شده، شامل نقاط غیرقابل تفسیر پزشکی بود، فیلتر میانه برای حذف این نقاط استفاده شد [۶].

با توجه به این‌که دامنه‌های تولیدشده و بازه‌های RR با بازه‌های زمانی برابر مطابقت ندارد، درون‌یابی مکعبی در طول بخش‌های ۵ دقیقه‌ای به‌کاربرده شد تا ۹۰۰ نقطه از دامنه و ۹۰۰ نقطه از بازه‌های RR به دست آید [۱].

#### ۴- روش انجام آزمایش

از جمله معماری‌های معروف و پرکاربرد CNN می‌توان چهار مدل VGG16، VGG19، ZFNet و AlexNet را نام برد که منجر به

[https://github.com/mbadiee/Sleep-Apnea-Detection-By-Optimized-DL-Algorithm\\_GWA](https://github.com/mbadiee/Sleep-Apnea-Detection-By-Optimized-DL-Algorithm_GWA)

<sup>۱</sup> <https://github.com/mbadiee/Sleep-Apnea-Detection-By-DL-Algorithm-WithOut-Optimization/tree/main>  
[https://github.com/mbadiee/Sleep-Apnea-Detection-By-Optimized-DL-Algorithm\\_HBA](https://github.com/mbadiee/Sleep-Apnea-Detection-By-Optimized-DL-Algorithm_HBA)

▪ نمره F1<sup>۴</sup>: معیار F1 یک معیار مناسب برای ارزیابی دقت یک آزمایش است. این معیار میانگین هماهنگی از دقت و یادآوری است. به بیان ریاضی، امتیاز F1 میانگین وزن‌دار از دقت و یادآوری است. بهترین مقدار برای F1، مقدار یک و بدترین مقدار آن صفر است.

### ۵- نتایج و بحث

جدول (۱) عملکرد ۱۲ الگوریتم ترکیبی یادگیری عمیق مورد بررسی را بدون اعمال هیچ‌کدام از بهینه‌سازهای هوش جمعی بر روی داده‌های آزمون، از نظر دقت، حساسیت، تشخیص‌پذیری و F-score به‌طور خلاصه نشان می‌دهد. همان‌طور که مشاهده می‌شود مدل ترکیبی ZFNet-BiLSTM به بالاترین میزان دقت (۹۴/۲۲٪) و F-Score (۹۲/۶۸٪) و کمترین مقدار خطا (۰/۲۶۲۲) در بین روش‌های مختلف، دست‌یافت. همچنین AlexNet-BiLSTM با بالاترین مقدار حساسیت (۹۴/۹۹٪) و VGG19-GRU با مطلوب‌ترین مقدار تشخیص‌پذیری (۱۰۰٪) نسبت به سایر مدل‌ها صدرنشین هستند.

تعداد ایپوک‌ها به‌عنوان مقادیر پایه معادل ۱۰۰ در نظر گرفته شد تا شرایط تمام آزمایش‌ها یکسان باشد.

### ۴-۲ معیارهای ارزیابی

معیارهای متنوعی برای ارزیابی کارایی الگوریتم‌های یادگیری ماشین، الگوریتم‌های طبقه‌بند و رگرسیون وجود دارد که برخی از آن‌ها عبارت‌اند از:

- دقت<sup>۱</sup>: متداول‌ترین معیار کارایی برای الگوریتم‌های طبقه‌بندی است و می‌توان آن را در قالب تعداد پیش‌بینی‌های صحیح نسبت به همه پیش‌بینی‌های صورت‌گرفته، تعریف کرد.
- تشخیص‌پذیری<sup>۲</sup>: از متداول‌ترین پارامترها که معمولاً در کنار حساسیت بررسی می‌شود، پارامتر تشخیص‌پذیری است که به آن نرخ پاسخ‌های منفی درست نیز گفته می‌شود.
- حساسیت<sup>۳</sup>: معیار حساسیت که نرخ پاسخ‌های مثبت درست نیز نامیده می‌شود، به معنی نسبتی از موارد مثبت است که آزمایش آن‌ها را به‌درستی به‌عنوان نمونه مثبت تشخیص داده است. این پارامتر مشخص می‌کند دسته‌بند، به چه اندازه در تشخیص تمام افراد مبتلا به بیماری موفق بوده است.

جدول (۱): عملکرد الگوریتم‌های ترکیبی یادگیری عمیق در تشخیص آپنه خواب

خطای مدل (۱۰۰)	F1 نمره	تشخیص‌پذیری	حساسیت	دقت	مدل‌ها
۰/۴۰۹۴	۹۱/۱۷	۹۱/۶	۹۴/۹	۹۲/۸۸	AlexNet-BiLSTM
۰/۳۷۱۱	۹۱/۶۴	۹۶/۴۳	۸۹/۳۴	۹۳/۶۸	AlexNet-GRU
۰/۴۰۷۳	۹۰/۴۲	۹۶/۱۴	۸۷/۵۶	۹۲/۸۲	AlexNet-LSTM
۰/۳۳۴۷	۸۸/۰۲	۹۳/۶	۸۶/۵۵	۹۰/۸۷	VGG16-BiLSTM
۰/۳۴۲۲	۸۶/۱۳	۹۰/۲۳	۸۷/۳۳	۸۹/۱۱	VGG16-GRU
۰/۳۳۴۳	۸۷/۴۴	۹۳/۴	۸۵/۷۸	۹۰/۴۵	VGG16-LSTM
۰/۳۳۳	۸۳/۴۱	۹۳/۱۶	۷۹/۲۹	۸۷/۷۹	VGG19-BiLSTM
۰/۶۶۸۵	۰	۱۰۰	۰	۶۱/۲۷	VGG19-GRU
۰/۲۹۱۶	۸۸/۰۳	۹۴/۲۴	۸۵/۷۸	۹۰/۹۶	VGG19-LSTM
۰/۲۶۲۲	۹۲/۶۸	۹۴/۱۴	۹۴/۳۶	۹۴/۲۲	ZFNet-BiLSTM
۰/۶۲۶۹	۸۱/۰۱	۷۹/۴۸	۹۰/۱۹	۸۳/۶۳	ZFNet -GRU
۰/۲۸۶۱	۹۱/۰۴	۹۳/۴	۹۲/۲۷	۹۲/۹۷	ZFNet -LSTM

<sup>۳</sup> Sensitivity  
<sup>۴</sup> F1-score

<sup>۱</sup> Accuracy  
<sup>۲</sup> Specificity

شناسایی دستی ابرپارامترهای بهینه در آن‌ها شده است که بهینه‌سازهای هوش جمعی می‌تواند با یافتن مقادیر بهینه برای ابرپارامترها به این چالش کمک کند.

در همین راستا بهینه‌سازهای گورکن عسل و گرگ خاکستری دو نمونه از تکنیک‌های هوش جمعی برای جلوگیری از عدم کارایی و همگرا شدن CNN ها به حداقل محلی و آموزش کارآمد است و برخی محدودیت‌های تعداد و تنوع نمونه‌ها را برطرف می‌کند.

برای ارزیابی کارایی این دو بهینه‌ساز بر روی مدل‌های پیشنهاد شده در جدول (۱)، برخی ابرپارامترهای ارائه شده در ساختار الگوریتم‌های CNN و RNN شامل تعداد نورون‌ها (فیلتر ورودی هر لایه)، نرخ یادگیری و تعداد دوره‌های آموزش<sup>۱</sup>، از طریق این بهینه‌سازها ارزیابی شد. جدول (۲) و (۳) به ترتیب نتایج بهینه‌سازی توسط الگوریتم‌های گورکن عسل و گرگ خاکستری برای مدل‌های منتخب را نمایش می‌دهد.

اکنون به تحلیل دقیق‌تر این بهبودها می‌پردازیم:

۱- نرخ یادگیری: مقدار اولیه برای تمام مدل‌ها به صورت دو مرحله‌ای، مقدار ۰/۰۰۱ برای دوره‌های کمتر از ۷۰ و مقدار ۰/۱ برای دوره‌های بیشتر از ۷۰ تعریف شده بود. در هر دو الگوریتم بهینه‌سازی، نرخ یادگیری ثابت به ۰/۰۰۱ کاهش یافته است.

این تغییر منجر به بهبود معیارهای عملکردی مانند دقت، حساسیت و نمره F شده و خطاهای مدل‌ها را کاهش داده است. این نشان می‌دهد که نرخ یادگیری ثابت و پایین‌تر برای مدل‌ها ثبات بیشتری ایجاد کرده و از نوسانات ناشی از تغییر نرخ یادگیری جلوگیری کرده است.

۲- تعداد نورون‌ها: تغییرات پیشنهادی در تعداد نورون‌های لایه‌ها به‌وضوح نشان‌دهنده کاهش تعداد نورون‌ها در لایه‌های مختلف مدل‌ها است.

مدل ترکیبی ZFNet-BiLSTM در آزمایش به‌عنوان بهترین مدل پیشنهادی معرفی شد، این مدل متشکل از ۹۶ گره در لایه ورودی و یک کرنل  $7 \times 1$  در لایه اول ساختار ZFNet و به ترتیب ۵۱۲، ۵۱۲ و ۱۰۲۴ گره در لایه‌های مخفی و یک کرنل  $5 \times 1$  و سه کرنل  $3 \times 1$  در لایه‌های میانی است که خروجی آن به یک مدل BiLSTM که در آن هر سلول یک ساختار دوبعدی  $24 \times 512$  و سپس ۱۲۸ لایه‌ای دریافت می‌کند، متصل گردیده است.

خروجی سپس مسطح شده و به دولایه کاملاً متصل با ۳۷ و ۲ گره تغذیه شده است. توجه شود که بعد از لایه اول، دوم و پنجم از حداکثر ادغام با اندازه  $3 \times 1$ ، قبل از نرمال‌سازی دسته‌ای، استفاده شده است.

بر اساس جدول (۱)، مدل‌های ترکیبی نسبت به مدل‌های ساده‌تر مانند CNN در [۶] بهبودهایی در معیارهای مختلف مانند دقت، حساسیت و تشخیص‌پذیری نشان داده‌اند، اما این بهبود در برخی موارد ناچیز است (مثلاً اختلاف ۱-۲ درصدی در دقت).

همچنین افزودن لایه‌های بازگشتی (LSTM/GRU) به CNN اگرچه باعث بهبود توانایی مدل در درک وابستگی‌های زمانی می‌شود که برای داده‌های سری زمانی مانند تشخیص آپنه خواب بسیار مهم است، ولی با توجه به نیاز به نگهداری وضعیت و پارامترهای بیشتر نیاز به حافظه و GPU بیشتر دارند که باعث افزایش هزینه‌های محاسباتی، از جمله مصرف حافظه و زمان اجرا می‌شود.

بنابراین، برای تعیین اینکه آیا این پیچیدگی اضافی ارزشمند است، باید مشخص کرد که آیا این بهبود عملکرد در شرایط عملی مانند سیستم‌های بلادرنگ ارزش هزینه‌های محاسباتی بالاتر را دارد یا خیر. اگر مثل کاربردهای پزشکی حساس، نیاز به دقت بالاتر، حتی به قیمت افزایش پیچیدگی باشد، مدل‌های ترکیبی ارزشمند هستند؛ اما اگر عملکرد بلادرنگ یا مصرف بهینه منابع اهمیت بیشتری داشته باشد، مدل‌های ساده‌تر مانند CNN ممکن است گزینه بهتری باشند.

نظر به این‌که CNN ها به خاطر تنوع زیاد ابرپارامترها در معماری‌های مختلف چالش دارند، این مهم باعث پیچیدگی در

<sup>1</sup> Epoch

جدول (۲): مقایسه مقدار ابرپارامترهای پیشنهادی توسط بهینه‌ساز گورکن عمل باحالت اولیه

مدل‌ها	ابریارامترها	مقدار اولیه	مقدار بهینه (الگوریتم گورکن)	توضیحات بهبود
AlexNet-BiLSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش دقت، تشخیص‌پذیری و نمره F همچنین کاهش مقدار خطا
	تعداد نورون‌ها	۳۸۴, ۲۵۶, ۹۶ ۲, ۱۸, ۲۵۶, ۳۸۴,	۳۷۴, ۲۴۶, ۸۶ ۸, ۶۴, ۱۲۸, ۳۷۴,	
	تعداد دوره‌های آموزش	۱۰۰	۵۰	
AlexNet-BiLSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش دقت، حساسیت، تشخیص‌پذیری و نمره F همچنین کاهش مقدار خطا
	تعداد نورون‌ها	۲, ۱۸, ۲۵۶, ۳۸۴, ۳۸۴, ۲۵۶, ۹۶	۸, ۶۴, ۱۲۸, ۳۷۴, ۳۷۴, ۲۴۶, ۸۶	
	تعداد دوره‌های آموزش	۱۰۰	۵۰	
VGG19-LSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش دقت، حساسیت و نمره F همچنین کاهش مقدار خطا
	تعداد نورون‌ها	, ۲۵۶, ۲۵۶, ۱۲۸, ۱۲۸, ۶۴, ۶۴ ۲۵۶, ۲۵۶ ۲۱, ۶۴, ۵۱۲, ۵۱۲, ۵۱۲, ۵۱۲, ۵۱۲,	, ۱۵۶, ۸۰, ۸۰, ۴۲, ۴۲ , ۱۵۶, ۱۵۶ , ۴۰۰, ۴۰۰, ۴۰۰, ۴۰۰, ۴۰۰, ۱۵۶ ۱۹, ۳۲	
	تعداد دوره‌های آموزش	۱۰۰	۱۰۰	

به‌طور کلی کاهش و ثابت نگه‌داشتن نرخ یادگیری باعث جلوگیری از نوسانات خروجی و بهبود تدریجی مدل‌ها شده است. این امر خصوصاً برای مدل‌های عمیق‌تر مانند VGG19 اهمیت زیادی دارد.

همچنین کاهش تعداد نورون‌ها تأثیر مستقیمی بر کاهش پیچیدگی مدل و افزایش کارایی آن داشته است. این امر حتی ممکن است اثر منفی تنظیم بیش‌برازش<sup>۱</sup> را کاهش دهد. در ادامه، کاهش تعداد دوره‌های آموزشی باعث صرفه‌جویی در زمان و منابع محاسباتی شده و درعین‌حال از اشباع مدل‌ها جلوگیری کرده است.

کاهش تعداد نورون‌ها به کاهش پیچیدگی مدل کمک کرده است که به‌نوبه خود باعث بهبود در سرعت و کاهش نیاز به منابع محاسباتی شده است. این امر بدون کاهش کیفیت خروجی مدل انجام شده است.

۳- تعداد دوره‌های آموزش (ایپوک‌ها): در بیشتر مدل‌ها تعداد دوره‌های آموزش از مقدار اولیه ۱۰۰ به ۵۰ یا ۳۰ کاهش یافته است. تنها استثنا در مدل VGG19-LSTM (با الگوریتم گورکن عمل) بود که تعداد دوره‌ها ثابت باقی‌مانده است. کاهش تعداد دوره‌ها در بیشتر مدل‌ها نشان‌دهنده کاهش هزینه محاسباتی و زمان آموزش است، درحالی‌که عملکرد مدل تحت تأثیر قرار نگرفته یا حتی بهبود یافته است.

<sup>1</sup> Overfitting

جدول (۳): مقایسه مقدار ابرپارامترهای پیشنهادی توسط بهینه‌ساز گرگ خاکستری باحالت اولیه

مدل‌ها	ابریارامترها	مقدار اولیه	مقدار بهینه (الگوریتم گرگ)	توضیحات بهبود
AlexNet-GRU	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش حساسیت و نمره F همچنین کاهش مقدار خطا
	تعداد نورون‌ها	۲, ۱۸, ۲۵۶, ۳۸۴, ۳۸۴, ۲۵۶, ۹۶	۶۴, ۶۴, ۶۴, ۶۴, ۱۶, ۳۲	
	تعداد دوره‌های آموزش	۱۰۰	۵۰	
AlexNet-BiLSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش دقت، حساسیت و نمره F همچنین کاهش مقدار خطا
	تعداد نورون‌ها	۶۴, ۶۴, ۱۲۸, ۱۲۸, ۲۵۶, ۵۱۲, ۵۱۲, ۵۱۲, ۵۱۲, ۵۱۲, ۶۴, ۲۱, ۲۵۶, ۲۵۶, ۲۵۶	۲۴۶, ۲۴۶, ۲۴۶, ۲۴۶, ۹۴, ۹۴, ۴۴, ۴۴, ۱۹, ۳۲, ۲۵۶, ۳۰۰, ۳۰۰, ۶۴, ۲۵۶	
	تعداد دوره‌های آموزش	۱۰۰	۳۰	
VGG19-LSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش تشخیص پذیری و کاهش سایر شاخص‌های مثبت همچنین افزایش خطا
	تعداد نورون‌ها	۲۵۶, ۱۲۸, ۱۲۸, ۶۴, ۶۴, ۲۵۶, ۲۵۶, ۲۵۶, ۵۱۲, ۵۱۲, ۵۱۲, ۵۱۲, ۲۱, ۶۴	۹۴, ۹۵, ۴۴, ۴۴, ۲۴۶, ۲۴۶, ۲۴۶, ۱۹, ۳۲, ۲۵۶, ۳۰۰, ۳۰۰, ۶۴, ۲۵۶	
	تعداد دوره‌های آموزش	۱۰۰	۳۰	
ZFNet-BiLSTM	نرخ یادگیری	برای ایپک‌های کمتر از ۷۰ مقدار ۰/۰۰۱ و برای بزرگ‌تر از ۷۰ مقدار ۰/۱	۰/۰۰۱	افزایش حساسیت و کاهش سایر شاخص‌های مثبت همچنین افزایش خطا
	تعداد نورون‌ها	۹۶, ۲۵۶, ۵۱۲, ۱۰۲۴, ۵۱۲, ۱۲۸, ۳۷	۸۶, ۲۴۶, ۴۸۰, ۹۲۴, ۴۸۰, ۱۱۸, ۳۵	
	تعداد دوره‌های آموزش	۱۰۰	۳۰	

با مقایسه نتایج جدول (۱) و (۴) مشاهده می‌شود، بعد از اعمال بهینه‌ساز گورکن عسل، شاخص دقت در مدل-ALEXNET از GRU از ۹۳/۶۸٪ به ۹۵٪ و تشخیص پذیری از ۹۶/۴۳٪ به ۹۷/۶۱٪ و F-Score از ۹۱/۶۴٪ به ۹۳/۳۷٪ افزایش یافته است که نتایج حاصل شده نسبت به حالت عادی و بدون بهینه‌سازی به مراتب بهبود قابل مشهودی داشته است.

همچنین اعمال بهینه‌ساز HBO بر روی مدل-AlexNet BiLSTM باعث افزایش ۹ درصدی حساسیت در این مدل شده است و با کاهش ۰/۶ در مقدار تابع خطا در مدل VGG19-LSTM این مدل را نیز مورد توجه قرار داده است.

جدول (۴) و (۵) به ترتیب عملکرد الگوریتم‌های یادگیری عمیق را بعد از بهینه‌سازی به کمک بهینه‌ساز گورکن عسل و گرگ خاکستری، از نظر دقت، حساسیت، تشخیص پذیری و F-score برای تمام مدل‌های آزمایش شده در جدول (۱) نمایش می‌دهد. همان‌طور که مشاهده می‌شود بعد از بهینه‌سازی انجام شده توسط بهینه‌ساز گورکن عسل، مدل ALEXNET-GRU به بهترین دقت (۹۵٪)، تشخیص (۹۷/۶۱٪) و F-Score (۹۳/۳۷٪) دست یافت. ZFNet-LSTM کمترین دقت (۸۵/۳۳٪) را نشان می‌دهد که ممکن است به دلیل مشکلات تنظیم ابرپارامترها یا عدم توانایی این ترکیب در استخراج ویژگی‌های مؤثر باشد. معماری ALEXNET-BiLSTM بهترین حساسیت (۹۲/۶۶٪) و VGG19-LSTM کمترین میزان خطا (۰/۲۳۳۵) را کسب نمودند.

جدول (۴): عملکرد الگوریتم‌های ترکیبی یادگیری عمیق در تشخیص آپته خواب بعد از اعمال بهینه‌ساز گورکن عمل

مدل‌ها	دقت	حساسیت	تشخیص پذیری	F1نمره	خطای مدل (۱۰۰٪)
AlexNet-BiLSTM	۹۳/۵۹	۹۲/۶۶	۹۴/۱۹	۹۱/۸۱	۰/۳۶۲۵
AlexNet-GRU	۹۵/۰۰	۹۰/۸۸	۹۷/۶۱	۹۳/۳۷	۰/۳۳۵۵
AlexNet-LSTM	۹۳/۳	۹۰/۶۵	۹۴/۹۷	۹۱/۲۸	۰/۳۳۴۷
VGG16-BiLSTM	۹۱/۵	۸۷/۹۴	۹۳/۷۵	۸۸/۹۱	۰/۴۵۱
VGG16-GRU	۹۱/۴۱	۹۰/۷۳	۹۱/۸۴	۸۹/۱۱	۰/۴۳۱۹
VGG16-LSTM	۹۰/۳۳	۸۴/۴۷	۹۴/۰۴	۸۷/۱۳	۰/۳۷۵۱
VGG19-BiLSTM	۹۱/۵۹	۹۰/۴۲	۹۲/۳۳	۹۲/۳۳	۰/۳۴۲۹
VGG19-GRU	۹۱/۱۴	۸۴/۵۴	۹۵/۳۱	۸۸/۰۸	۰/۲۸۰۳
VGG19-LSTM	۹۱/۱۴	۸۸/۲۵	۹۲/۹۷	۸۸/۵۳	۰/۲۳۳۵
ZFNet-BiLSTM	۹۳/۴۲	۹۱/۶۵	۹۴/۵۳	۹۱/۵۱	۰/۲۷
ZFNet-GRU	۹۳/۲۴	۹۱/۳۴	۹۴/۴۳	۹۱/۲۷	۰/۲۶۹۶
ZFNet-LSTM	۸۵/۳۳	۷۴/۷۳	۹۲/۰۴	۷۹/۷۹	۰/۵۲


در جدول (۵) (GWO) مدل ZFNet-BiLSTM بهترین حساسیت (۹۵/۴۴٪) را نشان داده است. مقدار F1-score در جدول (۴) برای اکثر مدل‌ها بالاتر است که نشان می‌دهد HBO در بهینه‌سازی تعادل بین حساسیت و تشخیص پذیری بهتر عمل کرده است. مقدار خطای مدل‌ها در جدول (۴) کمتر از جدول (۵) است که نشان می‌دهد HBO تأثیر بهتری بر کاهش خطاها داشته است. به صورت کلی، بهینه‌ساز HBO نسبت به GWO تأثیر بهتری بر بهبود دقت، حساسیت و کاهش خطا داشته است. AlexNet-GRU و AlexNet-BiLSTM بهترین عملکرد را پس از اعمال HBO داشته‌اند. ZFNet-LSTM در هر دو جدول عملکرد ضعیفی داشته و نیاز به بهینه‌سازی بیشتر دارد.

شبکه ALEXNET-GRU ترکیبی توسعه‌یافته، متشکل از ۸۶ گره ورودی و یک کرنل ۱۱×۱ در لایه اول ALEXNET و به ترتیب ۳۷۴، ۳۷۴، ۲۴۶ و ۱۲۸ نورون مخفی و یک کرنل ۵×۱ و سه کرنل ۳×۱ در لایه‌های میانی است که خروجی آن به یک مدل GRU که در آن هر سلول یک ساختار دوبعدی ۲۴×۱۲۸ و سپس ۶۴ لایه‌ای دریافت می‌کند، متصل گردید. خروجی سپس مسطح شده و به دولایه کاملاً متصل با ۸ و ۲ گره تغذیه شد. بعد از لایه اول، دوم و پنجم نیز از لایه ادغام Max-pooling با اندازه ۳×۱ قبل از نرمال‌سازی دسته‌ای استفاده شده است. با مقایسه نتایج جدول (۴) و (۵) مشاهده می‌شود، بعد از اعمال بهینه‌ساز گرگ خاکستری، امتیاز F-Score همچنان در مدل ALEXNET-GRU نسبت به وقتی که هیچ بهینه‌سازی اعمال نشده است (جدول ۱) اول است ولی دقت آن علی‌رغم اینکه بعد از اعمال بهینه‌ساز گرگ خاکستری نسبت به سایر الگوریتم‌ها بهتر بوده است، نسبت به مدل اصلی در جدول (۱) کاهش اندکی داشته است.


در جدول (۴) (HBO)، مدل‌های AlexNet-GRU و AlexNet-BiLSTM عملکرد برتری نسبت به سایر مدل‌ها دارند، درحالی‌که

جدول (۵): عملکرد الگوریتم‌های ترکیبی یادگیری عمیق در تشخیص آپنه خواب بعد از اعمال بهینه‌ساز گرگ خاکستری

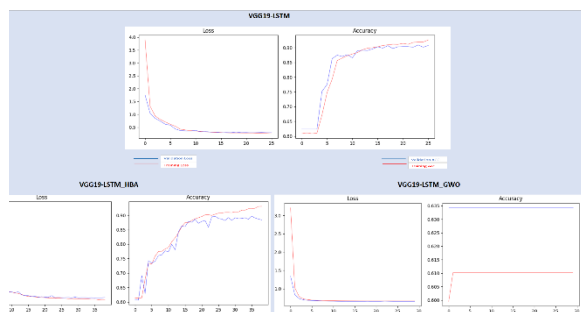
مدل‌ها	دقت	حساسیت	تشخیص‌پذیری	نمره F1	خطای مدل (۱۰۰٪)
AlexNet-BiLSTM	۹۲/۵۵	۸۳/۹۳	۹۸	۸۹/۷۱	۰/۳۸۶۱
AlexNet-GRU	۹۳/۵	۹۳/۱۲	۹۳/۷۵	۹۱/۷۴	۰/۳۵۴۷
AlexNet-LSTM	۹۲/۲۵	۸۶/۰۱	۶۹/۱۹	۸۹/۵۸	۰/۳۸۰۶
VGG16-BiLSTM	۹۰/۶۶	۸۸/۱۸	۹۲/۲۳	۸۷/۹۷	۰/۴۰۶۲
VGG16-GRU	۹۰	۸۷/۳۳	۹۱/۷	۸۷/۱۲	۰/۳۳۲۷
VGG16-LSTM	۸۹/۴۳	۸۲/۶۱	۹۳/۷۵	۸۵/۸۳	۰/۳۴۱۱
VGG19-BiLSTM	۳۳/۹۰	۸۷/۸۷	۹۱/۸۹	۸۷/۵۶	۰/۲۸۷۹
VGG19-GRU	۸۹/۵۸	۸۶/۵۵	۹۱/۵	۸۶/۵۵	۰/۳۶۱۲
VGG19-LSTM	۶۱/۲۷	۰	۱۰۰	۰	۰/۶۶۸
ZFNet-BiLSTM	۹۲/۱	۹۵/۴۴	۸۹/۹۹	۹۰/۳۴	۰/۳۴
ZFNet -GRU	۸۵/۵۷	۷۷/۸۲	۹۰/۴۷	۸۰/۶۹	۰/۵۰۹۸
ZFNet -LSTM	۸۸/۱۵	۸۹/۳۴	۸۷/۴	۸۵/۳۸	۰/۵۲



شکل (۳): ALEXNET-BiLSTM



شکل (۴): ALEXNET-GRU



طبق نتایج حاصل شده بهینه‌ساز گرگ خاکستری تأثیر مثبتی بر بهبود دقت و حساسیت مدل‌های مختلف داشته است، اما در برخی موارد، باعث افزایش نرخ خطا نیز شده است.

مدل AlexNet-GRU و ZFNet-BiLSTM بهترین عملکرد را نشان داده‌اند، درحالی‌که VGG19-LSTM و VGG19-GRU عملکرد ضعیف‌تری داشته‌اند.

مدل‌های مبتنی بر BiLSTM و GRU عموماً نتایج بهتری از LSTM داشته‌اند که نشان می‌دهد این روش‌های پردازش سری‌های زمانی کارآمدتر هستند.

یکی از چالش‌های هر دو بهینه‌ساز گورکن عسل و گرگ خاکستری، به دام افتادن تصادفی در نقاط بهینه محلی بود که در این مواقع نتیجه خوبی حاصل نشد و حتی نسبت به حالت بدون اعمال بهینه‌ساز عملکرد ضعیف‌تری حاصل شد، مانند مدل ZFNet-BiLSTM که مدل منتخب جدول (۱) و بدون اعمال بهینه‌ساز بود؛ ولی بعد از اعمال بهینه‌سازها نتیجه ضعیف‌تری کسب کرد.

در شکل (۳) تا (۷) می‌توانید نمودار همگرایی خطا و دقت معماری‌های منتخب را بعد از سه بار اجرای مختلف با و بدون اعمال بهینه‌ساز HBO و GWO مشاهده نمایید (محور X شماره ایپوک و محور Y مقدار خطا یا دقت است).

در این مقاله، یک چارچوب یکپارچه برای مقایسه چندین الگوریتم یادگیری عمیق ارائه شده است که به منظور تشخیص بیماری آپنه خواب از سیگنال ECG تک‌لیدی مورد بررسی قرار گرفته‌اند. به طور خلاصه در این پژوهش مشاهده شد که:

معماری‌های ترکیبی DRNN-CNN در تشخیص بیماری آپنه خواب تأثیر قابل توجهی داشت که در حالت معمول و بدون بهینه‌سازی ابرپارامترها، معماری ZFNET-BiLSTM به بالاترین میزان دقت و امتیاز F-Score و کمترین میزان خطا دست یافت و مدل AlexNet-BiLSTM و VGG19-GRU به ترتیب، بهترین حساسیت و تشخیص‌پذیری را کسب نمودند.


کارایی و قدرت تشخیص مدل‌های پیشنهادی بعد از به‌کارگیری بهینه‌ساز هوش جمعی گورکن عسل و گرگ خاکستری برای یافتن مقادیر بهینه برخی ابرپارامترها، به طور محسوسی بهبود یافت.

با اعمال بهینه‌ساز گورکن عسل برای یافتن مقدار بهینه برخی ابرپارامترها، مدل AlexNet-GRU بالاترین میزان دقت، تشخیص و امتیاز F-Score را کسب نمود و کمترین مقدار خطا به VGG19-LSTM و بالاترین مقدار حساسیت به مدل Alexnet-BiLSTM اختصاص یافت.


نتایج حاصل از اعمال بهینه‌ساز گورکن عسل بهتر از نتایج حاصل از اعمال بهینه‌ساز گرگ خاکستری بود.

در نتیجه، استفاده از شبکه‌های عصبی عمیق ترکیبی با رویکرد استفاده از بهینه‌سازهای هوش جمعی در جهت تخمین مقادیر بهینه ابرپارامترها، برای تشخیص آپنه خواب از ECG پیشنهاد می‌گردد. پیشنهادهای آتی این پژوهش شامل گسترش و تنوع بخشی به داده‌ها، به‌ویژه ترکیب سیگنال ECG با سایر سیگنال‌های فیزیولوژیکی مانند EEG و SpO2، برای افزایش دقت و تعمیم‌پذیری مدل‌ها است. بررسی الگوریتم‌های پیشرفته بهینه‌سازی هوش جمعی مانند الگوریتم ازدحام ذرات و ترکیب چند بهینه‌ساز و استفاده از معماری‌های نوین یادگیری عمیق نظیر Vision Transformers می‌تواند عملکرد مدل‌ها را ارتقا دهد. همچنین، آزمایش مدل‌ها در شرایط واقعی و طراحی سیستم‌های بلندرنج برای دستگاه‌های پوشیدنی از اولویت‌های آینده خواهد بود.

شکل (۵): VGG19- LSTM



شکل (۶): VGG19- BiLSTM



شکل (۷): ZFNET- BiLSTM

همچنین مقایسه نتایج ارائه شده در سایر تحقیقات [۱] با این پژوهش نشان می‌دهد که نسخه اصلاح شده الگوریتم بهینه‌سازی گورکن عسل (MHBA) عملکرد بهتری نسبت به روش‌های سنتی مبتنی بر شبکه‌های CNN دارد. MHBA نسبت به HBA و GWO عملکرد بهتری دارد؛ زیرا اگرچه دقت آن ۹۱٪ است که با بهترین مدل‌های HBA (۹۵٪) و GWO (۹۳٪) رقابت می‌کند، اما در سایر شاخص‌ها مانند حساسیت و تشخیص‌پذیری عملکرد بهتری نشان داده است.

الگوریتم پیشنهادی MHBA می‌تواند در بهینه‌سازی معماری CNN مؤثرتر باشد، به‌ویژه به دلیل استفاده از سه استراتژی بهبود یافته (یادگیری شبه مخالف، رهبر نخبه و جهش تطبیقی) که باعث افزایش دقت و تعمیم‌پذیری مدل شده است.

## ۶- نتیجه‌گیری

پیشرفت‌های چشمگیر در حوزه یادگیری عمیق، فرصت طلایی برای پایش خواب و شناسایی دقیق و بلندرنج بیماری‌های مرتبط با آن فراهم کرده است. این فناوری‌ها با هدف نظارت پیشرفته و تشخیص سریع مورد استفاده قرار می‌گیرند.

### سیاس‌گذاری

بدین‌وسیله از گروه مهندسی کامپیوتر و فناوری اطلاعات دانشگاه قم که در این زمینه حمایت و همکاری لازم را با نویسندگان مقاله داشته‌اند تشکر و قدردانی می‌شود.

بهینه‌سازی مصرف انرژی مدل‌ها برای کاربردهای قابل‌حمل، استفاده از روش‌های تفسیرپذیری برای افزایش اعتماد کاربران و مطالعات بالینی روی جمعیت‌های متنوع از دیگر مسیرهای پیشنهادی است. درنهایت، ادغام مدل‌ها با سیستم‌های اینترنت اشیا (IoMT) می‌تواند بستر مناسبی برای پایش هوشمند سلامت فراهم کند.

### References

- [1] A. K. Abasi, M. Aloqaily, and M. Guizani, "Optimization of CNN using modified honey badger algorithm for sleep apnea detection," *Expert Syst. Appl.*, vol. 229, p. 120484, 2023.
- [2] S. Ahmadzadeh, J. Luo, and R. Wiffen, "Review on biomedical sensors, technologies and algorithms for diagnosis of sleep disordered breathing: Comprehensive survey," *IEEE Rev. Biomed. Eng.*, vol. 15, pp. 4–22, 2020.
- [3] S. Akyol, M. Yildirim, and B. Alatas, "Multi-feature fusion and improved BO and IGWO metaheuristics based models for automatically diagnosing the sleep disorders from sleep sounds," *Comput. Biol. Med.*, vol. 157, p. 106768, 2023.
- [4] N. F. Alharbi and N. Hewahi, "Exploring deep neural network capability for intrusion detection using different mobile phones platforms," *Int. J. Comput. Digit. Syst.*, 2021.
- [5] A. A. Awad, A. F. Ali, and T. Gaber, "An improved long short term memory network for intrusion detection," *PLoS One*, vol. 18, no. 8, p. e0284795, 2023.
- [6] M. Bahrami and M. Forouzanfar, "Sleep apnea detection from single-lead ECG: A comprehensive analysis of machine learning and deep learning algorithms," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1–11, 2022.
- [7] A. Bhusal, A. Alsadoon, P. W. C. Prasad, N. Alsalamy, and T. A. Rashid, "Deep learning for sleep stages classification: modified rectified linear unit activation function and modified orthogonal weight initialisation," *Multimed. Tools Appl.*, vol. 81, no. 7, pp. 9855–9874, 2022.
- [8] J. H. Che, B. W.-K. Ling, Q. Liu, and Q. Miao, "Variational mode decomposition-based sleep stage classification using multi-channel polysomnograms," *Signal Image Video Process.*, vol. 17, no. 4, pp. 1355–1363, 2023.
- [9] L. Chen, X. Zhang, and C. Song, "An automatic screening approach for obstructive sleep apnea diagnosis based on single-lead electrocardiogram," *IEEE Trans. Autom. Sci. Eng.*, vol. 12, no. 1, pp. 106–115, 2014.
- [10] A. Darwish, D. Ezzat, and A. E. Hassanien, "An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis," *Swarm Evol. Comput.*, vol. 52, p. 100616, 2020.
- [11] M. R. Falahzadeh, F. Farokhi, A. Harimi, and R. Sabbaghi-Nadooshan, "Deep convolutional neural network and gray wolf optimization algorithm for speech emotion recognition," *Circ. Syst. Signal Process.*, vol. 42, no. 1, pp. 449–492, 2023.
- [12] M. Hafezi et al., "Sleep apnea severity estimation from tracheal movements using a deep learning model," *IEEE Access*, vol. 8, pp. 22641–22649, 2020.
- [13] P. Hamilton, "Open source ECG analysis," in *\*Comput. Cardiol.*, pp. 101–104, IEEE, 2002.
- [14] U. Hanif et al., "Estimation of apneahypopnea index using deep learning on 3-D craniofacial scans," *IEEE J. Biomed. Health Inform.*, vol. 25, no. 11, pp. 4185–4194, 2021.
- [15] I. Jabłoński, R. Morello, and J. Mroczka, "The complexity and variability mapping for prediction and explainability of the sleep apnea syndrome," *IEEE Sens. J.*, vol. 21, no. 13, pp. 14203–14212, 2021.
- [16] J. L. Kelly et al., "Diagnosis of sleep apnoea using a mandibular monitor and machine learning analysis: one-night agreement compared to in-home polysomnography," *Front. Neurosci.*, vol. 16, p. 726880, 2022.

- [17] H. Korkalainen et al., "Accurate deep learning-based sleep staging in a clinical population with suspected obstructive sleep apnea," *IEEE J. Biomed. Health Inform.*, vol. 24, no. 7, pp. 2073–2081, 2019.
- [18] H. Korkalainen et al., "Detailed assessment of sleep architecture with deep learning and shorter epoch-to-epoch duration reveals sleep fragmentation of patients with obstructive sleep apnea," *IEEE J. Biomed. Health Inform.*, vol. 25, no. 7, pp. 2567–2574, 2020.
- [19] G. Kouziokas, \*Swarm Intelligence and Evolutionary Computation: Theory, Advances and Applications in Machine Learning and Deep Learning\*. CRC Press, 2023.
- [20] M. Leo, G. M. Bernava, P. Carcagnì, and C. Distantè, "Video-based automatic baby motion analysis for early neurological disorder diagnosis: state of the art and future directions," *Sensors*, vol. 22, no. 3, p. 866, 2022.
- [21] N. Limbu et al., "A novel solution of deep learning for sleep apnea detection: enhancement of SC and elimination of GVICS," *Multimed. Tools Appl.*, vol. 81, no. 27, pp. 38569–38592, 2022.
- [22] H. W. Loh et al., "Automated detection of cyclic alternating pattern and classification of sleep stages using deep neural network," *Appl. Intell.*, vol. 52, no. 3, pp. 2903–2917, 2022.
- [23] S. N. Makhadmeh et al., "Recent advances in grey wolf optimizer, its versions and applications," *IEEE Access*, 2023.

# Optimization of Hyperparameters in Hybrid Deep Learning Models for Sleep Apnea Detection Using Swarm Intelligence Algorithms

Faranak Fotouhi-Ghazvini<sup>1\*</sup>, Maryam Badiee<sup>2</sup>

<sup>1</sup>Assistant Professor Department of Computer Engineering and IT, University of Qom, Qom, Iran

<sup>2</sup>M.Sc Student Department of Computer Engineering and IT, University of Qom, Qom, Iran

## Article Information

### Original Research Paper

Received:  
2025 January 9

Accepted:  
2025 February 15

Keywords:  
Sleep Apnea, HoneyBadger Optimizer, GreyWolf Optimizer, Convolutional Neural Network, Deep Recurrent Neural Network

Corresponding Author\*:  
F-Fotouhi@qom.ac.ir

## Abstract

This study investigates the efficiency of CNN-DRNN hybrid classifiers in detecting sleep apnea using electrocardiogram (ECG) signals. Various CNN models were evaluated, including AlexNet, VGG16, VGG19, and ZFNet, along with DRNN models such as LSTM, GRU, and BiLSTM. These models were compared with and without the application of swarm intelligence optimizers, namely the Honey Badger Algorithm (HBA) and Grey Wolf Optimizer (GWO), for optimizing hyperparameter values. The results demonstrated that the AlexNet-GRU hybrid model achieved the best performance after applying both optimizers, with an accuracy of 95%, a detection rate of 97.61%, and an F-Score of 93.37%. This research also explores the challenges of hyperparameter optimization in deep learning models using swarm intelligence-based optimizers. These optimizers, inspired by natural behaviors, facilitate problem-solving through intelligent distribution, indirect interactions among agents, and simplification of complex processes. Additionally, the findings revealed that HBA outperformed GWO in determining optimal hyperparameter values, leading to enhanced model performance. Overall, the study highlights the potential of integrating deep learning models with swarm intelligence optimizers to improve sleep apnea detection.

doi : 10.22034/ ABMIR.2025.22637.1087

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.22637.1087) /© 2024. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

