Development of a New Adaptive Method Based on Empirical Fourier Decomposition for the Diagnosis of Obstructive Sleep Apnea Using Electrocardiogram Signal Analysis

Masoumeh Pourezzat¹, Peyvand Ghaderyan^{2*}, Hamed Danandeh Hesar³

¹ M.Sc. Student, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran, E-mails: masoumehpourezzat@gmail.com ^{2*} Associate Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran, E-mails: p_ghaderyan@sut.ac.ir ³ Assistant Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran, E-mails: danandeh@sut.ac.ir

Short Abstract

Obstructive sleep apnea (OSA) is a common sleep-related breathing disorder that can have significant negative effects on people's quality of life and daily functioning. Currently, polysomnography is the gold standard for diagnosing sleep apnea which cannot provide the expectations of a fast and economical diagnosis by analyzing several signals simultaneously. In this regard, the development of automatic, reliable and cost-effective diagnosis algorithms is important. Therefore, in this study, with the aim of diagnosing obstructive sleep apnea events, an automatic diagnostic algorithm based on single-lead Electrocardiogram (ECG) signal has been proposed. For this purpose, a new adaptive method based on Empirical Fourier Decomposition (EFD) and extraction of statistical and fractal dimension features from the Fourier Intrinsic Band Functions (FIBF) of the signal along with the ReliefF feature selection algorithm and Random Forest classification has been used. Empirical Fourier Decomposition can be a new tool for signal decomposition, which can provide a suitable capability in extracting oscillations related to non-stationary components of the signal. In order to evaluate the proposed algorithm is able to detect obstructive sleep apnea events with %88.03 accuracy, %83.44 sensitivity, and %90.84 specificity. The high accuracy of the obtained results along with the number of suitable features indicates a compromise between the accuracy and the number of extracted features, which leads to a suitable computational load for the proposed algorithm, which makes it possible to use it in clinical applications.

Keywords

Obstructive sleep apnea (OSA), Electrocardiogram (ECG) signal, Empirical Fourier Decomposition (EFD).

Short Introduction

Sleep apnea is a sleep-related breathing disorder characterized by repeated pauses in breathing for at least 10 seconds during sleep. The most common type of sleep apnea is known as obstructive sleep apnea, which occurs due to physical obstruction of the upper airway. Currently, polysomnography is the gold standard for diagnosing sleep apnea, which is based on the simultaneous recording of different physiological variables during sleep. Polysomnography requires expensive hospital equipment and technical expertise to interpret different physiological data, which makes it very expensive, complex and time-consuming. The evaluation of ECG signals during sleep, considering the effect of respiratory changes in the morphology of the ECG signal, as well as the effect of changes in the autonomic nervous system activity caused by apnea events on the heart rate, can enable the reliable diagnosis of sleep-related breathing disorders.

Proposed Work and Methodology

In this proposed algorithm, the Empirical Fourier Decomposition method is used to decomposition the ECG signal and then a combination of statistical and fractal dimension features of Fourier Intrinsic Band Functions obtained from this decomposition have been extracted. Finally, the ReliefF algorithm was used to select the effective features and Random Forest classifier was used for the classification. In order to evaluate the proposed algorithm, the Apnea-ECG database which contains 70 recordings of single-channel ECG signals, has been used. The results have shown that the proposed algorithm is able to detect obstructive sleep apnea events with %88.03 accuracy, %83.44 sensitivity, and %90.84 specificity.

Conclusion

Obstructive sleep apnea syndrome is associated with a wide range of physical and cognitive disorders that can affect a person's personal and social life. Due to the time-consuming and expensive screening system that exists to diagnose this disease, most cases of this disease are not diagnosed. Therefore in this research, in order to solve these problems, an automatic detection algorithm based on the decomposition of the electrocardiogram signal by the Empirical Fourier Decomposition method has been used. The use of all the data in the database along with the suitable results obtained shows the provision of an effective method with high generalizability, which makes it possible to use it in clinical applications.

References

W. Zhou, Z. Feng, Y. Xu, X. Wang, and H. Lv, "Empirical Fourier decomposition: An accurate signal decomposition method for nonlinear and non-stationary time series analysis," Mechanical Systems and Signal Processing, vol. 163, p. 108155, 2022.
 W. Zhou, Z. Feng, X. Wang, and H. Lv, "Empirical fourier decomposition," arXiv preprint arXiv:1912.00414, 2019.

توسعه یک روش تطبیقی جدید بر پایه تجزیه فوریه تجربی برای تشخیص آپنه خواب انسدادی به کمک تحلیل سیگنال الکتروکاردیوگرام

معصومه پورعزت

دانشجوی کارشناسی ارشد، گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

پیوند قادریان دانشیار، گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

حامد داننده حصار

استادیار، گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

چکیدہ

آپنه خواب انسدادی یک اختلال شایع تنفسی در حین خواب است که میتواند عواقب منفی قابل توجهی بر کیفیت زندگی و عملکرد روزانه افراد داشته باشد. در حال حاضر، پلیسومنوگرافی استاندارد اصلی تشخیص آپنه خواب است که نمیتواند انتظارات یک تشخیص سریع و اقتصادی را با تحلیل چندین سیگنال بهصورت همزمان تأمین کند. در این راستا توسعه الگوریتم های تشخیصی خودکار، قابل اعتماد و مقرون بهصرفه حائز اهمیت است. ازاین رو در این مطالعه، باهدف تشخیص رویدادهای آپنه خواب انسدادی، یک الگوریتم تشخیصی خودکار بر اساس تحلیل تک لید سیگنال الکتروکار دیوگرام ارائه شده است. بدین منظور از یک روش تطبیقی جدید مبتنی بر تجزیه فوریه تجربی و استخراج ویژگیهای آماری و بعد فر کتال از توابع باند ذاتی فوریه سیگنال به همراه الگوریتم انتخاب ویژگی Palieff و طبقه بند جدید مبتنی بر تجزیه فوریه تجربی و استخراج ویژگیهای آماری و بعد فر کتال از توابع باند ذاتی فوریه سیگنال به همراه الگوریتم انتخاب ویژگی Palieff و طبقه بند جدید مبتنی بر تجزیه فوریه تجربی و استخراج ویژگیهای آماری و بعد فر کتال از توابع باند ذاتی فوریه سیگنال به همراه الگوریتم انتخاب ویژگی Palieff و طبقه بند جنگل تصادفی استفاده شده است. روش تجزیه فوریه تجربی میتواند به عنوان یک ابزار جدید تجزیه سیگنال قابلیت مناسبی در استخراج نوسانات مرتبط با اجزای غیر ایستای سیگنال ارائه دهد. در این مطالعه جهت بررسی قدرت تشخیص روش پیشنهادی از پایگاه داده Apnea-ECG که شامل ۷۰ ثبت از سیگنال الکتروکاردیوگرام تک کانال میباشد، استفاده شده است. نتایج حاصل نشان داده است که الگوریتم پیشنهادی قادر به تشخیص رویدادهای آینه خواب انسدادی با مقادیر صحت ۸۸/۲/، حساسیت ۲۰/۸۹/او اختصاصیت ۸/۱۹۰۶/ میباشد. صحت بالای نتایج به دستآمده به همراه تعداد ویژگیهای مناس نشان دهنده مصالحه بین دقت و تعداد ویژگیهای استخراجشده میباشد که منجر به بار محاساتی مناسب الگوریتم پیشنهادی میگردد که استفاده آن را در کاربردهای کلینیکی ممکن مقادیر صحت ۸/۸/۲۰ حساسیت ۲۰/۸۹/۱۰ و اختصاصیت ۲۰/۹۱/۹۰ میباست مناسب الگوریتم پیشنهادی میگردد که استفاده آن را در کاربردهای کلینیکی ممکن

كلمات كليدي

آپنه خواب انسدادي، سيگنال الكتروكارديوگرام، تجزيه فوريه تجربي.

نام نویسنده مسئول: پیوند قادریان ایمیل نویسنده مسئول: p_ghaderyan@sut.ac.ir

> تاریخ ارسال مقاله: ۱۴۰۱/۰۹/۳۰ تاریخ(های) اصلاح مقاله: ۱۴۰۱/۱۲/۰۸ تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۰۱

۱– مقدمه

خواب يک حالت عصبي پيچيده است که وظيفه اصلي آن فراهم کردن استراحت و بازیابی سطح انرژی بدن است [۱]. اختلال در ساختار منظم خواب با کاهش عملکردهای شناختی و رفتاری، افسردگی، مشکلات حافظه و بیماریهای قلبی-عروقی مرتبط است [۲, ۳]. ازاینرو، بیماریهای مربوط به خواب در کیفیت زندگی بیماران اثرگذار بوده، بهنحویکه نارضایتی از مشکلات مربوط به خواب بعد از مشکلات ناشی از درد، بهعنوان دومین عامل در مراجعه به جامعه پزشکی گزارش شده است [۴]. در این میان، آپنه خواب انسدادی بهعنوان شایعترین اختلال تنفسى مرتبط با خواب شناخته مى شود كه به دليل انسداد فيزيكى راه هوایی فوقانی اتفاق میافتد و کاهش یا توقف کامل جریان هوا را در طول خواب به مدت حداقل ده ثانیه در پی دارد [۵, ۶]. علیرغم بهبود استانداردهای تشخیص آپنه خواب، همچنان غربالگری گسترده جمعیت انسانی برای تشخیص این بیماری با محدودیتهایی روبهرو است که مانع از تشخیص همه بیماران می گردد [۴]. پلی سومنو گرافی استاندارد اصلی تشخیص آپنه خواب است که مبتنی بر ضبط همزمان متغیرهای مختلف فیزیولوژیکی در طول خواب است. نیاز به تجهیزات بیمارستانی گرانقیمت و زیرساختهای تخصصی مانند کلینیکهای تخصصی خواب و همچنین نیازمندی به منابع انسانی متخصص برای تفسیر دادههای متعدد فیزیولوژیکی، پلیسومنوگرافی را به روشی بسیار پرهزینه، پیچیده و وقت گیر تبدیل کرده است [۷, ۸]. بهعلاوه، بیماران باید در طول شب موقعیت خاصی را با سیمهای متعدد و سنسورهای متصل به بدن خود حفظ کنند که ممکن است شرایط یک خواب منظم شبانه را در زندگی واقعی آنها منعکس نکند [۹].

در سالهای اخیر، استفاده از حسگرهای پوشیدنی و فناوریهای مربوط به حسگرهای بی سیم برای نظارت بر شرایط سلامتی به طور فزاینده ای افزایش یافته است که می تواند یک بازخورد اطلاعاتی زمان واقعی را در مورد وضعیت سلامتی فرد فراهم کند. بنابراین، تلاش زیادی صرف توسعه روشهای سادهتر جهت استفاده مناسب تر از دستگاه پلی سومنو گرافی برای بهبود کارایی و کاهش هزینههای تشخیص آپنه خواب شده است [۱۰]. با توجه به اینکه هدف نهایی توسعه این روشها، تولید یک دستگاه نظارت بر آپنه خواب قابل حمل، پوشیدنی و کممصرف برای مراقبت در منزل میباشد، استفاده از حداقل تعداد کانالهای پلی سومنو گرافی برای کاهش بار محاسباتی الگوریتم مهم است [۱۱]. در طول تلاش تنفسی تغییر حجم هوا در ریهها منجر به تغییر توزیع امپدانس قفسه سينه مي گردد كه با تغيير مكان نسبي الكترود نسبت به قلب همراه است كه بر مورفولوژی سیگنال الکتروکاردیوگرام تأثیر می گذارد [۱۲]. علاوه بر این هنگامی که یک رویداد آینه رخ میدهد، سطح اکسیژن خون شروع به کاهش میکند و سیستم قلبی-تنفسی سعی میکند این تغییر را بهصورت کامل در ضربان قلب بهعنوان بازتابی از فعالیت سمپاتیک و پاراسمپاتیک جبران کند [۱۳]. بنابراین ارزيابى سيگنالهاى الكتروكارديوگرام شبانه مىتواند امكان تشخيص مؤثر رویدادهای تنفسی آپنه را در طول خواب فراهم کند.

تاکنون مطالعات متعددی برای تشخیص رویدادهای آپنه خواب انسدادی بر اساس سیگنال الکتروکاردیوگرام و مشتقات آن با استفاده از روشهای یادگیری ماشین انجام شده است که این روشها را میتوان بهطورکلی به چهار دسته ٔ تحلیل در حوزه زمان، تحلیل در حوزه فرکانس، تحلیل در حوزه زمان و فرکانس و تحلیل در حوزه تجزیه سیگنال تقسیم کرد. تحلیلهای حوزه زمان و حوزه فرکانس روشهای کلاسیک پردازش سیگنال هستند که در آنها متغیرهای زمان و فرکانس بهصورت مجزا بررسی میگردند. تحلیلهای حوزه

زمانبر اساس چگونگی تغییرات سیگنال در طول زمان و تحلیلهای حوزه فرکانس بر اساس بررسی میزان تغییر در مقادیر طیفی سیگنال صورت می گیرند [۱۴]. در تعداد مطالعات اندکی از تشخیص به کمک سیگنال الکتروکاردیوگرام به تنهایی در حوزه زمان و حوزه فرکانس استفاده شده است که این مطالعات شامل استخراج ویژگیهای غیرخطی مانند پارامترهای نگاشت پوانکاره [۱۵] و پارامترهای تحلیل کمی بازگشتی [۱۶, ۱۷] در حوزه زمان و استخراج ویژگی های آماری از طیف فرکانسی [۱۲] و ویژگیهای چگالی طیف توان [۱۲, ۱۸] در حوزه فرکانس هستند. در گروهی از مطالعات نیز از هر دودسته تحلیلهای حوزه زمان و حوزه فرکانس استفاده شده است که در این مطالعات عموماً ویژگی های آماری استخراجشده در حوزه زمان در کنار ویژگیهای چگالی طیف توان مورداستفاده قرار گرفته است [۱۹-۲۱]. در نقطه مقابل این روشها، تحلیلهای حوزه زمان-فرکانس سیگنال را بهطور همزمان در هر دو حوزه زمان و فرکانس بررسی میکنند [۱۴]. در این دسته از مطالعات از روشهای زمانی-فرکانسی چون تبدیل موجک گسسته (۹, ۲۲] و تبدیل موجک Q قابل تنظیم [۲۳-۲۵] استفاده شده است. تحليلهاي حوزه تجزيه، يک سيگنال ورودي غيرخطي و غیرایستا را به مؤلفه های معنی دار آن تجزیه می کنند [۱۴]. در تعداد مطالعات اندکی از این تحلیلها استفاده شده است که این مطالعات شامل روشهای تجزیه حالت تجربی [۲۶] و روش تجزیه فوریه (۲۷] است.

سیگنالهای الکتروکاردیوگرام دارای ماهیت غیرایستا و غیرخطی میباشند که دشواری تجزیهوتحلیل و پردازش این دادهها را افزایش میدهد [۲۸]. اغلب تحلیلهای حوزه زمان و حوزه فرکانس دارای محدودیت در تحلیل سیگنالهای غیرایستا به دلیل در نظر گرفتن شرط ایستایی سیگنال میباشند و معمولاً ویژگیهای سطح پایین را از یک سیگنال استخراج میکنند [۱۴]. بنابراین، تحليل سيگنالهاي الكتروكارديوگرام با استفاده ازاينروشها ممكن است نتواند ماهیت واقعی این سیگنالها را نشان دهد. تحلیلهای حوزه تجزیه ابزاری مؤثر برای کمک به استخراج مشخصههای پنهان و الگوهای معنی دار از سیگنال های غیرخطی و غیرایستا میباشند و بر اساس سه فرض مهم توسعه یافتهاند: ۱) ايجاد تعادل بين اطلاعات زماني و اطلاعات فركانسي سيگنال به دليل اصل عدم قطعیت هایزنبرگ، ۲) تجزیه سیگنال بدون در نظر گرفتن هیچ فرضی در مورد محتوا یا ترکیب سیگنال و ۳) تلاش برای تحلیل کارآمد سیگنال در زمان واقعی [۱۴]. بنابراین، با توجه به مطالب ذکرشده به نظر می سد که این روشها قابلیت کاربرد بر روی سیگنالهای الکتروکاردیوگرام برای تشخیص رویدادهای تنفسی آپنه انسدادی را داشته باشند. ازاینرو، در الگوریتم پیشنهادی برای نخستین بار از روش تجزیه فوریه تجربی^۲ بهمنظور تشخیص آپنه خواب انسدادی به کمک تحليل سيگنال الكتروكارديو گرام استفاده شده است. بررسي اثربخشي اين روش بر روی سیگنال های غیرایستا و غیرخطی نشان داده است که این روش میتواند نتایج تجزیه دقیقی را برای سیگنالهای غیرایستای چندحالته و سیگنالهایی که حالتهای نزدیک به هم دارند، ارائه دهد [۲۹]. همچنین این روش یک روش مقاوم به نویز، بهویژه در فرکانسهای نزدیک به هم و نویزهای فرکانس بالا است [۳۰]. ازاینرو، در این مطالعه از قابلیتهای ذکرشده برای این روش جهت تجزيه سيگنال الكتروكارديوگرام و انتخاب اجزاي مفيد سيگنال كه مرتبط با وقایع آپنه خواب انسدادی میباشد، استفاده شده است. سپس در ادامه ۲ دسته ویژگی آماری و غیرخطی جهت کمی سازی تغییرات آماری و همچنین پیچیدگی و خود شباهتی توابع باند ذاتی فوریه ^۳ استخراج گردیده است. درنهایت برای انتخاب ویژگیهای مؤثر از الگوریتم ReliefF استفاده گردیده و عملیات تصمیم گیری نهایی به کمک طبقهبند جنگل تصادفی اجرایی شده است.

¹ Fourier Decomposition Method (FDM)

^r Empirical Fourier Decomposition (EFD)

^{*} Fourier intrinsic band function (FIBF)

روند این مقاله در معرفی روش پیشنهادی بهصورت زیر قابل بیان می باشد: در بخش دوم مواد و روش تحقیق که شامل معرفی پایگاه داده و سیستم توسعه یافته برای تشخیص آپنه خواب انسدادی به کمک روش تجزیه فوریه تجربی است، شرح داده شدهاند، در بخش سوم نتایج شبیهسازی الگوریتم پیشنهادی گزارش شده و با سایر مطالعات مورد مقایسه قرار گرفته و در بخش چهارم نتیجه گیری حاصل از تحقیق ارائه شده است.

۲- مواد و روشها

در شکل ۱ بلوک دیاگرام روش پیشنهادی نشان داده شده است که شامل مراحل پیش پردازش، استخراج ویژگیهای آماری و بعد فرکتال از توابع باند ذاتی فوریه حاصل از روش تجزیه فوریه تجربی، انتخاب ویژگی با استفاده از الگوریتم ReliefF و طبقهبندی به کمک روش جنگل تصادفی میباشد. در ادامه، این مراحل به همراه پایگاه داده مورد استفاده با ذکر جزئیات بیان شدهاند.

۲-۱- یایگاه داده

در این پژوهش پایگاه داده Apnea-ECG بهمنظور ارزیابی کارایی الگوریتم پیشنهادی در تشخیص رویدادهای آپنه خواب انسدادی مورد استفاده قرار گرفته

است. این پایگاه داده توسط دکتر توماس پنزل از دانشگاه فیلیپس در شهر ماربورگ آلمان تهیه شده است و شامل ۷۰ ثبت تک لید از سیگنال الکتروکاردیوگرام میباشد که با استفاده از الکترود مرجع ۷2 ثبت شده است. مدت زمان سیگنالهای ثبتشده بین ۵۷۸–۴۰۱ دقیقه متغیر است و این سیگنالها در فرکانس ۱۰۰ هرتز نمونهبرداری شدهاند. داوطلبان موردبررسیموردبررسی در این پایگاه داده دارای محدوده سنی ۳۳–۲۷ سال و بین ۵/۳۱–۰۰ متغیر است. در این پایگاه داده برچسبگذاری برای هر یک دقیقه از سیگنال الکتروکاردیوگرام انجام شده است که نشاندهنده وجود یا عدم وجود آپنه در طول آن یک دقیقه میباشد. این برچسبها توسط یک متخصص و بر اساس دادههای پلی سومنوگرافی تهیه شده است. این پایگاه داده درمجموع شامل ۳۴۲۴۳ دقیقه سیگنال الکتروکاردیوگرام است که از این تعداد درمجموع شامل ۳۴۲۴۳ دقیقه سیگنال الکتروکاردیوگرام است که از این تعداد درمجموع دقیقه نرمال و ۲۰۰۶۲ دقیقه آپنه میباشد. [۳۲, ۳۲].



شکل ۱- بلوک دیاگرام الگوریتم پیشنهادی برای تشخیص رویدادهای آپنه انسدادی

شماره پیاپی ۱۰۵

همچنین بر اساس تعداد دقایق صرفشده یک ثبت با تنفس آپنه، سه گروه در این پایگاه داده تعریف شده است [۳۱]:

- گروه نرمال: ثبتهایی که کمتر از ۵ دقیقه تنفس آپنه داشتند، در گروه نرمال قرار گرفتند. ۲۰ ثبت در این گروه قرار گرفتند. داوطلبان این گروه شامل ۶ مرد و ۵ زن با میانگین سنی ۳۳ سال (۲۲ -۲۲ سال) بودند.
- ۲) گروه آپنه: ثبتهایی که ۱۰۰ دقیقه یا بیشتر تنفس آپنه داشتند، در گروه آپنه قرار گرفتند.۴۰ ثبت در این دسته بودند که هرکدام بین ۱۰۰ تا ۵۳۴ دقیقه تنفس آپنه داشتند. داوطلبان این گروه شامل ۱۵ مرد و ۱زن با میانگین سنی ۵۰ (۲۹–۶۳ سال) بودند.
- ۳) گروه مرزی: ثبتهایی که بین ۱۰ تا ۹۶ دقیقه تنفس آپنه داشتند، در گروه مرزی قرار گرفتند. ۱۰ ثبت در این گروه قرار گرفتند و اعضای این گروه، هم شامل داوطلبان سالم و هم شامل داوطلبان بیمار بودند. داوطلبان این گروه شامل ۴ مرد و ۱زن با میانگین سنی ۴۶ سال (۳۹–۵۳ سال) بودند.

۲-۲- پیشپردازش

مرحله پیش پردازش از دو قسمت تشکیل شده است. در قسمت اول پیش پردازش، ابتدا از یک فیلتر میان گذر باترورث مرتبه ۳ با فرکانس های قطع ۸/۰ و ۴۸ هرتز برای حذف نویز برق شهر و نویز انحراف خط زمینه سیگنال الکتروکار دیوگرام استفاده شده است. سپس سیگنال الکتروکار دیوگرام به پنجره های یک دقیقهای تقسیم بندی شده است. (۳۳]. در قسمت دوم پیش پردازش، از یک الگوریتم خودکار برای حذف پنجره های نویزی استفاده شده است. این الگوریتم خودکار که مبتنی بر خوشه بندی ضربان های سیگنال الکتروکار دیوگرام بر اساس ضریب همبستگی پیرسون می باشد، شامل مراحل زیر است (۳۳

- ۱- پیکهای R با استفاده از الگوریتم پنتامپکینز تشخیص داده می شوند.
- ۲- ضربان های سیگنال الکتروکار دیوگرام، با اضافه کردن ۳۰ نمونه به قبل از
 پیک R و ۵۰ نمونه به بعد از پیک R شناسایی می شوند [۳۶].
- ۳- ضربانها بر اساس ضریب همبستگی پیرسون، با استفاده از الگوریتم DBSCAN خوشهبندی شده و ضربانهای نویزی شناسایی میشوند. در این مطالعه، مقادیر دو پارامتر Eps و Minpts در الگوریتم خوشهبندی به ترتیب برابر ۰/۰۶ و ۲ در نظر گرفته شده است.
- ۴- نسبت تعداد ضربان های نویزی به تعداد کل ضربان ها محاسبه می گردد و اگر مقدار این آستانه بزرگتر از ۰/۱ باشد، آن پنجره حذف خواهد شد.

۲-۳- استخراج ویژگی

در این بخش ابتدا سیگنال الکتروکاردیوگرام توسط روش تجزیه فوریه تجربی به توابع باند ذاتی فوریه تجزیه گردیده و سپس ویژگیهای بعد فرکتال و آماری از این توابع باند ذاتی استخراج شدهاند.

تجزيه فوريه تجربى

تجزیه فوریه تجربی یک روش تجزیه تطبیقی میباشد که بر اساس روش های تبدیل موجک تجربی و روش تجزیه فوریه توسعه یافته است [۳۰]. تبدیل موجک تجربی یک الگوریتم تبدیل موجک تطبیقی میباشد که ابتدا از یک روش تقسیمبندی تطبیقی مبتنی بر ماکزیمم یا مینیمم محلی برای بخشبندی طیف فوریه استفاده میکند. سپس این الگوریتم، یک بانک فیلتر موجک را بر اساس بخشهای طیف فوریه ایجاد میکند. در تبدیل موجک تجربی، فازهای گذار بین توابع فیلتر در یک بانک فیلتر موجک وجود دارد که میتواند منجر به

مشکل اختلاط حالت برای سیگنالهایی که حالتهای نزدیک به هم دارند، شود. روش تجزیه فوریه نیز یک روش تطبیقی میباشد که یک سیگنال میانگین صفر را به مجموعهای از توابع باند ذاتی فوریه، بر اساس نظریه فوریه و تبدیل هیلبرت تجزیه میکند. هرچند، محدودیتهایی برای روش تجزیه فوریه شناسایی شده است. ازجمله اینکه برای بهدست آوردن یک تابع باند ذاتی فوریه، دو روش اسکن فرکانس توسعه داده شده است که نتایج تجزیه توسط این دو روش اسکن فرکانس ممکن است متناقض باشد و نمی توان تعیین کرد که کدام نتايج تجزيه صحيح است. علاوه بر اين، دو روش اسكن فركانس، هر دو داراى الگوریتمهای تکرارشونده هستند و به زمانهای محاسباتی طولانی برای بهدست آوردن توابع باند ذاتی نیاز دارند. ازاینرو اخیراً، تجزیه فوریه تجربی که یک روش تجزیه سیگنال تطبیقی است، برای حل مسائل ذکرشده پیشنهاد شده است. روش پیشنهادی، یک روش تقسیمبندی بهبودیافته طیف فوریه و یک بانک فیلتر فاز صفر را ترکیب میکند. روش تقسیمبندی، مشکل متناقص بودن نتایج در روش تجزیه فوریه را با از پیش تعریف کردن تعداد مؤلفههای سیگنالی که باید تجزیه شود، حل می کند. بانک فیلتر فاز صفر، هیچ فاز گذاری ندارد. بنابراین، می تواند مشکل اختلاط حالت را در روش تبدیل موجک تجربی حل کند [۲۹]. در این روش، طیف فوریه سیگنالی که باید تجزیه شود، بر روی یک محدوده فرکانسی نرمال شده [$-\pi,\pi$] تعریف می شود [۳۷]. در ادامه، روش تقسیم بندی بهبودیافته و ساخت یک بانک فیلتر فاز صفر برای طیف فوریه یک سیگنال در محدوده فرکانسی [۰, π] توضیح داده شده است.

در روش تقسیم,بندی بهبودیافته محدوده فرکانسی $[\pi, \cdot]$ به N بخش فرکانسی پیوسته تقسیم می گردد و هر بخش بهصورت $[m_{n-1} \ w_n] = Sn$ با مقادیر [1, N] = n نشان داده می شود. در این فرآیند مقادیر طیف فوریه در $w = \pi$, w = 0 و نقاط ماکزیمم محلی شناسایی می گردند. این مقادیر بهصورت یک سری به ترتیب نزولی مرتب می شوند. فرکانس های مربوط به N عدد اولی که بزرگ ترین مقادیر را در سری مرتب شده دارند، با $[n_{\Omega_1}, \Omega_2, ..., \Omega_N]$ نشان داده می شوند. همچنین $0 = _0 \Omega$ و $\pi = _{1+N} \Omega$ در نظر گرفته می شود و سپس مرزهای هر بخش توسط رابطه زیر تعیین می گردند:

 $\omega_n = \begin{cases} argmin\check{X}_n(\omega) \text{ if } 0 \le n \le N \text{ and } \Omega_n \ne \Omega_{n+1} \\ \Omega_n \text{ if } 0 \le n \le N \text{ and } \Omega_n = \Omega_{n+1} \end{cases}$ (1)

که در آن (ω) $\tilde{X}_n(\omega)$ نشان دهنده مقادیر طیف فوریه بین n و $1_{n+\Omega}$ بوده و (.). (.) منان دهنده آرگومان مینیمم است [۳۷]. بانک فیلتر فاز صفر بر اساس بخشهای فرکانسی بهدست آمده توسط روش تقسیم بندی بهبودیافته ساخته می شود. در هر بخش فرکانسی، یک فیلتر فاز صفر، یک فیلتر میان گذر با فرکانسهای قطع n و $1_{n-\Omega}$ می باشد و فازهای گذار ندارد. از این رو، فیلتر فاز صفر مؤلفه اصلی طیف فوریه را در هر بخش حفظ می کند و سایر مؤلفههای طیف فوریه را که فراتر از بخش می باشد، حذف می کند [۳۷]. تبدیل فوریه یک سیگنال (f(t) که باید تجزیه شود، به صورت زیر بیان می شود [۳۷].

$$\hat{f}(\omega) = \int_{-\infty} f(t)e^{-j\omega t}dt$$
(Y)

$$\hat{\mu}_n(\omega) = \begin{cases} 0 & \text{otherwise} \\ 0 & \text{otherwise} \end{cases}$$

$$(T)$$

که در آن N ≤ N ≥ 1 و مقادیر w_n با معادله (۱) تعیین میشوند. سیگنالهای فیلترشده با (µ(m)، توسط رابطه زیر محاسبه میشوند [۳۷]:

$$\widehat{f_n}(\omega) = \widehat{\mu}_n(\omega)\widehat{f}(\omega) = \begin{cases} \widehat{f}(\omega) & \text{if } \omega_{n-1} \le |\omega| \le \omega_n \\ 0 & \text{otherwise} \end{cases}$$
(*)

توابع باند ذاتی فوریه یا مؤلفههای تجزیه شده در حوزه زمان را میتوان با استفاده از تبدیل فوریه معکوس بهدست آورد [۳۷]:

$$f_n(t) = F^{-1}[\tilde{f}_n(\omega)] \tag{(\Delta)}$$

$$L_{m}(k) = \frac{1}{k} \left\{ \left(\sum_{i=1}^{\left\lfloor \frac{N-m}{k} \right\rfloor} |x(m+ik) - x(m+(i-1)k)| \right) \times \frac{N-1}{\left\lfloor \frac{N-m}{k} \right\rfloor \cdot k} \right\}$$
(Y)

 $m = L_m(k)$ میانگین طول منحنی برای هر k، بهعنوان مقدار متوسط $L_m(k)$ برای -۳ kmax محاسبه می شود و این محاسبه برای مقادیر k از ۲ تا k تکرار می گردد.

$$L(k) = \frac{1}{k} \sum_{m=1}^{k} \left(L_m(k) \right) \tag{A}$$

۴- آرایهای از مقادیر (L(k) تشکیل میشود و نمودار (ln(L(k)) در مقابل n(1/k) رسم می گردد. شیب خط حداقل مربعات خطی که بهترین تطبیق را با این نمودار داشته باشد، بهعنوان بعد فرکتال تعیین می شود.

روش دومی که در این مطالعه برای محاسبه بعد فرکتال مورد استفاده قرار گرفته است، روش کاتز است که برای یک سری زمانی طبق رابطه زیر محاسبه می گردد [۴۳]:

$$D = \frac{\log_{10}(L)}{\log_{10}(d)}$$
(9)

که در آن L طول کل سری زمانی و b فاصله اقلیدسی بین اولین نقطه و دورترین نقطه در سری زمانی میباشد. عبارت فوق را میتوان با مقدار a نرمال کرد، که a میانگین فاصله بین نقاط متوالی است. معادله اصلاحشده بالا توسط رابطه زیر بیان می گردد:

$$D = \frac{\log_{10}(\frac{L}{a})}{\log_{10}(\frac{d}{a})} \tag{(1)}$$

با در نظر گرفتن $\frac{L}{a} = n$ که n تعداد گامها در سری زمانی میباشد، میتوان معادله نهایی بعد فرکتال کاتز را بهصورت زیر نوشت:

$$D = \frac{\log_{10}(n)}{\log_{10}(n) + \log_{10}(\frac{d}{L})}$$
(11)

الگوریتم پتروسین روش دیگری برای محاسبه بعد فرکتال است که جهت افزایش سرعت محاسبات، از یک دنباله باینری استفاده می کند. چندین الگوریتم مختلف برای محاسبه بعد فرکتال پتروسین وجود دارد. این الگوریتمها، اساساً در نحوه ایجاد دنباله باینری متفاوت هستند. در این پژوهش، از الگوریتم پتروسین C استفاده شده است. در این الگوریتم، نمونههای متوالی در سری زمانی از یکدیگر کم می شوند و یک دنباله باینری بر اساس نتیجه تفریق ایجاد می شود. برای هر نتیجه مثبت یا منفی یک 1+ یا 1- به ترتیب اختصاص داده می شود و بعد فرکتال طبق رابطه زیر محاسبه می گردد [۳]:

$$D = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left(\frac{n}{n + 0.4N_{\Delta}}\right)}$$
(17)

که در آن n طول کل دنباله و N_{Δ} تعداد تغییرات علامت در دنباله باینری است. علاوه بر ویژگیهای غیرخطی بعد فرکتال، در مطالعه حاضر جهت کمی سازی نحوه توزیع توابع باند ذاتی فوریه از تعدادی ویژگی آماری نیز استفاده شده است که در ادامه معرفی میگردند.

ویژگیهای آماری

در این قسمت، چهار ویژگی آماری میانگین انحراف مطلق، دامنه بین چارکی، ضریب شکل و ضریب کرست مورد استفاده قرار گرفته است. میانگین انحراف مطلق و دامنه بین چارکی دو معیار آماری هستند که اطلاعات مفیدی را در مورد پراکندگی نمونه ها در سیگنال ارائه میدهند. میانگین انحراف مطلق، میانگین مطلق فاصله بین هر نمونه و میانگین تعداد کل نمونه ها را در سیگنال محاسبه میکند. در مورد سیگنال های واقعی که متحمل خطا در فرآیند $\int_{-\omega_n}^{-\omega_{n-1}} \hat{f}(\omega)e^{j\omega t} d\omega + \int_{\omega_{n-1}}^{\omega_n} \hat{f}(\omega)e^{j\omega t} d\omega$ در این پژوهش مقدار ۶=۸ در نظر گرفته شده و ویژگیها از توابع باند ذاتی فوریه ۱ تا ۶ استخراج گردیدهاند. در شکل ۲ تجزیه یک سیگنال ۱۰ ثانیهای نرمال و آپنه توسط این روش تجزیه به ۶ تابع باند ذاتی نشان داده شده است. همانگونه که از این شکل مشخص است تفاوتهایی در نحوه توزیع ضرایب و شکل آنها در زیر باندهای مختلف افراد سالم و بیمار قابل مشاهده است.



شکل ۲- اعمال روش تجزیه فوریه تجربی بر روی سیگنال الکتروکاردیوگرام. (الف): سیگنال الکتروکاردیوگرام آپنه به همراه توابع باند ذاتی فوریه، (ب): سیگنال الکتروکاردیوگرام نرمال به همراه توابع باند ذاتی فوریه

ویژگیهای بعد فرکتال

یک فراکتال را میتوان بهعنوان الگوهای خود متشابهی در نظر گرفت که در هر مقیاسی که سیگنال در آن تحلیل میشود، تکرار میشوند [۳۸]. بنابراین، خودشباهتی و پیچیدگی سیگنالهای غیرایستا مانند الکتروکاردیوگرام را میتوان با استفاده از شاخص بعد فراکتال اندازه گیری کرد. از سوی دیگر ابعاد فراکتال، مستقیماً در حوزه زمان یا حوزه اصلی سیگنال محاسبه میگردند. ازاینرو، این ویژگیها نسبت به ویژگیهای غیرخطی مانند بعد همبستگی و نمای لیاپانوف که برای محاسبه نیاز به بازسازی فضای فاز دارند، ترجیح داده میشوند [۳۹. ۴۰]. الگوریتمهای زیادی برای محاسبه بعد فرکتال در دسترس هستند که در این پژوهش روشهای هیگوچی، کاتز و پتروسین مورد استفاده قرار گرفتهاند.

اگر (x(1),x(2),x(3)...,x(N) یک سیگنال گسسته با N نمونه باشد، بعد فراکتال هیگوچی طی مراحل زیر از آن استخراج میگردد [۴۱, ۴۲]: ۱- ابتدا سریهای زمانی خودمتشابه ^k

$$x_k^m: x(m), x(m+k), \dots, x(m+\left[\frac{N-m}{k}\right], k)$$
(\mathcal{F})

در رابطه بالا m زمان اولیه و دارای مقادیر 1, ..., k میباشد. k نیز بیانگر گام زمانی و دارای مقادیر 1, ..., kmax میباشد. kmax یک پارامتر دلخواه است. در این الگوریتم پیشنهادی مقدار kmax برابر ۶ در نظر گرفته شده است. ۲- طول هر منحنی x_k^m طبق رابطه زیر محاسبه می گردد: كرد [۵۳]. مراحل ساخت طبقهبند جنگل تصادفي را ميتوان بهصورت زير بيان

روند یادگیری طبقهبند جنگل تصادفی با ساختن هر درخت آغاز می شود.

۲) مرحله بعد ایجاد یک زیرمجموعه آموزشی تصادفی برای هر درخت می

بسیاری از روشهای درختسازی مانند کارت، C4.5 ،J48 و ... وجود

دارند. در این الگوریتم پیشنهادی، از الگوریتم کارت برای ایجاد درختان

باشد. این زیرمجموعه آموزشی که مجموعه داده درون کیسه نامیده می

شود، با نمونهبرداری از تقریباً دوسوم مجموعه داده آموزشی اولیه با

استفاده از روش بوت استرپینگ^[†] (نمونهبرداری با جایگزینی) تشکیل می شود و اندازه آن برابر مجموعه داده آموزشی اولیه است. مجموعه داده آموزشی باقیمانده که مجموعه داده خارج از کیسه نامیده می شود، می تواند برای محاسبه خطای طبقهبندی و کالیبره کردن عملکرد هر درخت

۳) سپس برای هر درخت تعدادی ویژگی تصادفی انتخاب میشود و برای ساخت گرهها و برگهای درخت مورد استفاده قرار میگیرد. معمولاً جذر تعداد کل ویژگیها بهعنوان تعداد ویژگی بهینه انتخاب شده در نظر گرفته میشود. این انتخاب تصادفی ویژگیها دقت طبقهبندی را افزایش و

حساسیت به نویز در دادهها را کاهش میدهد. همچنین همبستگی بین

های آموزشی به زیرمجموعهها بر اساس ویژگی انتخاب شده میباشد.

الگوریتم کارت برای پیدا کردن این ویژگی از شاخص جینی^۵ استفاده می

کند و یک ویژگی با کمترین مقدار شاخص جینی در گره ریشه قرار می

گیرد. در هر گره t، شاخص جینی G(t) به صورت زیر محاسبه می شود

 $G(t) = 1 - \sum_{k=1}^{\infty} p^2(k|t)$

۴) مرحله بعد شامل انتخاب یک ویژگی در گره ریشه و سپس تقسیم داده

کرد [۵۴ ,۵۲]:

استفاده شده است.

استفاده شود.

:[24]

(17)

اندازه گیری میباشند، این ویژگی، معیار پراکندگی بهتری نسبت به انحراف معیار ارائه میدهد. دامنه بین چارکی تفاوت میان چارک اول و سوم سیگنال را محاسبه میکند. این ویژگی نسبت به تأثیر نمونههای پرت مصونتر است. ازاینرو، بهعنوان یک ویژگی متمایزکننده بین موارد آپنه و نرمال برای از بین بردن اثر نمونههای پرت که ممکن است به دلیل انحرافات زیاد در سیگنالهای الکتروکاردیوگرام وجود داشته باشند، مفید خواهد بود [۲۲, ۴۴]. ضریب کرست از تقسیم بیشینه سیگنال بر جذر میانگین مربعات سیگنال حاصل میگردد. ضریب شکل نیز از تقسیم جذر میانگین مربعات سیگنال بر میانگین مقادیر مطلق سیگنال محاسبه میشود [۴۵]. برای یک سیگنال بر میانگین مقادیر این ویژگیها طبق روابط زیر محاسبه میگردند [۴۶, ۴۶] :

$$MAD = \frac{1}{N} \sum_{i=1}^{N} \left| x_i - \frac{1}{N} \sum_{i=1}^{N} x_i \right|$$
(17)

$$IQR = Q3 - Q1 \tag{14}$$

$$Crest Factor = \frac{MM(|x_i|)}{\sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}}$$
(1Δ)

Shape Factor =
$$\frac{\sqrt{\frac{1}{N}\sum_{i=1}^{N}x_i^2}}{\frac{1}{N}\sum_{i=1}^{N}|x_i|}$$
(19)

۲-۴- انتخاب ویژگی

رویکردهای انتخاب ویژگی در یادگیری ماشین برای انتخاب زیرمجموعهای از ویژگیهای مرتبط از میان مجموعهای از ویژگیهای اصلی استفاده میشوند. آنها بعد ویژگی را کاهش میدهند، درنتیجه پیچیدگی سیستم و زمان پردازش را کاهش میدهند [۴۸, ۴۸]. در این مطالعه، بهمنظور انتخاب ویژگیهای با قدرت تفكيك بالاتر از الگوريتم ReliefF استفاده گرديده است. الگوريتم ReliefF به دلیل سادگی و عدم پیچیدگی، مقاومت در برابر نویز و استحکام در تشخیص ویژگیهای مؤثر حتی زمانی که ویژگیها بهشدت به یکدیگر وابسته هستند، یکی از موفق ترین روش های انتخاب ویژگی در نظر گرفته می شود [۴۹]. این الگوریتم اهمیت هر ویژگی را بر اساس وزنی که به آن اختصاص میدهد، مشخص مىسازد. عملكرد اين الگوريتم بدين صورت است كه ابتدا تعدادى نمونه تصادفی را انتخاب میکند و سپس برای هر نمونه انتخاب شده، K همسایه نزدیک از کلاس مشابه نمونه انتخاب شده و K همسایه نزدیک از سایر کلاسها را پیدا میکند. سپس از یک تابع ارزیابی برای محاسبه وزن هر ویژگی استفاده می کند. این تابع اختلاف بین نمونه های انتخاب شده و همسایه های نزدیک آن را محاسبه مىكند. بدين ترتيب اختلاف كمتر بين نمونه انتخاب شده و همسایه های نزدیک از کلاس مشابه منجر به افزایش و اختلاف کمتر بین نمونه انتخاب شده و همسایه های نزدیک از سایر کلاس ها منجر به کاهش وزن ویژگی می گردد. درنهایت این الگوریتم فهرستی از وزنهای محاسبه شده برای ویژگیها را ارائه میدهد و ویژگیهای با وزن بیشتر برای طبقهبندی مورد استفاده قرار می گیرند [۵۰].

۲-۵- طبقهبندی

در این مرحله ویژگیها با استفاده از الگوریتم جنگل تصادفی طبقهبندی شدهاند. طبقهبند جنگل تصادفی اولین بار توسط بریمن در سال ۲۰۰۱ پیشنهاد شده است [۵1]. این طبقهبند شامل بسیاری از درختهای طبقهبندی منفرد است که در آن خروجی طبقهبندی کلی با انتخاب بیشترین آرا از خروجی طبقهبندی همه درختان تعیین میشود [۲۲]. ازجمله مزایای استفاده از این طبقهبند میتوان به مقاومت در برابر بیشبرازش، توانایی کار مؤثر با مجموعه دادههای بزرگ، سرعتبالا، مقاومت در برابر نویز و عدم نیاز به نرمالسازی اشاره

شاخه و ویژگیهای باقیمانده میرسد، تکرار میشود. انتخاب ویژگی بعدی نیز

ویژگیها را به حداقل میرساند.

بر اساس کمترین مقدار شاخص جینی حاصل از ویژگیهای باقیمانده انجام میشود. هر گره شاخه تا زمانی رشد پیدا میکند که زیرمجموعهای که به آن میرسد، فقط شامل اعضای یک کلاس باشد.

که در آن، Q ,..., q احتمالات تخمین زده شده k = 1, 2, ..., Q احتمالات تخمین زده شده

برای هر کلاس k می باشد. این فرآیند با استفاده از زیر مجموعه ای که به هر گره

- ۵) این فرآیند برای ساختن و آموزش همه درختان تکرار می شود.
- ۶) خروجی طبقهبند کلی برای نمونههای آزمایشی با رأی گیری از خروجی همه درختان تعیین می شود.

در این پژوهش، تعداد درختان برابر ۹۰ و تعداد ویژگیهای تصادفی برابر جذر تعداد کل ویژگیها در نظر گرفته شده است. همچنین به منظور ارزیابی روش پیشنهادی در این مطالعه طبقهبندی دادهها به دو صورت دقیقه به دقیقه و فرد به فرد انجام شده است. در طبقهبندی دقیقه به دقیقه، روش اعتبارسنجی متقابل IO-Fold مورد استفاده قرار گرفته است. در طبقهبندی فرد به فرد، از روش اعتبارسنجی Leave-One-Out استفاده شده است و سپس AHI مربوط به این افراد با استفاده از برچسبهای پیشبینی شده برای سیگنالهای یک دقیقه ای محاسبه شده است. AHI تعداد رویدادهای تنفسی آپنه و هایپوآپنه را در هر ساعت خواب مشخص میکند و طبق رابطه زیر محاسبه می شود [۲].

$$AHI = \frac{Number of (Apnea + Hyponea)}{Total sleep time(in minutes)} \times 60$$
(1Å)

ازآنجاییکه در این پایگاه داده برچسبگذاری برای هر یک دقیقه از سیگنال انجام شده است و همچنین تمایزی بین دقیقههای آپنه و هایپوآپنه ایجاد نشده است و دقیقههای هایپوآپنه نیز بهعنوان آپنه برچسب خوردهاند، بنابراین این فرمول به شکل زیر تغییر مییابد (۲, ۳۳]:

$$AHI = \frac{Number \ of \ Apnea \ segments}{Total \ sleep \ time(in \ minutes)} \times 60 \tag{19}$$

پس از محاسبه شاخص AHI، برچسبهای این افراد با توجه به جدول ۱ که توسط آکادمی پزشکی خواب آمریکا تنظیم شده است، تعیین گردیده است. سپس این برچسبهای پیشبینیشده با برچسبهای واقعی این

افراد مقایسه شده و بدین ترتیب، پارامترهای ارزیابی برای طبقهبندی محاسبه شده است (۷, ۵۵].

جدول ۱- برچسب گذاری افراد پایگاه داده بر اساس AHI [۷].

AHI	كلاس	برچسب
<i>AHI</i> < 5	فرد سالم	0
$AHI \geq 5$	فرد بيمار	1

جدول ۲- عملکرد طبقهبندی دقیقه به دقیقه توسط ویژگیهای استخراج شده از توابع باند ذاتی بدون استفاده از الگوریتم انتخاب ویژگی ReliefF

اختصاصيت (٪)	حساسيت (٪)	صحت (./)	تعداد ويژگي	نوع ویژگی
٨٩/٠٣ 干٠/٠٠۵٩	۲۴/۹۶ ∓۰/۰۰۹۹	٨٣/۶٨ ∓۰/۰۰۴۸	۲۴	آمارى
メ۹/۲۵ 干・/・・۹۵	∀٩/٩١ ∓۰/۰۱۰۴	$A\Delta/99 \mp \cdot / \cdot \cdot Y1$	١٨	بعد فركتال
۹۰/۷۸ Ŧ۰/۰۰۴۴	λ٣/٧٢ ∓・/・۱ ۱・	۸۸/۰۹ Ŧ۰/۰۰۶۸	47	آماری + بعد فرکتال

جدول ۳- عملكرد طبقهبندى دقيقه به دقيقه توسط ويژگىهاى استخراج شده از توابع باند ذاتى با استفاده از الگوريتم انتخاب ويژگى ReliefF

اختصاصيت (٪)	حساسيت (٪)	صحت (./`)	ویژگیها
۸۶/۸ •	۶۸/۹۴	٨٠	۲۰٪ ویژگیهای برتر
۲۹/۶۹	۲۹/۹۱	٨۵/٩٧	۴۰٪ ویژگیهای برتر
٩٠/٨۴	٨٣/۴۴	٨٨/٠٣	۶۰٪ ویژگیهای برتر
۹ • /۷۵	٨٣/٣٠	٨٧/٩٣	۸۰٪ ویژگیهای برتر
٩٠/٧٨	٨٣/٧٢	٨٨/٠٩	۱۰۰٪ ویژگیها

۳- یافتهها و بحث

در الگوریتم پیشنهادی مجموعهای از ویژگیهای آماری و بعد فرکتال در حوزه تجزیه سیگنال باهدف تشخیص رویدادهای آپنه خواب مورد استفاده قرار گرفته است که این ویژگیها از توابع باند ذاتی فوریه حاصل از تجزیه سریهای زمانی مختلف مربوط به افراد بیمار و سالم استخراج شدهاند. در این تحقیق به منظور بررسی کارایی الگوریتم پیشنهادی در تشخیص رویدادهای آپنه پارامترهای صحت، حساسیت و اختصاصیت موردمطالعه قرار گرفته است که این معیارها طبق روابط زیر محاسبه می گردند:

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \times 100$$
 (Y ·)

$$Sensitivity = \frac{IP}{TP + FN} \times 100$$
 (71)

$$Specificity = \frac{TN}{TN + FP} \times 100$$
 (Y.)

که در این روابط T P تعداد نمونههایی که بهدرستی بیمار، T N تعداد نمونههایی که بهدرستی سالم، F P تعداد نمونههایی که به اشتباه بیمار و F N تعداد نمونههایی است که به اشتباه سالم تشخیص داده شدهاند.

نتایج طبقهبندی دقیقه به دقیقه با استفاده از ویژگیهای استخراج شده از توابع باند ذاتی فوریه بدون استفاده از الگوریتم انتخاب ویژگی ReliefF در جدول ۲ ارائه شده است. همانگونه که در این جدول مشاهده می گردد، نتایج در سه حالت موردبررسیموردبررسی قرار گرفتهاند. در حالت اول فقط ویژگیهای بعد

فرکتال، در حالت دوم فقط ویژگیهای آماری و در حالت سوم ترکیب این ویژگیها برای طبقهبندی مورد استفاده قرار گرفته است. نتایج بهدست آمده نشان میدهد که هنگامیکه از ویژگیهای بعد فرکتال استفاده شده است، صحت بالاتری نسبت به هنگامیکه از ویژگیهای آماری استفاده شده است، حاصل گردیده است. این صحت بالاتر را میتوان مرتبط با این موضوع دانست که با توجه به ماهیت غیرخطی سیگنال الکتروکاردیوگرام، ابعاد فرکتال میتوانند با بررسی میزان پیچیدگی و خودشباهتی این سیگنال، به آشکارسازی ماهیت غیرخطی آن کمک بیشتری کنند. همچنین نتایج حاصل نشان میدهد که ترکیب ویژگیهای آماری و بعد فرکتال منجر به افزایش صحت تشخیص شده با مقادیر میانگین و انحراف معیار ۲۹/۰۰۶۸، ۲۰۱۰/۲۷/۲۰۱۱ م با مقادیر میانگین و انحراف معیار داده است.

در ادامه ارزیابی الگوریتم پیشنهادی، نتایج طبقهبندی دقیقه به دقیقه با استفاده از الگوریتم انتخاب ویژگی Relieff موردبررسی قرار گرفته است و نتایج آن در جدول ۳ گزارش شده است. همان گونه که در این جدول مشاهده می گردد، نتایج طبقهبندی با استفاده از ۶۰٪ ویژگیهای رتبهبندی شده (تعداد ۲۵ ویژگی) توسط الگوریتم Relieff، مشابه نتایج طبقهبندی با استفاده از تمام ویژگیها میباشد که این نشاندهنده اهمیت بیشتر ۶۰ درصد از ویژگیها است که در کم نمودن تعداد ویژگیهای استخراجی میتواند کمک نماید. همچنین در این حالت نتیجه طبقهبندی فرد به فرد مورد ارزیابی قرار گرفته است و

مقادیر پارامترهای صحت، حساسیت و اختصاصیت به ترتیب برابر ۸۴/۲۸٪، ۸۴/۷۸٪ و ۸۳/۳۳٪ حاصل شده است که در این روش اعتبارسنجی نیز نتایج به دستآمده گویای عملکرد مناسب روش پیشنهادی می اشد.

همچنین جهت بررسی ویژگیهای با قدرت تفکیک بالاتر ۲۵ ویژگی برتر که بیشترین دفعات تکرار را در اعتبارسنجی متقابل 10-Fol داشتهاند، در جدول ۴ ذکر گردیده و به منظور بررسی معنادار بودن نتایج نیز آزمون آماری ویلکاکسون جمعی رتبهای بر روی این ویژگیها اعمال شده است و مقادیر -q value مربوط به آنها گزارش شده است. همان گونه که نتایج مربوط به جدول نشان می دهد مقادیر value به دستآمده بیان گر معنادار بودن نتایج و قدرت تفکیک ویژگیهای استخراج شده می باشد. به منظور ارزیابی بهتر الگوریتم تشخیصی ارائه شده، در جدول ۵ نتایج طبقهبندی دقیقه به دقیقه حاصل از این مطالعه با تعدادی از مطالعات انجام ده بر روی این پایگاه داده مقایسه

شده است. همچنین از آنجایی که در اکثر مطالعات مورد مقایسه فقط از دادههای مربوط به ۳۵ فرد اول استفاده شده بود، نتایج حاصل از این الگوریتم بر روی این ۳۵ داده نیز گزارش شده است. هماانگونه که در این جدول مشاهده می گردد، بسیاری از مطالعات انجام شده دارای دقتهای تشخیص پایین تری نسبت به الگوریتم پیشنهادی ارائه شده می باشند. در مطالعات [۱۹] و [۲۳] که دارای دقتهای تشخیص بالاتری نسبت به این الگوریتم می باشند، تعداد ویژ گیهای بیشتری مورد استفاده قرار گرفته است. این مسئله نشان دهنده این است که روش پیشنهادی این مطالعه قادر است مصالحه بهتری بین دقت و تعداد ویژ گیهای استخراج شده که منجر به بار محاسباتی مناسب آن می شود، ارائه دهد.

p-value	زير باند	نوع ویژگی		
•/••۴	زیر باند ۱	ميانگين انحراف مطلق		
•/••٨	زیر باند ۶			
• / • • 1	زیر باند ۳	دامنه بین چارکی		
•/• \Y	زیر باند ۶			
•/••٢	زیر باند ۳			
٠/• ١٩	زیرباند ۴	ضريب شكل		
•/••٣	زیرباند ۵			
•/•٢٩	زيرباند ۶			
• / • • ٢	زیرباند ۱			
• ,• • •	زیرباند ۵	ضریب کرست		
٠/•۴١	زیرباند ۶			
•/•••	زیرباند ۱			
•/• 49	زیرباند ۲			
•/•• ١	زیرباند ۳	بعد فركتال هيگوچي		
• / • • •	زیرباند ۴			
• / • • •	زیرباند ۵			
•/•78	زيرباند ۶			
•/• ١٨	زیرباند ۲	بعد فركتال كاتز		
• / • • •	زیرباند ۶			
• / • • •	زیرباند ۱			
• / • • •	زیرباند ۲			
• / • ٣٣	زیرباند ۳	بعد فركتال پتروسين		
• / • • •	زیرباند ۴			
•/•••	زیرباند ۵			
۰/۰۱۴	زیرباند ۶	7		

جدول ۴-بررسی معنادار بودن نتایج ویژگیها با استفاده از آزمون آماری ویلکاکسون جمعی رتبهای

اختمام تخا			نوع طبقهبند	تعداد	نوع ویژگی	تعداد	مالة
الحنصاصيت	حساسيت	صحت		ویژگی		افراد	معاد
አ ፈ/ _ይ ለ	٨۶/٣٧	۸۵/۲۶	Soft Decision Fusion	۲۲	ویژگیهای مبتنی بر آنالیز کمی بازگشتی	۳۵	[18]
٨٨/۴	٧٩/۵	۸۳/۸	LS-SVM	۵	ویژگیهای آماری و ویژگیهای ضرایب بسط هرمیت	٧٠	[68]
٩٠/٧٢	۸۱/۹۹	۸۷/۳۳	Adaptive Boosting	۳۶	پارامترهای مدل گوسی معکوس استخراجشده از زیر باندهای تبدیل موجک Q قابل تنظیم	۳۵	[74]
۸۲/۷۹	٨۵/٢	٨٣/٧٧	ELM	۲۸	ویژگیهای آماری استخراجشده از توابع باند ذاتی حاصل از تجزیه حالت تجربی	۳۵	[79]
٨۵/٩۴	۶۸/۷۳	४१/४१	Majority Vote	۲۷	ویژگیهای آماری، غیرخطی، چگالی طیف توان، شاخص قلبی-عروقی و شاخص قلبی سمپاتیک	٧٠	[ΔΥ]
۷۵/۳۲	۲٩/۲۵	۷۷/۲۷	ELM	١٢	ویژگیهای انرژی و آنتروپی فازی استخراجشده از توابع باند ذاتی حاصل از روش تجزیه فوریه	۳۱	[77]
٩١/٨	አ ٩/۶	٩ • /٩	ANN	۸۵	ویژگیهای آماری، چگالی طیف توان، ضرایب همبستگی سریالی و فاکتورهای آلن فرکتال	٧٠	[19]
११/४१	AY/8A	۸ ۸/۸۸	RUSBoost	٨١	ویژگیهای آماری استخراجشده از زیر باندهای تبدیل موجک Q قابل تنظیم	۳۵	[77]
٨٢/١	٨٨/٩	٨۴/٧	Decision Fusion	-	مبتنی بر یادگیری ژرف	٧٠	[۵٨]
٨۴/۴	٨۶/٢	٨۵/١	TDCS	-	مبتنی بر یادگیری ژرف	٧٠	[۵٩]
۸۳/۸	٩٠	٨۶/٢٢	proposed model	-	مبتنی بر یادگیری ژرف	٧٠	[۶٠]
٩١/٧١	84/26	88/48	RF	٢۵	ویژگیهای آماری و غیرخطی استخراجشده از توابع باند ذاتی حاصل از تجزیه فوریه تجربی	۳۵	روش پیشنهادی
٩٠/٨۴	83/66	۸۸/۰۳	RF	۲۵	ویژگیهای آماری و غیرخطی استخراجشده از توابع باند ذاتی حاصل از تجزیه فوریه تجربی	٧٠	روش پیشنهادی

جدول ۵- مقایسه عملکرد الگوریتم پیشنهادی با سایر مطالعات انجام شده بر روی پایگاه داده مشترک

۴- نتیجهگیری

سندرم آپنه خواب انسدادی با طیف گستردهای از اختلالات جسمی و شناختی همراه است که می تواند در زندگی فردی و اجتماعی فرد اثر گذار باشد [۲, ۳]. امروزه روشهای مؤثری برای درمان این بیماری توسعه یافتهاند، اما بهدلیل سیستم غربالگری زمانبر و پرهزینهای که برای تشخیص این بیماری وجود دارد، اکثر موارد مبتلا به این بیماری تشخیص داده نمی شوند [۴, ۷, ۸]. از این رو، در تحقيق حاضر بهمنظور حل اين مشكلات از يك الگوريتم تشخيص خودكار که مبتنی بر روشهای یادگیری ماشین و سیگنال الکتروکاردیوگرام میباشد، برای تشخیص رویدادهای آپنه خواب انسدادی استفاده شده است. در الگوریتم پیشنهادی از ویژگیهای آماری و بعد فرکتال استخراج شده از توابع باند ذاتی فوريه حاصل از تجزيه سيگنال الكتروكارديوگرام توسط تجزيه فوريه تجربي به همراه الگوريتم انتخاب ويژگىReliefF و طبقهبند جنگل تصادفي براي تفكيك رویدادهای آپنه از نرمال استفاده شده است. نتایج کلی بهدست آمده از این تحقیق گویای کارایی روش پیشنهادی در تشخیص رویدادهای آپنه خواب انسدادی می باشد. استفاده از تمامی دادههای موجود در پایگاه داده به همراه نتايج مناسب بهدست آمده نشان از ارائه يک روش مؤثر با قابليت عموميت پذیری بالا دارد که کاربرد آن را برای استفاده کلینیکی مفید میسازد.

انجام کارهای تحقیقاتی همواره با محدودیتهایی همراه است که رفع این محدودیتها می تواند هدفی برای مطالعات آینده باشد. روش پیشنهادی در این مطالعه فقط در تشخیص آپنه خواب انسدادی کاربرد دارد، بنابراین مطالعات آینده می تواند بر تشخیص انواع مختلف آپنه از یکدیگر متمرکز باشد. همچنین بررسی تأثیر عوامل دموگرافیک در تشخیص آپنه خواب و استفاده از طبقهبندهای ترکیبی برای بهبود عملکرد روشهای تشخیص می تواند هدفی برای مطالعات آینده باشد.

مراجع

- V. M. Kumar, "Sleep and sleep disorders," *Indian Journal of Chest Diseases and Allied Sciences*, vol. 50, no. 1, p. 129, 2008.
- [2] T. Porkka-Heiskanen, K. M. Zitting, and H. K. Wigren, "Sleep, its regulation and possible mechanisms of sleep disturbances," *Acta physiologica*, vol. 208, no. 4, pp. 311-328, 2013.
- [3] R. Rohan, D. S. Kumar, and S. R. Patri, "Various methods for identification of obstructive sleep apnea using electrocardiogram features," *Journal of Scientific Research*, vol. 64, no. 1, 2020.
- [4] A. R. Hassan, "Automatic screening of obstructive sleep apnea from single-lead electrocardiogram," in 2015 international conference on electrical engineering and

- [24] A. R. Hassan, "Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting," Biomedical Signal Processing and Control, vol. 29, pp. 22-30, 2016.
- A. Nishad, R. B. Pachori, and U. R. Acharya, "Application of [25] TQWT based filter-bank for sleep apnea screening using ECG signals," Journal of Ambient Intelligence and Humanized Computing, pp. 1-12, 2018.
- A. R. Hassan and M. A. Haque, "Computer-aided obstructive [26] sleep apnea identification using statistical features in the EMD domain and extreme learning machine," Biomedical Physics & Engineering Express, vol. 2, no. 3, p. 035003, 2016.
- R. Tripathy, "Application of intrinsic band function technique [27] for automated detection of sleep apnea using HRV and EDR signals," Biocybernetics and Biomedical Engineering, vol. 38, no. 1, pp. 136-144, 2018.
- S. H. El-Khafif and M. A. El-Brawany, "Artificial neural [28] network-based automated ECG signal classifier." International Scholarly Research Notices, vol. 2013, 2013.
- [29] W. Zhou, Z. Feng, Y. Xu, X. Wang, and H. Lv, "Empirical Fourier decomposition: An accurate signal decomposition method for nonlinear and non-stationary time series analysis," Mechanical Systems and Signal Processing, vol. 163, p. 108155, 2022.
- [30] W. Zhou, Z. Feng, X. Wang, and H. Lv, "Empirical fourier decomposition," arXiv preprint arXiv:1912.00414, 2019.
- [31] T. Penzel, G. B. Moody, R. G. Mark, A. L. Goldberger, and J. H. Peter, "The apnea-ECG database," in Computers in Cardiology 2000. Vol. 27 (Cat. 00CH37163), 2000: IEEE, pp. 255-258.

[32] [33]

- https://physionet.org/content/apnea-ecg/1.0.0/. (accessed. A. Zarei and B. M. Asl, "Performance evaluation of the spectral autocorrelation function and autoregressive models for automated sleep apnea detection using single-lead ECG signal," Computer Methods and Programs in Biomedicine, vol. 195, p. 105626, 2020.
- [34] Y. Liu et al., "Diagnosis of AF based on time and frequency features by using a hierarchical classifier," in 2017 Computing in Cardiology (CinC), 2017: IEEE, pp. 1-4.
- [35] J. Li, I. Tobore, Y. Liu, A. Kandwal, L. Wang, and Z. Nie, "Non-invasive monitoring of three glucose ranges based on ECG by using DBSCAN-CNN," IEEE Journal of Biomedical and Health Informatics, vol. 25, no. 9, pp. 3340-3350, 2021.
- [36] C. S. Viswabhargav, R. Tripathy, and U. R. Acharya, "Automated detection of sleep apnea using sparse residual entropy features with various dictionaries extracted from heart rate and EDR signals," Computers in biology and medicine, vol. 108, pp. 20-30, 2019.
- [37] W. Zhou, Z. Feng, Y. Xu, X. Wang, and H. Lv, "Empirical Fourier Decomposition: An Accurate Adaptive Signal Decomposition Method," arXiv preprint arXiv:2009.08047, 2020.
- [38] M. Sharma and R. B. Pachori, "A novel approach to detect epileptic seizures using a combination of tunable-Q wavelet transform and fractal dimension," Journal of Mechanics in Medicine and Biology, vol. 17, no. 07, p. 1740003, 2017.
- [39] J. E. Jacob, G. K. Nair, A. Cherian, and T. Iype, "Application of fractal dimension for EEG based diagnosis of encephalopathy," Analog Integrated Circuits and Signal Processing, vol. 100, no. 2, pp. 429-436, 2019.
- [40] U. R. Acharya, E. C.-P. Chua, O. Faust, T.-C. Lim, and L. F. B. Lim, "Automated detection of sleep apnea from electrocardiogram signals using nonlinear parameters," Physiological measurement, vol. 32, no. 3, p. 287, 2011.
- [41] M. Bachmann, J. Lass, A. Suhhova, and H. Hinrikus, "Spectral asymmetry and Higuchi's fractal dimension depression electroencephalogram," measures of Computational and mathematical methods in medicine, vol. 2013, 2013.
- C. F. Vega and J. Noel, "Parameters analyzed of Higuchi's [42] fractal dimension for EEG brain signals," in 2015 Signal Processing Symposium (SPSympo), 2015: IEEE, pp. 1-5.
- [43] R. Esteller, G. Vachtsevanos, J. Echauz, and B. Lilt, "A comparison of fractal dimension algorithms using synthetic and experimental data," in 1999 IEEE International Symposium on Circuits and Systems (ISCAS), 1999, vol. 3: IEEE, pp. 199-202.
- [44] M. Bedeeuzzaman, T. Fathima, Y. U. Khan, and O. Farooq, "Seizure prediction using statistical dispersion measures of

information communication technology (ICEEICT), 2015: IEEE, pp. 1-6.

- J. Balcerzak, "Obstructive sleep apnea syndrome--the most [5] common sleep related breathing disorder," Otolaryngologia Polska= The Polish Otolaryngology, vol. 55, no. 5, pp. 483-487, 2001.
- H. Sharma and K. Sharma, "Sleep apnea detection from ECG [6] using variational mode decomposition," Biomedical Physics & Engineering Express, vol. 6, no. 1, p. 015026, 2020.
- A. Zarei and B. M. Asl, "Automatic classification of apnea [7] and normal subjects using new features extracted from HRV and ECG-derived respiration signals," Biomedical Signal Processing and Control, vol. 59, p. 101927, 2020.
- [8] B. Fatimah, P. Singh, A. Singhal, and R. B. Pachori, "Detection of apnea events from ECG segments using Fourier decomposition method," Biomedical Signal Processing and Control, vol. 61, p. 102005, 2020.
- V. P. Rachim, G. Li, and W.-Y. Chung, "Sleep apnea [9] classification using ECG-signal wavelet-PCA features," Biomedical materials and engineering, vol. 24, no. 6, pp. 2875-2882 2014
- [10] L. Chen, X. Zhang, and H. Wang, "An obstructive sleep apnea detection approach using kernel density classification based on single-lead electrocardiogram," Journal of medical systems, vol. 39, no. 5, pp. 1-11, 2015.
- [11] A. R. Hassan, "A comparative study of various classifiers for automated sleep apnea screening based on single-lead electrocardiogram," in 2015 International Conference on Electrical & Electronic Engineering (ICEEE), 2015: IEEE, pp. 45-48.
- [12] R. Atri and M. Mohebbi, "Obstructive sleep apnea detection using spectrum and bispectrum analysis of single-lead ECG signal," Physiological measurement, vol. 36, no. 9, p. 1963, 2015.
- [13] T. Penzel et al., "Modulations of heart rate, ECG, and cardiorespiratory coupling observed in polysomnography," Frontiers in physiology, vol. 7, p. 460, 2016.
- S. Krishnan and Y. Athavale, "Trends in biomedical signal feature extraction," *Biomedical Signal Processing and* [14] Control, vol. 43, pp. 41-63, 2018.
- S. Rezaei, S. Moharreri, N. J. Dabanloo, K. Maghooli, and S. [15] Parvanch, "Sleep Apnea Detection Using Multi-Lag Poincare Plot," in 2021 Computing in Cardiology (CinC), 2021, vol. 48: IEEE, pp. 1-4.
- [16] H. D. Nguyen, B. A. Wilkins, Q. Cheng, and B. A. Benjamin, "An online sleep apnea detection method based on recurrence quantification analysis," IEEE journal of biomedical and health informatics, vol. 18, no. 4, pp. 1285-1293, 2013.
- [17] C. Cheng, C. Kan, and H. Yang, "Heterogeneous recurrence analysis of heartbeat dynamics for the identification of sleep apnea events," Computers in biology and medicine, vol. 75, pp. 10-18, 2016.
- [18] S. Babaeizadeh, D. P. White, S. D. Pittman, and S. H. Zhou, "Automatic detection and quantification of sleep apnea using heart rate variability," Journal of electrocardiology, vol. 43, no. 6, pp. 535-541, 2010.
- P. Janbakhshi and M. Shamsollahi, "Sleep apnea detection [19] from single-lead ECG using features based on ECG-derived respiration (EDR) signals," Irbm, vol. 39, no. 3, pp. 206-218, 2018.
- [20] P. De Chazal, C. Heneghan, E. Sheridan, R. Reilly, P. Nolan, and M. O'Malley, "Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea," IEEE transactions on biomedical engineering, vol. 50, no. 6, pp. 686-696, 2003.
- C. Song, K. Liu, X. Zhang, L. Chen, and X. Xian, "An [21] obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals," IEEE Transactions on Biomedical Engineering, vol. 63, no. 7, pp. 1532-1542, 2015.
- A. Zarei and B. M. Asl, "Automatic detection of obstructive [22] sleep apnea using wavelet transform and entropy-based features from single-lead ECG signal," *IEEE journal of* biomedical and health informatics, vol. 23, no. 3, pp. 1011-1021.2018.
- A. R. Hassan and M. A. Haque, "An expert system for [23] automated identification of obstructive sleep apnea from single-lead ECG using random under sampling boosting," Neurocomputing, vol. 235, pp. 122-130, 2017.

- [53] C. Donos, M. Dümpelmann, and A. Schulze-Bonhage, "Early seizure detection algorithm based on intracranial EEG and random forest classification," *International journal of neural* systems, vol. 25, no. 05, p. 1550023, 2015.
- [54] C. Nguyen, Y. Wang, and H. N. Nguyen, "Random forest classifier combined with feature selection for breast cancer diagnosis and prognostic," 2013.
- [55] J. Kim, T. Kim, D. Lee, J.-W. Kim, and K. Lee, "Exploiting temporal and nonstationary features in breathing sound analysis for multiple obstructive sleep apnea severity classification," *Biomedical engineering online*, vol. 16, pp. 1-18, 2017.
- [56] H. Sharma and K. Sharma, "An algorithm for sleep apnea detection from single-lead ECG using Hermite basis functions," *Computers in biology and medicine*, vol. 77, pp. 116-124, 2016.
- [57] M. Bahrami and M. Forouzanfar, "Sleep apnea detection from single-lead ECG: a comprehensive analysis of machine learning and deep learning algorithms," *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-11, 2022.
- [58] K. Li, W. Pan, Y. Li, Q. Jiang, and G. Liu, "A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal," *Neurocomputing*, vol. 294, pp. 94-101, 2018.
- [59] K. Feng, H. Qin, S. Wu, W. Pan, and G. Liu, "A sleep apnea detection method based on unsupervised feature learning and single-lead electrocardiogram," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-12, 2020.
- Instrumentation and Measurement, vol. 70, pp. 1-12, 2020.
 S. A. Singh and S. Majumder, "A novel approach osa detection using single-lead ECG scalogram based on deep neural network," *Journal of Mechanics in Medicine and Biology*, vol. 19, no. 04, p. 1950026, 2019.

intracranial EEG," *Biomedical Signal Processing and Control*, vol. 10, pp. 338-341, 2014.

- [45] O. Yaman, F. Ertam, and T. Tuncer, "Automated Parkinson's disease recognition based on statistical pooling method using acoustic features," *Medical Hypotheses*, vol. 135, p. 109483, 2020.
- [46] N. Rafiuddin, Y. U. Khan, and O. Farooq, "Feature extraction and classification of EEG for automatic seizure detection," in 2011 International Conference on Multimedia, Signal Processing and Communication Technologies, 2011: IEEE, pp. 184-187.
- [47] J. Miao and L. Niu, "A survey on feature selection," *Procedia Computer Science*, vol. 91, pp. 919-926, 2016.
- [48] S. Khalid, T. Khalil, and S. Nasreen, "A survey of feature selection and feature extraction techniques in machine learning," in 2014 science and information conference, 2014: IEEE, pp. 372-378.
- [49] E. Pippa *et al.*, "Improving classification of epileptic and nonepileptic EEG events by feature selection," *Neurocomputing*, vol. 171, pp. 576-585, 2016.
- [50] J. Yang and R. Yan, "A multidimensional feature extraction and selection method for ECG arrhythmias classification," *IEEE Sensors Journal*, vol. 21, no. 13, pp. 14180-14190, 2020.
- [51] G. Biau, L. Devroye, and G. Lugosi, "Consistency of random forests and other averaging classifiers," *Journal of Machine Learning Research*, vol. 9, no. 9, 2008.
- [52] L. Fraiwan, K. Lweesy, N. Khasawneh, H. Wenz, and H. Dickhaus, "Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier," *Computer methods and programs in biomedicine*, vol. 108, no. 1, pp. 10-19, 2012.