



Research Paper

A Multimodal Convolutional Neural Networks (CNN) Approach for Prediction of Sudden Cardiac Death Versus Congestive Heart Failure

Sara Tavazo ¹, Farideh Ebrahimi ^{2*}

1. Master's Degree, Faculty of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Shariati Ave., Babol, Iran.

2. Assistant Professor of Electrical and Computer Engineering, Faculty of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Shariati Ave., Babol, Iran.

Use your device to scan
and read the article online**Citation** Tavazo S, Ebrahimi F. [A Multimodal Convolutional Neural Networks (CNN) Approach for Prediction of Sudden Cardiac Death Versus Congestive Heart Failure (Persian)]. Jundishapur Scientific Medical Journal. 2026; 24(6): 519-533.<https://doi.org/10.22118/jsmj.2025.515064.3885>**ABSTRACT****Background and Objectives** Sudden cardiac death (SCD) remains one of the leading causes of mortality worldwide. The purpose of this study is to predict SCD early and to distinguish it from congestive heart failure (CHF), which presents with similar electrocardiographic patterns.**Subjects and Methods** In this study, shallow and fully automated models based on convolutional neural networks (CNNs) are presented to predict SCD. In these models the electrocardiogram (ECG) signal is given as input to the model, and classification is performed at the output of the model.**Results** The first model, which is based on one-dimensional CNNs, could predict SCD with an accuracy of 96%. In the next step, by adding data related to CHF, an accuracy of 97.85 was obtained in the three-class classification (normal, before SCD, and CHF). In the second model, which is based on two-dimensional CNNs, first, each part of the ECG signals was converted into two-dimensional images using continuous wavelet transform (CWT) and given as input to the model. This model was able to predict SCD with 99% accuracy.**Conclusion** The proposed fully automated CNN-based models demonstrated high predictive accuracy for SCD within one hour before its occurrence.**Keywords** Electrocardiogram (ECG), Convolutional Neural Networks (CNNs), Sudden Cardiac Death (SCD), Congestive Heart Failure (CHF).

Received: 1 May 2025

Revised: 11 Nov 2025

Accepted: 19 Nov 2025

*** Corresponding Author:**

Farideh Ebrahimi

Address: Faculty of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Shariati Ave., Babol, Iran.

Tel: +981132332071

E-Mail: f.ebrahimi96@nit.ac.ir

Extended Abstract

Introduction

SCD is one of the main causes of death and a significant global health concern. It usually occurs suddenly and is triggered by arrhythmias, such as ventricular fibrillation (VF). SCD can be prevented and detected early, which can significantly enhance patient outcomes and reduce the strain on healthcare systems. In this study, we present a completely automatic and comprehensive three-class classification framework based on advanced deep learning methods of one-dimensional (1D) and two-dimensional (2D) CNNs. This work introduces a novel and powerful scheme for automated SCD, CHF, and normal classification of ECGs using both one-dimensional (1D) and two-dimensional (2D) CNNs. We extended the classification task to a three-class problem by introducing data from patients with congestive heart failure (CHF). The classes included normal, pre-SCD, and CHF. This modification aimed to investigate whether the models could differentiate between different types of cardiac abnormalities beyond SCD.

Methods

The ECG data for this investigation were acquired from public clinical databases. All recordings were annotated and segmented into uniform windows for training and assessment. This study presents two convolutional neural network (CNN) approaches — 1D-CNN and 2D-CNN — for the prediction of sudden cardiac death (SCD) and its differentiation from congestive heart failure (CHF).

In the first model, raw ECG signals were directly input into a 1D-CNN model. In the second approach, we transformed the ECG signals using continuous wavelet transform (CWT) into 2D time-frequency representations. These data were then fed into a 2D-CNN network. The improved performance of the 2D-CNN model highlights its effectiveness in extracting more informative features from ECG signals for accurate SCD predictions.

The intended architecture of the 1D-CNN model has multiple layers of convolutional kernel networks, has ReLU activations, and culminates at max pooling layers to perform dimensionality reduction and find more prominent features from the ECG signal over time. The last layers consist of flattening, fully connected dense layers, and the softmax output layer for multiclass prediction.

On the other hand, the 2D-CNN model was trained on images created from CWTs through a deeper architecture. Convolutional layers optimized their kernel sizes for medically sketched spectrograms and were joined with dropout and batch normalization to prevent overfitting and increase generalization. Both models were trained by cross-entropy loss, using the Adam optimizer, with learning rate tuning and early stopping employed against overtraining.

These results demonstrate the effectiveness of both CNN architectures in distinguishing between normal, pre-SCD, and CHF conditions, with the 2D-CNN model again outperforming the 1D-CNN. This could be due to the fact

that, in comparison to 1D CNNs, 2D CNNs, inspired by the human visual system, are better equipped to capture complex spatial features, and when combined with the Discrete Wavelet Transform (DWT), they further enhance the feature extraction by leveraging multi-resolution and multi-directional analysis.

To optimize computational performance and reduce the complexity of the models without sacrificing accuracy, we implemented architectural and hyperparameter optimizations on both of the CNN models. These results confirm the potential of the proposed method as a reliable tool for the early prediction of SCD and the stratification of cardiac risk. Such results make these models highly suitable for real-time or embedded healthcare monitoring systems.

An important advantage of the proposed framework is that it eliminates the need for manual feature extraction by automatically learning complex patterns directly from raw or transformed data, which, in turn, simplifies the analysis process.

Moreover, both the 1D-CNN and 2D-CNN models were designed with shallow architectures to balance performance and computational efficiency, making them suitable for real-time clinical applications or implementation on portable monitoring devices. Using CWT as a preprocessing step in the 2D-CNN pipeline allowed the extraction of meaningful time-frequency patterns associated with different cardiac states, further contributing to the model's better performance.

To validate our models, we used a publicly available ECG dataset containing annotated recordings of normal, pre-SCD, and CHF conditions. We applied standard data preprocessing procedures, including signal normalization and segmentation. For the 2D-CNN, CWT was applied using the Morlet wavelet function, and the data were resized to standard dimensions for the model input. We performed 10-fold cross-validation to ensure the statistical robustness of the reported metrics. Keeping in mind the importance of model generalizability, we have validated our best-performing models on a completely separate set of external ECG datasets, showing relatively consistent performance since the accuracy and precision of the models have only slightly decreased. This shows the strong robustness of the models across varied data sources and patient populations. Hence, it can be said that the trained CNN architectures not only learn patient-specific features but are also generalizable to broader clinical scenarios.

The results across all experiments showed that both CNN models were capable of distinguishing between cardiac conditions with high accuracy, sensitivity, and specificity. The success of this work highlights the applicability of deep learning to life-critical biomedical signal analysis.

In summary, this study presents a novel and efficient deep learning-based framework for predicting sudden cardiac death and classifying other related cardiac abnormalities using ECG signals. The integration of CWT with CNN models, particularly in the 2D-CNN architecture, significantly enhances the model's ability to learn discriminative features and improves classification performance. The proposed system offers a scalable and

accurate solution for real-time cardiac monitoring by automating the detection process and avoiding reliance on handcrafted features.

What makes this study particularly important is that it extends the prediction window for SCD to within 60 minutes of occurrence. This improvement is considerably more than what one study has ever reported. Early prediction of this time window permits the testing of clinical intervention strategies like administering medication, remote monitoring, or defibrillation, which may then save lives. Further, the differentiation between chronic heart failure (CHF) and SCD is highly pertinent clinically CHF patients frequently demonstrate similar ECG risk patterns to those observed in SCD, which can lead to misclassification and inappropriate treatment. This is where our proposed system comes in to address this challenge, rendering a valuable decision-support tool for clinicians.

Results

In the two-class classification (pre-SCD and normal), the 1D-CNN model achieved 96% accuracy, while the 2D-CNN achieved 99% accuracy. For the three-class task (normal, pre-SCD, and CHF), the 1D-CNN model achieved 97.85% accuracy, and the 2D-CNN model achieved 99% accuracy. After implementing architectural and hyperparameter optimizations, the improved models reached higher accuracy rates: 98.68% for two-class and 99.71% for three-class classification. The 2D-CNN consistently outperformed the 1D-CNN, likely due to its ability to capture complex spatial features and leverage multi-resolution analysis provided by the CWT. What makes this study particularly important is that it extends the prediction window for SCD to within 60 minutes of occurrence.

Conclusion

The integration of raw time-series analysis with time-frequency transformations permits a multi-faceted viewpoint of cardiac behavior, thus furthering classification performance. The accuracy that was obtained, particularly in the three-class scenario, showcases deep learning's capability of transforming cardiac risk assessment and patient monitoring.

The future work will engage in integrating other

biosignals, such as Heart Rate Variability (HRV) and Blood Pressure (BP), into a multimodal framework for enhancing prediction accuracy and reliability. Moreover, we will work on deploying our model in a real-time wearable environment to evaluate its performance in continuous cardiac monitoring settings. We shall also look into the use of explainable AI for model decisions and improve the transparency and interpretability of model decisions for better acceptance in clinical practice. Furthermore, using transfer learning and increasing patient populations could be performance improvement. Deployment of the models on embedded systems for real-time monitoring and alert generation is also a promising direction.

Our findings underscore the potential of deep learning as a transformative tool in preventive cardiology. With continued development, such systems can support clinicians in identifying at-risk patients, enabling timely intervention and ultimately saving lives.

Ethical Considerations

Compliance with ethical guidelines

The data used in this study are publicly available via PhysioNet (<https://physionet.org>).

Funding

This study received no financial support.

Author's contributions

Sara Tavazo (First Author): Study design, data preparation, data analysis, writing, and editing. Farideh Ebrahimi (Corresponding Author): Conceptualization, study design, data analysis, writing, and editing.

Conflicts of interest

The authors have no conflicts of interest to declare.

Acknowledgements

This study is the result of a Master's thesis (Thesis ID: 1219 conducted at Babol Noshirvani University of Technology. The authors would like to express their sincere gratitude to all the professors and staff of the university for their support.

مقاله پژوهشی

رویکرد چندوجهی شبکه‌های عصبی پیچشی برای پیش‌بینی مرگ ناگهانی قلبی و تمایز از نارسایی قلبی

سارا تواضع^۱، فریده ابراهیمی خاله‌سری^{۲*}

۱. کارشناسی ارشد گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران.
۲. استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران.

Use your device to scan and read the article online 	Citation Tavazo S, Ebrahimi F. [A Multimodal Convolutional Neural Networks (CNN) Approach for Prediction of Sudden Cardiac Death Versus Congestive Heart Failure (Persian)]. Jundishapur Scientific Medical Journal. 2026; 24(6): 519-533.  https://doi.org/10.22118/jsmj.2025.515064.3885
--	---

چکیده

زمینه و هدف: مرگ ناگهانی قلبی (SCD) همچنان یکی از علل اصلی مرگ‌ومیر در سراسر جهان است. هدف از این مطالعه پیش‌بینی زودهنگام SCD و تمایز آن از نارسایی احتقانی قلب (CHF) است که الگوهای الکتروکاردیوگرافی مشابهی دارد.

روش بررسی: در این مطالعه، مدل‌های کم‌عمق و کاملاً خودکار مبتنی بر شبکه‌های عصبی کانولوشن (CNN) برای پیش‌بینی SCD ارائه شده است، به‌طوری که سیگنال الکتروکاردیوگرام (ECG) به‌عنوان ورودی به مدل داده شده و طبقه‌بندی در انتهای مدل انجام شده است.

یافته‌ها: مدل اول، که مبتنی بر CNNهای یک‌بعدی بود، توانست SCD را با دقت ۹۶ درصد پیش‌بینی کند. در مرحله بعد، با اضافه کردن داده‌های مربوط به CHF، دقت ۹۷/۸۵ درصد در طبقه‌بندی سه‌کلاسه (عادی، قبل از مرگ ناگهانی قلبی و نارسایی قلبی) به دست آمد. در مدل دوم، که مبتنی بر CNNهای دوبعدی بود، ابتدا هر بخش از سیگنال‌های ECG با استفاده از تبدیل موجک پیوسته (CWT)، به تصاویر دوبعدی تبدیل و به‌عنوان ورودی به مدل داده شدند. این مدل توانست SCD را با دقت ۹۹ درصد پیش‌بینی کند.

نتیجه‌گیری: مدل‌های کاملاً خودکار مبتنی بر CNN پیشنهادی، دقت پیش‌بینی بالایی را برای SCD، در عرض یک ساعت قبل از وقوع آن، نشان دادند.

کلیدواژه‌ها: سیگنال الکتروکاردیوگرام (ECG)، شبکه‌های عصبی پیچشی (CNN)، مرگ ناگهانی قلبی (SCD)، نارسایی احتقانی قلب (CHF).



تاریخ دریافت: ۱۱ اردیبهشت ۱۴۰۴
دریافت اصلاحات: ۲۰ آبان ۱۴۰۴
تاریخ پذیرش: ۲۸ آبان ۱۴۰۴

* نویسنده مسئول:

فریده ابراهیمی خاله‌سری

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

تلفن: ۰۱۱۳۳۳۳۲۰۷۱

رایانامه: f.ebrahimi96@nit.ac.ir

مقدمه

مرگ ناگهانی قلبی (SCD) نتیجه ازدست دادن ناگهانی عملکرد قلب است و ممکن است در فردی بدون سابقه بیماری قلبی اتفاق بیفتد. زمان و نحوه مرگ غیرمنتظره است و بلافاصله یا اندکی پس از شروع علائم رخ می دهد. علل زمینه ای SCD، متنوع و گاهی ناشناخته است؛ برخی از علل شناخته شده شامل ایسکمی قلبی، هدایت الکتریکی غیرطبیعی در قلب، ناهنجاری های ساختاری قلب، بیماری عروق کرونر و تغییرات در قلب، به دلیل فشار خون طولانی مدت است. عوامل خطر SCD شامل سابقه خانوادگی بیماری قلبی، افزایش سن، جنسیت، فشار خون بالا، کلسترول بالا، سیگار کشیدن و دیابت هستند. عواملی همچون سابقه انفارکتوس میوکارد و کاهش کسر جهشی بطن چپ نیز خطر SCD را افزایش می دهند [۱].

آگاهی از این علائم و نشانه ها، به ویژه برای زنان و جوانان، اهمیت زیادی دارد؛ زیرا ممکن است بیماری قلبی را به عنوان مشکلی مختص مردان و سالمندان نادیده بگیرند. نبود تعریف دقیق از SCD، پیش بینی آن را دشوار کرده است. این مشکل با ناقص بودن دفاتر ثبت مرگ های ناگهانی تشدید می شود. اطلاعات موجود درباره بروز SCD عمدتاً از قربانیانی به دست می آید که برای آن ها اقدام به احیا شده است، در حالی که مرگ های بدون شاهد در آمار نادیده گرفته می شوند. همچنین، کالبدشکافی، که امکان شناسایی دقیق موارد SCD را فراهم می کند، برای درصد کمی از قربانیان انجام می شود.

اصطلاح «حمله قلبی» نیز، که به مرگ بافت عضله قلب به دلیل ازدست دادن جریان خون اشاره دارد، به اشتباه برای توصیف SCD استفاده می شود. مرگ ناگهانی قلبی در واقع نتیجه ایست قلبی احیانشده است که می تواند تقریباً با هر بیماری قلبی شناخته شده ای ایجاد شود. این عدم قطعیت ها و داده های ناکافی، پیش بینی SCD را دشوار می کنند. مطالعات نشان می دهند که مهم ترین علت SCD در بزرگسالان، بیماری عروق کرونر است و شایع ترین رویدادهایی که به SCD منجر می شوند انحطاط تاکی کاردی بطنی (Ventricular Tachycardia) به فیبریلاسیون بطنی (Ventricular Fibrillation) است که باعث انقباضات نامنظم و بی اثر بطن ها می شود [۱].

تخمین دقیق مدت زمان ظهور علائم قبل از مرگ در قربانیان ایست قلبی خارج از بیمارستان دشوار است. بنابراین، پیش بینی زمان دقیق وقوع ممکن نیست، اما تشخیص زودهنگام علائم قلبی می تواند به درمان سریع تر، باز شدن شریان ها و امکان دفیبریلاسیون منجر شود که کاهش آسیب های قلبی و جلوگیری از مرگ را به همراه دارد. شایان ذکر است اطلاعات بالینی موجود قبل از شروع SCD، خصوصاً در دوره یک ساعت قبل از ایست قلبی، محدود است. تنها علامت بالینی، افزایش ضربان قلب قبل از وقوع VF در داده های مانیتورینگ است [۱].

نارسایی احتقانی قلب (Congestive Heart Failure) وضعیت بالینی پیچیده ای است که در آن، قلب قادر به پمپاژ خون کافی برای

نیازهای بدن نیست. ناهنجاری هایی که باعث اختلال در پرشدن بطن ها یا خروج خون به گردش خون سیستمیک می شوند، این وضعیت را ایجاد می کنند [۲]. علائم اولیه CHF، همچون مشکلات تنفسی، سرگیجه و خستگی، مشابه علائم SCD است [۳]. بنابراین، وضعیت قلبی عروقی در SCD و CHF مشابه است و تمایز بین این دو عارضه قلبی برای درمان مؤثر اهمیت زیادی دارد.

تاکنون برای پیش بینی SCD تلاش های زیادی شده است. در گذشته، از روش های سنتی بر پایه یادگیری ماشین برای پیش بینی استفاده می شد. در این روش ها، ویژگی ها به کمک روابط ریاضی به طور مستقیم از سیگنال ECG استخراج می شدند، یا ابتدا سیگنال تغییرپذیری ضربان قلب (Heart Rate Variability) از سیگنال ECG استخراج و سپس اطلاعات از سیگنال HRV استخراج و برای پیش بینی استفاده می شدند. امروزه، با پیشرفت هایی که در هوش مصنوعی و به ویژه یادگیری عمیق حاصل شده است، فرایند پیش بینی به کمک شبکه های عصبی پیچشی کاملاً خودکار شده است. در ادامه، مرور تعدادی از پژوهش های انجام شده به ترتیب بر پایه روش های سنتی یادگیری ماشین و روش های مبتنی بر یادگیری عمیق آمده است.

ابراهیم زاده و همکاران با استخراج ویژگی های زمانی، فرکانسی و زمان - فرکانس، الگوریتمی برای پیش بینی یک دقیقه قبل از وقوع SCD پیشنهاد کرده اند [۴]. آن ها در ادامه پژوهش قبلی خود، با اضافه کردن ویژگی های غیرخطی و رویکرد انتخاب زیر مجموعه ویژگی های محلی، بازه پیش بینی را به دوازده دقیقه افزایش داده اند [۵]. شیلا و همکاران با تغییر بازه استخراج ویژگی به بازه هایی به طول ده دقیقه و استخراج ویژگی های زمانی و فرکانسی، موفق شدند بازه پیش بینی را تا سی دقیقه گسترش دهند [۶]. موروگاپان و همکاران با انتخاب قسمت هایی از سیگنال ECG از اوج R تا انتهای موج (R - Tend)، که مربوط به شروع دیلاریلاسیون بطنی تا انتهای رپلاریلاسیون بطنی است، توانستند پنج دقیقه قبل از وقوع SCD را با دقت ۱۰۰ درصد پیش بینی کنند [۷]. آچاریا و همکاران با تجزیه و تحلیل غیرخطی سیگنال های ECG بعد از گرفتن تبدیل موجک گسسته (DWT)، دقت پیش بینی را تا چهار دقیقه قبل از وقوع SCD، که قبلاً با پردازش سیگنال HRV انجام شده بود، افزایش دادند [۸]. سانچز و همکاران بیست دقیقه قبل از شروع SCD را به کمک ویژگی ای تحت عنوان شاخص همگنی (HI)، که با ضرایب حاصل از تبدیل بسته موجک (WPT) به دست می آید، پیش بینی کرده اند [۹].

لی و همکاران پنج نشانگر خطر آریتمی را، که بسیاری از مطالعات بالینی پیشنهاد کرده اند، به صورت جداگانه استخراج و محاسبه کردند. با اضافه کردن داده AHADB از افراد در معرض خطر SCD، تعداد داده های SCD قبلی خود را افزایش دادند و توانستند سی دقیقه قبل از SCD را پیش بینی کنند. همچنین، شاخص جدیدی تحت عنوان SCDI برای پیش بینی SCD با استفاده از سه نشانگر انتخاب شده از پنج نشانگر

است. بر این اساس، در این پژوهش تلاش شده است با استفاده از شبکه‌های عصبی پیچشی یک‌بعدی و دوبعدی، مراحل استخراج و انتخاب دستی ویژگی‌ها حذف و پیش‌بینی SCD به بازه یک ساعت قبل از وقوع گسترش داده شود. در ادامه، ابتدا ابزار و روش پیشنهادی آورده شده، سپس نتایج پیاده‌سازی روش پیشنهادی روی پایگاه داده گزارش شده است. در بخش بعدی، نتایج حاصل از روش پیشنهادی با پژوهش‌های انجام شده در ادبیات، مقایسه و درباره آن‌ها بحث شده است. سرانجام، نتیجه‌گیری و پیشنهادهایی برای ادامه این پژوهش مطرح شده است.


روش بررسی

بلوک دیاگرام روش پیشنهادی در شکل ۱ آورده شده است. پس از انجام پیش‌پردازش، از دو روش برای انجام این تحقیق استفاده شد. از آنجاکه داده مورد استفاده به‌صورت سیگنال است، در روش اول، ابتدا از شبکه‌های عصبی پیچشی یک‌بعدی استفاده شد. در این زمینه، سیگنال‌های ECG در بخش‌های یک‌دقیقه‌ای به‌عنوان ورودی به CNN‌های یک‌بعدی (CNN_1d) داده شدند. سپس از آنجاکه استفاده از شبکه‌های عصبی پیچشی در پردازش تصویر موفقیت‌های چشمگیری داشته است، در ادامه، CNN‌های دوبعدی (CNN_2d) بررسی شدند. به‌منظور آماده‌سازی ورودی‌ها برای مدل CNN_2d، قدر مطلق ضرایب تبدیل موجک پیوسته (scalogram) سیگنال‌های ECG محاسبه شدند. پس از کمی‌سازی اطلاعات به کمک شبکه‌های عصبی پیچشی یک و دوبعدی، برای طبقه‌بندی بردارهای ویژگی متعلق به دو کلاس نرمال و داده قبل از وقوع SCD، از لایه کاملاً متصل و تابع Softmax استفاده شد. علاوه بر این، سیگنال‌های ECG افراد مبتلا به CHF به داده‌های قبلی اضافه شدند و طبقه‌بندی سه کلاسه‌ای نیز انجام شد.

آریتمی معرفی کردند [۱۰]. وگا و همکاران با ترکیب ماهرانه الگوریتم‌های بعد فراکتال (FD) و یک سیستم منطق فازی، بازه پیش‌بینی را به شصت دقیقه پیش از وقوع گسترش دادند [۱۱]. از روش‌های مبتنی بر شبکه‌های عصبی پیچشی می‌توان به پژوهش اولیویا بارگاس و همکارانش برای پیش‌بینی SCD تا ۲۵ دقیقه قبل از وقوع SCD اشاره کرد [۱۲]. در این تحقیق پس از جداسازی باندهای فرکانسی سیگنال ECG، با استفاده از تجزیه حالت تجربی (EMD)، ویژگی‌ها استخراج شدند. پس از انتخاب متمایزترین ویژگی‌ها، با استفاده از تحلیل واریانس (ANOVA)، از یک شبکه عصبی پرسپترون چندلایه (MLP) برای طبقه‌بندی استفاده شد و به دقت ۹۴ درصد دست یافتند.

وینسنت و همکاران با استفاده از روشی ترکیبی، شامل تبدیل بسته موجک و شبکه‌های عصبی پیچشی یک‌بعدی (CNN-1D) برای پیش‌بینی سی دقیقه قبل از شروع SCD، دقت ۹۵/۸۹ درصد را گزارش کردند [۱۳]. مانوئل و همکاران نیز برای پیش‌بینی سی دقیقه قبل از وقوع مرگ ناگهانی قلبی، از روشی مبتنی بر تجزیه حالت تجربی مجموعه کامل (Complementary Ensemble Empirical Mode Decomposition) برای تجزیه سیگنال قلبی به توابع حالت ذاتی (IMFs) و از نوعی شبکه عصبی پیچشی دوبعدی (CNN-2D) برای تشخیص خودکار استفاده کردند و به دقت ۹۷/۵ درصد دست یافتند [۱۴]. پورومب و همکاران برای شناسایی نارسایی احتقانی قلب (CHF) پس از استخراج ضربان قلب، از شبکه‌های عصبی پیچشی (CNN) استفاده کردند و به دقت ۱۰۰ درصد دست یافتند [۱۵].

مرور ادبیات نشان می‌دهد که در اغلب مطالعات انجام‌شده تاکنون، بازه پیش‌بینی سی دقیقه قبل از وقوع مرگ بوده است. به‌علاوه، رویکرد مطالعات به این صورت بوده است که استفاده از شبکه‌های عصبی پیچشی به‌منظور خودکار کردن فرایند پیش‌بینی مورد توجه محققان قرار گرفته



شکل ۱. بلوک دیاگرام روش پیشنهادی

پایگاه داده

(۱۱) مرد، ۲۲ تا ۷۱ سال، و ۴ زن (۵۴ تا ۶۳ سال) با نارسایی احتقانی شدید قلبی است [۱۶]. همچنین، پایگاه داده VF شامل ۳۵ ضبط هشت دقیقه‌ای ECG از افرادی است که دوره‌های تاکی کاردی بطنی پایدار، فلاتر بطنی و VF را تجربه کرده‌اند [۱۷]. از پایگاه داده SCD و پایگاه داده نرمال به عنوان دو گروه اصلی، به منظور پیش‌بینی، استفاده شد همچنین پایگاه داده CHF برای طبقه‌بندی سه کلاس (نرمال، پیش SCD، CHF) و پایگاه داده VF به عنوان داده تست دوم در اعتبار سنجی مدل پیشنهادی در پیش‌بینی SCD استفاده شدند.

پیش پردازش

سیگنال‌های ECG از دو لید ثبت شده موجود در پایگاه داده SCDH دقیقاً یک ساعت قبل از وقوع مرگ ناگهانی، برای آنالیز استفاده شدند. از افراد سالم نیز یک ساعت سیگنال به صورت تصادفی استخراج شد. در ادامه، سیگنال‌ها، در بازه ۱- تا ۱ نرمالیزه و سپس به بازه‌ای یک دقیقه‌ای تقسیم شدند. از آنجاکه کاهش نویز می‌تواند دقت و کارایی الگوریتم پیش‌بینی را تا حد زیادی افزایش دهد، نویزهای پس زمینه و برق شهر حذف شدند. همچنین، به دلیل متفاوت بودن نرخ نمونه برداری سیگنال‌های ECG از افرادی که به مرگ ناگهانی قلبی مبتلا شده‌اند، یکسان سازی فرکانس نمونه برداری به کمک فرایند کاهش نمونه‌های سیگنال با افراد نرمال انجام شد. سیگنال‌های ECG یک دقیقه‌ای، پس از پیش پردازش برای آنالیز بیشتر به دو ساختار مبتنی بر شبکه‌های عصبی پیچشی یک (CNN-1D) و دوبعدی (CNN-2D) داده شدند. به منظور آماده سازی سیگنال ECG به عنوان ورودی ساختارهای مبتنی بر شبکه عصبی پیچشی دوبعدی، از تبدیل موجک پیوسته استفاده شد که در ادامه تشریح شده است.

دوبعدی سازی داده‌ها با تبدیل موجک پیوسته

تبدیل موجک پیوسته سیگنال $S(t)$ به کمک رابطه (۱) به دست می‌آید. جایی که $S(t)$ یک سیگنال انرژی محدود است، ψ^* مزدوج مختلط موجک مادر است و a و b پارامترهایی هستند که به ترتیب مقیاس و انتقال موجک را کنترل می‌کنند. مقادیر مقیاس بزرگ، موجک را در زمان گسترش می‌دهد و اطلاعات فرکانس پایین در سیگنال را نشان می‌دهد، در حالی که مقادیر مقیاس کوچک‌تر، فرکانس‌های بالای موجود در سیگنال را نمایان می‌کنند. اسکیلوگرام، که نوعی نمایش بصری حاصل از تبدیل موجک پیوسته (Continous Wavelet Transform) یک سیگنال است، شبیه به طیف نگاری ایجاد شده با استفاده از تبدیل فوریه کوتاه مدت (STFT) است. تبدیل موجک پیوسته در مقایسه با STFT وضوح زمانی و فرکانسی بالاتری فراهم می‌کند. اسکالوگرام سیگنال‌ها به وضوح فرکانس‌های موجود در زمان‌های مختلف در سیگنال

در این پژوهش از چهار پایگاه داده، که در جدول ۱ ذکر شده، استفاده شده است. پایگاه داده نرمال (Normal Sinus Rhythm database)، شامل سیگنال‌های ECG از ۱۸ فرد نرمال در محدوده سنی ۲۰ تا ۵۰ سال است. تیمی از متخصصان قلب و عروق تأیید کردند که شرکت کنندگان، ضربان قلب طبیعی دارند. پایگاه داده (Sudden Cardiac Death Holter Database) شامل سیگنال‌های ECG از ۲۳ فرد در محدوده سنی ۱۷ تا ۸۲ سال است که دچار مرگ ناگهانی قلبی شده‌اند. در این پایگاه داده زمان دقیقی که شخص دچار مرگ ناگهانی قلبی ناشی از فیبریلاسیون بطنی شده، معلوم و ثبت شده است [۹]. پایگاه داده CHF شامل ضبط طولانی مدت ECG از ۱۵ نفر را نشان و نوعی نمایش بصری ارائه می‌دهد که می‌تواند برای تمایز استفاده شود [۱۸].

$$Z(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} s(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

دسته خاصی از موجک‌ها، که به عنوان موجک‌های تحلیلی شناخته می‌شوند، موجک‌هایی پیچیده هستند و در فرکانس‌های منفی مقدار آن‌ها برابر صفر است. یکی از این نمونه‌ها، موجک‌های مورس است که Daubechies و Paul برای اولین بار معرفی و به تفصیل ارائه کردند. در این خانواده موجک، دو پارامتر γ و p وجود دارد که با تغییر این دو پارامتر، بسیاری از موجک‌های تحلیلی رایج ایجاد می‌شوند. این موجک‌ها در حوزه فرکانس مطابق معادله زیر تعریف می‌شوند.

$$\varphi_{p,\gamma}(\omega) = U(\omega) a_{p,\gamma} \omega^{\frac{p}{\gamma}} e^{-\omega \gamma} \quad (2)$$

در این معادله، $U(\omega)$ تابع پله واحد است و $a_{p,\gamma}$ یک ثابت برای نرمالیزه سازی است. γ تقارن دامنه فرکانس را کنترل می‌کند، در حالی که جذر حاصل ضرب پهنای باند زمان (p) متناسب با مدت زمان موجک است و با افزایش γ و p ، موجک در زمان، بیشتر نوسان می‌کند و در فرکانس باریک می‌شود [۱۹].

شبکه‌های عصبی پیچشی

حوزه یادگیری ماشین با ظهور شبکه عصبی مصنوعی پیشرفت چشمگیری کرد. این مدل‌های محاسباتی الهام گرفته شده از بیولوژی می‌توانند به مراتب کاربردی‌تر از مدل‌های قبلی هوش مصنوعی در وظایف رایج یادگیری ماشین باشند [۲۰]. واژه یادگیری عمیق یا شبکه عصبی عمیق به شبکه‌های عصبی مصنوعی با چند لایه اطلاق می‌شود که در چند دهه اخیر، یکی از قدرتمندترین ابزارهاست و قادر به مدیریت حجم عظیمی از داده‌هاست. یکی از چشمگیرترین اشکال معماری شبکه‌های عصبی مصنوعی، شبکه عصبی پیچشی (Convolutional Neural Network) است که این نام از عملیات خطی ریاضی بین ماتریس‌ها، به

پیچشی، لایه‌های ادغام و لایه‌های کاملاً متصل استفاده می‌شود. لایه‌های پیچشی و کاملاً متصل دارای پارامتر هستند، اما لایه‌های ادغام پارامتر ندارند. لایه پیچشی گامی اساسی برای استخراج ویژگی است و خروجی‌های لایه پیچشی، نقشه‌های ویژگی نامیده می‌شوند. اعمال یک کرنل پیچشی با اندازه مشخص روی تصاویر موجب می‌شود که اطلاعات حاشیه حذف شود. برای برگرداندن تصویر به اندازه قبلی، از لایه‌گذاری (padding) استفاده می‌شود. پارامتر دیگر برای کنترل پیچیدگی، گام است. هرچه گام بزرگ‌تر باشد، تعداد خروجی کمتر است. علاوه بر این، نقشه‌های ویژگی متشکل از تعداد زیادی ویژگی هستند که این مسئله مدل را مستعد مشکل بیش‌برازش می‌کند. از این‌رو، لایه ادغام برای جلوگیری از بیش‌برازش پیشنهاد شده است [۲۲]. برخی از عملیات ادغام رایج عبارت‌اند از: ادغام حداکثر، ادغام متوسط، ادغام تصادفی، ادغام طیفی، ادغام هرم فضایی و ادغام بدون نظم چند مقیاسی. همچنین، اخیراً در برخی از معماری‌ها لایه کاملاً متصل با یک لایه میانگین جهانی جایگزین شده است [۲۳].

نام کانولوشن، گرفته شده است [۲۱]. CNNها تمایل دارند الگوهای بصری را مستقیماً از پیکسل‌های تصویر خام تشخیص دهند. این ساختارها عمدتاً برای حل وظایف دشوار تشخیص الگوی مبتنی بر تصویر استفاده می‌شوند و با معماری دقیق و در عین حال ساده خود، روش ساده‌ای برای شروع کار با شبکه‌های عصبی مصنوعی ارائه می‌دهند. مزایای استفاده از CNN شامل موارد ذیل است: ۱. اتصالات محلی: در این ساختارها هر نورون به تمام نورون‌های لایه قبلی متصل نیست، بلکه فقط به تعداد کمی از نورون‌ها متصل است که این مسئله در کاهش تعداد پارامترها و سرعت‌بخشیدن به همگرایی مؤثر است؛ ۲. اشتراک وزن: گروهی از اتصالات می‌توانند وزن‌های یکسانی را به اشتراک بگذارند که باعث کاهش بیشتر پارامترها می‌شود؛ ۳. کاهش ابعاد نمونه‌برداری: یک لایه ادغام با حذف ویژگی‌های بی‌اهمیت، تعداد پارامترها را کاهش می‌دهد. این سه ویژگی جذاب، CNN را به یکی از معروف‌ترین الگوریتم‌ها در زمینه یادگیری عمیق تبدیل کرده است [۲۲]. در مدل‌های مبتنی بر شبکه عصبی پیچشی، اغلب از لایه‌های

جدول ۱. پایگاه داده

پایگاه داده	طول ثبت‌ها	تعداد ثبت‌ها (تعداد زن)	سن
MIT-BIH NSR (سالیم)	ثبت طولانی مدت (Long term recording)	۱۸ (۱۳)	۳۵±۱۵
SCDH(SCD) (بیمار مبتلا به مرگ ناگهانی قلبی)	ثبت طولانی مدت (Long term recording)	۲۳ (۸)	۴۹/۵±۳۲/۵
CUDb(VF) (بیمار مبتلا به فیبریلاسیون بطنی)	ثبت‌های هشت دقیقه‌ای	۳۵	—
CHF (بیمار مبتلا به نارسایی قلبی)	ثبت طولانی مدت (Long term recording)	۱۵ (۱۴)	۴۹±۲۲

یافته‌ها

۰/۰۰۱، فرکانس ارزیابی (Validation frequency) ۵۰، اندازه دسته (miniBatchSize) ۱۲۸، تعداد دوره (epoch) ۱۵ برای آموزش مدل استفاده شد. معماری شبکه CNN_1d در شکل ۲ آورده شده است. بعد از تقسیم‌بندی تصادفی، ۲۰ درصد از داده‌ها به عنوان داده تست مجزا کنار گذاشته شد. ۲۰ درصد به عنوان داده اعتبارسنجی و ۶۰ درصد به عنوان داده آموزش در اختیار شبکه قرار داده شد. از داده اعتبارسنجی با استفاده از تنظیمات Erlystopping برای جلوگیری از آموزش بیش از حد شبکه و تعیین تعداد دوره‌های بهینه استفاده شد. در هر بار اجرای شبکه، به دلیل تفاوت در مقداردهی اولیه وزن‌ها و تقسیم‌بندی متفاوت داده‌ها، نتایج شبکه تفاوت اندکی با یکدیگر داشتند، به همین دلیل، چندین بار آموزش مجدد انجام شد و نتایجی که بیشترین تکرار را داشتند به عنوان نتیجه نهایی گزارش شدند. سپس داده افراد مبتلا به CHF به داده‌های قبلی اضافه شدند و آموزش شبکه برای جدا کردن سه کلاس سالم، پیش SCD و CHF انجام شد. به دلیل دقت کم شبکه، یک لایه پیچشی دیگر با همان

در این پژوهش به منظور خودکارسازی کامل فرایند پیش‌بینی، از شبکه‌های عصبی پیچشی برای استخراج ویژگی استفاده شد. پس از انجام مراحل پیش‌پردازش، مانند نرمالیزه کردن، حذف نویز و تقسیم به بازه‌های یک دقیقه‌ای، ۴۸۰۰ بردار با ابعاد ۱×۷۵۰۰ آماده شد که بردارهایی با فاصله زمانی یک دقیقه، از سیگنال‌هایی با فرکانس نمونه‌برداری ۱۲۵ هرتز بود و به عنوان ورودی مدل CNN-1D استفاده شدند. در مدل اول پیشنهادی، از یک لایه پیچشی با ۳۲ فیلتر با عرض ۳، گام حرکت ۱ و لایه‌گذاری از نوع همانند (same) برای استخراج ویژگی استفاده شد. در ادامه، تابع فعال‌ساز Relu به خروجی لایه پیچشی اعمال شد و میانگین ویژگی‌ها به کمک لایه ادغام ویژگی جهانی، محاسبه شدند. سپس ویژگی‌های استخراج‌شده با لایه کاملاً متصل و تابع فعال‌سازی softmax طبقه‌بندی شدند. شایان ذکر است که به دلیل محدودیت تعداد ثبت‌های موجود، تا حد ممکن از ساختارهایی با تعداد لایه کمتر استفاده شد. پس از طراحی لایه‌ها، از الگوریتم بهینه‌سازی adam، نرخ یادگیری


یادگیری ۰/۰۰۱، فرکانس ارزیابی ۵۰، اندازه دسته ۱۲۸ و تعداد دوره ۱۵ استفاده شد. همانند بخش قبلی، که از شبکه‌های عصبی پیچشی یک‌بعدی استفاده شد، در اینجا نیز به‌صورت تصادفی، ۲۰ درصد از داده‌ها به‌عنوان داده آزمون مجزا کنار گذاشته شدند. ۲۰ درصد دیگر به‌عنوان داده اعتبارسنجی و ۶۰ درصد به‌عنوان داده آموزش در اختیار شبکه قرار داده شدند. در هر بار اجرای شبکه، به‌دلیل تفاوت در مقداردهی اولیه وزن‌ها و تقسیم‌بندی متفاوت داده‌ها، نتایج شبکه تفاوت اندکی با یکدیگر داشتند. به همین دلیل، چندین بار آموزش مجدد انجام شد و نتایجی که بیشترین تکرار را داشتند، به‌عنوان نتیجه نهایی گزارش شدند.

برای ارزیابی قابلیت اعتماد به نتایج حاصل‌شده، از داده افراد مبتلا به فیبریلاسیون بطنی نیز به‌عنوان داده تست دوم استفاده شد. در مرحله بعد، طبقه‌بندی سه‌کلاسه سالم، پیش SCD و CHF نیز با مدل CNN_2d انجام شد که نتایج در شکل ۵ آورده شده است. برای کاهش تعداد پارامترهای آموزش‌پذیر و افزایش سرعت در ساختار مبتنی بر شبکه عصبی پیچشی دو‌بعدی (CNN_2d)، معماری شبکه به‌صورت موجود در شکل ۴، قسمت b و c، به‌ترتیب برای طبقه‌بندی دو و سه کلاسه، اصلاح شد. در این ساختارها نیز برای آموزش شبکه از الگوریتم بهینه‌سازی adam استفاده شد و نرخ یادگیری ۰/۰۰۱، فرکانس ارزیابی ۵۰، اندازه دسته ۱۲۸ و تعداد دوره ۲۰ انتخاب شد. شایان ذکر است که در این قسمت نرخ یادگیری بعد از هر ۵ دوره، با ضریب ۰/۱ کاهش یافت و گام حرکت ۳ در نظر گرفته شد. با کاهش پارامترهای قابل آموزش، مدت‌زمان آموزش در نرم‌افزار متلب برای CNN_2d از ۴۰ به ۱۰ دقیقه و مدت‌زمان تست از ۷ به ۲ دقیقه کاهش یافت. در این پژوهش، علاوه بر نرم‌افزار متلب، از نرم‌افزار پایتون نیز برای پیاده‌سازی مدل پیشنهادی استفاده شد که مدت‌زمان آموزش در نرم‌افزار پایتون تقریباً نصف زمان مورد نیاز در نرم‌افزار متلب است.


تنظیمات قبلی، بعد از لایه پیچشی اول قرار داده شد که از این ساختار نتایج قابل قبولی حاصل شد. از شبکه طراحی‌شده برای تفکیک سه کلاسه، در تفکیک دو کلاسه سالم و پیش SCD نیز استفاده شد که دقت از ۹۶ به ۹۸/۶ روی داده‌های تست افزایش پیدا کرد. پس از آن، تغییر پارامترهای شبکه و اضافه کردن تعداد لایه‌ها در افزایش دقت مؤثر نبود.

در ادامه، با توجه به این نکته که CNN‌ها عملکرد بسیار خوبی در مسائل یادگیری ماشین، به‌ویژه از داده‌های تصویری دارند، شبکه‌های عصبی دو‌بعدی نیز استفاده شدند. برای دو‌بعدی‌سازی سیگنال ورودی، روش‌های رایجی مانند تبدیل کسینوسی گسسته (DCT)، تبدیل موجک پیوسته (CWT) و تبدیل موجک گسسته (DWT) وجود دارند که در این پژوهش از اسکیلوگرام استفاده شد. اسکیلوگرام قدر مطلق ضرایب CWT سیگنال است. موجک مورس با $\gamma = 3$ و $P = 60$ به‌عنوان موجک مادر استفاده شد. با استفاده از CWT، اسکیلوگرام‌ها استخراج و با اندازه $224 \times 224 \times 3$ ذخیره شدند که به‌عنوان ورودی شبکه CNN دو‌بعدی استفاده شدند. پس از آن، یک لایه پیچشی با ۳۲ فیلتر با ابعاد 3×3 و گام حرکت ۱، برای استخراج ویژگی استفاده شد. فرایند اعمال فیلترهای پیچشی روی تصویر، نقشه ویژگی را به دست می‌دهد. شکل ۳ نحوه اعمال فیلترها روی تصویر ورودی در لایه پیچشی را نشان می‌دهد. در شکل ۳، علامت * عملیات کانولوشن را نشان می‌دهد و علامت ϕ تابع فعال‌ساز Relu است. همچنین، نمادهای مربع خاکستری بین این عملگرها، فیلترهای پیچشی را نشان می‌دهند. لایه پیچشی به تعداد فیلترهای پیچشی، نقشه ویژگی تولید می‌کند.


در ادامه، نقشه‌های ویژگی استخراج‌شده به آرایه یک‌بعدی تبدیل و با شبکه عصبی تماماً متصل و تابع فعال‌سازی softmax طبقه‌بندی شدند. معماری CNN_2d در شکل ۴ قسمت a آورده شده است. پس از طراحی لایه‌ها، برای آموزش شبکه از الگوریتم بهینه‌سازی adam، نرخ




شکل ۲. معماری CNN-1D برای حالت دو و سه‌کلاسه با خط چین مشخص شده است. در لایه پیچشی ۳۲ فیلتر با اندازه 3×1 استفاده شده است.




شکل ۳. ایجاد نداشت‌های ویژگی دوبعدی با لایه پیچشی در مدل CNN-2D



شکل ۴. الف. معماری CNN_2d برای پیش‌بینی (Normal, Pre SCD)؛ ب. معماری CNN_2d بهبودیافته برای پیش‌بینی (Normal, Pre SCD)؛ ج. معماری CNN_2d بهبودیافته برای پیش‌بینی (Normal, Pre SCD, CHF)، اعداد داخل پرانتز به‌ترتیب نمایانگر تعداد و اندازه فیلترها در لایه پیچشی هستند. ۳* و در مدل میانی و پایینی به‌ترتیب به معنای دو و سه بار تکرار بخش‌های داخل جعبه است.



شکل ۵. درصد صحت روش‌های پیشنهادی



The time prior to the SCD

[4]	[27]	[8]	[25]	[26]	[7]	[32]	[33]	[5]	[34]	[35]	[9]	[12]	[6]	[14]	[13]	[10]	[11]	Proposed Method chr_16	Proposed Method chr_26
-----	------	-----	------	------	-----	------	------	-----	------	------	-----	------	-----	------	------	------	------	------------------------	------------------------

شکل ۶. مقایسه روش پیشنهادی با ادبیات

بحث

افزایش خطر ابتلا به SCD با تعداد زیادی علت، که شامل بسیاری از علائم پاتولوژیک است، مشخص می‌شود. این علل شامل آریتمی‌های قلبی، بیماری عروق کرونر، ناهنجاری‌های مادرزادی شریان کرونری، کاردیومیوپاتی هیپرتروفیک، دیسپلازی بطن راست آریتموژنیک، کاردیومیوپاتی اتساعی و تنگی دریچه آئورت است. یکی از شایع‌ترین علل SCD، بیماری عروق کرونر (Coronary Artery Disease) است که در ۳۰ درصد موارد ابتلا به بیماری عروق کرونر، با پیشرفت بیماری، فیبریلاسیون بطنی ایجاد می‌شود و در ادامه، به دلیل انسداد شریان‌ها، به وقوع SCD منجر می‌شود [۲۴].

از طرفی، فیبریلاسیون بطنی عامل اصلی (۲۰ درصد) مرگ‌های ناگهانی قلبی است [۹، ۲۵]. بنابراین، با اطمینان می‌توان ادعا کرد فیبریلاسیون بطنی می‌تواند علت وقوع حدود ۵۰ درصد از مرگ‌های ناگهانی قلبی باشد. به همین دلیل، در پژوهش‌های مرور شده در این مطالعه برای پیش‌بینی SCD، از داده افرادی استفاده شده است که بر اثر فیبریلاسیون بطنی دچار SCD شده‌اند. روش‌های بسیاری برای پیش‌بینی SCD براساس پردازش سیگنال‌های ECG و HRV توسعه یافته است. هدف بسیاری از این مطالعات دستیابی به دقت بالا، افزایش فاصله پیش‌بینی SCD و بهبود روش‌های موجود بوده است. در مطالعات قبلی، مجموعه‌های متفاوتی از ویژگی‌ها با استفاده از روش‌های گوناگون در حوزه زمان، فرکانس، زمان - فرکانس و روش‌های غیرخطی و همچنین ویژگی‌های مبتنی بر مورفولوژی استخراج شده است [۴، ۵، ۷، ۸، ۱۱، ۲۶، ۲۷]. امروزه، شبکه‌های عصبی پیچشی جایگزین قدرتمندی برای رویکردهای یادگیری ماشین سنتی هستند؛ زیرا با استفاده از ساختارهای مبتنی بر شبکه‌های عصبی پیچشی، ویژگی‌ها می‌توانند به‌طور خودکار از سیگنال و تصاویر

استخراج شوند. مطالعه ادبیات نشان می‌دهد نتایج به‌دست‌آمده از CNN‌ها در طبقه‌بندی آریتمی‌های قلبی قابل قبول بوده است [۲۸-۳۱]. بر همین اساس، از CNN‌ها برای پیش‌بینی مرگ ناگهانی قلبی و تشخیص CHF استفاده شده است [۱۳-۱۵].

در این پژوهش نیز تلاش شد برای پیش‌بینی مرگ ناگهانی قلبی از شبکه‌های عصبی پیچشی یک‌بعدی (CNN-1D) و دوبعدی (CNN-2D) استفاده شود. مدل‌های مبتنی بر شبکه‌های عصبی پیچشی یک‌بعدی برای پردازش داده‌های سری زمانی مانند سیگنال‌های ECG مناسب هستند. با آموزش مدل CNN-1D (مسیر ۱ در شکل ۱ و شکل ۳) مشاهده شد که استفاده از ساختار پیشنهادی نتایج مطلوبی در پیش‌بینی SCD به دست می‌دهد. در این مدل، از یک لایه پیچشی استفاده شده است که شامل ۳۲ فیلتر پیچشی با ابعاد ۱×۳ است. همچنین، در مدل پیشنهادی، برای کاهش ابعاد نقشه‌های ویژگی و در نتیجه، کاهش پیچیدگی، از Global Average Pooling استفاده شده است. برای ارزیابی قابلیت اعتماد به مدل پیشنهادی، علاوه بر ارزیابی مدل با پایگاه داده اصلی، که مدل با آن آموزش دیده است، پایگاه داده مجزایی برای آزمون استفاده شده است که نتایج پیش‌بینی روی این پایگاه داده نیز در شکل ۵ آمده است. مقایسه نتایج مدل پیشنهادی و دیگر روش‌های ارائه‌شده در ادبیات در شکل ۶ نشان می‌دهد که این مدل در مقایسه با دیگر روش‌های ارائه‌شده در ادبیات، توانسته است پیش‌بینی را تا شصت دقیقه قبل از وقوع مرگ، با درصد دقت بیشتری انجام دهد. به‌طور کلی، رسیدن به دقت بالاتر در پیش‌بینی SCD با مدل‌های مبتنی بر شبکه عصبی پیچشی، به پیچیدگی بیشتر مدل منجر خواهد شد. درحالی‌که مدل CNN-1D بدون نیاز به پیش‌پردازش‌های بیشتر و پیچیده‌تر (مانند دوبعدی کردن ورودی‌ها) و با استفاده از یک لایه پیچشی، توانست در

پیش‌بینی مرگ ناگهانی قلبی عملکرد مطلوبی داشته باشد.

در ادامه، از آنجاکه شبکه‌های عصبی پیچشی از ساختار و عملکرد قشر بصری مغز الهام گرفته شده‌اند و دقت بالاتری در پردازش تصاویر به دست داده‌اند، به‌منظور افزایش دقت پیش‌بینی، ابتدا سیگنال‌ها با تبدیل موجک پیوسته به تصاویر دوبعدی تبدیل شدند و سپس برای پیش‌بینی، از ساختار مبتنی بر شبکه‌های عصبی پیچشی دو بعدی استفاده شد. با آموزش مدل CNN-2D (مسیر ۲ در شکل ۱ و شکل ۴ قسمت الف)، که یک لایه پیچشی شامل ۳۲ فیلتر با ابعاد ۳×۳ دارد، مشاهده شد که با استفاده از این ساختار، نتایج در پیش‌بینی SCD بهبود می‌یابد (شکل ۵). همچنین، طبقه‌بندی سه کلاسه (سالم، سیگنال قلبی قبل از وقوع مرگ ناگهانی قلبی و نارسایی قلبی) نیز با مدل CNN-2D انجام شد که نتایج در شکل ۵ قابل مشاهده است.

شایان ذکر است که استفاده از GAP در مدل CNN-2D سبب کاهش عملکرد مدل در پیش‌بینی شد که با تغییر معماری مدل تلاش شد پیچیدگی محاسباتی تا حد قابل توجهی کم شود و در عین حال، کاهش چندانی در نتایج حاصل مشاهده نشود (قسمت ب و ج در شکل ۴). در شکل ۶ که نتایج روش‌های پیشنهادی و روش‌های ارائه شده در ادبیات نشان داده شده است، مشاهده می‌شود روش‌های پیشنهادی توانسته‌اند فاصله زمانی را تا حداکثر مقدار ممکن گسترش دهند و همچنین در مقایسه با دیگر مطالعات در همان بازه، دقت بیشتری دارند.

در مقایسه نتایج این پژوهش با دیگر روش‌های ارائه شده در ادبیات، برای نمونه می‌توان گفت که مدل‌های مبتنی بر شبکه عصبی پیچشی یک [۱۳] و دوبعدی [۱۴]، که اخیراً در ادبیات ارائه شده‌اند، در مقایسه با مدل‌های پیشنهادی در این پژوهش، توانسته‌اند حداکثر سی دقیقه قبل از وقوع مرگ را با دقت کمتری پیش‌بینی کنند. به‌علاوه، روش تجزیه سیگنال قلبی و نحوه ارائه آن به شبکه عصبی پیچشی در مدل مبتنی بر شبکه عصبی پیچشی دوبعدی [۱۴]، متفاوت با این پژوهش است (از CEEMD به جای CWT). همچنین، در ادبیات از مدل‌های مبتنی بر شبکه عصبی پیچشی برای تشخیص CHF از حالت نرمال استفاده شده است و به دقت ۱۰۰ درصد دست یافته‌اند [۱۵]، اما همان‌طور که قبلاً گفته شد، بین سیگنال ECG در CHF و قبل از وقوع مرگ ناگهانی قلبی، شباهت زیادی وجود دارد و جداکردن این دو حالت دشوار است که مدل‌های پیشنهادی توانسته‌اند با دقت زیاد این دو را طبقه‌بندی کنند.

بنابراین، به‌طور خلاصه می‌توان گفت که در این مطالعه تعمیم‌پذیری روش‌های پیشنهادی با استفاده از مجموعه داده‌های آزمون جداگانه نیز بررسی شده است که این بررسی در هیچ‌یک از مطالعات قبلی انجام نشده است. نکته متمایز دیگر این پژوهش طبقه‌بندی هم‌زمان سه کلاسه (سالم، سیگنال قلبی قبل از وقوع مرگ ناگهانی قلبی و نارسایی قلبی) با پردازش سیگنال ECG است. از آنجاکه بین سیگنال ECG در نارسایی قلبی و قبل از وقوع مرگ ناگهانی قلبی شباهت وجود دارد، تفکیک این دو دشوار است. در این پژوهش تلاش شد این طبقه‌بندی با به‌کاربردن معماری

شبکه عصبی پیچشی یک‌بعدی و دوبعدی انجام شود.

مشاهده شد که مدل‌های پیشنهادی قادرند این دو کلاس را با دقت بالا از یکدیگر متمایز کنند. شایان ذکر است که اخیراً پیش‌بینی مرگ ناگهانی قلبی با روش‌های مبتنی بر یادگیری ماشین و با ادغام اطلاعات سیگنال ECG و سیگنال HRV در پژوهش دیگری انجام شده است. عملکرد مدل ارائه شده در پیش‌بینی مرگ ناگهانی قلبی مطلوب بوده است، اما در جداکردن سیگنال ECG قبل از وقوع مرگ ناگهانی قلبی از CHF، عملکرد بسیار ضعیف بوده است [۳۶]. کم‌عمق بودن مدل‌های پیشنهادی و در نتیجه کاهش پیچیدگی محاسباتی می‌تواند در آموزش مدل پیشنهادی و بهبود قابلیت تعمیم آن، به‌دلیل محدود بودن اندازه پایگاه داده، مؤثر باشد. همچنین، به‌دلیل سادگی مدل‌های پیشنهادی می‌توان از این روش‌ها در دستگاه‌های هوشمند قابل حمل در خانه یا بیمارستان برای پیش‌بینی SCD استفاده کرد.

نسخه عمیق این مدل‌ها را می‌توان برای پایگاه داده بزرگ‌تر با دامنه وسیع‌تری از علل SCD پیاده‌سازی کرد؛ زیرا SCD می‌تواند به هر دلیلی، غیر از فیبریلاسیون بطنی، رخ دهد. بنابراین، گسترش پایگاه داده این امکان را می‌دهد که علل دیگر، به‌جز فیبریلاسیون بطنی و همچنین عوامل دیگری مانند سن و جنسیت، در پیش‌بینی SCD بررسی شود. نکته دیگر این است که در این مطالعه از ثبت ECG دوکاناله استفاده شد. استفاده از ثبت‌های دوازده‌کاناله می‌تواند در پژوهش‌های آینده بررسی شوند. به‌علاوه، در نظر گرفتن مفاهیمی مانند مکانیسم توجه در مدل‌های پیشنهادی و اعمال آن روی بخش‌های مهم سیگنال از ECG مانند قطعات ST، به‌جای استفاده از کل سیگنال ECG برای استخراج ویژگی‌های مورفولوژیکی نیز می‌تواند نتایج پیش‌بینی را بهبود دهد.

نتیجه‌گیری

در این تحقیق دو مدل مبتنی بر شبکه عصبی پیچشی ارائه شد. مدل اول مبتنی بر شبکه‌های عصبی پیچشی یک‌بعدی است که دقت این مدل در پیش‌بینی مرگ ناگهانی قلبی ۹۶ درصد است. مدل دوم، که مبتنی بر شبکه‌های عصبی پیچشی دوبعدی است، توانست با تبدیل سیگنال‌های ECG به تصاویر دوبعدی و استفاده از آن‌ها به‌عنوان ورودی، با دقت ۹۹ درصد مرگ ناگهانی قلبی را پیش‌بینی کند. همچنین، در این پژوهش طبقه‌بندی سه کلاسه (نرمال، قبل از وقوع مرگ ناگهانی قلبی و نارسایی قلبی) نیز با هر دو مدل پیشنهادی انجام شد که به‌ترتیب به دقت ۹۷/۸۵ و ۹۹ با شبکه‌های عصبی پیچشی یک‌بعدی و دوبعدی رسید.

برای بررسی قابلیت تعمیم مدل‌های پیشنهادی، عملکرد مدل‌ها روی یک پایگاه داده مجزا نیز بررسی و تلاش شد با ارائه مدل‌های کم‌عمق، که مبتنی بر شبکه عصبی پیچشی هستند، ویژگی‌ها به‌طور خودکار استخراج شوند و دوره پیش‌بینی به شصت دقیقه قبل از وقوع SCD، با دقت بیشتری افزایش یابد. این گسترش بازه پیش‌بینی به شصت دقیقه قبل از وقوع مرگ، قبلاً تنها در یک مطالعه بررسی شده است.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

داده‌های این پژوهش در دسترس عموم قرار دارد
(<https://physionet.org>).

حامی مالی

این مقاله حامی مالی ندارد.

مشارکت نویسندگان

مشارکت نویسندگان در این پژوهش به این صورت است: سارا تواضع (نویسنده اول): طراحی مطالعه، آماده‌سازی داده‌ها، تجزیه و تحلیل داده‌ها، نگارش و ویراستاری مقاله؛ فریده ابراهیمی (نویسنده دوم و نویسنده مسئول مکاتبات): ایده کلی، طراحی مطالعه، تجزیه و تحلیل داده‌ها، نگارش و ویراستاری مقاله.

تعارض منافع

در این مقاله تعارض منافع وجود ندارد.

تشکر و قدردانی

این پژوهش حاصل پایان‌نامه کارشناسی ارشد به شماره ۱۲۱۹ پ (ع) در دانشگاه صنعتی نوشیروانی بابل است. بدین وسیله از تمام استادان و کارکنان دانشگاه تشکر می‌کنیم.

References

1. Capucci A. Sudden cardiac death. Informa Healthcare.
2. Malik A, Brito D, Vaqar S, Chhabra L. Congestive heart failure.
3. Liu T, Si Y, Yang W, Huang J, Yu Y, Zhang G, Zhou R. Inter-patient congestive heart failure detection using ECG-convolution-vision transformer network. *Sensors*. 2022 Apr 25;22(9):3283. [[10.3390/s22093283](#)] [[PMID](#)]
4. Ebrahimzadeh E, Pooyan M. Early detection of sudden cardiac death by using classical linear techniques and time-frequency methods on electrocardiogram signals. *Journal of Biomedical science and Engineering*. 2011 Nov 17;4(11):699-706.
5. Ebrahimzadeh E, Manuchehri MS, Amoozegar S, Araabi BN, Soltanian-Zadeh H. A time local subset feature selection for prediction of sudden cardiac death from ECG signal. *Medical & biological engineering & computing*. 2018 Jul;56(7):1253-70. [[10.1007/s11517-017-1764-1](#)] [[PMID](#)]
6. Sheela CJ, Vanitha L. Prediction of sudden cardiac death using support vector machine. In 2014 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2014] 2014 Mar 20 (pp. 377-381). IEEE.
7. Murugappan M, Murugesan L, Jerritta S, Adeli H. Sudden cardiac arrest (SCA) prediction using ECG morphological features. *Arabian Journal for Science and Engineering*. 2021 Feb;46(2):947-61.
8. Acharya UR, Fujita H, Sudarshan VK, Sree VS, Eugene LW, Ghista DN, San Tan R. An integrated index for detection of sudden cardiac death using discrete wavelet transform and nonlinear features. *Knowledge-Based Systems*. 2015 Jul 1;83:149-58.
9. Amezcua-Sanchez JP, Valtierra-Rodriguez M, Adeli H, Perez-Ramirez CA. A novel wavelet transform-homogeneity model for sudden cardiac death prediction using ECG signals. *Journal of medical systems*. 2018 Oct;42(10):176. [[10.1007/s10916-018-1031-5](#)] [[PMID](#)]
10. Lai D, Zhang Y, Zhang X, Su Y, Heyat MB. An automated strategy for early risk identification of sudden cardiac death by using machine learning approach on measurable arrhythmic risk markers. *IEEE Access*. 2019 Jul 1;7:94701-16.
11. Piña-Vega R, Valtierra-Rodriguez M, Perez-Ramirez CA, Amezcua-Sanchez JP. Early prediction of sudden cardiac death using fractal dimension and ecg signals. *Fractals*. 2021 May 16;29(03):2150077.
12. Vargas-Lopez O, Amezcua-Sanchez JP, De-Santiago-Perez JJ, Rivera-Guillen JR, Valtierra-Rodriguez M, Toledano-Ayala M, Perez-Ramirez CA. A new methodology based on EMD and nonlinear measurements for sudden cardiac death detection. *Sensors*. 2019 Dec 18;20(1):9. [[10.3390/s20010009](#)] [[PMID](#)]
13. Saragih YV, Isa SM. CNN performance improvement using wavelet packet transform for SCA prediction. *J. Theor. Appl. Inf. Technol*. 2022 Sep 30;100:5458-68.
14. Centeno-Bautista MA, Rangel-Rodriguez AH, Perez-Sanchez AV, Amezcua-Sanchez JP, Granados-Lieberman D, Valtierra-Rodriguez M. Electrocardiogram analysis by means of empirical mode decomposition-based methods and convolutional neural networks for sudden cardiac death detection. *Applied Sciences*. 2023 Mar 10;13(6):3569.
15. Porumb M, Iadanza E, Massaro S, Pecchia L. A convolutional neural network approach to detect congestive heart failure. *Biomedical Signal Processing and Control*. 2020 Jan 1;55:101597.
16. Nolle FM, Badura FK, Catlett JM, Bowser RW, Sketch MH. CREI-GARD, a new concept in computerized arrhythmia monitoring systems. *Computers in Cardiology*. 1986 Oct;13(1):515-8.
17. Baim DS, Colucci WS, Monrad ES, Smith HS, Wright RF, Lanoue A, Gauthier DF, Ransil BJ, Grossman W, Braunwald E. Survival of patients with severe congestive heart failure treated with oral milrinone. *Journal of the American College of Cardiology*. 1986 Mar 1;7(3):661-70. [[10.1016/s0735-1097\(86\)80478-8](#)] [[PMID](#)]
18. Meintjes A, Lowe A, Legget M. Fundamental heart sound classification using the continuous wavelet transform and convolutional neural networks. In 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC) 2018 Jul 18 (pp. 409-412). IEEE. [[10.1109/EMBC.2018.8512284](#)] [[PMID](#)]
19. Lilly JM, Olhede SC. Generalized Morse wavelets as a superfamily of analytic wavelets. *IEEE Transactions on Signal Processing*. 2012 Jul 31;60(11):6036-41.
20. O'shea K, Nash R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. 2015 Nov 26.
21. Albawi S, Mohammed T, Al-Zawi S. Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) 2017 Aug 21 (pp. 1-6).
22. Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. 2021 Jun 10;33(12):6999-7019. [[10.1109/TNNLS.2021.3084827](#)] [[PMID](#)]
23. Aloysius N, Geetha M. A review on deep convolutional neural networks. In 2017 international conference on communication and signal processing (ICCSP) 2017 Apr 6 (pp. 0588-0592). IEEE.
24. Goyal V, Jassal DS, Dhalla NS. Pathophysiology and prevention of sudden cardiac death. *Canadian journal of physiology and pharmacology*. 2016;94(3):237-44. [[10.1139/cjpp-2015-0366](#)] [[PMID](#)]
25. Fujita H, Acharya UR, Sudarshan VK, Ghista DN, Sree SV, Eugene LW, Koh JE. Sudden cardiac death (SCD) prediction based on nonlinear heart rate variability features and SCD index. *Applied Soft Computing*. 2016 Jun 1;43:510-9.
26. Murugappan M, Murugesan L, Omar I, Khatun S, Murugappan S. Time domain features based sudden cardiac arrest prediction using machine learning algorithms. *Journal of Medical Imaging and Health Informatics*. 2015 Nov;5(6):1267-71.
27. Acharya UR, Fujita H, Sudarshan VK, Ghista DN, Lim WJ, Koh JE. Automated prediction of sudden cardiac death risk using Kolmogorov complexity and recurrence quantification analysis features extracted from HRV signals. In 2015 IEEE international conference on systems, man, and cybernetics 2015 Oct 9 (pp. 1110-1115). IEEE.
28. Eltrass AS, Tayel MB, Ammar AI. Automated ECG multi-class classification system based on combining deep learning features with HRV and ECG measures. *Neural Computing and Applications*. 2022 Jun;34(11):8755-75.

29. Rahul J, Sharma LD. Automatic cardiac arrhythmia classification based on hybrid 1-D CNN and Bi-LSTM model. *Biocybernetics and Biomedical Engineering*. 2022 Jan 1;42(1):312-24.
30. Ahmed AA, Ali W, Abdullah TA, Malebary SJ. Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model. *Mathematics*. 2023 Jan 20;11(3):562.
31. Izci E, Ozdemir MA, Degirmenci M, Akan A. Cardiac arrhythmia detection from 2d ecg images by using deep learning technique. In 2019 medical technologies congress (TIPTEKNO) 2019 Oct 3 (pp. 1-4). IEEE.
32. Khazaei M, Raeisi K, Goshvarpour A, Ahmadzadeh M. Early detection of sudden cardiac death using nonlinear analysis of heart rate variability. *Biocybernetics and Biomedical Engineering*. 2018 Jan 1;38(4):931-40.
33. Devi R, Tyagi HK, Kumar D. A novel multi-class approach for early-stage prediction of sudden cardiac death. *Biocybernetics and Biomedical Engineering*. 2019 Jul 1;39(3):586-98.
34. Ebrahimzadeh E, Foroutan A, Shams M, Baradaran R, Rajabion L, Joulani M, Fayaz F. An optimal strategy for prediction of sudden cardiac death through a pioneering feature-selection approach from HRV signal. *Computer methods and programs in biomedicine*. 2019 Feb 1;169:19-36.
35. Shi M, He H, Geng W, Wu R, Zhan C, Jin Y, Zhu F, Ren S, Shen B. Early detection of sudden cardiac death by using ensemble empirical mode decomposition-based entropy and classical linear features from heart rate variability signals. *Frontiers in physiology*. 2020 Feb 25;11:118.
36. Tavazo, S., Ebrahimi, F. "Sudden Cardiac Death Prediction by Fusing Electrocardiogram and Heart Rate Variability Signals", *International Journal of Engineering*, 2025; 38(1): 86-98.



Authors retain the copyright and full publishing rights.

Published by [Ahvaz Jundishapur University of Medical Science](#). This article is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 (<https://creativecommons.org/licenses/by-nc/4.0/>).