



## Detection of Fetal QRS Complex from Non-Invasive Abdominal ECG Signals using Deep Learning Methods

Esmaeili Alidash, Kimia<sup>1</sup> / Danandeh Hesar, Hamed<sup>2\*</sup>

<sup>1</sup> - M.Sc. Student, Faculty of Biomedical Engineerin, Sahand University of Technology, Tabriz, Iran

<sup>2</sup> - Assistant Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

### ARTICLE INFO

DOI: 10.22041/ijbme.2024.2027136.1897

Received: 23 April 2024

Revised: 29 October 2024

Accepted: 24 November 2024

### KEYWORDS

*Detection of Fetal QRS Complex*  
*Fetal Heart Rate*  
*Deep Learning Methods*

### ABSTRACT

Heart defects are the leading cause of birth defect-related deaths. Monitoring fetal electrocardiogram (FECG) is very important for early detection of heart defects and abnormal FHR patterns. The detection of QRS complexes in FECG signals has a notable role in determining benchmarks correlated with fetal health e.g. fetal heart rate, intervals between each heartbeat, identification of congenital heart diseases, distress, Hypoxia etc. In this study a novel and automated approach based on deep learning methods has been introduced through applying which we're be capable of detecting fetal QRS complexes from FECG signals. Data used in this experiment are collected from set-a of PhysioNet/computing in the cardiology challenge database (NI-FECGDB). This study proposes a 1-D Convolutional neural network architecture. The architecture of neural network consists of 5 convolutional layers, 7 batch normalization layers, 3 dropout layers and 3 dense layers. First step is consisted of preprocessing the data. In this step the data is being prepared to be used by the suggested approach through changing scale input signal, data augmentation and also building annotations that are applicable to the suggested network. Next step is consisted of application of the suggested algorithm. The performance of suggested method is the evaluated using evaluation criteria such as accuracy, mean error square, F1-score, sensitivity, specificity and precision, and following that the calculated results has been compared to the accumulated results of other studies done on NI-FECGDB database. In this study several methods have been used for evaluating the suggested neural network. In the best method accuracy, sensitivity, specificity and precision of the suggested method in detection of fetal QRS complex is 96.79%, 97.91%, 92.79% and 97.88% respectively. It is noteworthy that some of innovations of the suggested method are the capability of training the suggested network with only 20 of AECG signals and not removing maternal ECG from AECG signals.

### \*Corresponding Author


**Address:** Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

**Postal Code:** 51335-1996

**E-Mail:** danandeh@sut.ac.ir

**Tel:** +98-41-33458413





## شناسایی کمپلکس QRS جنین از ثبت غیرتهاجمی سیگنال الکتروکاردیوگرام شکمی به کمک روش‌های یادگیری ژرف

اسمعیلی علیدانش، کیمیا<sup>۱</sup> / داننده حصار، حامد<sup>۲\*</sup>

<sup>۱</sup> - دانشجوی کارشناسی ارشد، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران  
<sup>۲</sup> - استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2027136.1897

پذیرش: ۴ آذر ۱۴۰۳

بازنگری: ۸ آبان ۱۴۰۳

ثبت در سامانه: ۴ اردیبهشت ۱۴۰۳

### چکیده

### واژه‌های کلیدی

نارسایی‌های قلبی مادرزادی یکی از دلایل اصلی مرگ‌های مرتبط با نارسایی در زمان تولد است. پایش سیگنال الکتروکاردیوگرام قلب جنین (FECG) در تشخیص زودهنگام نارسایی‌های قلبی و الگوهای غیرطبیعی در ضربان قلب موثر و حائز اهمیت است. تشخیص کمپلکس QRS در سیگنال FECG در تعیین معیارهای مرتبط با سلامت جنین هم‌چون نرخ ضربان قلب جنین، تشخیص بیماری‌های قلبی مادرزادی، دیسترس، هیپوکسی جنین و برخی از بیماری‌های دیگر نقش به‌سزایی دارد. از این رو در این مطالعه روشی نوین و خودکار مبتنی بر روش‌های یادگیری عمیق ارائه گردیده است که از این طریق می‌توان اقدام به شناسایی کمپلکس QRS جنین از سیگنال ECG شکمی (AECG) نمود. پایگاه داده‌ی مورد استفاده در این مطالعه برگرفته از پایگاه داده‌ی معرفی شده در مجموعه‌ی a از چالش ۲۰۱۳ فیزیونت است. در مطالعه‌ی حاضر استفاده از یک معماری شبکه‌ی عصبی کانولوشنی (CNN) یک‌بعدی پیشنهاد شده است. شبکه‌ی عمیق پیشنهادی دارای ۲۰ لایه شامل ۵ لایه کانولوشنی، ۷ لایه نرمال‌سازی دسته‌ای، ۳ لایه حذف تصادفی و ۳ لایه متراکم است. در گام اول از الگوریتم پیشنهادی ابتدا سیگنال AECG تحت پیش‌پردازش قرار گرفته، سپس با تغییر اندازه‌ی سیگنال ورودی، داده‌افزایی و هم‌چنین ساخت برجسب‌های قابل استفاده توسط شبکه، داده‌ها برای استفاده توسط شبکه‌ی عمیق پیشنهادی آماده شده است. در گام بعد داده‌ها با هدف آموزش و ارزیابی به عنوان ورودی در اختیار شبکه‌ی پیشنهادی قرار داده شده است. روش پیشنهادی به کمک معیارهایی هم‌چون صحت، میانگین مربعات خطا، امتیاز F1، حساسیت، اختصاصیت و دقت مورد ارزیابی قرار گرفته و در ادامه با نتایج حاصل از سایر تحقیقات صورت گرفته روی این پایگاه داده، مقایسه شده است. در این مطالعه چندین رویکرد برای ارزیابی شبکه‌ی پیشنهادی مورد استفاده قرار گرفته است. در بهترین رویکرد صحت، حساسیت، اختصاصیت و دقت شبکه‌ی پیشنهادی در شناسایی کمپلکس QRS جنین به ترتیب معادل ۹۶/۷۹٪، ۹۷/۹۱٪، ۹۲/۷۹٪ و ۹۷/۸۸٪ است. از جمله نوآوری‌های شبکه‌ی پیشنهادی عدم حذف الکتروکاردیوگرام مادر و قابلیت آموزش شبکه تنها با استفاده از ۲۰ سیگنال از ثبت‌های AECG است.

شناسایی کمپلکس QRS جنین  
نرخ ضربان قلب جنین  
روش‌های یادگیری عمیق

### \*نویسنده‌ی مسئول

نشانی: گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

تلفن: ۳۳۴۵۸۴۱۳-۴۱-۹۸+

پست الکترونیک: danandeh@sut.ac.ir

کد پستی: ۵۱۳۳۵-۱۹۹۶



## ۱- مقدمه

ناهنجاری قلبی از جمله ناهنجاری‌های رایج در زمان تولد بوده و از دلایل اصلی مرگ‌های مرتبط با ناهنجاری در زمان تولد به شمار می‌آید [۱]. منشا بسیاری از نارسایی‌های قلبی و بیماری‌های ثانویه ناشی از آن مربوط به دوران بارداری و جنینی است [۲]. طبق گزارش‌ها تخمین زده می‌شود که تقریباً یک نوزاد از هر ۱۲۵ نوزاد با نوعی از ناهنجاری‌های قلبی مادرزادی به دنیا می‌آید [۱، ۲]. نرخ ضربان قلب جنین<sup>۱</sup> (FHR) به عنوان یکی از مهم‌ترین علائم حیاتی جنین، به پزشکان اجازه‌ی ارزیابی شرایط فیزیولوژیکی جنین را می‌دهد و از این رو پایش FHR با استفاده از سیگنال الکتروکاردیوگرام جنین<sup>۲</sup> (FECG) به طور گسترده در مانیتورینگ دوره‌های زایمان و قبل از زایمان<sup>۳</sup> مورد استفاده قرار گرفته است. علاوه بر این، الگوهای غیرطبیعی در ضربان قلب جنین مثل کاهش یا افزایش سریع در FHR می‌تواند بیان‌گر رویداد اضطراب جنین باشد [۳]. هم‌چنین کمبود اکسیژن و اکسیژن‌رسانی ناکافی به جنین که می‌تواند به شکل بالقوه‌ی منجر به آسیب‌های بازگشت‌ناپذیر به ارگان‌های حیاتی جنین شود، با بررسی تغییرات FHR قابل شناسایی است [۴]. تغییراتی که در عرض کمپلکس‌های QRS سیگنال FECG رخ می‌دهد اطلاعاتی با جزئیات بیشتر راجع به حالات قلب جنین در اختیار متخصصان قرار می‌دهد [۵].

آنالیز شکل موج سیگنال FECG دیدگاهی کلی از نقص‌های قلبی مادرزادی در قلب جنین ارائه می‌دهد [۶]. با آنالیز سیگنال FECG، نارسایی‌های قلبی که منجر به مرگ جنین می‌شوند در طول زایمان قابل پیش‌گیری خواهند بود [۵]. لذا تکنیک‌های موثر برای پایش شرایط قلبی جنین در دوره‌ی بارداری و زایمان مورد نیاز است [۳]. البته آنالیز سیگنال غیرتهاجمی ECG شکمی<sup>۴</sup> (AECG) کار آسانی نیست زیرا این سیگنال به شدت توسط تداخلات و نویزهایی مثل ECG مادر، تداخلات برق شهری<sup>۵</sup>، فعالیت الکتریکی عضلات مادر (EMG)، انحرافات خط مبنای<sup>۶</sup>، آرتیفکت‌های حرکتی و غیره آلوده است. شناسایی کمپلکس QRS جنین در سیگنال AECG یکی از چالش‌های مهم بوده و هدف این مقاله ارائه‌ی یک روش بر مبنای شبکه‌های عصبی کانولوشنی<sup>۷</sup> (CNN) جهت شناسایی کمپلکس QRS جنین و تشخیص FHR از سیگنال AECG است.

این مقاله در ۶ بخش تدوین شده است. بخش ۲ شامل مروری بر پیشینه‌ی پژوهش و بررسی روش‌های موجود در این زمینه می‌باشد. بخش ۳ شامل مواد و جزئیات الگوریتم ارائه شده برای تشخیص QRS جنین از سیگنال AECG است. در بخش ۴ پنج رویکرد مختلف در پیاده‌سازی شبکه پیشنهاد شده و نتایج هر کدام از آن‌ها به طور جداگانه ارائه شده است. در بخش ۵ نتایج به دست آمده از این مطالعه با مطالعات دیگر مقایسه شده است. بخش ۶ نیز شامل یک جمع‌بندی کلی روی این تحقیق است.

## ۲- مروری بر پیشینه‌ی پژوهش

در سال‌های اخیر رویکردهای یادگیری عمیق به شکل فزاینده‌ای در حوزه‌ی تحلیل سری‌های زمانی به کار گرفته شده است. در این سال‌ها مطالعات متعددی در زمینه‌ی به کارگیری روش‌های یادگیری عمیق در حوزه‌ی پردازش سیگنال FECG صورت گرفته است. در مطالعه‌ی [۳] یک روش یادگیری عمیق بر اساس شبکه‌های عصبی کانولوشنی (CNN) برای شناسایی کمپلکس‌های QRS جنین پیشنهاد شده است. این روش به لحاظ این که در آن نیازی به حذف سیگنال ECG مادر نیست، با روش‌های متعارف پیشین متفاوت است. پایگاه داده‌ی مورد استفاده در این مطالعه، پایگاه داده‌ی ثبت غیرتهاجمی FECG فیزیونت<sup>۸</sup> (NI-FECGDB) [۷] است. در این مطالعه با استفاده از آنتروپی نمونه به ارزیابی کیفیت سیگنال‌ها پرداخته شده و کانال‌های دارای کیفیت پایین مورد استفاده قرار نگرفته است. مدل CNN پیشنهادی در این مقاله شامل سه لایه‌ی کانولوشنی و یک لایه‌ی متراکم<sup>۹</sup> است که از یک سیگنال تک‌کاناله‌ی AECG به عنوان ورودی استفاده می‌کند. باید توجه داشت که در این مقاله علاوه بر داده‌های موجود در NI-FECGDB از داده‌ی مصنوعی نیز برای آموزش استفاده شده است. در مطالعه‌ی دیگر مدل CNN پیشنهادی دارای معماری عمیق‌تری است تا عمل‌کرد بهتری در استخراج ویژگی‌های کمپلکس QRS جنین از سیگنال AECG داشته باشد [۵]. این معماری شامل ۷ لایه‌ی کانولوشنی و دو لایه‌ی تمام متصل<sup>۱۰</sup> بوده که روی سیگنال چندکاناله‌ی AECG اعمال گردیده و هم‌چنین خروجی مدل به منظور بهبود دقت تشخیص کمپلکس QRS جنین از سیگنال AECG تحت پردازش ثانویه

<sup>۶</sup> Baseline Drifts

<sup>۷</sup> Convolutional Neural Network

<sup>۸</sup> Non-Invasive FECG Database

<sup>۹</sup> Dense Layer

<sup>۱۰</sup> Fully-Connected Layer

<sup>۱</sup> Fetal Heart Rate

<sup>۲</sup> Fetal Electrocardiogram

<sup>۳</sup> Antepartum related to the Period before Childbirth

<sup>۴</sup> Abdominal ECG

<sup>۵</sup> Powerline Interference

AECG به مولفه‌های جنین و مادر صورت گرفته است. روش معرفی شده در این مقاله ترکیبی از شبکه‌ی CNN با شبکه‌ی LSTM است. این شبکه روی پایگاه داده‌ی خصوصی ثبت شده توسط مرکز پزشکی ماکسیم<sup>۵</sup> به توافق درصد مثبت (PPA) ۹۷/۳٪ و در پایگاه داده‌ی NI-FECGDB به توافق درصد مثبت (PPA) ۹۹/۶٪ دست یافته است. مطالعه‌ی [۱۲] با هدف شناسایی سیگنال FECG از ثبت‌های AECG یک روش مبتنی بر یادگیری عمیق را پیشنهاد داده و از سیگنال‌های AECG چندکاناله به عنوان ورودی استفاده کرده است. تکنیک معرفی شده شامل چندین مرحله‌ی پیش‌پردازش بوده و این سیگنال‌ها با اعمال تبدیل فوریه‌ی زمان-کوتاه<sup>۶</sup> به طیف نگاره<sup>۷</sup> تبدیل شده است. سپس این طیف نگاره‌ها با هدف طبقه‌بندی به شبکه‌ی CNN دوبعدی و سپس یک لایه‌ی تمام متصل داده شده است. پس از پردازش ثانویه‌ی نتایج، این روش در نهایت به صحت ۹۵/۲۰٪ دست یافته است. در یک مطالعه‌ی دیگر محققان با استفاده از سیگنال‌های تک‌کاناله‌ی AECG موجود در سه پایگاه داده به استخراج الگوهای سیگنال FECG پرداخته‌اند [۱۳]. این مطالعه از مدل توجه دوگانه<sup>۸</sup> در معماری شبکه‌ی CNN و LSTM بهره برده است. اندازه‌ی پنجره‌ی پیش‌بینی در این مطالعه معادل ۲۰۰ میلی‌ثانیه در نظر گرفته شده است. نتایج صحت، امتیاز F1، حساسیت و دقت به دست آمده در این مطالعه به ترتیب برابر با ۹۶/۲۶٪، ۹۸/۰۲٪، ۹۷/۳۸٪ و ۹۸/۶۸٪ است. در پژوهش [۱۴] یک معماری مبتنی بر شبکه‌ی خودرمنزنگار پیشنهاد شده است که در آن ECG مادر و جنین در خروجی رمزگشا به طور جداگانه تخمین زده می‌شود. پس از جداسازی سیگنال FECG، پیک R جنین شناسایی می‌گردد. امتیاز F1، دقت و حساسیت روش پیشنهادی این مطالعه به ترتیب برابر با ۹۶/۹۱٪، ۹۷/۴۵٪ و ۹۵/۷۴٪ است. در مقاله‌ی [۱۵] یک رویکرد نوین بر اساس اینترنت اشیا پزشکی<sup>۹</sup> ارائه شده که در آن با استفاده از روش‌های یادگیری عمیق بدون حذف مولفه‌های سیگنال ECG مادر، کمپلکس QRS جنین شناسایی شده است. این مطالعه پس از تبدیل سیگنال‌های AECG به تصاویر زمانی-فرکانسی آن را به عنوان ورودی به شبکه‌ی عمیق می‌دهد. برای استخراج تصاویر زمانی-فرکانسی از تبدیل هیلبرت-هوانگ (HHT) و تبدیل استاکول<sup>۱۰</sup> (ST)

قرار گرفته است. پایگاه مورد استفاده در این مقاله نیز همان NI-FECGDB است. نویسندگان این مقاله به دقت ۹۲/۷۷٪ و حساسیت ۸۹/۰۶٪ دست یافته‌اند. با این وجود، حساسیت به دست آمده در تکنیک معرفی شده در مرجع [۵] به نسبت عمق شبکه‌ی پیشنهادی نسبت به سایر تحقیقات کم‌تر است. در مطالعه‌ی [۸] یک شبکه‌ی پیچشی رمزگذار-رمزگشای باقی‌مانده<sup>۱</sup> (RCED-Net) برای استخراج سیگنال FECG از سیگنال تک‌کاناله‌ی AECG ارائه شده است. این تکنیک نیازمند وجود FECG هدف در طول آموزش شبکه بوده که این FECG هدف برگرفته از داده‌ی مصنوعی می‌باشد و ممکن است در شرایط واقعی که رخدادهای پیچیده سیگنال ثبتی را تحت تاثیر قرار می‌دهند قابل اعتماد نباشد. الگوریتم پیشنهادی در مقاله‌ی [۸] روی پایگاه داده‌ی NI-FECGDB توانسته است به ترتیب به میانگین حساسیت، دقت و امتیاز F1 معادل ۹۶/۰۶٪، ۹۲/۲۵٪ و ۹۴/۱۰٪ دست یابد. در مطالعه‌ی [۹] یک مدل مبتنی بر معماری شبکه‌ی باقی‌مانده<sup>۲</sup> (ResNet) به شکل یک شبکه‌ی یک‌بعدی نوین اکتاو کانولوشنی (OctConv) پیشنهاد شده که برای یادگیری ویژگی‌های فرکانسی پویای موجود در AECG به کار رفته است. استفاده از این روش منجر به کاهش حجم حافظه‌ی مورد نیاز و هزینه‌ی محاسباتی شده است. پایگاه داده‌ی مورد استفاده در این مقاله نیز NI-FECGDB است. در مطالعه‌ی [۱۰] با ترکیب شبکه‌ی CNN و شبکه‌ی حافظه‌ی طولانی کوتاه‌مدت<sup>۳</sup> (LSTM) ارتباطات طولانی‌مدت و کوتاه‌مدت ویژگی‌های AECG کشف شده است تا از این طریق بتوان پیش‌بینی درستی از FHR ارائه داد. الگوریتم پیشنهادی این مطالعه با استفاده از یک پایگاه داده‌ی خصوصی که در حین زایمان ثبت شده، آموزش داده شده و عمل کرد آن روی پایگاه داده‌ی NI-FECGDB ارزیابی شده است. این الگوریتم به ترتیب به توافق درصد مثبت<sup>۴</sup> (PPA) ۹۲/۱٪ و ۹۸/۱٪ در دو پایگاه داده‌ی مذکور دست یافته است. این روش در شرایطی که نرخ SNR سیگنال شدیداً پایین است، عمل کرد محدودی دارد و در تخمین FHR در این سیگنال‌ها ناموفق می‌باشد. مطالعه‌ی [۱۱] نیز با استفاده از روش‌های یادگیری عمیق روشی برای استخراج FHR از سیگنال‌های AECG پیشنهاد کرده است. در این مطالعه استخراج FECG به وسیله‌ی تجزیه‌ی سیگنال

<sup>۶</sup> Short-Time Fourier Transform

<sup>۷</sup> Spectrogram

<sup>۸</sup> Dual Attention Model

<sup>۹</sup> Internet of Medical Things

<sup>۱۰</sup> Stockwell Transform

<sup>۱</sup> Residual Convolutional Encoder-Decoder Network

<sup>۲</sup> Residual Network

<sup>۳</sup> Long Short-Term Memory Networks

<sup>۴</sup> Positive Percent Agreement

<sup>۵</sup> Máxima Medical Center

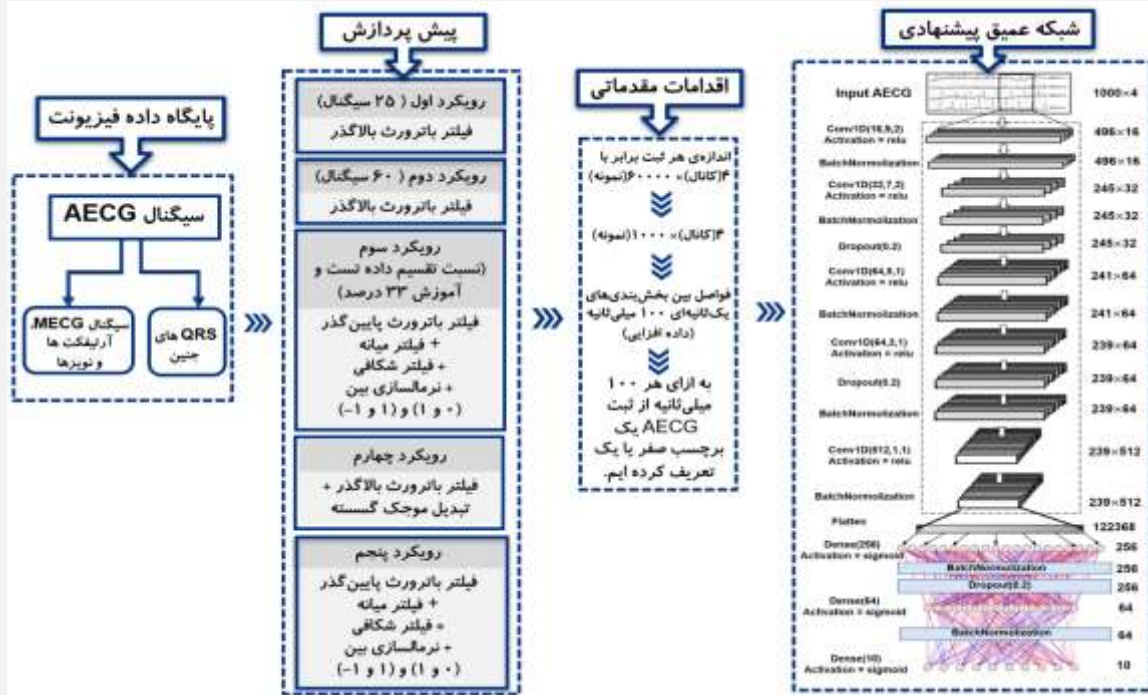
رفتن دقت شبکه‌ی عمیق پیشنهادی شده است. هم‌چنین در این مطالعه با در نظر گرفتن غنای پایگاه داده و به کارگیری روش‌های داده‌افزایی، بدون نیاز به شبکه‌های از پیش آموزش دیده، نتایج قابل قبولی به دست آمده است. در این مطالعه داده‌ها برای آموزش به بخش‌های یک ثانیه‌ای با هم‌پوشانی ۹۰ درصدی بخش‌بندی شده است. هم‌چنین با یک روش ابتکاری، برای هر بخش یک ثانیه‌ای ۱۰ برچسب به ازای هر بازه‌ی ۱۰۰ میلی‌ثانیه تخصیص داده شده که هر کدام بیان‌گر وقوع یا عدم وقوع کمپلکس QRS جنین در آن بازه است.

در این مطالعه ۵ رویکرد متفاوت برای آموزش شبکه‌ی عمیق با استفاده از سیگنال‌های مختلف معرفی شده است. در خلال اجرای این رویکردها مشخص شده که شبکه می‌تواند با استفاده از ۲۵ سیگنال (۲۰ سیگنال آموزشی و ۵ سیگنال تست) آموزش داده شود و رویکرد اول این مقاله در همین راستا معرفی شده که با حداقل پیش‌پردازش به نتایج چشم‌گیری دست یافته است. هم‌چنین با استفاده از داده‌های کم‌تر از ۲۵ سیگنال نیز آزمایش‌هایی انجام شده اما بهترین نتایج با ۲۵ سیگنال به دست آمده است. در رویکرد دوم با استفاده از ۶۰ سیگنال، تاثیر اعمال توابع پنجره در مرحله‌ی پیش‌پردازش بررسی شده است. در رویکرد سوم ادعای مبنی بر توانایی آموزش شبکه با استفاده از ۲۵ سیگنال (۲۰ سیگنال آموزشی) مورد بررسی بیشتر قرار گرفته است. در این رویکرد با تغییر دادن نسبت تقسیم داده‌ی آموزش و تست به ۳۳ درصد (۲۰ سیگنال آموزش و ۴۰ سیگنال تست) شبکه‌ی پیشنهادی به چالش کشیده شده است. با توجه به نتایج رویکرد سوم می‌توان استنباط کرد که نتایج به دست آمده در این رویکرد حتی در شرایطی که شبکه به چالش کشیده شده نیز قابلیت مقایسه با نتایج گزارش شده در دیگر مقالات را دارد و حتی در برخی موارد نتایج بالاتری نیز به دست آمده است. این نتایج ادعای این مقاله مبنی بر قابلیت آموزش شبکه با استفاده از ۲۰ سیگنال آموزشی را تایید می‌کند. در رویکرد چهارم تاثیر به کارگیری تبدیل موجک گسسته روی نتایج حاصل از شبکه‌ی پیشنهادی بررسی و گزارش شده است. در نهایت در رویکرد پنجم با اعمال سه مرحله پیش‌پردازش با استفاده از فیلترهای باترورث، میانه و شکافی، نتایج به دست آمده بررسی و گزارش شده است. در بخش بعد به معرفی روش پیشنهادی پرداخته شده که شامل پنج رویکرد مختلف برای شناسایی کمپلکس QRS جنین با استفاده از معماری شبکه‌ی عمیق پیشنهادی در شکل (۱) است.

استفاده شده است. پایگاه داده‌ی NI-FECGDB برای ارزیابی عمل‌کرد مورد استفاده قرار گرفته است. الگوریتم پیشنهادی از مدل‌هایی که با استفاده از یادگیری انتقالی<sup>۱</sup> پیش‌تر آموزش دیده‌اند برای طبقه‌بندی استفاده کرده است. ارزیابی این روش به وسیله‌ی پارامترهای ارزیابی صحت، حساسیت، دقت و امتیاز F1 بررسی شده و به ترتیب مقادیر ۰/۹۱/۳۲، ۰/۸۹/۵۲، ۰/۹۴/۳۷ و ۰/۹۰/۱۲ به دست آمده است. مطالعه‌ی تغییرات FHR به عنوان یک ابزار مفید برای ارزیابی سلامت جنین در حین بارداری و زایمان شناخته شده و از این رو تبدیل به پروسه‌ای حیاتی برای زنان باردار شده است. اما همانطور که پیش‌تر اشاره گردید شناسایی کمپلکس QRS جنین به دلیل آلودگی سیگنال AECG به نویزهای مختلف کار آسانی نیست.

با بررسی مطالعات پیشین مشخص می‌شود که محققان از ترکیب شبکه‌های CNN با LSTM، RCED-Net، OctConv، مدل توجه دوگانه و دیگر شبکه‌های پیچیده استفاده کرده‌اند که برخی از آن‌ها بار محاسباتی بالایی دارد. هدف این مطالعه این است که با استفاده از معماری مناسب CNN، شبکه‌ی CCN به تنهایی و بدون افزودن پیچیدگی‌ها و معماری‌های دیگر، برای شناسایی کمپلکس QRS جنین و تشخیص FHR به کار گرفته شود. این تحقیق بدون استفاده از سایر معماری‌های کمکی، تنها با بهره‌گیری مناسب از لایه‌های کانولوشنی، روشی کارآمد با پیچیدگی پایین برای تشخیص کمپلکس QRS جنین ارائه می‌دهد. یکی از نوآوری‌های این مطالعه، عدم حذف QRS مادر در مراحل پیش‌پردازش است. بلوک دیاگرام کلی روش پیشنهادی در شکل (۱) نشان داده شده است. در ابتدا به نظر می‌رسد که شبکه‌ی پیشنهادی دارای عمق بالایی بوده اما باید توجه داشت که این معماری تنها شامل ۵ لایه‌ی کانولوشنی است. لایه‌های نرمال‌سازی دسته‌ای و لایه‌های حذف تصادفی در این معماری به منظور جلوگیری از مشکلاتی مانند بیش‌برازش، ناپدید شدن گرادیان، انفجار گرادیان و شیف‌ت توزیع داخلی اضافه شده است و به تنهایی پردازش داده‌ها را انجام نمی‌دهند. نتایج چشم‌گیر حاصل از این معماری با استفاده از تنها ۵ لایه‌ی کانولوشنی، بیان‌گر برتری و کارایی شبکه‌ی پیشنهادی است. هم‌چنین در طول آزمایش‌های مختلف مشخص شده است که شبکه می‌تواند تنها با استفاده از ۲۵ سیگنال (۲۰ سیگنال آموزشی و ۵ سیگنال تست) آموزش ببیند. نوآوری دیگر این مطالعه، استفاده از پنجره‌ی پیش‌بینی ۱۰۰ میلی‌ثانیه‌ای در تشخیص QRS جنین بوده که باعث بالا

<sup>۱</sup> Transfer Learning



شکل (۱) - بلوک دیاگرام رویکرد کلی پیشنهادی

رویدادهای پیچیده‌ای وجود دارند که می‌توانند بر کیفیت سیگنال‌های ثبت شده AECG تاثیر بگذارند. بنابراین تمام سیگنال‌های ثبت شده لزوماً با کیفیت نخواهند بود و روش‌های پیشنهادی در این مطالعات تحت تاثیر نسبت سیگنال به نویز (SNR) سیگنال‌های ورودی قرار می‌گیرند. در مراجع [۱۱] و [۱۲] روش‌های پیش‌پردازش به شناسایی و حذف کمپلکس‌های QRS مادر اختصاص یافته‌اند. همچنین در مراجع [۱۰]، [۱۳] و [۱۴] از تکنیک‌هایی مانند فیلترهای باترورث و نرمال‌سازی داده‌ها در مراحل پیش‌پردازش استفاده شده است. در مطالعه‌ی [۹] فیلتر کالمن توسعه یافته به کار گرفته شده و در مرجع [۱۵] از تبدیل‌های هیلبرت-هوانگ<sup>۱</sup> (HHT) استاکول (ST) بهره‌برداری شده است.

در این مقاله روش‌های پیش‌پردازش صرفاً با هدف حذف نویزهای موجود در پایگاه داده اعمال شده و داده‌های با کیفیت پایین‌تر حذف نشده است. با توجه به تنوع روش‌های پیش‌پردازش مورد استفاده در مطالعات دیگر، در پنج رویکرد معرفی شده در این تحقیق، تاثیر روش‌های مختلف پیش‌پردازش بر نتایج به دست آمده بررسی شده و تاثیر سطوح متفاوت پیش‌پردازش بر نتایج حاصل از الگوریتم پیشنهادی مقایسه و گزارش شده است. در ادامه به معرفی روش‌های پیش‌پردازش به کار رفته در هر رویکرد پرداخته شده است.

### ۳- مواد و روش‌ها

#### ۳-۱- پایگاه داده

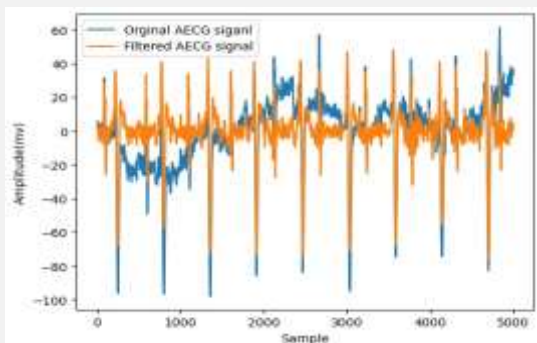
در این مطالعه از مجموعه‌ی داده‌ی a معرفی شده در چالش ۲۰۱۳ فیزیوت (NI-FECGDB) استفاده شده است. تمام داده‌های موجود در چالش متشکل از مجموعه‌ای از ثبت‌های یک دقیقه‌ای از سیگنال AECG است. هر ثبت شامل ۴ کانال از سیگنال AECG بوده که با فرکانس ۱۰۰۰ هرتز نمونه‌برداری شده است. طول هر کانال ۶۰۰۰ نمونه (۶۰ ثانیه) است. از ثبت‌های a<sub>۳۳</sub>، a<sub>۳۸</sub>، a<sub>۴۷</sub>، a<sub>۵۲</sub>، a<sub>۵۴</sub>، a<sub>۷۱</sub> و a<sub>۷۴</sub> به دلیل عدم برخورداری از برچسب درست استفاده نشده است [۱۶]. همچنین ثبت‌های a<sub>۰۱</sub>، a<sub>۰۲</sub>، a<sub>۰۷</sub>، a<sub>۰۹</sub>، a<sub>۱۱</sub>، a<sub>۱۶</sub>، a<sub>۱۸</sub> و a<sub>۴۳</sub> به دلیل عدم ثبت اطلاعات سیگنال AECG در برخی از کانال‌های این ثبت‌ها مورد استفاده قرار نگرفته‌اند. در نهایت از مجموع ۷۵ سیگنال موجود در مجموعه‌ی a از چالش ۲۰۱۳، در این مقاله صرفاً از ۶۰ سیگنال استفاده شده است.

#### ۳-۲- پیش‌پردازش

در مطالعات پیشین، روش‌های متنوعی برای پیش‌پردازش به منظور بهبود عمل‌کرد شبکه‌های پیشنهادی به کار گرفته شده است. در مراجع [۳] و [۸] محققان به گزینش سیگنال‌های با کیفیت پرداخته‌اند اما باید توجه داشت که در شرایط واقعی،

<sup>۱</sup> Hilbert-Huang

(با پنجره‌ی ۰/۲۶ ثانیه) حذف شده است. شکل (۳) نمونه‌ای از اعمال این فیلتر روی یک پنجره‌ی ۶ ثانیه‌ای از کانال سوم ثبت  $a_0^3$  سیگنال AECG را نشان می‌دهد.

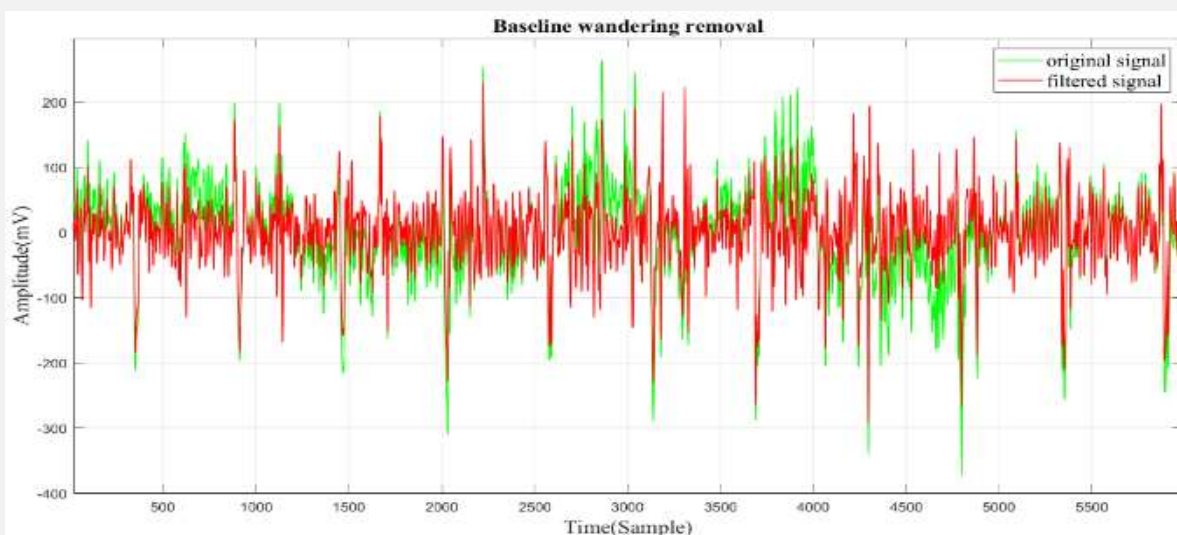


شکل (۲) - اعمال فیلتر میان‌گذر باترورث روی سیگنال AECG، سیگنال اصلی دارای نویز: آبی، سیگنال فیلتر شده: نارنجی

### ۳-۲-۱- فیلتر باترورث

در این مقاله برای حذف نویز انحراف خط مبنای سیگنال AECG از یک فیلتر بالاگذر باترورث مرتبه‌ی ۲ با فرکانس قطع ۵ هرتز استفاده شده است. در شکل (۲) نمونه‌ای از اعمال این فیلتر روی یک پنجره‌ی ۵ ثانیه‌ای از یکی از کانال‌های ثبت  $a_0^3$  نشان داده شده است.

در این مطالعه از رویکرد مقاله‌ی [۱۷] برای حذف انحراف خط مبنا الهام گرفته شده است. در این راستا برای جلوگیری از اعوجاج فرکانسی، حذف انحراف خط مبنا با به کارگیری یک فیلتر پایین‌گذر باترورث مرتبه‌ی ۱ در دو جهت روبه‌جلو و روبه‌عقب (با فرکانس قطع ۳/۱۷ هرتز) انجام شده است. با محاسبه کردن اختلاف بین خط زمینه‌ی محاسبه شده و سیگنال اصلی، سیگنال حاصل از حذف خط مبنا به دست آمده است. سپس آرتیفکت‌های باقی‌مانده در سیگنال که حاصل از حرکت‌های سریع در خط مبنا بوده با استفاده از فیلتر میانه<sup>۱</sup>



شکل (۳) - اعمال فیلتر پایین‌گذر باترورث روی سیگنال AECG، سیگنال اصلی دارای نویز: سبز، سیگنال فیلتر شده: قرمز

بیش‌تر از حد آستانه‌ی تخمینی باشد، مقدار تخمینی جایگزین بازه‌ی مربوطه شده است. در شکل (۴) نمونه‌ای از حذف داده‌های خارج از محدوده روی یک پنجره‌ی ۲۲۰ میلی‌ثانیه‌ای در ثبت  $a_0^3$  نشان داده شده است. در این شکل بازه‌های آلوده به نویز آرتیفکت حرکتی که بالاتر از حد آستانه‌ی تخمینی هستند با رنگ قرمز و مقادیر جایگزین آن‌ها با رنگ آبی مشخص شده است.

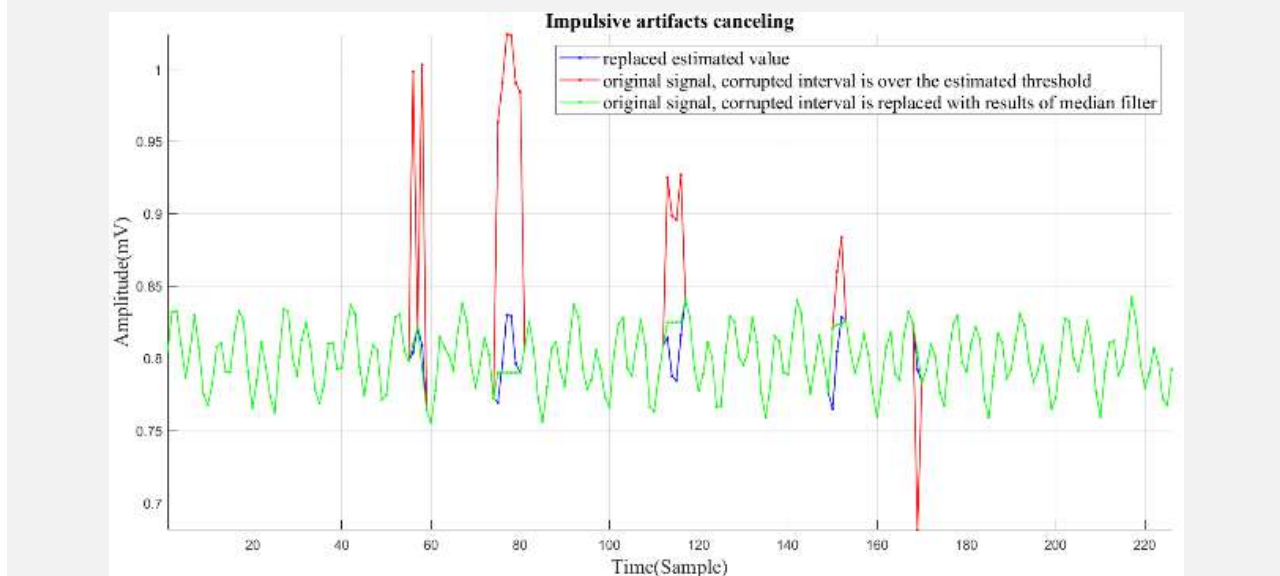
### ۳-۲-۲- جست‌وجو و حذف داده‌های خارج از محدوده

در این مطالعه با الهام گرفتن از روش پیش‌پردازش پیشنهاد شده در مرجع [۱۷] داده‌های خارج از محدوده<sup>۲</sup> حذف شده است. به ازای هر کانال از سیگنال AECG فیلتر میانه با پنجره‌ی ۶۰ میلی‌ثانیه به کار گرفته شده و قدرمطلق تفاضل<sup>۳</sup> بین سیگنال اصلی و سیگنال فیلتر شده با فیلتر میانه محاسبه شده است. در صورتی که قدرمطلق اختلاف بین این دو سیگنال

<sup>۱</sup> Absolute Difference

<sup>۱</sup> Median Filtering

<sup>۲</sup> Outlier



شکل (۴) - اعمال فیلتر میانه روی سیگنال AECG، بازه‌های آلوده به نویز آرتیفکت حرکتی: قرمز، مقادیر تخمینی جایگزین بازه‌ی آلوده به آرتیفکت حرکتی: آبی، سیگنال اصلی که در آن بازه‌های آلوده به نویز آرتیفکت حرکتی با مقادیر حاصل از اعمال فیلتر میانه جای‌گذاری شده است: سبز

بنابراین در بازسازی سیگنال فقط از ضرایب جزئیات سطح ۱ تا ۴ استفاده گردیده است. شکل (۵) نمونه‌ای از اعمال DWT روی یک پنجره‌ی ۲۰ ثانیه‌ای از کانال ۲ ثبت ۳a است.

### ۳-۳- آمادگی داده برای آموزش

در این مطالعه هر ثبت از سیگنال AECG به بخش‌های یک ثانیه‌ای تقسیم‌بندی شده است. فواصل بین بخش‌بندی‌های یک ثانیه‌ای ۱۰۰ میلی‌ثانیه در نظر گرفته شده و این به معنای وجود هم‌پوشانی ۹۰ درصدی بین بخش‌بندی اول و دوم است (شکل ۶). با این کار نوعی داده‌افزایی نیز برای پایگاه داده‌ی مورد استفاده صورت گرفته است. همچنین با توجه به این که برچسب‌های اعلام شده در پایگاه داده صرفاً شامل زمان‌های رخ دادن کمپلکس‌های QRS جنین بوده، با هدف تبدیل این زمان‌ها به برچسب‌های قابل استفاده در شبکه‌ی پیشنهادی به ازای هر ۱۰۰ میلی‌ثانیه از ثبت AECG یک برچسب صفر یا ۱ تعریف شده که صفر معادل عدم وجود پیک QRS جنین و ۱ معادل رخداد QRS جنین در آن ۱۰۰ میلی‌ثانیه است.

در شکل (۷) یک نمونه‌ی یک ثانیه‌ای جدا شده از یک سیگنال نمونه‌ی AECG قابل مشاهده است. مشاهده می‌شود که در نقاطی از سیگنال AECG که QRS جنین رخ داده (ستاره‌ی سبز)، برچسب‌ها معادل عدد ۱ و در سایر نقاط سیگنال AECG برچسب‌ها معادل عدد صفر در نظر گرفته شده است.

### ۳-۲- یکسان‌سازی دامنه‌ی داده‌ها

برای یکسان‌سازی دامنه‌ی ثبت‌ها در بازه‌ی ۱ و ۱- از روابط (۱) تا (۳) استفاده شده است. همچنین با بهره‌گیری از رابطه‌ی (۴) یکسان‌سازی دامنه‌ی ثبت‌ها در بازه‌ی صفر و ۱ صورت گرفته است. در اعمال مرحله‌ی یکسان‌سازی دامنه بر هر سیگنال، ابتدا ماکسیمم و مینیمم همان سیگنال محاسبه شده و سپس عملیات یکسان‌سازی روی آن سیگنال اجرا شده و این فرایند به ازای تمام سیگنال‌ها تکرار شده است.

$$a = \min(AECG) \quad (1)$$

$$b = \max(AECG) \quad (2)$$

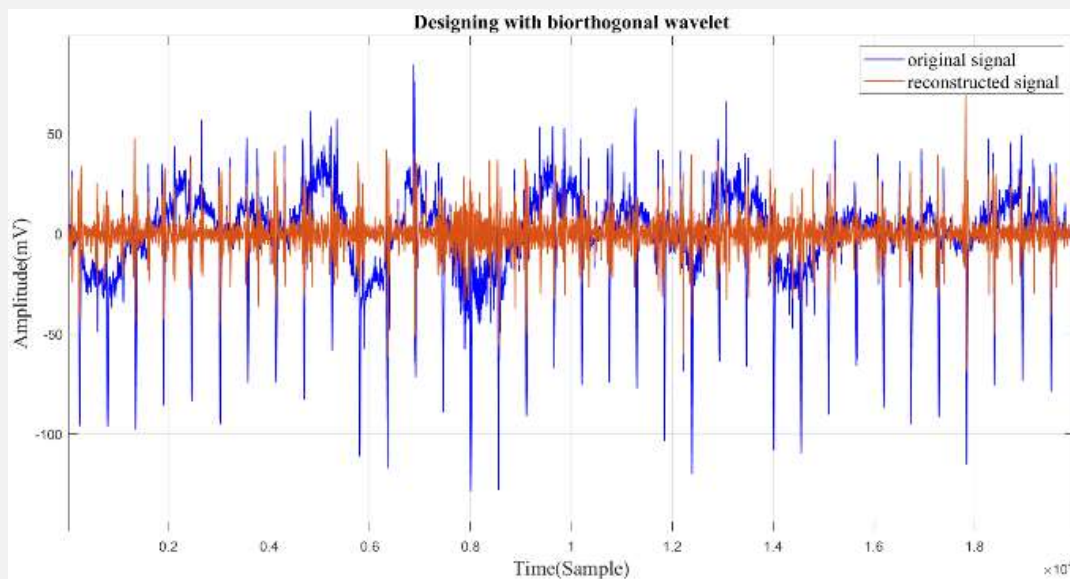
$$normalization = 2 \times \frac{AECG - a}{(b - a)} - 1 \quad (3)$$

$$normalization = \frac{AECG - a}{(b - a)} \quad (4)$$

### ۳-۲-۴- تبدیل موجک گسسته

در یکی از رویکردهای پیشنهادی این مقاله، از تبدیل موجک گسسته<sup>۱</sup> (DWT) در پیش‌پردازش داده‌ها استفاده شده است. در این رویکرد، سیگنال AECG موجود در هر کانال با استفاده از موجک متعامد دوطرفه‌ی ۴/۴ تا ۱۰ سطح تجزیه شده است. کمپلکس‌های QRS جنین و مادر دارای محتوای فرکانسی بالاتری هستند و آزمایش‌ها نشان داده است که اطلاعات مربوط به این کمپلکس‌ها تنها در سطوح تجزیه‌ی ۱ تا ۴ قرار دارند.

<sup>۱</sup> Discrete Wavelet Transform



شکل (۵) - اعمال DWT روی سیگنال AECG، سیگنال اصلی: آبی، سیگنال بازسازی شده: نارنجی


شبکه‌ی پیشنهادی ارائه شده است. این کار با هدف جلوگیری از یادگیری به صورت سری زمانی توسط شبکه و افزایش دقت و مهارت شبکه در رویارویی با داده‌های جدید انجام شده است.

### ۴-۳- معماری شبکه‌ی CNN پیشنهادی

در این مطالعه یک معماری جدید از شبکه‌ی CNN برای شناسایی کمپلکس QRS جنین و تشخیص FHR معرفی شده که هدف آن بهبود صحت نتایج و کاهش پیچیدگی‌های محاسباتی است. ساختار شبکه‌ی پیشنهادی در شکل (۸) قابل مشاهده است. ورودی شبکه پس از اعمال مراحل پیش‌پردازش و اقدامات اولیه با ابعاد ۴ (کانال) × ۱۰۰۰ (نمونه) به شبکه‌ی پیشنهادی داده می‌شود. خروجی شبکه‌ی پیشنهادی به ازای هر ۱۰۰۰ میلی‌ثانیه از سیگنال AECG یک بردار ۱۰ نمونه‌ای معادل با ۱۰ پیش‌بینی برای آن بازه ارائه می‌دهد. در این بردار ۱ نشان دهنده‌ی وجود QRS جنین و صفر نشان دهنده‌ی عدم وجود QRS جنین است. به عبارت دیگر به ازای هر ۱۰۰ میلی‌ثانیه یک پیش‌بینی صفر یا ۱ توسط شبکه صورت گرفته است که در صورت انطباق پیش‌بینی شبکه بر برچسب‌های واقعی (محل حقیقی رخداد QRS جنین) معادل با پیش‌بینی صحیح توسط شبکه خواهد بود. در مطالعات صورت گرفته در زمینه‌ی استخراج FEKG در صورتی که کمپلکس QRS جنین پیش‌بینی شده در فاصله‌ی ۵۰ میلی‌ثانیه‌ای از برچسب واقعی قرار گرفته باشد یک مثبت واقعی<sup>۱</sup> (TP) یا طبقه‌بندی صحیح



شکل (۶) - نحوه‌ی اعمال تقسیم‌بندی یک ثانیه‌ای



شکل (۷) - نحوه‌ی تقسیم‌بندی ۱۰۰ میلی‌ثانیه‌ای برچسب‌ها در یک نمونه‌ی داده‌ی یک ثانیه‌ای، نحوه‌ی تطابق و مقایسه‌ی این برچسب‌ها با پیش‌بینی‌های شبکه نیز قابل مشاهده است


بخش‌های داده‌ی انتخاب شده از هر ثبت AECG دارای هم‌پوشانی ۹۰ درصدی با بخش قبلی است. این کار با هدف داده‌افزایی و افزایش دقت در رویکرد پیشنهادی انجام شده است. پس از جداسازی داده‌ی متعلق به تست و اعتبارسنجی از داده‌ی ورودی، مقادیر باقی‌مانده به صورت به‌هم‌ریخته به

<sup>۱</sup> True Positive

ارزیابی قابلیت آموزش شبکه‌ی عمیق پیشنهادی با استفاده از تعداد کم‌تری از سیگنال‌ها (۲۵ سیگنال) است.

این قابلیت با تعداد سیگنال‌های کم‌تر از ۲۵ نیز مورد بررسی قرار گرفته اما بهترین نتایج و عمل کرد بهینه‌ی شبکه در شرایط استفاده از ۲۵ سیگنال به دست آمده است. بنابراین حداقل تعداد سیگنال مورد نیاز برای آموزش شبکه ۲۵ سیگنال در نظر گرفته شده است. علاوه بر این، عمل کرد شبکه با حداکثر تعداد سیگنال‌های قابل استفاده (۶۰ سیگنال) نیز مورد ارزیابی قرار گرفته است. با توجه به این که با افزایش گام<sup>۴</sup>، ابعاد نقشه‌ی ویژگی<sup>۵</sup> حاصل کاهش می‌یابد [۱۸] در لایه‌های کانولوشنی اول و دوم با هدف کاهش ابعاد خروجی‌های حاصل از این دو لایه، با گام ۲ در نظر گرفته شده است. تابع فعال‌ساز مورد استفاده پس از هر لایه‌ی کانولوشنی تابع واحد خطی تنظیم شده<sup>۶</sup> (ReLU) بوده که رایج‌ترین تابع فعال‌ساز مورد استفاده در شبکه‌های عصبی کانولوشنی است. تابع فعال‌ساز ReLU تمام مقادیر ورودی را به مقادیر مثبت تبدیل می‌کند. برتری این تابع فعال‌ساز نسبت به دیگر توابع فعال‌ساز در کاهش بار محاسباتی است [۱۸]. یکی از مشکلاتی که در حین استفاده از تابع فعال‌ساز ReLU ممکن است رخ بدهد، مشکل میرایی<sup>۷</sup> ReLU می‌باشد. میرایی ReLU نوعی ناپدید شدن گرادیان<sup>۸</sup> محسوب می‌شود و عبارت است از شرایطی که نورون‌های ReLU غیرفعال شده و به ازای تمام ورودی‌ها خروجی صفر را می‌دهند. این حالت به عنوان یکی از مشکلات در حین آموزش شبکه‌های عصبی پیش‌خور عمیق که دارای تابع فعال‌ساز ReLU هستند به حساب می‌آید. یک راه حل برای این مشکل اضافه کردن تکنیک‌های نرمال‌سازی داده‌ها است. یکی از موفق‌ترین روش‌های نرمال‌سازی استفاده از نرمال‌سازی دسته‌ای است [۱۹، ۲۰]. در آموزش شبکه‌ی عمیق علاوه بر رویارویی با مشکل ناپدید شدن و انفجار گرادیان، مشکل تغییر در توزیع داده در هر لایه نیز وجود دارد که با نام پدیده‌ی شیفت توزیع داخلی<sup>۹</sup> شناخته می‌شود. از نرمال‌سازی دسته‌ای برای حذف تاثیر این پدیده نیز استفاده می‌شود [۲۱]. در معماری‌های CNN اضافه کردن لایه‌های بیش‌تر به دلیل مشکل ناپدید شدن گرادیان موجب افت عمل کرد شبکه می‌شود [۲۲] و با توجه به عمق بالا در شبکه‌ی پیشنهادی این مطالعه، نرمال‌سازی دسته‌ای با هدف

به حساب می‌آید [۳] به همین دلیل فریم پیش‌بینی در این مطالعه برابر با ۱۰۰ میلی‌ثانیه در نظر گرفته شده است. مدل پیشنهادی متشکل از ۵ لایه‌ی کانولوشنی، ۷ لایه‌ی نرمال‌سازی دسته‌ای<sup>۱</sup>، ۳ لایه‌ی حذف تصادفی<sup>۲</sup> و ۳ لایه‌ی متراکم<sup>۳</sup> است.



در طی اجراهای متفاوت از شبکه‌ی پیشنهادی، قابلیت آموزش شبکه با تعداد کم‌تری از سیگنال‌ها آشکار شده است. شبکه‌ی پیشنهادی در این مقاله در دو حالت مختلف با استفاده از تعداد متفاوتی از سیگنال‌ها مورد بررسی قرار گرفته است. در حالت اول از ۲۵ سیگنال موجود در پایگاه داده استفاده شده و در حالت دوم ۶۰ سیگنال به کار رفته است. هدف از این بررسی،

<sup>۶</sup> Rectified Linear Unit

<sup>۷</sup> Dying Relu

<sup>۸</sup> Vanishing Gradient

<sup>۹</sup> Internal Covariate Shift

<sup>۱</sup> Batch Normalisation

<sup>۲</sup> Dropout

<sup>۳</sup> Dense

<sup>۴</sup> Stride

<sup>۵</sup> Feature Map

تابع هزینه‌ی دیگر خطای میانگین مربعات لگاریتمی خطا<sup>۵</sup> (MSLE) است. تابع هزینه‌ی MSLE نسبت لگاریتمی بین مقادیر پیش‌بینی شده و مقادیر حقیقی را اندازه‌گیری می‌کند.

$$MSLE = \frac{1}{n} \sum_{i=1}^n (\log(1 + \hat{Y}_i) - \log(1 + Y_i))^2 \quad (۸)$$

تابع هزینه‌ی شباهت کسینوسی<sup>۶</sup> (CosSim)، شباهت کسینوسی بین پیش‌بینی‌های شبکه و مقادیر حقیقی را محاسبه کرده و با رابطه‌ی زیر تعریف می‌شود.

$$CosSimLoss = 1 - \frac{\hat{Y}Y^T}{norm(\hat{Y})^2 norm(Y)^2} \quad (۹)$$

تابع هزینه‌ی دیگر تابع هزینه‌ی LogCosh<sup>۷</sup> لگاریتم کسینوس هایپربولیک خطای پیش‌بینی را با رابطه‌ی زیر محاسبه می‌کند.

$$LogCosh = \frac{1}{n} \sum_{i=1}^n \log((\exp(Y_i) - \exp(-\hat{Y}_i))/2) \quad (۱۰)$$

آخرین تابع هزینه‌ی مورد استفاده تابع هزینه‌ی هوبر<sup>۸</sup> است. در مسائل درون‌یابی که حساس به داده‌های پرت<sup>۹</sup> هستند از این تابع هزینه استفاده می‌شود. تابع هزینه‌ی هوبر با رابطه‌ی زیر قابل محاسبه است.

$$Huber(\hat{Y}_i, Y_i) = \begin{cases} \frac{1}{2}(\hat{Y}_i - Y_i)^2 & \text{if } |\hat{Y}_i - Y_i| \leq \delta \\ \delta|\hat{Y}_i - Y_i| - \frac{1}{2}\delta^2 & \text{if } |\hat{Y}_i - Y_i| > \delta \end{cases} \quad (۱۱)$$

الگوریتم بهینه‌سازی مورد استفاده در این مطالعه الگوریتم بهینه‌سازی آدام<sup>۱۰</sup> بوده که یکی از روش‌های مبتنی بر گرادینت نزولی تصادفی<sup>۱۱</sup> (SGD) و پرکاربردترین الگوریتم بهینه‌سازی است. در صورت وجود نرخ پایین در یادگیری الگوریتم بهینه‌سازی، آموزش با سرعت کم‌تر و همراه با به‌روزرسانی‌های تدریجی روی پارامترها بوده و از طرف دیگر وجود نرخ بالای یادگیری به معنای گام‌های بزرگ یا به‌روزرسانی‌های شدید روی پارامترها است. در این مطالعه نرخ یادگیری الگوریتم بهینه‌سازی معادل ۰/۰۰۰۰۳ در نظر گرفته شده است.

دوری از مواجهه با این مشکل نیز استفاده شده است. در ادامه برای جلوگیری از بروز بیش‌برازش<sup>۱</sup> از حذف تصادفی استفاده شده است. حذف تصادفی یک روش رایج در مطالعات است زیرا در هنگام استفاده از آن نیازی به ایجاد تغییرات اساسی در شبکه نیست [۲۳]. در ادامه پس از اعمال لایه‌های کانولوشنی، نرمال‌سازی دسته‌ای و حذف تصادفی، خروجی دوبعدی حاصل از شبکه پس از تبدیل به یک بردار به سه لایه‌ی متراکم داده شده است. تابع فعال‌ساز مورد استفاده در لایه‌های متراکم، تابع سیگموئیدی<sup>۲</sup> است. ورودی این تابع فعال‌ساز اعداد واقعی بوده در حالی که خروجی آن بین اعداد صفر و ۱ محدود است. تابع سیگموئیدی به شکل S<sup>۳</sup> بوده و به صورت زیر تعریف می‌شود.

$$f(x)_{sigm} = \frac{1}{1 + e^{-x}} \quad (۵)$$

باید اشاره کرد که نسبت تقسیم داده‌ی آموزش و تست ۸۰-۲۰ در نظر گرفته شده است. در آموزش شبکه‌ی عمیق یک تابع هزینه معمولاً بهینه‌سازی می‌شود. در این مقاله با محاسبه کردن اختلاف بین مقادیر پیش‌بینی شده توسط شبکه و مقادیر واقعی، مساله به نوعی مساله‌ی درون‌یابی تبدیل شده است. انواع مختلفی از توابع هزینه‌ی کاربردی در مسائل درون‌یابی در این مطالعه مورد استفاده قرار گرفته است. خطای میانگین مربعات<sup>۴</sup> (MSE) اولین تابع هزینه‌ی مورد استفاده است که به صورت میانگین مربعات اختلاف بین مقادیر واقعی و مقادیر پیش‌بینی شده محاسبه می‌شود. هم‌چنین این تابع پرکاربردترین تابع هزینه در مسائل درون‌یابی بوده و به صورت زیر تعریف می‌شود.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (۶)$$

در این رابطه  $Y_i$  مقادیر حقیقی و  $\hat{Y}_i$  مقادیر پیش‌بینی شده با شبکه‌ی پیشنهادی است. تابع هزینه‌ی بعدی خطای درصد میانگین مطلق<sup>۴</sup> (MAPE) است. این تابع بزرگی میانگین خطای تولید شده توسط مدل پیشنهادی را اندازه‌گیری کرده و یا اختلاف بین پیش‌بینی‌های شبکه و میانگین را می‌دهد.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{Y}_i - Y_i|}{Y_i} \quad (۷)$$

<sup>۷</sup> Logcosh Loss Function

<sup>۸</sup> Huber Loss Function

<sup>۹</sup> Outliers

<sup>۱۰</sup> Adam (Adaptive Moment Estimation)

<sup>۱۱</sup> Stochastic Gradient Descent Method

<sup>۱</sup> Overfitting

<sup>۲</sup> Sigmoid

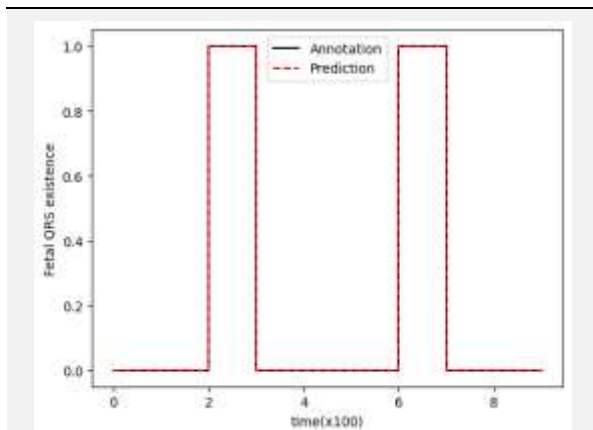
<sup>۳</sup> Mean Squared Error

<sup>۴</sup> Mean Absolute Percentage Error

<sup>۵</sup> Mean Squared Logarithmic Error


<sup>۶</sup> Cosine Similarity Loss Function

پیش‌بینی صحیح توسط شبکه بوده و عدم انطباق خطوط به معنای پیش‌بینی نادرست توسط شبکه است.



شکل (۱۰) - نمونه‌ی یک ثانیه‌ای از سیگنال a<sub>۶</sub>، تطبیق خطوط سیاه و قرمز که نشان دهنده‌ی برچسب‌ها و پیش‌بینی‌های شبکه هستند، به معنای پیش‌بینی صحیح توسط شبکه‌ی پیشنهادی است

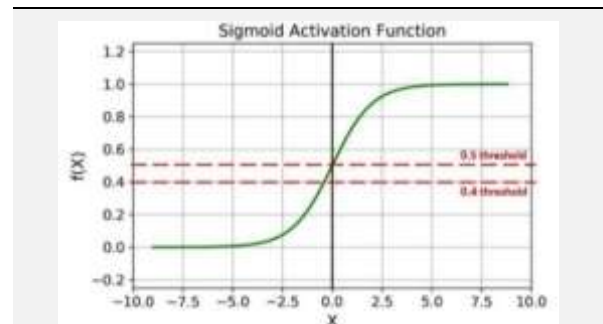
برای هر سیگنال ورودی (حاوی ۶۰۰۰۰ نمونه)، ۶۰۰ پیش‌بینی توسط شبکه ایجاد می‌شود. به عنوان مثالی از نحوه‌ی کارکرد شبکه و نحوه‌ی ارزیابی آن، نمونه‌ای از پیش‌بینی‌های شبکه به ازای ۱۰ ثانیه‌ی اول از سیگنال a<sub>۶</sub> در شکل (۱۱) ترسیم شده است. مشاهده می‌شود که عدم انطباق خطوط قرمز و سیاه در ثانیه‌ی ۲ به معنای پیش‌بینی نادرست توسط شبکه بوده و در ثانیه‌ی ۹ شبکه رخداد QRS جنین را پیش‌بینی نکرده است. شکل (۱۲) ۵ ثانیه‌ی اول از سیگنال a<sub>۸</sub> به همراه برچسب‌های آن به ازای هر چهار کانال این سیگنال را نشان می‌دهد.



شکل (۱۱) - پیش‌بینی‌های بازسازی شده‌ی شبکه به ازای ۱۰ ثانیه‌ی اول از سیگنال a<sub>۶</sub>

معیار مورد استفاده برای ارزیابی روند یادگیری شبکه، صحت باینری<sup>۱</sup> است. این معیار میزان انطباق برچسب‌های پیش‌بینی شده با برچسب‌های واقعی را محاسبه می‌کند.

خروجی حاصل از شبکه‌ی پیشنهادی تحت تاثیر اعمال تابع هزینه‌ی سیگموئیدی بین ۱ و صفر نگاشت می‌شود. با اعمال یک آستانه می‌توان این خروجی‌ها را به اعداد باینری تبدیل نمود. در این مطالعه مطابق شکل (۹) با اعمال حد آستانه‌ی ۰/۴ و ۰/۵ نتایج حاصل از شبکه مورد بررسی قرار گرفته است.



شکل (۹) - اعمال حد آستانه‌ی ۰/۴ و ۰/۵ بر خروجی تابع سیگموئیدی

مشاهده می‌شود که در لایه‌ی آخر شبکه‌ی عصبی پیشنهادی ۱۰ نورون قرار گرفته است که یک سیگنال ۱۰ بیتی را به ازای ورودی ۱۰۰۰×۴ (نمونه) در اختیار قرار می‌دهد. به عبارت دیگر این سیگنال ۱۰ بیتی پیش‌بینی‌های شبکه به ازای داده‌ی ورودی یک ثانیه‌ای می‌باشد. به ازای هر ۱۰۰ میلی‌ثانیه از ثبت AECG یک برچسب صفر یا ۱ تعریف شده که هر صفر معادل عدم وجود پیک QRS جنین و هر ۱ معادل رخداد QRS جنین در آن ۱۰۰ میلی‌ثانیه است. در نتیجه به ازای هر داده‌ی ورودی یک ثانیه‌ای، سیگنال خروجی ۱۰ بیتی حاصل از شبکه‌ی عصبی با ۱۰ برچسب تولید شده به ازای همان ثانیه مقایسه شده و بدین ترتیب میزان صحت<sup>۲</sup>، دقت<sup>۳</sup>، حساسیت<sup>۴</sup> و اختصاصیت<sup>۵</sup> شبکه‌ی پیشنهادی محاسبه شده است. نمونه‌ی یک ثانیه‌ای از سیگنال a<sub>۶</sub> در شکل (۱۰) نشان داده شده است. در این شکل محور عمودی شامل اعداد صفر و ۱ (صفر معادل عدم رخداد پیک QRS جنین و ۱ معادل رخداد QRS جنین) است. همچنین خطوط سیاه نشان دهنده‌ی برچسب‌های حقیقی<sup>۶</sup> و نقطه‌چین قرمز نشان دهنده‌ی پیش‌بینی‌های شبکه می‌باشد. انطباق این دو خط به معنای

<sup>۱</sup> Sensitivity

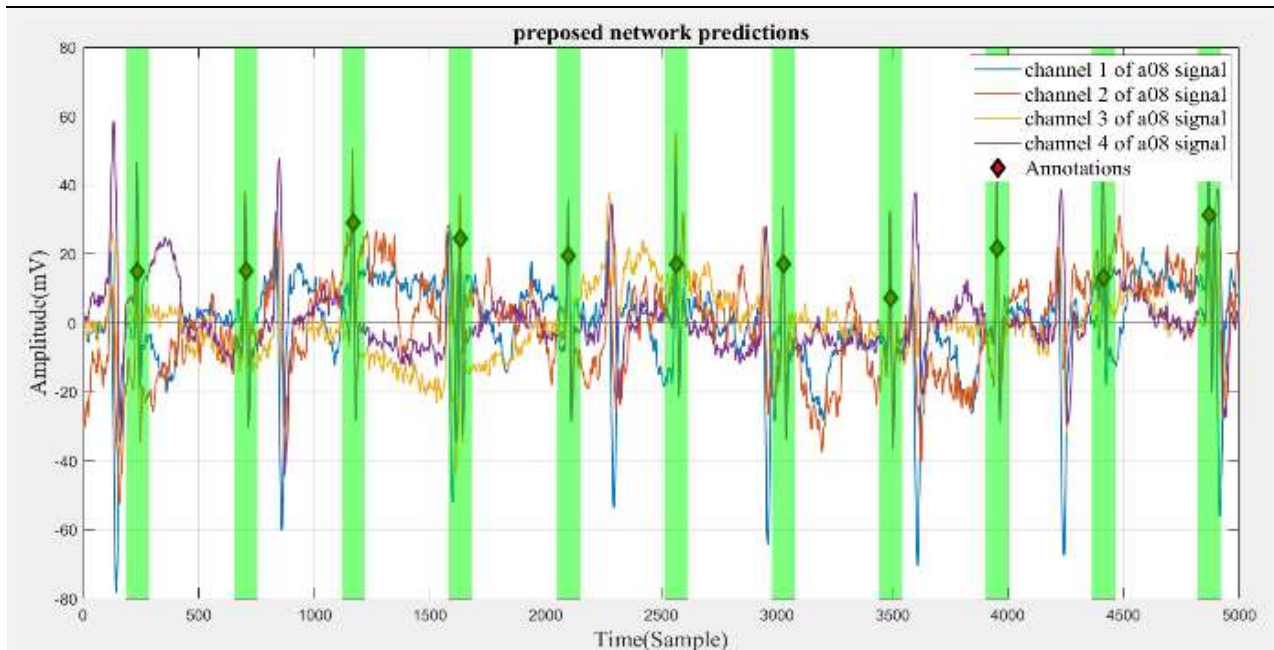
<sup>۲</sup> Specificity

<sup>۳</sup> Ground Truth Labels

<sup>۴</sup> Binary Accuracy

<sup>۵</sup> Accuracy

<sup>۶</sup> Precision



شکل (۱۲) - چهار کانال سیگنال a08 به همراه برجسب‌های رخداد QRS جنین در شکل معین شده است، در صورتی که برجسب‌ها در درون بازه‌ی سبز رنگ پیش‌بینی شبکه قرار گیرد به معنای پیش‌بینی صحیح توسط شبکه‌ی عمیق پیشنهادی بوده و در صورتی که برجسب‌ها در درون بازه‌ی رنگی پیش‌بینی شبکه قرار نگیرد به معنای پیش‌بینی نادرست توسط شبکه است

#### ۴-۱- رویکرد اول: به کارگیری تنها ۲۵ ثبت از سیگنال AECG برای آموزش

در این رویکرد تنها از ۲۵ ثبت از سیگنال‌های AECG برای آموزش و ارزیابی شبکه استفاده شده است. به منظور انجام پیش‌پردازش در این رویکرد صرفاً از یک فیلتر بالاگذر باترورت مرتبه‌ی ۲ با هدف حذف نویز انحراف خط زمینه‌ی سیگنال AECG استفاده شده است. تابع هزینه در این رویکرد در ابتدای کار MSE بوده و به ازای حدهای آستانه‌ی ۰/۴ و ۰/۵ و همچنین مقادیر متفاوتی از دوره‌های آموزشی<sup>۱</sup> ۳۰، ۳۵، ۴۰، ۵۰، ۷۰، ۱۰۰ برای آموزش شبکه در نظر گرفته شده است. نسبت تقسیم داده‌ی آموزش و تست در رویکرد اول برابر با ۲۰ درصد است. بهترین نتایج به دست آمده با استفاده از این رویکرد در جدول (۱) گزارش شده است. با مقایسه‌ی نتایج به دست آمده در جدول (۱) در دو حد آستانه‌ی ۰/۴ و ۰/۵ می‌توان استنباط کرد که نتایج حاصل در این دو حد آستانه تفاوت اندکی با هم دارند اما نتایج حاصل از اعمال حد آستانه‌ی ۰/۵ در حالت کلی بالاتر است. علاوه بر تابع هزینه MSE توابع هزینه‌ی دیگر نیز با هدف بررسی و مقایسه‌ی تاثیر آن‌ها اعمال شده که تنها نتایج تابع هزینه MAPE قابل مقایسه با MSE بوده که در جدول (۲) گزارش شده است. نتایج این جدول به

بازه‌های ۱۰۰ میلی‌ثانیه‌ای پیش‌بینی شبکه‌ی عمیق پیشنهادی نیز با رنگ سبز به صورت هایلایت در شکل مشخص گردیده است. در صورتی که برجسب‌ها در درون بازه‌ی رنگی پیش‌بینی شبکه قرار گیرند به معنای پیش‌بینی صحیح توسط شبکه‌ی عمیق پیشنهادی بوده و همچنین در صورتی که برجسب‌ها در درون بازه‌ی رنگی پیش‌بینی شبکه قرار نگیرند به معنای پیش‌بینی نادرست توسط شبکه است. همان‌طور که در شکل (۱۲) مشاهده می‌شود تمام برجسب‌ها در درون بازه‌ی پیش‌بینی شده توسط شبکه قرار گرفته و در این ۵ ثانیه از سیگنال a08 پیش‌بینی صحیح توسط شبکه انجام شده است.

#### ۴- نتایج

در این بخش از مقاله به ارائه‌ی نتایج پیاده‌سازی شبکه‌ی پیشنهادی پرداخته شده است. چندین رویکرد مختلف برای پیاده‌سازی شبکه‌ی پیشنهادی وجود داشته که نتایج پیاده‌سازی تمام آن‌ها به صورت جداگانه در جدول‌های مختلف ارائه شده است. نتایج موجود در این جدول‌ها حاصل از میانگین‌گیری ۵ بار اجرای جداگانه‌ی هر رویکرد است. همچنین مقادیر انحراف معیار حاصل نیز همراه با دیگر معیارهای ارزیابی در تمام جداول گزارش شده است.

<sup>۱</sup> Epoch

از آنجا که اعمال آن‌ها منجر به افزایش و یا بهبود نتایج جدول (۳) نشده، از گزارش آن‌ها خودداری گردیده است.

#### جدول (۳) - نتایج روش پیشنهادی در رویکرد دوم با حدهای

آستانه‌ی ۰/۵ و ۰/۴ به ازای تابع هزینه‌ی MSE

حد آستانه	۰/۴	۰/۵
دوره	۵۰	۳۲
صحت (%)	۹۲/۲۴±۰/۸۴	۹۲/۵۶±۰/۰۹
میانگین مربعات خطا	۰/۰۶±۰/۰۰۸	۰/۰۷±۰/۰۰۵
امتیاز FI	۸۲/۱۹±۰/۴۵	۸۳/۶۷±۰/۳۴
حساسیت (%)	۹۵/۰۶±۰/۷۲	۹۶/۹۳±۰/۱۵
اختصاصیت (%)	۸۱/۳۰±۰/۹۴	۸۱/۵۴±۰/۸۷
دقت (%)	۹۴/۰۸±۰/۵۶	۹۴/۴۷±۰/۲۲

#### ۳-۴ - رویکرد سوم: تغییر نسبت تقسیم داده‌ی آموزش و تست

در این رویکرد امکان آموزش شبکه با درصد کم‌تری از داده‌های آموزشی بررسی شده است. داده‌ی ورودی شبکه شامل ۶۰ سیگنال AECG در نظر گرفته شده است. در حین تقسیم داده‌ی ورودی به داده‌های آموزش و تست، نسبت تقسیم داده از ۲۰ درصد به ۳۳ درصد تغییر داده شده است. نتایج حاصل از این رویکرد در جدول (۴) گزارش شده است. مرحله‌ی پیش‌پردازش مورد استفاده در این رویکرد صرفاً شامل یک فیلتر بالاگذر باترورث مرتبه‌ی ۲ بوده و تابع هزینه نیز MSE است.

#### جدول (۴) - رویکرد سوم با حدهای آستانه‌ی ۰/۵ و ۰/۴ به

ازای اعمال تقسیم داده‌ی ۳۳ درصدی با تابع هزینه‌ی MSE

نسبت تقسیم داده	۳۳	۳۳
حد آستانه	۰/۴	۰/۵
دوره	۵۰	۵۰
صحت (%)	۹۰/۲۹±۰/۷۷	۹۰/۹۵±۰/۵۱
میانگین مربعات خطا	۰/۰۹±۰/۰۰۸	۰/۰۸±۰/۰۰۴
امتیاز FI	۷۹/۴۳±۱/۲۷	۷۹/۴۷±۱/۲۴
حساسیت (%)	۹۳/۲۹±۰/۶۲	۹۵/۸۳±۰/۴
اختصاصیت (%)	۷۹/۸۷±۲/۸۵	۷۴/۹۵±۱/۷۶
دقت (%)	۹۳/۸۴±۰/۸	۹۲/۶۱±۰/۴۹

در ادامه با هدف بررسی تاثیر مراحل پیش‌پردازش متفاوت روی نتایج کسب شده در این رویکرد، اصلاحاتی در مراحل پیش‌پردازش و آماده‌سازی داده‌ها اعمال شده است. این اصلاحات شامل حذف آرتیفکتهای حرکتی با به کارگیری فیلتر میانه، حذف نویز برق شهری با استفاده از یک فیلتر

ازای حد آستانه‌ی ۰/۵ و دوره‌ی آموزشی ۷۰ می‌باشد. با توجه به جدول (۲) به نظر می‌رسد که نتایج به دست آمده در شرایط اعمال تابع هزینه‌ی MAPE در مقایسه با نتایج به دست آمده در شرایط اعمال تابع هزینه‌ی MSE بهبود و افزایش یافته است. در نتیجه این نتایج به عنوان بالاترین نتایج به دست آمده در حالت اول در نظر گرفته شده است.

#### جدول (۱) - نتایج روش پیشنهادی در رویکرد اول با حدهای

آستانه‌ی ۰/۵ و ۰/۴ به ازای تابع هزینه‌ی MSE

حد آستانه	۰/۴	۰/۵
دوره	۱۰۰	۱۰۰
صحت (%)	۹۶/۷۰±۰/۳۲	۹۶/۹۸±۰/۲۱
میانگین مربعات خطا	۰/۰۲±۰/۰۰۴	۰/۰۲±۰/۰۰۵
امتیاز FI	۹۲/۸±۰/۷	۹۳/۳۱±۰/۴۵
حساسیت (%)	۹۷/۲۳±۰/۲۵	۹۷/۷۶±۰/۲۹
اختصاصیت (%)	۹۴/۸۹±۰/۶۳	۹۴/۲±۰/۴۱
دقت (%)	۹۸/۵±۰/۱۸	۹۸/۳۴±۰/۱۱

#### جدول (۲) - نتایج رویکرد اول با اعمال توابع هزینه‌ی متفاوت

	MSE	MAPE
صحت (%)	۹۶/۹۸±۰/۲۱	۹۸/۳۶±۰/۰۷
میانگین مربعات خطا	۰/۰۲±۰/۰۰۵	۰/۰۱±۰
امتیاز FI	۹۳/۳۱±۰/۴۵	۹۶/۳۵±۰/۱۶
حساسیت (%)	۹۷/۷۶±۰/۲۹	۹۸/۷۹±۰/۱۳
اختصاصیت (%)	۹۴/۲±۰/۴۱	۹۶/۸۵±۰/۴۳
دقت (%)	۹۸/۳۴±۰/۱۱	۹۹/۰۹±۰/۱۲

#### ۲-۴ - رویکرد دوم: به کارگیری ۶۰ ثبت از سیگنال AECG برای آموزش و ارزیابی

در این رویکرد از ۶۰ ثبت از سیگنال‌های AECG برای آموزش و ارزیابی شبکه استفاده شده است. جهت پیش‌پردازش در این رویکرد صرفاً از یک فیلتر بالاگذر باترورث مرتبه‌ی ۲ با هدف حذف نویز انحراف خط زمینه‌ی سیگنال AECG استفاده شده است. تابع هزینه در این رویکرد در ابتدای کار MSE بوده و به ازای حدهای آستانه‌ی ۰/۴ و ۰/۵ و هم‌چنین مقادیر متفاوتی از دوره‌های آموزشی (۳۰، ۳۵، ۴۰، ۵۰، ۷۰، ۱۰۰) برای آموزش و شبکه در نظر گرفته شده است. نسبت تقسیم داده‌ی آموزش و تست در رویکرد دوم ۲۰ درصد است. بهترین نتایج به دست آمده از این رویکرد در جدول (۳) گزارش شده است. مشاهده می‌شود که به ازای حد آستانه‌ی ۰/۵ و ۳۲ دوره‌ی آموزشی و تابع هزینه‌ی MSE بالاترین نتایج هزینه به دست آمده است. در رویکرد دوم نیز سایر توابع هزینه مورد بررسی قرار گرفته و

و از آن‌جا که اعمال آن‌ها منجر به افزایش و یا بهبود نتایج جدول (۶) نشده، از گزارش آن‌ها خودداری شده است.

**جدول (۶) -** رویکرد چهارم با حدهای آستانه‌ی ۰/۵ و ۰/۴ با اعمال مرحله‌ی پیش‌پردازش تبدیل موجک و با یکسان‌سازی دامنه در بازه‌ی صفر و ۱ به ازای تابع هزینه‌ی MSE

حد آستانه	۰/۴	۰/۵
دوره	۵۰	۷۰
صحت (%)	۹۵/۶۹±۰/۱۸	۹۵/۰۹±۰/۲۹
میانگین مربعات خطا	۰/۰۴±۰/۰۰۵	۰/۰۴±۰/۰۰۴
امتیاز FI	۹۰/۹۸±۰/۴۲	۸۹/۲۷±۰/۶۴
حساسیت (%)	۹۷/۳۶±۰/۱	۹۵/۵۲±۰/۳
اختصاصیت (%)	۹۰/۰۵±۰/۴۵	۸۹/۱۸±۱/۳۲
دقت (%)	۹۷/۰۹±۰/۱۳	۹۶/۲۳±۰/۲۴

#### ۴-۵- رویکرد پنجم: عدم استفاده از تبدیل موجک

##### گسسته

در این رویکرد از ۶۰ ثبت از سیگنال‌های AECG برای آموزش و ارزیابی شبکه استفاده شده و جهت پیش‌پردازش نیز ابتدا از یک فیلتر بالاگذر باترورث مرتبه‌ی ۲ با هدف حذف نویز انحراف خط زمین‌ی سیگنال AECG بهره گرفته شده اما برخلاف رویکرد چهارم از تبدیل موجک استفاده نشده است. تابع هزینه در این رویکرد MSE بوده و یکسان‌سازی دامنه‌ها در بازه‌ی صفر تا ۱ اعمال شده است. نتایج رویکرد پنجم در جدول (۷) ارائه شده که بالاترین نتایج به ازای تعداد دوره‌ی آموزشی ۱۰۰ و حد آستانه‌ی ۰/۴ به دست آمده است. نتایج حاصل از اعمال مراحل پیش‌پردازش تبدیل موجک و یکسان‌سازی دامنه در بازه‌ی ۱ و ۱- نیز بررسی شده اما چون این نتایج کم‌تر از نتایج جدول (۷) بوده از گزارش آن خودداری شده است.

**جدول (۷) -** رویکرد پنجم با حدهای آستانه‌ی ۰/۵ و ۰/۴ در شرایط اعمال مراحل پیش‌پردازش متفاوت (یکسان‌سازی دامنه‌ی داده در بازه‌ی صفر و ۱) به ازای تابع هزینه‌ی MSE

حد آستانه	۰/۴	۰/۵
دوره	۱۰۰	۳۲
صحت (%)	۹۶/۷۹±۰/۸۷	۹۴/۸۲±۰/۵۸
میانگین مربعات خطا	۰/۰۳±۰/۰۰۵	۰/۰۵±۰/۰۰۴
امتیاز FI	۹۳/۰۲±۱/۳۶	۸۸/۸۱±۱/۲۸
حساسیت (%)	۹۷/۹۱±۱/۰۱	۹۶/۷۲±۰/۲۶
اختصاصیت (%)	۹۲/۷۹±۱/۵	۸۸/۵۸±۱/۵۸
دقت (%)	۹۷/۸۸±۰/۴۳	۹۶/۵۴±۰/۴۸

شکافی، یکسان‌سازی دامنه‌ی داده‌ها در بازه‌ی صفر و ۱ است. نتایج حاصل از این اصلاحات در جدول (۵) گزارش شده است. مشاهده می‌شود که اصلاحات انجام شده باعث بهبود عمل کرد شبکه در رویکرد سوم شده است.

**جدول (۵) -** نتایج حاصل از اعمال اصلاحات پیشنهادی در رویکرد سوم به ازای تابع هزینه‌ی MSE

نسبت تقسیم داده	۳۳	۳۳
حد آستانه	۰/۴	۰/۵
دوره	۵۰	۵۰
صحت (%)	۹۳/۹۵±۰/۶۶	۹۴/۵۴±۰/۴۷
میانگین مربعات خطا	۰/۰۶±۰/۰۰۸	۰/۰۵±۰/۰۰۵
امتیاز FI	۸۶/۰۸±۱/۴۳	۸۷/۵۴±۱/۱
حساسیت (%)	۹۵/۳۶±۰/۳۸	۹۶/۶۵±۰/۱۸
اختصاصیت (%)	۸۷/۱۵±۱/۵۹	۸۶/۲۳±۱/۵۳
دقت (%)	۹۶/۵۸±۰/۴۸	۹۶/۲۵±۰/۴۴

از میان دو حد آستانه‌ی گزارش شده در جدول (۵)، حد آستانه‌ی ۰/۵ بالاترین مقادیر از صحت به دست آمده بوده و در نتیجه به عنوان بالاترین نتایج به دست آمده در حالت سوم با به کارگیری تابع هزینه‌ی MSE در نظر گرفته شده است. در رویکرد سوم نیز سایر توابع هزینه مورد بررسی قرار گرفته و از آن‌جا که اعمال آن‌ها منجر به افزایش و یا بهبود نتایج جدول (۵) نشده، از گزارش آن‌ها خودداری گردیده است.

#### ۴-۴- رویکرد چهارم: استفاده از تبدیل موجک

##### گسسته

در این رویکرد از ۶۰ ثبت از سیگنال‌های AECG برای آموزش و ارزیابی شبکه استفاده شده است. جهت پیش‌پردازش نیز ابتدا از یک فیلتر بالاگذر باترورث مرتبه‌ی ۲ با هدف حذف نویز انحراف خط زمین‌ی سیگنال AECG و سپس از تبدیل موجک برای حفظ کمپلکس‌های QRS مادر و جنین و حذف سایر موارد از کانال‌ها استفاده شده است. تابع هزینه در این رویکرد نیز MSE است. هم‌چنین یکسان‌سازی دامنه‌ها در بازه‌ی صفر تا ۱ اعمال شده است. نتایج حاصل از رویکرد چهارم در جدول (۶) ارائه شده که بالاترین نتایج به ازای تعداد دوره‌ی آموزشی ۵۰ و حد آستانه‌ی ۰/۴ به دست آمده است. نتایج حاصل از اعمال مراحل پیش‌پردازش تبدیل موجک و یکسان‌سازی دامنه در بازه‌ی ۱ و ۱- نیز بررسی شده اما چون نتایج به دست آمده کم‌تر از نتایج جدول (۶) بوده از گزارش آن خودداری شده است. در رویکرد چهارم نیز سایر توابع هزینه مورد بررسی قرار گرفته



شکل (۱۳) - صحت‌های رویکردهای پیشنهادی



شکل (۱۴) - امتیازهای F1 رویکردهای پیشنهادی



شکل (۱۵) - حساسیت‌های رویکردهای پیشنهادی



شکل (۱۶) - اختصاصیت‌های رویکردهای پیشنهادی



شکل (۱۷) - دقت‌های به دست آمده در رویکردهای پیشنهادی

در رویکرد پنجم نیز سایر توابع هزینه مورد بررسی قرار گرفته و از آن‌جا که اعمال آن‌ها منجر به افزایش و یا بهبود نتایج جدول (۷) نشده، از گزارش آن‌ها خودداری شده است. با مقایسه‌ی نتایج رویکردهای مختلف در جداول (۱) تا (۷) می‌توان به این نتیجه رسید که رویکرد اول و پنجم از سایر رقبا نتایج بهتری کسب کرده‌اند. هم‌چنین رویکرد چهارم در جایگاه سوم قرار گرفته است. برای بخش بعدی، نتایج حاصل از رویکردهای اول و پنجم برای مقایسه با نتایج گزارش شده در سایر مطالعات مورد استفاده قرار گرفته است.

جدول (۸) - بالاترین نتایج به دست آمده در ۵ رویکرد

رویکرد	اول	پنجم
صحت (%)	98/36 ± 0/07	96/79 ± 0/87
میانگین مربعات خطا	0/01 ± 0	0/03 ± 0/005
امتیاز F1	96/35 ± 0/16	93/02 ± 1/36
حساسیت (%)	98/79 ± 0/13	97/91 ± 1/01
اختصاصیت (%)	96/85 ± 0/43	92/79 ± 1/5
دقت (%)	99/09 ± 0/12	97/88 ± 0/43

در شکل‌های (۱۳) تا (۱۷) نمودارهای میله‌ای به منظور تسهیل فرایند مقایسه‌ی نتایج به دست آمده در رویکردهای مختلف ارائه شده است. شکل (۱۳) به مقایسه‌ی صحت‌های به دست آمده در رویکردهای پیشنهادی اختصاص داده شده است. با توجه به این شکل مشاهده می‌شود که رویکرد اول بالاترین صحت را کسب کرده است در حالی که رویکردهای پنجم و چهارم نیز صحت‌های قابل توجهی دارند. هم‌چنین رویکرد دوم کم‌ترین صحت را به خود اختصاص داده است. شکل (۱۴) به مقایسه‌ی امتیازهای F1 به دست آمده در این رویکردها پرداخته است. مشاهده می‌شود که در این مورد نیز رویکرد اول بالاترین امتیاز F1 را کسب کرده است و رویکردهای پنجم و چهارم در رتبه‌های بعدی قرار دارند. رویکرد دوم نیز کم‌ترین امتیاز را به دست آورده است. در شکل (۱۵) حساسیت‌های به دست آمده در رویکردهای پیشنهادی بررسی شده است. رویکرد اول بالاترین حساسیت را داشته و رویکردهای پنجم و چهارم حساسیت‌های قابل قبولی دارند. رویکرد دوم در این بخش نیز کم‌ترین حساسیت را به خود اختصاص داده است. شکل‌های (۱۶) و (۱۷) به ترتیب به اختصاصیت و دقت مربوط بوده و نتایج مشابهی را در مورد رویکردها نشان می‌دهند. در این شکل‌ها نیز رویکرد اول بهترین عمل‌کرد را دارد در حالی که رویکرد دوم پایین‌ترین نتایج را به ثبت رسانده است.

و دقت از نتایج مقاله‌ی [۸] پیشی گرفته است. امتیاز F1 به دست آمده در مطالعه‌ی [۱۴] از امتیاز F1 به دست آمده در هر دو رویکرد اول و پنجم بالاتر بوده اما حساسیت و دقت رویکردهای پیشنهادی بالاتر از حساسیت و دقت مطالعه‌ی [۱۴] می‌باشد. صحت دو رویکرد اول و پنجم بالاتر از صحت و حساسیت به دست آمده در مطالعه‌ی [۱۳] بوده اما امتیاز F1 به دست آمده در مطالعه‌ی [۱۳] از امتیاز F1 هر دو رویکرد بالاتر است. با این وجود دقت رویکرد اول از دقت مطالعه‌ی [۱۳] بالاتر است. هم‌چنین اندازه‌ی پنجره‌ی پیش‌بینی در این مطالعه معادل ۲۰۰ میلی‌ثانیه در نظر گرفته شده و اندازه‌ی پنجره‌ی پیش‌بینی در مدل این مقاله معادل با ۱۰۰ میلی‌ثانیه بوده که نشان دهنده‌ی دقت بیش‌تر مدل پیشنهاد شده نسبت به مدل مورد استفاده در مطالعه‌ی [۱۳] است.

## ۵- مقایسه‌ی نتایج روش پیشنهادی با سایر مطالعات

در جدول (۹) نتایج به دست آمده از پیاده‌سازی شبکه‌ی عمیق پیشنهادی این مطالعه با استفاده از معیارهای ارزیابی متفاوت با سایر مطالعات انجام شده روی پایگاه داده‌ی NI-FECGDB مقایسه شده است. در این جدول در هر دو رویکرد اول و پنجم روش پیشنهادی این مقاله، بالاترین مقدار صحت، حساسیت و اختصاصیت و کم‌ترین مقدار میانگین مربعات خطا در مقایسه با تمام روش‌های رقیب قابل مشاهده است. در هر دو رویکرد اول و پنجم در مقایسه با مطالعات [۳، ۵، ۹، ۱۰، ۱۱، ۱۲، ۱۵] نتایج بالاتری در صحت، امتیاز F1، حساسیت، اختصاصیت و دقت به دست آمده است. در مقایسه با مطالعه‌ی [۸] رویکرد اول نتایج بالاتری داشته در حالی که رویکرد پنجم در حساسیت

جدول (۹) - مقایسه‌ی نتایج حاصل از روش پیشنهادی با سایر مطالعات

مرجع	روش	پایگاه داده	صحت (%)	میانگین مربعات خطا	امتیاز F1 (%)	حساسیت (%)	اختصاصیت (%)	دقت (%)	تعداد کل پارامترها
[۳]	1-D CNN	PCDB	۷۷/۳۸	-	۷۷/۸۵	۸۰/۵۴	-	۷۵/۳۳	-
[۵]	1-D CNN	PCDB	-	-	-	۸۹/۰۶	-	۹۲/۷۷	-
[۸]	RCED-Net	PCDB	-	-	۹۳/۶۲	۹۲/۶۰	-	۹۴/۶۸	-
[۹]	1-D OctConv	PCDB	-	-	۹۱/۱	۹۰/۳۲	-	۹۱/۸۲	-
[۱۰]	CNN + LSTM	PCDB و خصوصی	-	۱۹/۶	-	-	-	PPA= ۹۲/۱	-
[۱۱]	dilated CNN + LSTM	PCDB و خصوصی	-	۶/۹	-	-	-	PPA= ۹۹/۶	-
[۱۲]	2-D CNN	PCDB و [۲۴]	۹۵/۲۰	-	-	-	-	-	-
[۱۳]	مدل توجه دوگانه در معماری شبکه‌ی CNN و LSTM	PCDB و [۲۴] و A&D FECG	۹۶/۲۶	-	۹۸/۰۲	۹۷/۳۸	-	۹۸/۶۸	-
[۱۴]	W-net	PCDB و [۲۴]	-	-	۹۶/۹۱	۹۵/۷۴	-	۹۷/۴۵	-
[۱۵]	معماری شبکه‌ی عمیق بر اساس اینترنت اشیا	PCDB	۹۱/۳۲	-	۹۰/۱۲	۸۹/۵۲	-	۹۴/۳۷	-
این مقاله رویکرد	1D-CNN	PCDB	۹۸/۳۶ ±۰/۰۷	۰/۰۱ ±۰	۹۶/۳۵ ±۰/۱۶	۹۸/۷۹ ±۰/۱۳	۹۶/۸۵ ±۰/۴۳	۹۹/۰۹ ±۰/۱۲	۳۱۴۰۷۷۳۸
این مقاله رویکرد	1D-CNN	PCDB	۹۶/۷۹ ±۰/۸۷	۰/۰۳ ±۰/۰۰۵	۹۳/۰۲ ±۱/۳۶	۹۷/۹۱ ±۱/۰۱	۹۲/۷۹ ±۱/۵	۹۷/۸۸ ±۰/۴۳	۳۱۴۰۷۷۳۸

پیشنهاد شده است. نتایج مقایسه‌ای نشان می‌دهد که روش پیشنهادی عمل‌کرد مناسبی در شناسایی دقیق محل وقوع کمپلکس‌های QRS جنین دارد. در بهترین رویکرد، صحت، حساسیت، اختصاصیت و دقت شبکه‌ی پیشنهادی به ترتیب

## ۶- نتیجه‌گیری

در این مقاله یک روش مبتنی بر یادگیری عمیق و شبکه‌های کانولوشنی برای تشخیص کمپلکس‌های QRS جنین معرفی شده است. چندین رویکرد مختلف برای پیاده‌سازی این روش

- [4] C. Shaw, C. Lees, and D. Giussani, "Variations on fetal heart rate variability," *The Journal of Physiology*, vol. 594, no. 5, p. 1279, 2016.
- [5] J. S. Lee, M. Seo, S. W. Kim, and M. Choi, "Fetal QRS detection based on convolutional neural networks in noninvasive fetal electrocardiogram," in *2018 4th International Conference on Frontiers of Signal Processing (ICFSP)*, 2018: IEEE, pp. 75-78.
- [6] P. Podziemski and J. Gieraltowski, "Fetal heart rate discovery: algorithm for detection of fetal heart rate from noisy, noninvasive fetal ECG recordings," in *Computing in Cardiology 2013*, 2013: IEEE, pp. 333-336.
- [7] Noninvasive Fetal ECG [Online] Available: <https://physionet.org/content/challenge-2013/1.0.0/>
- [8] W. Zhong, L. Liao, X. Guo, and G. Wang, "Fetal electrocardiography extraction with residual convolutional encoder-decoder networks," *Australasian physical & engineering sciences in medicine*, vol. 42, pp. 1081-1089, 2019.
- [9] K. Vo, T. Le, A. M. Rahmani, N. Dutt, and H. Cao, "An efficient and robust deep learning method with 1-D octave convolution to extract fetal electrocardiogram," *Sensors*, vol. 20, no. 13, p. 3757, 2020.
- [10] E. Fotiadou, M. Xu, B. van Erp, R. J. van Sloun, and R. Vullings, "Deep convolutional long short-term memory network for fetal heart rate extraction," in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2020: IEEE, pp. 1-4.
- [11] E. Fotiadou, R. J. van Sloun, J. O. van Laar, and R. Vullings, "A dilated inception CNN-LSTM network for fetal heart rate estimation," *Physiological Measurement*, vol. 42, no. 4, p. 045007, 2021.
- [12] Y.-C. Ting, F.-W. Lo, and P.-Y. Tsai, "Implementation for fetal ECG detection from multi-channel abdominal recordings with 2D convolutional neural network," *Journal of Signal Processing Systems*, vol. 93, no. 9, pp. 1101-1113, 2021.
- [13] H. Ghonchi and V. Abolghasemi, "A dual attention-based autoencoder model for fetal ECG extraction from abdominal signals," *IEEE Sensors Journal*, vol. 22, no. 23, pp. 22908-22918, 2022.
- [14] K. J. Lee and B. Lee, "End-to-end deep learning architecture for separating maternal and fetal ecgs using w-net," *IEEE Access*, vol. 10, pp. 39782-39788, 2022.
- [15] A. J. D. Krupa, S. Dhanalakshmi, K. W. Lai, Y. Tan, and X. Wu, "An IoMT enabled deep learning framework for automatic detection of fetal QRS: A solution to remote prenatal care," *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 9, pp. 7200-7211, 2022.

معادل  $96/79$ ،  $97/91$ ،  $92/79$  و  $97/88$  است. از نوآوری‌های این شبکه می‌توان به عدم حذف الکتروکاردیوگرام مادر و قابلیت آموزش شبکه با استفاده از تنها بخش کوچکی از ثبت‌های AECG اشاره کرد. یکی از دلایل اصلی موفقیت شبکه‌ی پیشنهادی، نحوه‌ی بخش‌بندی داده‌ها و برجسبدهی بازه‌های ۱۰۰ میلی‌ثانیه‌ای هر بخش از سیگنال AECG بوده که کمک شایانی به شبکه‌ی پیشنهادی برای آموزش بهتر با لایه‌های کم‌تر کرده است. در این مطالعه ۵ رویکرد متفاوت معرفی شده است. با استفاده از تعداد مختلفی از داده‌ها، قابلیت آموزش شبکه مورد بررسی قرار گرفته و مشخص شده است که شبکه می‌تواند تنها با استفاده از ۲۵ سیگنال (۲۰ سیگنال آموزشی و ۵ سیگنال تست) آموزش ببیند. رویکرد اول با حداقل پیش‌پردازش، نتایج چشم‌گیری به دست آورده است. در رویکرد دوم با استفاده از ۶۰ سیگنال، تاثیر توابع پنجره در مرحله‌ی پیش‌پردازش مورد بررسی قرار گرفته است. در رویکرد سوم ادعای قابلیت آموزش شبکه با ۲۵ سیگنال (۲۰ سیگنال آموزشی) با تغییر نسبت تقسیم داده‌ها به ۳۳ درصد (۲۰ سیگنال آموزشی و ۴۰ سیگنال تست) به چالش کشیده شده است. نتایج این رویکرد نشان داده که حتی در شرایط چالش‌برانگیز، عمل کرد شبکه قابل مقایسه با نتایج سایر مقالات بوده و در برخی موارد نتایج بهتری به دست آمده است. در رویکرد چهارم تاثیر تبدیل موجک گسسته بر نتایج شبکه بررسی و گزارش شده است. در رویکرد پنجم نیز با استفاده از ۶۰ سیگنال و اعمال سه مرحله‌ی پیش‌پردازش با فیلترهای باتروث، میانه و شکافی، نتایج به دست آمده بررسی شده است. با توجه به نتایج مثبت در هر ۵ رویکرد می‌توان نتیجه‌گیری کرد که شبکه‌ی عمیق پیشنهادی عمل کرد موفق‌تری داشته است. بالاترین نتایج در دو حالت استفاده از ۲۵ و ۶۰ سیگنال در رویکردهای اول و پنجم به دست آمده و این نتایج برای مقایسه با مقالات دیگر انتخاب شده است.

## ۷- مراجع

- [1] R. Sameni and G. D. Clifford, "A review of fetal ECG signal processing; issues and promising directions," *The open pacing, electrophysiology & therapy journal*, vol. 3, p. 4, 2010.
- [2] N. Widatalla, Y. Kasahara, Y. Kimura, and A. Khandoker, "Model based estimation of QT intervals in non-invasive fetal ECG signals," *Plos one*, vol. 15, no. 5, p. e0232769, 2020.
- [3] W. Zhong, L. Liao, X. Guo, and G. Wang, "A deep learning approach for fetal QRS complex detection," *Physiological measurement*, vol. 39, no. 4, p. 045004, 2018.



- [21] S. Wu, S.-h. Zhong, and Y. Liu, "A novel convolutional neural network for image steganalysis with shared normalization," *IEEE Transactions on Multimedia*, vol. 22, no. 1, pp. 256-270, 2019.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [23] C. Garbin, X. Zhu, and O. Marques, "Dropout vs. batch normalization: an empirical study of their impact to deep learning," *Multimedia Tools and Applications*, vol. 79, pp. 12777-12815, 2020.
- [24] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals," *circulation*, vol. 101, no. 23, pp. e215-e220, 2000.
- [16] J. Behar, J. Oster, and G. D. Clifford, "Non-invasive FECG extraction from a set of abdominal sensors." *IEEE*, 2013.
- [17] M. Varanini, G. Tartarisco, L. Billeci, A. Macerata, G. Pioggia, and R. Balocchi, "A multi-step approach for non-invasive fetal ECG analysis," in *Computing in Cardiology 2013*, 2013: IEEE, pp. 281-284.
- [18] L. Alzubaidi et al., "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions," *Journal of big Data*, vol. 8, pp. 1-74, 2021.
- [19] L. Lu, Y. Shin, Y. Su, and G. E. Karniadakis, "Dying relu and initialization: Theory and numerical examples," *arXiv preprint arXiv:1903.06733*, 2019.
- [20] S. Santurkar, D. Tsipras, A. Ilyas, and A. Madry, "How does batch normalization help optimization?," *Advances in neural information processing systems*, vol. 31, 2018.