

شبکه کانولوشنی و یادگیری چندنمونه‌ای برای برآورد غیرتماسی ضربان قلب از اطلاعات حالت کانال در

شرایط داده محدود

علیرضا ابوالقاسمی^۱، سید محمدتقی المدرسی^{۲*}

^۱ دانشجوی دکتری مهندسی برق، دانشکده مهندسی برق، دانشگاه یزد، یزد، ایران

^۲ دانشیار، دانشکده مهندسی برق، گروه مخابرات، دانشگاه یزد، یزد، ایران

مقاله پژوهشی

چکیده

پایش غیرتماسی ضربان قلب با استفاده از اطلاعات حالت کانال (CSI) سیگنال وای‌فای، به‌عنوان رویکردی نوپدید در حسگری زیست‌پزشکی، امکان نظارت پیوسته بر وضعیت فیزیولوژیکی افراد را بدون نیاز به تماس فیزیکی یا تجهیزات پوشیدنی فراهم می‌سازد. با این حال، تغییرپذیری قابل توجه الگوهای CSI میان افراد مختلف و کمبود داده‌های برچسب‌دار، توسعه مدل‌های یادگیری عمیق تعمیم‌پذیر را با چالش جدی مواجه می‌کند. در این پژوهش، یک چارچوب مبتنی بر یادگیری داده‌محدود برای تخمین ضربان قلب از سیگنال‌های CSI ارائه می‌شود که از ساختارهای یادگیری شباهت‌محور (Siamese) و رابطه‌محور (Relation-based) بهره می‌گیرد. در این چارچوب، شبکه‌های عصبی کانولوشنی SE-DenseNet، SEResNet10 و MobileNetV2 به‌عنوان رمزگذار و ویژگی‌به‌کار گرفته شده‌اند تا نمایش‌های تمایز بخش از سیگنال‌های زمانی و طیف‌نگارهای فرکانسی CSI استخراج شود. سپس، با استفاده از تعداد محدودی نمونه پشتیبان، مدل قادر است به‌صورت سریع با توزیع داده سوژه جدید تطبیق یابد، بدون آنکه دچار بیش‌برازش شود. با ارزیابی به روش LOSO کمترین میزان خطا $bpm\ 38/1$ در روش شباهت‌محور با رمزگذار و ویژگی SE-DenseNet حاصل گردید. این طراحی امکان تحلیل نقش هم‌ترازی میان معماری شبکه، نمایش زمانی یا فرکانسی CSI و راهبرد یادگیری داده‌محدود را در توسعه سامانه‌های پایش غیرتماسی ضربان قلب فراهم می‌سازد.

تاریخ دریافت:

۱۴۰۴/۱۰/۰۸

تاریخ پذیرش:

۱۴۰۴/۱۲/۰۷

کلیدواژه‌ها:

ضربان قلب، یادگیری داده‌محدود، پایش غیرتماسی، اطلاعات حالت کانال، سنجش مبتنی بر وای‌فای

نویسنده مسئول:

Smta@yazd.ac.ir

doi : 10.22034/ABMIR.2026.24171.1214

۱- مقدمه

دسته از بیماران می‌تواند مزایای مضاعفی داشته باشد؛ چرا که هم نیاز به معاینات فیزیکی مکرر و پرخطر را کاهش می‌دهد و هم به حداقل رساندن تماس مستقیم، خطر بروز عفونت سوختگی به‌طور چشمگیری کم می‌شود [۵].

سیستم‌های سنجش بدون تماس به دو دسته، مبتنی بر رادار و مبتنی بر وای‌فای (Wi-Fi) تقسیم‌بندی می‌شوند. از رادار موج پیوسته مدوله‌شده در فرکانس برای برآورد نرخ تنفس و ضربان قلب استفاده می‌شود، اگرچه این سامانه قادر به نظارت هم‌زمان چندین فرد است [۶]. اما به سخت‌افزاری سفارشی با پهنای باند گسترده ۱/۷۹ گیگاهرتزی نیاز دارد. دیگر فناوری‌ها از جمله رادار داپلر و رادار فوق پهن‌بند نیز برای نظارت بر علائم حیاتی به کار گرفته شده‌اند که آن‌ها نیز متضمن سخت‌افزارهای اختصاصی با پهنای باند بالا و هزینه فراوان هستند [۷].

در مقابل راه‌حل مبتنی بر وای‌فای با حفظ حریم خصوصی و هزینه پایین قابل استفاده است. این فناوری با بهره‌گیری از در دسترس بودن گسترده سیگنال‌های وای‌فای، نظارت بدون تماس علائم حیاتی مانند ضربان قلب و تنفس را با تشخیص تغییرات ظریف در ویژگی‌های سیگنال ناشی از فعالیت‌های فیزیولوژیکی امکان‌پذیر می‌سازد [۸]. در این روش سیگنال اطلاعات حالت کانال^۲ (CSI) را که بیانگر ویژگی‌های ظریف کانال بوده استخراج می‌گردد [۹]. روش‌های پیشرفته سنجش وای‌فای از CSI استفاده می‌کنند، که جزئیاتی از جمله دامنه و فاز در کانال‌های فرکانسی مختلف را درباره سیگنال فراهم کرده و امکان ضبط نوسانات دقیق ناشی از ضربان قلب و تنفس را می‌دهد.

باین‌حال، روش‌های موجود در تشخیص نرخ ضربان قلب با چالش‌هایی روبرو هستند، زیرا تغییرات ظریف ناشی از ضربان قلب اغلب توسط حرکات تنفسی پوشانده می‌شوند. علاوه بر این، سیستم‌ها به‌شدت به عوامل محیطی و ویژگی‌های فردی حساس هستند، که دقت مدل‌های آموزش‌دیده را در محیط‌های واقعی محدود می‌کند.

سازمان جهانی بهداشت^۱ (WHO) بر ضرورت انطباق نظام‌های سلامت با نیازهای سالمندان تأکید دارد. ادغام سامانه‌های پایش فردی در محیط‌های داخلی با ساختارهای مراقبت از سالمندان، نقشی اساسی در ارتقای فرآیند تصمیم‌گیری، ارائه مراقبت‌های فردمحور، پشتیبانی و تقویت همکاری‌های چندرشته‌ای ایفا می‌کند و در نهایت، اثربخشی و قابلیت اتکای خدمات مراقبت از راه دور را افزایش می‌دهد [۱].

بیماری‌های غیرواگیر از جمله تومورها، بیماری‌های مزمن تنفسی و بیماری‌های قلبی-عروقی، مسئول ۶۰٪ از مرگ‌ومیر جهانی بوده و از مهم‌ترین عوامل ناتوان‌کننده و مرگ‌آفرین محسوب می‌شوند. در اتحادیه اروپا، این بیماری‌ها ۹۰٪ از موارد فوت را تشکیل می‌دهند؛ به‌گونه‌ای که ۴۰٪ ناشی از بیماری‌های قلبی-عروقی، ۲۶٪ مربوط به سرطان‌ها و ۵٪ ناشی از بیماری‌های مزمن تنفسی است. ماهیت طولانی‌مدت و پیش‌رونده بیماری‌های غیرواگیر، بار ساختاری و مالی قابل توجهی بر نظام‌های سلامت تحمیل کرده و با کاهش بهره‌وری و افزایش نیاز به مراقبت‌های غیررسمی خانوادگی، روند توسعه اقتصادی کشورها را نیز تحت تأثیر قرار می‌دهد [۲].

بنابراین سیستم‌های نظارت علائم حیاتی غیرتماسی مبتنی بر فرکانس رادیویی مورد توجه فراوانی قرار گرفته‌اند که از سیگنال‌های رادیویی برای تشخیص حرکت قفسه‌سینه ناشی از تنفس و قلب بهره می‌برند. نظارت بدون تماس به‌عنوان یک رویکرد تحول‌آفرین برای درک محیط و به‌ویژه در حوزه مراقبت‌های بهداشتی در حال ظهور است [۳].

با توجه به نیاز مبرم به نظارت غیرتماسی علائم حیاتی در دوران همه‌گیری کووید-۱۹، به‌ویژه برای نظارت بر نرخ تنفس افراد در قرنطینه بدون ایجاد خطر انتقال بیماری [۴] و همچنین با در نظر گرفتن کاربردهای گسترده این فناوری در تشخیص اختلالات فیزیولوژیکی و نیز پایش افرادی که دچار سوختگی قابل توجهی شده‌اند، توسعه یک سیستم کم‌هزینه و غیرتهاجمی برای نظارت پیوسته بر علائم حیاتی امری ضروری و اجتناب‌ناپذیر است. استفاده از سیستم‌های نظارت از راه دور برای نظارت علائم حیاتی این


² Channel State Information

¹ World Health Organization

و فاز $\angle H(f_k, t)$ است. زیرحامل با فرکانس مرکزی f_k به صورت رابطه ۱ بیان می‌شود:

$$H(f_k, t) = |H(f_k, t)| e^{\angle H(f_k, t)} \\ = A(f_k, t) e^{\theta(f_k, t)} \quad (1)$$

بررسی متون موجود در زمینه سیستم‌های سنجش مبتنی بر CSI، طیفی از تکنیک‌ها را نشان می‌دهد که برای برآورد RR و HR پیشنهاد و به کار گرفته شده‌اند. همان‌گونه که در شکل ۱ مشاهده می‌نمایید دو رویکرد اصلی مبتنی بر مدل و مبتنی بر الگو در پژوهش‌ها مورد استفاده قرار گرفته است.



شکل (۱): چارچوب کلی سنجش مبتنی بر CSI [۹].

در رویکردهای مبتنی بر مدل برای سنجش علائم حیاتی، برآوردها از طریق اعمال مدل‌های ریاضی بر روی سیگنال‌های CSI استخراج می‌شوند. برخلاف رویکردهای مبتنی بر مدل الگوریتم‌های مبتنی بر الگو یا یادگیری، از داده‌های آموزشی برای استخراج روابط بین ویژگی‌های CSI و علائم حیاتی بهره می‌برند.

۱-۲ روش‌های مبتنی بر مدل

این روش‌ها شامل پیش‌پردازش و پردازش سیگنال است. در پژوهش‌های مرتبط، منابع نویز متعددی شناسایی شده‌اند که می‌توانند بر دقت اندازه‌گیری‌های CSI تأثیر بگذارند. این منابع معمولاً شامل تغییرات محیطی ناخواسته و تداخل سیگنال‌های فرکانس رادیویی می‌شوند. به منظور افزایش اعتبار و پایداری داده‌ها، کالیبراسیون و پیش‌پردازش داده‌ها امری ضروری است. در این راستا، از روش‌های فیلترینگ چند مرحله‌ای استفاده می‌شود: حذف داده‌های پرت^۴ و فرکانس بالا: در گام نخست، برای مقابله با مقادیر شدیداً متفاوت و ناهمگون، از فیلتر همپل استفاده می‌شود.

برای غلبه بر این چالش‌ها، در این پژوهش بر ادغام پردازش سیگنال و یادگیری ماشین، از جمله عملکرد شبکه‌های عمیق، متمرکز می‌شویم تا دقت و قابلیت اطمینان تشخیص علائم حیاتی را بهبود بخشیم. از آنجا که جمع‌آوری داده‌ها برچسب‌دار جهت آموزش شبکه محدود است، راهکار انتقال آموزش را در شبکه‌های عمیق پیشنهاد می‌دهیم. در ادامه ابتدا به مروری بر راهکارهای پیشین پرداخته و سپس روش پیشنهادی مبتنی بر داده‌های CSI و ارزیابی نتایج و نتیجه‌گیری را ارائه خواهیم نمود.

۲- مروری بر ادبیات

سیگنال ارسالی از فرستنده به گیرنده در مسیرهای مختلف، درجات متفاوتی از تضعیف توان، تأخیر انتشار و تغییرات فاز را تجربه می‌کند. برجسته‌سازی تغییرات بسیار ظریف ایجادشده در ناحیه قفسه سینه انسان (در حدود ۴ تا ۱۲ میلی‌متر) ناشی از نرخ تنفس^۱ (RR) و ضربان قلب^۲ (HR)، از چالش‌های اساسی در پایش علائم حیاتی محسوب می‌شوند. اطلاعات CSI نحوه انتقال سیگنال از فرستنده (ها) به گیرنده (ها) را توصیف کرده و نشان می‌دهد که چگونه عواملی نظیر تضعیف توان، محوشدگی و پراکندگی بر انتشار سیگنال تأثیر می‌گذارند. شناخته‌شده‌ترین ابزار پایش CSI در کاربردهای بدون نیاز به تماس، ابزار 802.11n Linux مبتنی بر کارت شبکه ۵۳۰۰ اینتل است که از درایورهای بی‌سیم متن‌باز لینوکس و میان‌افزارهای متعارف بهره می‌برد. این ابزار به‌طور انحصاری برای سیستم‌عامل لینوکس با اوبونتو LTS10.04 و کرنل 2.6.36 طراحی شده است. در این روش، مقادیر فاز و دامنه برای هر مؤلفه ماتریس CSI ذخیره می‌شود. این میان‌افزار با دریافت موفق هر بسته 802.11n، حالت اشکال‌زدایی^۳ را در سخت‌افزار اینتل فعال کرده و هنگامی که فرستنده در هر ثانیه تعدادی بسته داده ارسال می‌کند در گیرنده از هر بسته دریافتی، یک ماتریس پاسخ فرکانسی کانال با ابعاد ۳×۳۰ استخراج می‌شود؛ که عدد ۳ تعداد آنتن‌های گیرنده و عدد ۳۰ بیانگر تعداد زیرحامل فرکانسی است. هر CSI، $H(f_k, t)$ شامل دو مؤلفه دامنه $|H(f_k, t)|$

³ Debug mode

⁴ Outliers

¹ Respiration Rate


² Heart Rate

برای جداسازی موفقیت‌آمیز سیگنال‌های تنفس و ضربان قلب اعمال فیلترگذاری باندگذر در حوزه فرکانس ضروری است. به‌طور خاص، برای استخراج نرخ تنفس، از یک فیلتر باندگذر با محدوده فرکانسی پایین‌تر استفاده می‌شود که معمولاً بین $0/133$ هرتز (8 bpm^5) تا $0/5$ هرتز (30 bpm) تنظیم می‌گردد؛ این محدوده، تمامی نرخ‌های طبیعی تنفس در گروه‌های سنی کودکان، بزرگسالان و سالمندان را پوشش می‌دهد [۱۲]. در مقابل، برای بازسازی سیگنال ضربان قلب، از فیلتر باندگذر دیگری با محدوده فرکانسی بالاتر، اغلب از $0/625$ هرتز ($37/5 \text{ bpm}$) تا $2/5$ هرتز (150 bpm) استفاده می‌شود [۱۳]. این فیلترینگ دوگانه تضمین می‌کند که سیگنال‌های ناشی از تنفس و ضربان قلب، بدون تداخل متقابل و با حداقل نویزهای فرکانس بالا، برای برآورد نرخ‌های حیاتی آماده‌سازی شوند.

به‌منظور تفکیک دقیق سیگنال‌های تنفس و ضربان قلب، از روش تبدیل موجک گسسته^۶ (DWT) نیز استفاده می‌شود. ابتدا سیگنال اصلی در چهار سطح با استفاده از فیلتر موجک دابشیز تجزیه می‌شود. برای دستیابی به سیگنال تنفسی بدون نویز، از ضریب تقریب استفاده می‌شود، زیرا این ضریب، سیگنال‌های با فرکانس پایین را در محدوده صفر هرتز تا $0/625$ هرتز در برمی‌گیرد که متناظر با نرخ‌های تنفسی طبیعی است. سپس، برای بازسازی سیگنال ضربان قلب، حاصل جمع ضرایب جزئیات مورد استفاده قرار می‌گیرد؛ این ترکیب، محدوده فرکانسی از $0/625$ هرتز تا $2/5$ هرتز را شامل می‌شود که دقیقاً محدوده فرکانسی موردنیاز برای استخراج ضربان قلب است [۱۳]. در رویکردی دیگر، از تجزیه مد متغیر^۷ (VMD) استفاده می‌شود. سیگنال اندازه‌گیری CSI به شش موجک تجزیه می‌شود و سپس مد ذاتی^۸ پنجم (IMF₅) برای تحلیل تنفس مورد استفاده قرار می‌گیرد و از (IMF₄) برای تحلیل ضربان قلب استفاده می‌شود [۱۴].

پس از استخراج سیگنال مطابق شکل ۳، گام نهایی برای استخراج نرخ‌های حیاتی، تحلیل در حوزه فرکانس است [۱۵]. بدین منظور،

این فیلتر به‌صورت یک پنجره متحرک بر روی داده‌های هر زیرحامل^۱ اعمال می‌گردد تا نویزهای لحظه‌ای با دامنه بالا حذف شوند. در گام بعدی، به‌منظور حذف نویزهای ناخواسته با فرکانس بالا که منشأ آن‌ها حرکات محیطی هستند، از فیلتر میانگین متحرک^۲ استفاده می‌گردد. این فیلتر تضمین می‌کند که تنها مؤلفه‌های فرکانسی پایین‌تر که با حرکات فیزیولوژیک انسان مطابقت دارند حفظ شوند [۱۰]. خروجی پردازش چند مرحله‌ای در شکل ۲ نمایش داده شده است.



شکل (۲): کالیبراسیون مقادیر دامنه یک زیرحامل [۱۰].

تنوع فرکانسی در اندازه‌گیری‌های CSI زیرحامل‌های مختلف، نقش مهمی در استخراج سیگنال‌های حیاتی ایفا می‌کند. به دلیل تفاوت در فرکانس مرکزی و طول موج زیرحامل‌ها و اثرات چندمسیری^۳ محیط، دامنه CSI در زیرحامل‌های مختلف متفاوت است. در نتیجه، هر زیرحامل حساسیت متفاوتی نسبت به حرکات تنفسی با فرکانس پایین و ارتعاشات ظریف ضربان قلب با فرکانس بالاتر دارد. این ناهمگونی حساسیت باعث می‌شود زیرحامل‌ها اطلاعات مکملی از سیگنال‌های تنفسی و قلبی فراهم کنند و تفکیک دقیق‌تر این سیگنال‌ها را ممکن سازند [۱۱].

تکنیک تحلیل مؤلفه‌های اصلی^۴ (PCA) برای استخراج مؤلفه‌های اصلی از اندازه‌گیری‌های دامنه CSI فیلترشده در تمامی زیرحامل‌ها استفاده می‌کند. مؤلفه‌های اصلی استخراج‌شده، غالب‌ترین تغییرات ناشی از حرکات بدن را جذب می‌کنند؛ درحالی‌که اطلاعات زائد ناشی از همبستگی بالا در زیرحامل‌ها را حذف می‌نمایند [۱۲].

⁵ Beat per minute

⁶ Discrete Wavelet Transform

⁷ Variable Mode Decomposition

⁸ Intrinsic Mode Functions

¹ Subcarrier

² Moving Average Filter

³ Multipath

⁴ Principal Component Analysis


محیط‌های داخلی، استفاده مستقیم از داده‌های خام CSI را با چالش مواجه می‌سازد. از این رو، پیش‌پردازش سیگنال به منظور بهبود عملکرد مدل و اطمینان از تشخیص و طبقه‌بندی دقیق علائم حیاتی امری ضروری است.

طبقه‌بندی شاخص‌های فیزیولوژیکی بر اساس استانداردهای کلینیکی معتبر برای نرخ تنفس پنج کلاس متمایز تعریف شده است: کلاس ۱ بیانگر برادی‌پنه $10 \leq \text{bpm}$ ؛ کلاس‌های ۲ و ۳ به ترتیب ۱۱-۱۳ و ۱۴-۱۶ نشان‌دهنده دامنه‌های تنفسی زیرطبیعی تا طبیعی؛ کلاس ۴، ۱۷-۱۹ بیانگر اندکی افزایش در RR و کلاس ۵ $20 \geq \text{bpm}$ معرف تاکی‌پنه^۶ است. در طبقه‌بندی RR با استفاده از KNN، بیشترین دقت حاصل شده برابر با ۹۹/۱۸٪ بود [۱۸].

برای ضربان قلب بر اساس استانداردهای کلینیکی، سه کلاس در نظر گرفته شده است: کلاس ۱ ضربان $60 \leq \text{bpm}$ نشان‌دهنده برادی‌کاردی^۷؛ کلاس ۲ نرخ ضربان $61-80 \text{ bpm}$ معرف دامنه طبیعی؛ و کلاس ۳ ضربان $81 \geq \text{bpm}$ بیانگر تاکی‌کاردی^۸ است. در ارزیابی روش طبقه‌بندی KNN، دقت‌های به دست آمده به ترتیب ۶۱/۱۵٪، ۴۱/۹۲٪ و ۶۶/۵۸٪ برای سه کلاس هدف، بالاترین عملکرد ثبت شده را نشان می‌دهند [۱۸]. بر پایه یک شبکه کانولوشنی عمیق، ماژول تشخیص تنفس ResFi طراحی شده است (شکل ۴)؛ شبکه‌ای که هدف آن استخراج خودکار ویژگی‌های متمایزکننده از داده CSI و دسته‌بندی نرخ تنفس در سناریوهای مختلف است [۱۹].

این معماری شامل دو مؤلفه اصلی است: رمزگذار و ویژگی^۹ و طبقه‌بندی‌کننده. رمزگذار و ویژگی: در بخش رمزگذار، چندین لایه کانولوشنی به همراه لایه‌های تجمیع^{۱۰} به صورت سلسله‌مراتبی قرار گرفته‌اند. ورودی شبکه، دامنه سیگنال CSI پس از پیش‌پردازش است. لایه‌های کانولوشنی با یادگیری فیلترهای مناسب، قادرند الگوهای موجی و تغییرات تناوبی مرتبط با انبساط و انقباض قفسه سینه را استخراج کنند. لایه‌های pooling نیز ضمن کاهش ابعاد، به حذف بخشی از نویزهای محیطی با حفظ

از چگالی طیف توان که با استفاده از تبدیل فوریه سریع به دست می‌آید، استفاده می‌شود تا اطلاعات نرخ تنفس از داده‌های CSI در حوزه فرکانس استخراج گردد [۱۵]. همچنین شیانگ ژانگ و همکاران [۱۶] پس از غلبه بر دو چالش، یکی ضعیف بودن اثر ناشی از تنفس/ضربان قلب در CSI و دوم، حذف اثر حرکتی مانند غلتیدن، نرخ ضربان را در حوزه فرکانس به دست آورده‌اند. روش دیگری استخراج نرخ، تحلیل قله‌های برجسته سیگنال متناظر با تنفس و ضربان قلب است که برای تشخیص دقیق این قله‌ها که متناظر با نرخ تنفس و ضربان قلب می‌باشند، از الگوریتم تشخیص قله استفاده می‌شود. با شناسایی قله مربوط به فرکانس تنفس (در محدوده ۰/۱۳۳ تا ۰/۵ هرتز) و قله مربوط به ضربان قلب (در محدوده ۰/۶۲۵ تا ۲/۵ هرتز)، می‌توان نرخ‌های دقیق تنفس و ضربان قلب را محاسبه و برآورد نمود [۱۷].



شکل (۳): نمایش سیگنال ضربان قلب با پردازش CSI و سیگنال ثبتی از سنسور ACC [۱۵].

۲-۲ روش‌های مبتنی بر الگو

این روش‌ها عمدتاً با به‌کارگیری الگوریتم‌های یادگیری نظارت‌شده مانند ماشین بردار پشتیبان^۱ (SVM)، نزدیک‌ترین همسایگی^۲ (KNN) و همچنین مدل‌های یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی^۳ (CNN) و بازگشتی^۴ (RNN) به کشف تابع نگاشت بین اندازه‌گیری‌های CSI و برجسب‌های واقعی می‌پردازند. اگرچه این مدل‌ها به‌ویژه به دلیل توانایی در یادگیری ویژگی‌های پیچیده و غیرخطی مستقیماً از داده‌های خام یا پیش‌پردازش شده CSI مورد توجه هستند، اما اثر چندمسیری در

⁶ Tachypnea

⁷ Bradycardia

⁸ Tachycardia

⁹ Feature Encoder

¹⁰ Pooling

¹ Support Vector Machine

² K-nearest Neighbors

³ Convolutional Neural Network

⁴ Recurrent Neural Network

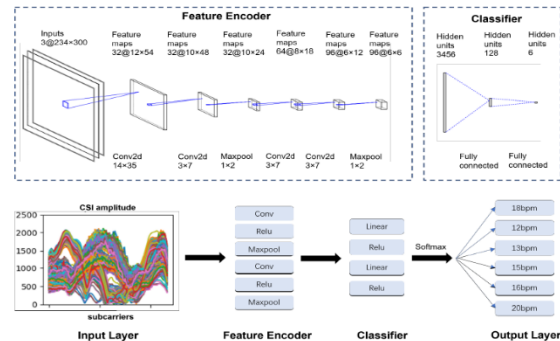
⁵ Bradypnea

Adam یا SGD آموزش می‌بیند و عملکرد آن با داده‌های اعتبارسنجی پایش می‌شود. مقایسه نتایج شبکه با داده‌های واقعی به دست آمده از برنامه پایش ضربان قلب هوشمند نشان می‌دهد که به کارگیری CNN همراه با مراحل مناسب پیش‌پردازش و پس‌پردازش، دقتی در حدود ۹۶٪ در تحلیل داده‌ها فراهم کرده است [۲۰].

به منظور استخراج هم‌زمان دو شاخص حیاتی بنیادین، یعنی ضربان قلب و نرخ تنفس، این پژوهش یک شبکه عصبی کانولوشنی با ورودی یکتا و دو خروجی معرفی می‌کند که با عنوان شبکه نرخ ضربان قلب و نرخ تنفس (H3RN) شناخته می‌شود. طراحی این شبکه بر مبنای این مشاهده فیزیولوژیک انجام شده است که ریتم قلب و الگوی تنفس دارای پیوند درونی و هم‌بستگی طبیعی هستند؛ بنابراین، برآورد توأم آن‌ها از یک منبع داده مشترک مانند CSI می‌تواند به دقت بیشتر و پیچیدگی محاسباتی کمتر منجر شود [۲۱].

ساختار کلی H3RN، مطابق شکل ۵، از سه بخش اصلی شامل لایه‌های اشتراکی^۱، لایه تخت‌سازی^۲، لایه‌های تمام‌متصل تشکیل شده است. لایه‌های اشتراکی شامل سه بلوک کانولوشنی هستند که به منظور استخراج الگوهای مشترک زمانی-فرکانسی از داده‌های دامنه و فاز CSI طراحی شده‌اند. بلوک اول با کرنل 5×5 و بیشینه‌برداری 4×4 ، ویژگی‌های پایه CSI را استخراج می‌کند؛ بلوک دوم با کرنل 3×3 و بیشینه‌برداری 2×2 ، ویژگی‌های میانی مرتبط با پویایی‌های تنفسی و تغییرات ضربان قلب را مدل می‌کند؛ و بلوک سوم با کرنل 2×2 و بیشینه‌برداری 3×3 ، الگوهای ریزمقیاس و ویژگی‌های سطح بالای قلبی-تنفسی را استخراج می‌نماید. پس از مرحله تخت‌سازی، ویژگی‌ها وارد لایه‌های تمام‌متصل شده و دو خروجی مستقل برای تخمین نرخ تنفس و ضربان قلب تولید می‌شود. این معماری دو خروجی با اشتراک‌گذاری مؤثر ویژگی‌ها، هم‌افزایی اطلاعات قلبی و تنفسی موجود در CSI را به‌طور بهینه بهره‌برداری می‌کند.

ویژگی‌های کلیدی کمک می‌کنند. در نهایت، خروجی این بخش به یک بردار یک‌بعدی تبدیل می‌شود که نماینده ویژگی‌های سطح بالا و استخراج شده از سیگنال است. نتایج آزمایش‌ها نشان می‌دهد که افزایش تعداد لایه‌های کانولوشنی، قدرت تمایزدهی مدل را افزایش می‌دهد؛ هرچند این کار نیازمند داده آموزشی بیشتر و زمان آموزش طولانی‌تر است.



شکل (۴): بلوک دیاگرام الگوریتم ResFi [۱۹].

طبقه‌بندی‌کننده: پس از رمزگذاری ویژگی‌ها، بردار حاصل به بخش طبقه‌بندی‌کننده وارد می‌شود. این بخش شامل دو لایه کاملاً متصل^۱ است که وظیفه نگاشت ویژگی‌های استخراج شده به کلاس‌های خروجی یعنی نرخ تنفس را بر عهده دارد. انتخاب این ساختار ساده اما کارآمد باعث می‌شود شبکه بتواند روابط غیرخطی میان الگوهای تنفسی و کلاس‌های برچسب‌خورده را به خوبی بیاموزد. برای اعمال عملکرد غیرخطی در لایه‌های درونی، از تابع فعال‌سازی ReLU به صورت $f(x) = \max(0, x)$ استفاده شده است. این تابع افزون بر سادگی محاسباتی، از بروز مشکل محوشدگی گرادیان در شبکه‌های عمیق جلوگیری می‌کند.

داده‌های CSI که به صورت ماتریس‌های مختلط ثبت می‌شوند، پیش از ورود به CNN نیازمند پیش‌پردازش شامل تغییر ساختار به قالب تنسوری، نرمال‌سازی، کاهش نویز و در صورت لزوم افزایش داده هستند. معماری CNN طراحی شده از لایه‌های کانولوشنی برای استخراج ویژگی، لایه‌های pooling برای کاهش ابعاد، و لایه‌های کاملاً متصل برای انجام فرایند طبقه‌بندی یا رگرسیون تشکیل می‌شود. مدل با استفاده از داده‌های برچسب‌گذاری شده و به کمک یک تابع هزینه مناسب و الگوریتم‌های بهینه‌سازی نظیر

³ Flatten Layer

¹ Fully Connected

² Shared Layers

ویژگی‌های طیفی به یک شبکه تمام‌متصل کم‌پارامتر تغذیه می‌شوند که معماری و توابع فعال‌سازی آن به‌طور ویژه برای سازگاری با طرح رمزنگاری همومورفیک CKKS طراحی شده است، به‌گونه‌ای که طبقه‌بندی نرخ تنفس و ضربان قلب مستقیماً روی داده‌های رمزگذاری‌شده و بدون افشای محتوای سیگنال در سمت سرور انجام می‌گیرد.


۳- روش پیشنهادی

در این بخش به تشریح چارچوب پیشنهادی برای برآورد غیرتماسی نرخ ضربان قلب بر مبنای CSI در شبکه‌های وای‌فای می‌پردازیم. روش پیشنهادی باهدف استخراج کارآمد اطلاعات فیزیولوژیکی از سیگنال‌های چندزیرباند CSI طراحی شده است و هم‌زمان چالش‌های مرتبط با تغییرات ذاتی میان افراد و محدودیت حجم داده‌های آموزشی به دلیل آنکه مجموعه داده هم‌زمان CSI و تماسی علائم حیاتی محدود و جمع‌آوری آن زمان‌بر است، را مورد توجه قرار می‌دهد. نمای کلی از جریان پردازش در شکل ۶ نشان داده شده است.

۳-۱ یادگیری داده‌محدود

در مسائل طبقه‌بندی یادگیری داده‌محدود^۱ (FSL) به توانایی مدل در تشخیص صحیح نمونه‌های مجموعه پرس‌وجو اطلاق می‌شود، حتی در شرایطی که تنها تعداد بسیار محدودی نمونه برچسب‌دار از هر کلاس در مجموعه پشتیبانی در دسترس باشد [۲۴].

برخلاف روش‌های متداول یادگیری عمیق که به حجم قابل توجهی از داده‌های برچسب‌دار وابسته‌اند، یادگیری داده‌محدود چارچوبی کارآمد برای مواجهه با سناریوهایی فراهم می‌آورد که در آن‌ها گردآوری یا برچسب‌زنی داده‌ها پرهزینه، زمان‌بر یا عملاً غیرممکن است [۲۵]. ریشه‌های پژوهشی FSL به رویکردهای اولیه یادگیری تک‌نمونه مبتنی بر مدل‌های بیزی بازمی‌گردد که نخستین بار توسط لی و همکاران معرفی شدند [۲۶]. با پیشرفت روش‌های یادگیری عمیق، بسیاری از رویکردهای نوین FSL بر مبنای فرایادگیری یا «یادگیری برای یادگیری» توسعه یافته‌اند [۲۷]. در این چارچوب، مدل از طریق آموزش بر روی مجموعه‌ای از وظایف کمکی، دانش



شکل (۵): ساختار شبکه H3RN [۲۱].

باهداف مقابله با چالش‌های ذاتی ناشی از مدولاسیون غیرخطی سیگنال و حرکات ناخواسته بدن در محیط‌های عملی روش DeepVS تخمین HR و RR را به‌عنوان یک مسئله رگرسیون انتها-به-انتها فرموله می‌کند. این چارچوب از معماری دوجریانی استفاده می‌کند که به‌طور مشترک نمایه‌های حوزه زمانی و حوزه فرکانسی سیگنال‌های RF را بهره‌برداری می‌نماید و امکان توصیف مکمل حرکات فیزیولوژیکی دوره‌ای و نشانه‌های طیفی آن‌ها را فراهم می‌آورد [۲۲]. در هر جریان، شبکه‌های عصبی کانولوشنی یک‌بعدی (IDCNN) برای ثبت الگوهای زمانی محلی و قله‌های طیفی فشرده، به ترتیب، به کار گرفته می‌شوند.

DeepVS با ادغام مکانیزم خود-توجهی برای تجمیع اطلاعات در چندین پنجره زمانی متوالی، ظرفیت مدل‌سازی وابستگی‌های بلندمدت و مقاومت در برابر اختلالات گذرا را افزایش می‌دهد. این چارچوب همچنین یک ساختار رگرسیون چندسر معرفی می‌کند که HR و RR را به‌صورت هم‌زمان در قالب یک مدل یکپارچه برآورد کرده و امکان یادگیری ویژگی‌های مشترک در کنار سرهای پیش‌بینی ویژه هر وظیفه را فراهم می‌سازد. ترکیب هیبریدی استخراج ویژگی کانولوشنی و مدل‌سازی زمانی مبتنی بر توجه، موجب کاهش تداخلات ناشی از هارمونیک‌های تنفسی، مصنوعات حرکتی و اثرات اختلاط غیرخطی شده و دقت و پایداری بالاتری را نسبت به روش‌های غیریادگیری‌محور و مدل‌های عمیق تک‌دامنه در حسگری RF ارائه می‌دهد. احسنول اسلام و همکاران [۲۳]، روشی بر اساس چارچوب یادگیری عمیق سبک‌وزن مبتنی بر CSI معرفی نموده‌اند که ابتدا با استفاده از فیلترهای کلاسیک و PCA، ابعاد داده‌های دامنه سیگنال‌های CSI را کاهش داده و چگالی طیفی توان را به‌عنوان ویژگی ورودی استخراج می‌کند؛ سپس این

¹ Few-Shot Learning

بهره می‌برند که در مرحله آموزش اولیه بر روی داده‌های پایه آموزش داده شده است. ارزیابی عملکرد این شبکه‌ها با در نظر گرفتن ۱۰ نمونه از هر کاربر به‌عنوان مجموعه پشتیبانی انجام شده است.

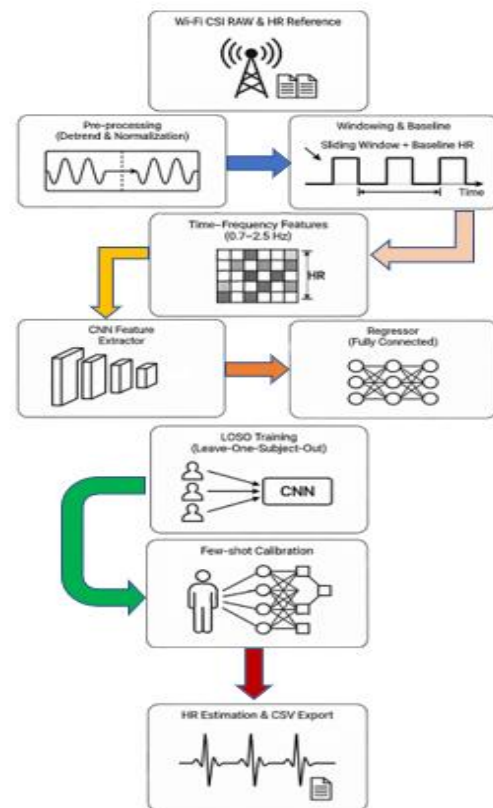
با توجه به ماهیت سیگنال‌های CSI که در مقایسه با داده‌های تصویری متداول از غنای اطلاعاتی کمتری برخوردارند، به‌کارگیری معماری‌های بسیار عمیق می‌تواند منجر به بیش‌برازش و کاهش قابلیت تعمیم مدل شود. از این رو، در این پژوهش از معماری‌های کانولوشنی نسبتاً کم‌عمق به‌عنوان رمزگذار و ویژگی استفاده شده است تا تعادلی مناسب میان ظرفیت یادگیری و پیچیدگی مدل برقرار گردد. در این راستا، سه معماری کانولوشنی شامل SE-ResNet10، DenseNet و MobileNetV2 با وزن‌های از پیش آموزش دیده بر روی مجموعه داده ImageNet مورد بررسی قرار گرفتند [۳۰].

روش پیشنهادی این پژوهش برای تخمین ضربان قلب مبتنی بر سیگنال‌های CSI وای‌فای، در چارچوب یادگیری با داده‌های محدود طراحی شده است. در این رویکرد، پس از مرحله آموزش اولیه، لایه‌های استخراج ویژگی به‌صورت ثابت نگه‌داشته شده و تنها لایه‌های رگرسیونی در مرحله تطبیق سریع^۳ بر روی مجموعه پشتیبان^۴ به‌روزرسانی می‌شوند [۲۵]. این راهکار، ضمن کاهش تعداد پارامترهای قابل آموزش در مرحله تطبیق، امکان یادگیری سریع و پایدار را فراهم کرده و از بیش‌برازش در شرایط کم‌نمونه جلوگیری می‌کند.

۲-۳ پیش پردازش

فرض کنید دامنه سیگنال CSI را در زمان t برای زیرحامل s ام نشان دهد. برای هر آزمودنی، ابتدا دامنه خام سیگنال‌های CSI با فیلتر میانگین متحرک پردازش می‌کنیم تا اثر رانش‌های فرکانس پایین ناشی از ناپایداری سخت‌افزاری و عوامل محیطی حذف گردد. در ادامه، برای کاهش تفاوت‌های مقیاسی و بهبود پایداری فرآیند آموزش، هر زیرحامل با استفاده از

قابل‌انتقالی را فرامی‌گیرد که امکان تعمیم مؤثر به وظایف جدید با داده‌های محدود را فراهم می‌سازد. این راهبرد، ضمن افزایش توان یادگیری مدل، از بروز پدیده بیش‌برازش که معمولاً در به‌کارگیری شبکه‌های عمیق بر روی داده‌های اندک مشاهده می‌شود، جلوگیری می‌کند.




شکل (۶): بلوک دیاگرام روش پیشنهادی

بر این اساس، هدف از به‌کارگیری فرایادگیری در این پژوهش، استخراج دانش مشترک و قابل انتقال از مجموعه آموزشی پایه است؛ به‌گونه‌ای که مدل قادر باشد با تکیه بر تعداد محدودی نمونه در مجموعه پشتیبانی، فرآیند یادگیری را به‌صورت مؤثر انجام داده و در نهایت عملکرد قابل اطمینانی بر روی مجموعه آزمون ارائه دهد. در راستای انتخاب مناسب‌ترین معماری شبکه برای پیاده‌سازی این چارچوب، دو ساختار پرکاربرد در این حوزه، شامل شبکه‌های شباهت‌محور^۱ [۲۸] و شبکه‌های رابطه‌ای^۲ [۲۹]، مورد بررسی و مقایسه قرار گرفتند. هر دو ساختار از یک رمزگذار ویژگی مشترک

³ Fine-Tuning
⁴ Support Set


¹ Siamese Network
² Relation Network

تصویری چندکاناله $XER^{C \times F \times T}$ تشکیل می‌شود که در آن $C=30$ بیانگر تعداد زیرحامل‌ها است. F و T به ترتیب نمایانگر ابعاد فرکانس و زمان هستند.



شکل (۸): طیف‌نگاره اولین زیرحامل

نمایش ساختاریافته شکل ۹، عملکرد حاصل از ویژگی‌های دامنه برای یک پنجره ۲۵ ثانیه‌ای را نمایش می‌دهد.



شکل (۹): نمایش تصویری طیف‌نگاره $RC \times F$

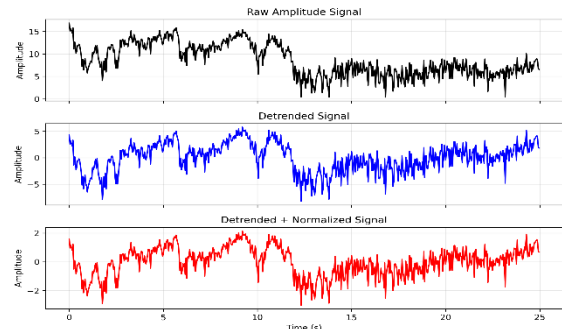
این تبدیل سیگنال‌های خام CSI را به ورودی‌هایی با ساختار مشابه تصویر تبدیل می‌کند و شبکه‌های عصبی کانولوشنی قادر خواهند بود هم‌بستگی‌های مکانی میان زیرحامل‌ها و الگوهای طیفی ناشی از حرکت قلب را به‌طور هم‌زمان استخراج نمایند.

۳-۴ استخراج ویژگی مبتنی بر CNN

با توجه به ماهیت غیرایستانت سیگنال‌های CSI و حساسیت آن‌ها به حرکات ریز بدن، نویز محیطی و تغییرات کانال، انتخاب نحوه نمایش ورودی نقش تعیین‌کننده‌ای در کیفیت ویژگی‌های استخراج‌شده دارد. از این‌رو، در این مطالعه دو رویکرد مکمل برای

نرمال‌سازی Z-نمره^۱ استانداردسازی می‌شود. شکل ۷ مراحل پیش‌پردازش اعمال‌شده بر روی سیگنال دامنه زیرحامل اولین شخص در یک پنجره ۲۵ ثانیه‌ای را نمایش می‌دهد.

Amplitude Signal Preprocessing (Subcarrier 1, 25s Window)



شکل (۷): نمایش سیگنال خام، سیگنال با حذف اجزای تغییرات آهسته و سیگنال نرمال‌شده

در نتیجه این فرآیند، دنباله‌ای از قطعه‌های کوتاه‌مدت سیگنال به دست می‌آید که هر پنجره بازه‌ای کوتاه از وضعیت فیزیولوژیکی آزمودنی را نمایش می‌دهد.

۳-۳ نمایش زمان-فرکانس

هر پنجره CSI شامل سیگنال‌هایی از ۳۰ زیرحامل انتخاب‌شده است که به‌طور مشترک تنوع مکانی موجود در کانال بی‌سیم را ثبت می‌کنند. برای هر زیرحامل، تبدیل فوریه کوتاه‌مدت^۲ (STFT) به‌منظور محاسبه نمایش زمان-فرکانس آن اعمال می‌شود. طیف‌نگاره‌های حاصل سپس با استفاده از فیلتر میان‌گذر پردازش می‌گردند تا تنها مؤلفه‌های فرکانسی واقع در بازه فیزیولوژیکی ضربان قلب (۰/۷ تا ۲/۵ هرتز) حفظ شوند.

$$S_k(f, \tau, s) = \left| \sum_{t=0}^{T_W-1} A_k(t, s) w(t-\tau) e^{-j2\pi f t} \right|^2 \quad (2)$$

در رابطه بالا $w(\cdot)$ تابع پنجره‌گذاری را نشان می‌دهد. به‌منظور پایدارسازی دامنه عددی و برجسته‌سازی تغییرات نسبی طیفی، فشرده‌سازی لگاریتمی بر روی نتایج اعمال می‌شود:

$$\tilde{S}_k(f, \tau, s) = \delta + \log(S_k(f, \tau, s)) \quad (3)$$

طیف‌نگاره‌های حاصل همانند شکل ۸ از هر پنجره به دست می‌آید، از پشته شدن تمامی زیرحامل‌ها در کنار یکدیگر یک نمایش

² Short-time Fourier Transform

¹ Z-score Normalization

بر CSI ایفا می‌کنند. در نهایت، چنین طراحی‌ای موجب افزایش جامعیت تحلیل‌ها و تقویت اعتبار نتایج ارائه‌شده می‌شود. جدول ۱ ساختار معماری و مشخصات اصلی سه شبکه کانولوشنی مورد استفاده به‌عنوان رمزگذار و ویژگی ارائه‌شده است. که در آن SE توجه به کانال، r نرخ کاهش در مکانیزم SE و BN نرمال‌سازی دسته‌ای است.

جدول (۱): مقایسه ساختار معماری شبکه‌ها

شبکه/کدگذار	ابعاد ورودی	لایه‌های اصلی	مکانیزم SE
SE-DenseNet	طیف‌نگار ($8 \times 8 \times 30$)	Conv2D ($64, 3 \times 3$) BN, ReLU, AdaptiveAvgPool	SE-Block (دوبعدی) ($r=16$)
MobileNetV2	طیف‌نگار ($8 \times 8 \times 30$)	تطبيق دهنده کانال MobileNetV2 از پیش آموزش دیده	در bottleneck ها
SE-ResNet10	سیگنال یک‌بعدی ($T \times 30$)	Conv1D ($64, 7$) MaxPool, ۴ مرحله باقیمانده	SE-Block (یک‌بعدی) ($r=16$)

۴- نتایج روش پیشنهادی

به‌منظور ارزیابی منصفانه و واقع‌بینانه روش پیشنهادی، از چارچوب اعتبارسنجی «حذف یک سوژه (LOSO)» استفاده شده است. در این چارچوب، در هر تکرار، داده‌های مربوط به یک سوژه به‌عنوان مجموعه آزمون در نظر گرفته‌شده و داده‌های سایر سوژه‌ها برای آموزش اولیه مدل مورد استفاده قرار می‌گیرند.

در هر تکرار LOSO، پس از اتمام مرحله آموزش اولیه، فرآیند تطبیق سریع مدل با سوژه هدف انجام می‌گیرد. بدین منظور، تعداد محدودی نمونه از داده‌های سوژه آزمون به‌عنوان مجموعه پشتیبان انتخاب شده و تنها بخشی از پارامترهای مدل، متناسب با چارچوب یادگیری داده‌محدود، به‌روزرسانی می‌شوند. این مرحله باهدف انطباق مدل با توزیع داده سوژه جدید و بدون نیاز به آموزش مجدد کامل شبکه انجام می‌پذیرد. در ادامه، عملکرد مدل تطبیق‌یافته بر روی باقی‌مانده داده‌های سوژه آزمون که در فرآیند تطبیق مورد استفاده قرار نگرفته‌اند، مورد ارزیابی قرار می‌گیرد.

نمایش داده‌ها در نظر گرفته‌شده است: نمایش در حوزه فرکانس و نمایش در حوزه زمان. این انتخاب باهدف بررسی تأثیر نوع نمایش سیگنال بر توانایی شبکه در استخراج الگوهای مرتبط با ضربان قلب و افزایش قابلیت تعمیم مدل انجام‌شده است.

در رویکرد مبتنی بر حوزه فرکانس، سیگنال‌های CSI ابتدا به طیف‌نگار دوبعدی تبدیل می‌شوند که در آن، توزیع انرژی سیگنال در بازه فرکانسی مرتبط با ضربان قلب به‌صورت صریح قابل مشاهده است. این نمایش، امکان برجسته‌سازی الگوهای تناوبی و تغییرات فرکانسی ظریف ناشی از ضربان قلب را فراهم می‌سازد و در نتیجه، برای معماری‌های کانولوشنی دوبعدی که در استخراج الگوهای مکانی-فرکانسی عملکرد مناسبی دارند، ورودی مناسبی محسوب می‌شود. بر این اساس، دو شبکه کانولوشنی SE-DenseNet و MobileNetV2 از نمایش طیف فرکانسی به‌عنوان ورودی استفاده می‌کنند تا بتوانند همبستگی‌های فرکانسی میان زیرکانال‌ها و تغییرات زمانی ضربان قلب را به‌طور هم‌زمان مدل‌سازی نمایند.

در مقابل، یکی از معماری‌ها، SE-ResNet10، به‌گونه‌ای طراحی شده است که مستقیماً بر روی سیگنال زمانی CSI عمل می‌کند. دلیل این انتخاب آن است که در نمایش زمانی، اطلاعات فاز و دامنه سیگنال بدون اعمال تبدیل‌های میانی حفظ می‌شود و شبکه قادر است الگوهای زمانی کوتاه‌مدت و وابستگی‌های ترتیبی سیگنال را به‌صورت مستقیم بیاموزد. استفاده از کانولوشن‌های یک‌بعدی در این ساختار، امکان مدل‌سازی پویایی‌های زمانی سیگنال و پاسخ‌های گذرای ناشی از تغییرات ضربان قلب را فراهم می‌کند؛ بدون آن‌که محدودیت‌های ناشی از انتخاب پارامترهای تبدیل فرکانسی بر فرآیند یادگیری تحمیل شود.

به‌کارگیری هم‌زمان نمایش‌های زمانی و فرکانسی در این پژوهش، نه‌تنها به‌عنوان یک انتخاب معماری، بلکه به‌عنوان یک راهبرد تحلیلی در نظر گرفته‌شده است. این رویکرد امکان مقایسه توان استخراج ویژگی در دو حوزه مکمل را فراهم کرده و به ارزیابی این موضوع کمک می‌کند که آیا اطلاعات فرکانسی صریح یا پویایی‌های زمانی خام، نقش مؤثرتری در تخمین ضربان قلب مبتنی

¹ Leave-One-Subject-Out

۱-۴ مجموعه دادگان

آرمتا گارسیا و همکاران [۱۸] در آزمایشگاه علوم و مهندسی داده دانشگاه خودمختار باخا کالیفرنیا^۱ (UABC) یک مجموعه دادگان گردآوری کرده‌اند. ۱۷ فرد سالم در این پژوهش شرکت نموده‌اند و هر شخص در وضعیت روبه‌بالا روی تخت قرار گرفته است (شکل ۱۰). در دو سوی تخت، دو رایانه کوچک با سیستم‌عامل Ubuntu 14.04 و کارت شبکه Intel-5300 در فاصله ۱/۵ متری از یکدیگر مستقر شده؛ به گونه‌ای که قفسه سینه آزمودنی همواره در میدان دید هر دو رایانه قرار داشته باشد.



شکل (۱۰): سناریو دریافت اطلاعات [۱۸]

در این پیکربندی، یک دستگاه به‌عنوان فرستنده مورد استفاده قرار گرفته که با بهره‌گیری از یک آنتن همه‌جهته، بسته‌های داده را با نرخ ۲۵ بسته در ثانیه در باند ۵ گیگاهرتز ارسال می‌کند. در سوی گیرنده سه آنتن همه‌جهته نصب شده است. برای ارزیابی نرخ تنفس، شرکت‌کنندگان تنفس خود را با یک مترونوم که بر فواصل زمانی متناظر با ۱۸ تا ۴۲ ضربه در دقیقه (معادل ۹ تا ۲۱ تنفس در دقیقه) تنظیم شده بود، همگام نمودند. برای هر یک از نرخ‌های تنفس، پنج فایل ۵ دقیقه‌ای ثبت شده است. داده‌های تنفس مرجع با استفاده از یک شتاب‌سنج سه‌محوره که روی قفسه سینه فرد نصب شده بود جمع‌آوری شده است. همچنین، مقادیر مرجع ضربان قلب توسط حسگر Polar H9 اندازه‌گیری شد؛ در ثبت ضربان قلب، فرد در طول ثبت یک مجموعه داده ۵ دقیقه‌ای کاملاً بی‌حرکت باقی می‌ماند. در نهایت، داده‌های CSI استخراج و برای تحلیل‌های بعدی ذخیره شدند و در دسترس عموم^۲ قرار گرفته‌اند.

۲-۴ راهبرد ترکیب خروجی‌ها

در چارچوب روش پیشنهادی، پیش‌بینی نهایی ضربان قلب بر مبنای ترکیب دو منبع مکمل اطلاعات انجام می‌شود: (۱) برآورد مبتنی بر شباهت یا رابطه با نمونه‌های مجموعه پشتیبان، و (۲) پیش‌بینی مستقیم حاصل از نگاهت ویژگی‌های استخراج شده به فضای ضربان قلب. این راهبرد ترکیبی باهدف بهره‌گیری هم‌زمان از دانش نمونه‌محور و قابلیت تعمیم مدل یادگرفته شده طراحی شده است.

در مدل پیشنهادی SiameseHR، پیش‌بینی ضربان قلب از طریق میانگین وزنی دو مؤلفه انجام می‌شود. مؤلفه نخست، برآورد ضربان قلب بر پایه فاصله ویژگی‌های نمونه پرس‌وجو از نمونه‌های مجموعه پشتیبان است که با استفاده از تابع softmax بر روی فواصل، وزن‌دهی می‌شود. این بخش نقش مهمی در انطباق پیش‌بینی با الگوهای خاص هر سوژه ایفا می‌کند. مؤلفه دوم، پیش‌بینی مستقیم حاصل از لایه‌های رگرسیونی است که بیانگر دانش کلی آموخته شده در مرحله آموزش اولیه است.

در مقابل، در مدل پیشنهادی RelationHR، پیش‌بینی نهایی بر پایه ترکیب غیرمقارن دو مؤلفه انجام می‌گیرد. در این ساختار، شبکه رابطه‌ای به‌طور صریح میزان ارتباط هر نمونه پرس‌وجو با نمونه‌های مجموعه پشتیبان را مدل‌سازی می‌کند و خروجی آن بیانگر درجه شباهت یادگرفته شده در فضای ویژگی است. جدول ۲ راهبرد ترکیب خروجی‌ها و ضرایب به‌کاررفته در پیش‌بینی نهایی ضربان قلب برای هر یک از مدل‌ها را نشان می‌دهد.

جدول (۲): تنظیمات پیش‌بینی ضربان قلب

مدل	راهبرد تلفیق
SiameseHR	$\alpha \times \text{Weighted HR} + (1-\alpha) \times \text{Direct Predictio}$
RelationHR	$\beta \times \text{Relation-based HR} + (1-\beta) \times \text{Direct Prediction}$

ضرایب ترکیب در مدل SiameseHR با استفاده از جستجوی شبکه‌ای محدود^۳ در بازه ۰/۳ تا ۰/۷ با گام ۰/۱ تنظیم شدند. معیار انتخاب، کمینه‌سازی میانگین خطای قدرمطلق (MAE) در

³ Grid Search

¹ Universidad Autónoma de Baja California


² <https://github.com/AlbanyArmenta0711/WiFi-CSI-MiningTool/tree/main/Datasets>

۴-۴ ارزیابی عملکرد LOSO

استفاده از این پروتکل ارزیابی، علاوه بر کاهش سوگیری‌های ناشی از هم‌پوشانی داده‌های آموزشی و آزمون، امکان بررسی پایداری و کارایی روش پیشنهادی را در شرایط کم‌نمونه و بین‌سوژه‌ای فراهم می‌کند. از این‌رو، چارچوب LOSO به‌عنوان یکی از سخت‌گیرانه‌ترین و درعین‌حال کاربردی‌ترین روش‌های ارزیابی در مسائل پایش سلامت مبتنی بر سیگنال‌های زیستی، برای این پژوهش انتخاب شده است. نتایج نشان می‌دهد که این فرآیند تطبیقی، امکان دستیابی به عملکرد مناسب حتی با تعداد بسیار محدود نمونه را فراهم می‌کند. پارامترهای انتخابی برای ارزیابی عملکرد در جدول ۳ ارائه شده است. نتایج حاصل از عملکرد الگوریتم‌های مختلف در شکل ۱۲ نمایش داده شده است.

جدول (۳): پارامترهای ارزیابی روش پیشنهادی

پارامتر	مقدار
طول پنجره	۳۰ s
گام پنجره	۱ s
زیرحامل‌های انتخابی	۳۰
طول STFT	۱۲۸
هم‌پوشانی STFT	۶۴
باند ضربان قلب (۴۲-۱۵۰ ضربه در دقیقه)	-۷/۵ HZ
K-shot	۱۰
نمونه‌های پرس‌وجو	۱۵
اندازه دسته فرادسته	۴

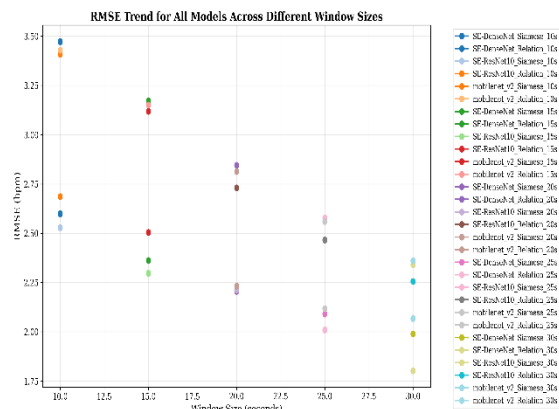


شکل (۱۲): ارزیابی میزان خطا روش‌ها

اعتبارسنجی LOSO بود که $\alpha=0.05$ به دست آمد. لذا ترکیب متقارن (۰/۵، ۰/۵) به‌عنوان مقدار نهایی انتخاب شد که تعادل مناسبی میان سازگاری مبتنی بر نمونه‌های پشتیبان و توان تعمیم شبکه برقرار می‌کند. ضرایب ترکیب در RelationHR با جستجوی شبکه‌ای محدود در بازه ۰/۵ تا ۰/۸ با گام ۰/۱ تنظیم شدند. مقدار بهینه بر اساس کمینه MAE اعتبارسنجی انتخاب گردید. مقدار $\beta=0.7$ برای مؤلفه رابطه‌ای بهترین عملکرد را از نظر MAE نشان داد، که بیانگر اهمیت بیشتر ساختار تطبیقی مبتنی بر رابطه در تنظیم بین‌سوژه‌ای است.

۴-۳ ارزیابی طول پنجره زمانی

بررسی اثر طول پنجره زمانی مورد پردازش بر نتایج، با انتخاب پنجره‌های ۱۰ تا ۳۰ ثانیه با گام ۵ ثانیه روش پیشنهادی ارزیابی شد. نتایج در شکل ۱۱ مشاهده می‌نمایند.



شکل (۱۱): نتایج ارزیابی اثر طول پنجره

بر اساس نتایج کمترین خطا به‌ازای پنجره ۳۰ ثانیه‌ای رخ می‌دهد که از نظر فیزیولوژیکی و سیگنال‌پردازی نقطه تعادل است. طول پنجره به‌اندازه‌ای هست که چندین سیکل ضربان قلب (حداقل ۴۰-۳۰ ضربه) را پوشش دهد. بنابراین تغییرات گذرای نویز، حرکت‌های تصادفی و تداخل چندمسیره‌ای فای میانگین‌گیری می‌شوند. درعین‌حال، پنجره آن‌قدر طولانی نیست که باعث هموارسازی بیش‌ازحد و از دست رفتن تغییرات واقعی ضربان شود.

نتایج جدول ۴ نشان می‌دهد مدل پیشنهادی در هر سه کلاس عملکرد بسیار مطلوبی دارد، به طوری که امتیاز F بالاتر از ۸۶٪ و بازخوانی و دقت بالا بیانگر توانایی مناسب مدل در تشخیص صحیح کلاس‌ها و کاهش خطای طبقه‌بندی است.

۵- تجزیه و تحلیل

در این بخش به تحلیل عمیق نتایج تجربی می‌پردازیم و با تأکید ویژه بر رفتار مدل، قابلیت تعمیم‌پذیری، و پیامدهای یادگیری در شرایط داده‌های محدود. فراتر از دقت عددی، پایداری و سازگاری مدل‌های پیشنهادی را بررسی می‌نماییم.

۱-۵ بررسی مدل‌سازی زمانی و زمان-فرکانسی

عملکرد مدل با استفاده از چندین شاخص مکمل سنجیده می‌شود. در جدول ۵ خطای میانگین قدرمطلق (MAE) و ضریب همبستگی پیرسون گزارش می‌شود تا رفتار مدل‌ها در مقایسه با H3RN [21]. فراتر از دقت تجمعی مورد تحلیل قرار گیرد.

جدول (۵): شاخص‌های ارزیابی روش پیشنهادی

RelationHR		SiameseHR		روش یادگیری داده‌محدود مدل
ضریب همبستگی	MAE	ضریب همبستگی	MAE	
۰/۹۸۵	۱/۸۷	۰/۹۸۷	۱/۳۸	SE-DenseNet
۰/۹۸۶	۱/۹۳	۰/۹۸۶	۱/۵۷	MobileNetV2
۰/۹۸۶	۱/۸۶	۰/۹۹۳	۱/۵۲	SE-ResNet10
۰/۹۸۴	۲/۳۱	۰/۹۷۶	۱/۹۴	H3RN [21]

بر اساس نتایج تجربی جدول ۵، مدل SE-DenseNet با روش Siamese به‌عنوان بهترین مدل برای تخمین ضربان قلب در تنظیمات یادگیری داده‌محدود شناسایی شد. نتایج به‌دست‌آمده نشان می‌دهد که انتخاب معماری شبکه و نوع نمایش ورودی نقش تعیین‌کننده‌ای در عملکرد سیستم در سناریوی یادگیری داده‌محدود مبتنی بر سیگنال‌های CSI ایفا می‌کند.

در معماری SE-DenseNet، استفاده از اتصالات متراکم امکان باز استفاده مؤثر از ویژگی‌ها در لایه‌های مختلف شبکه را فراهم می‌سازد و موجب تقویت جریان اطلاعات و کاهش اتلاف ویژگی‌های ظریف مرتبط با ضربان قلب می‌شود. باین‌حال، افزایش نسبی پیچیدگی این معماری می‌تواند حساسیت آن را نسبت به

۴-۵ طبقه‌بندی ضربان قلب

پس از انجام تخمین پیوسته ضربان قلب توسط شبکه‌های عصبی کانولوشنی (SE-DenseNet_SiameseHR)، خروجی‌های عددی مدل به‌منظور ارزیابی عملکرد در سناریوی طبقه‌بندی، مشابه با رویکرد ارائه‌شده در [۱۸]، به سه کلاس فیزیولوژیکی گسسته تقسیم شدند. بدین ترتیب، مقادیر ضربان قلب کمتر یا مساوی ۶۰ ضربه در دقیقه به‌عنوان کلاس اول ($\geq 60 \text{ bpm}$)، مقادیر بین ۶۱ تا ۸۰ ضربه در دقیقه به‌عنوان کلاس دوم ($61-80 \text{ bpm}$) و مقادیر بالاتر از ۸۰ ضربه در دقیقه به‌عنوان کلاس سوم ($\leq 80 \text{ bpm}$) در نظر گرفته شد. بر این اساس، برچسب‌های طبقه‌بندی متناظر با مقادیر واقعی و تخمینی استخراج و عملکرد سیستم با شاخص‌های آماری ارائه‌شده در جدول ۴ مورد ارزیابی قرار گرفت که دقت کلی طبقه‌بندی برابر با ۹۰/۸۶٪ به‌دست آمد. به‌منظور مقایسه منصفانه، نتایج حاصل با روش احسنول اسلام و همکاران [۲۳] مبتنی بر همین پایگاه داده [۱۸]، مقایسه شد.

$$Recall = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1\text{-score} = \frac{Precision \times Recall \times 2}{Precision + Recall} \quad (8)$$

جدول (۴): مقایسه شاخص‌های آماری عملکرد روش پیشنهادی با


روش [۲۳] و روش [۱۸] در سطح کلاس

نوع طبقه Class	دقت Recall	حساسیت Precision	بازخوانی Specificity	امتیاز F-score
۱ پیشنهادی [۱۸]	۹۸/۶٪	۸۷/۵۲٪	۹۳/۷٪	۹۲/۷٪
۲ پیشنهادی [۱۸]	۲۲/۷٪	۴۱/۳۸٪	۸۲/۲۷٪	۲۹/۳۷٪
۳ پیشنهادی [۱۸]	۸۵/۲۴٪	۹۸/۱۶٪	۹۸/۳۴٪	۹۱/۲٪
۴ پیشنهادی [۱۸]	۷۲/۰۶٪	۳۰/۵۵٪	۲۸/۸۳٪	۴۲/۴۹٪
۵ پیشنهادی [۱۸]	۹۳/۳۰٪	۸۱/۰۸٪	۹۵/۱۶٪	۸۶/۷۷٪
۶ پیشنهادی [۱۸]	۱۲/۹۲٪	۱۲/۹۲٪	۹۲/۹۸٪	۲۰/۴۴٪
[۲۳]	۷۰/۸۷٪	-	-	۷۰/۸۷٪

بهتری ارائه می‌دهد، چرا که شبکه‌های Relation شباهت را از طریق یک شبکه یادگرفتنی اضافی مدل می‌کند و به دلیل پارامترهای بیشتر و حساسیت بالاتر به نویز بین‌سوژه‌ای، مستعد بیش‌برازش هستند.

۳-۵ ارزیابی طبقه‌بند

نتایج جدول ۵ نشان می‌دهد مدل پیشنهادی در هر سه کلاس عملکرد بسیار مطلوبی دارد، به طوری که امتیاز F بالاتر از ۸۰٪ و بازخوانی و دقت بالا بیانگر توانایی مناسب مدل در تشخیص صحیح کلاس‌ها و کاهش خطای طبقه‌بندی است. در مقابل، نتایج مرجع [۱۸] به ویژه در کلاس‌های ۱ و ۳ دارای امتیاز F بسیار پایین و حساسیت ضعیف است که نشان‌دهنده ناتوانی آن روش در شناسایی صحیح نمونه‌های واقعی است. ماتریس درهم‌ریختگی شکل ۱۳ عملکرد روش پیشنهادی را مورد ارزیابی قرار می‌دهد.



شکل (۱۳): ماتریس درهم‌ریختگی طبقه‌بند پیشنهادی

روش رمزگذار [۲۳] اگرچه با تمرکز بر حفظ حریم خصوصی و امکان انجام استنتاج مستقیم روی داده‌های رمزگذاری شده، یک چارچوب امن و کاربردی ارائه می‌دهد، اما به دلیل محدودیت‌هایی نظیر نرخ نمونه‌برداری پایین CSI و استفاده صرف از اطلاعات دامنه سیگنال، دقت طبقه‌بندی گزارش شده آن (۷۰/۸۷٪) به طور محسوسی پایین‌تر از نتایج حاصل در روش پیشنهادی (۹۰/۸۶٪) است. این مقایسه نشان می‌دهد که رویکرد مبتنی بر یادگیری داده‌محدود و بهره‌گیری مؤثر از تطبیق بین‌سوژه‌ای، حتی بدون تحمیل سربار محاسباتی رمزنگاری، می‌تواند به بهبود معنادار دقت طبقه‌بندی ضربان قلب منجر شود.

محدودیت داده‌های پشتیبان افزایش دهد؛ موضوعی که در عملکرد این شبکه در ترکیب با مدل RelationHR و افزایش MAE نسبت به حالت SiameseHR قابل مشاهده است.

در مقابل، روش SE-ResNet10 مبتنی بر Siamese که ورودی آن سیگنال زمانی CSI است، شبکه قادر است الگوهای نوسانی و شبه‌تناوبی مرتبط با ضربان قلب را مستقیماً از دامنه زمان استخراج کند. وجود مکانیزم با وزن‌دهی کانالی (SE) در این معماری، امکان برجسته‌سازی زیرحامل‌ها و مسیرهایی را فراهم می‌سازد که بیشترین همبستگی را با حرکات فیزیولوژیکی دارند، که این موضوع به بهبود پایداری مدل در شرایط کم‌نمونه و بین‌سوژه‌ای منجر شده است.

در نهایت، روش مبتنی بر MobileNetV2 با ورودی طیف‌نگار فرکانسی، با تکیه بر معماری سبک‌وزن و کانولوشن‌های عمقی جداپذیر، توان کمتری در مدل‌سازی تغییرات طیف دامنه ظریف ضربان قلب داشته و بیشترین خطا را ثبت کرده است.

مدل H3RN که برای استخراج هم‌زمان ویژگی‌های قلبی و تنفسی طراحی شده است، در مقایسه با روش پیشنهادی عملکرد ضعیف‌تری در تخمین ضربان قلب نشان داده است. خطای بالاتر این مدل، به ویژه در چارچوب SiameseHR، می‌تواند ناشی از پیچیدگی معماری دوخروجی و توزیع توجه شبکه میان چند وظیفه باشد که در سناریوهای داده‌محدود منجر به افت دقت تخمین ضربان قلب می‌شود. به‌طورکلی، نتایج این پژوهش نشان می‌دهد که هم‌ترازی میان ظرفیت معماری شبکه، نوع نمایش سیگنال (زمانی یا فرکانسی) و راهبرد یادگیری داده‌محدود، عامل کلیدی در دستیابی به عملکرد بهینه و تعمیم‌پذیر در تخمین و طبقه‌بندی ضربان قلب مبتنی بر CSI است.

۲-۵ مقایسه عملکرد ساختار Siamese/Relation

روش Siamese به‌طور سیستماتیک عملکرد بهتری نسبت به روش Relation دارد، که نشان‌دهنده سازگاری بیشتر این روش با ماهیت داده‌های قلبی در شرایط یادگیری داده‌محدود است. مقایسه ساختارهای Siamese و Relation نشان می‌دهد که در شرایط یادگیری کم‌نمونه، استفاده از معیارهای فاصله ساده و پایدار در شبکه‌های Siamese نسبت به توابع رابطه یادگرفتنی عملکرد

منجر به استخراج مؤثر الگوهای نوسانی مرتبط با ضربان قلب و بهبود پایداری بین‌سوژه‌ای شد، درحالی‌که مدل‌های سبک‌وزن مبتنی بر طیف‌نگار فرکانسی، اگرچه از نظر محاسباتی کارآمد بودند، توان محدودی در مدل‌سازی تغییرات طریف ضربان قلب نشان دادند.

علاوه بر تخمین پیوسته، نتایج طبقه‌بندی ضربان قلب در سه کلاس فیزیولوژیکی نیز نشان داد که چارچوب پیشنهادی قادر است با دقت قابل قبول و برتری معنادار نسبت به کارهای مرجع مبتنی بر همین پایگاه داده، عملکرد مناسبی در سناریوهای کاربردی ارائه دهد. این یافته‌ها تأیید می‌کنند که بهره‌گیری از یادگیری داده‌محدود و طراحی آگاهانه معماری، می‌تواند بدون نیاز به داده‌های حجیم یا تجهیزات پوشیدنی، به راهکاری عملی و قابل اعتماد برای پیش سلامت غیرتماسی مبتنی بر وای‌فای منجر شود.

در مجموع، این پژوهش نشان می‌دهد که هم‌ترازی میان ظرفیت مدل، نمایش سیگنال و راهبرد یادگیری، عامل کلیدی در توسعه سامانه‌های پیش سلامت مبتنی بر CSI است و می‌تواند مسیر مناسبی برای تحقیقات آینده در زمینه تخمین علائم حیاتی در شرایط واقعی و داده‌محدود فراهم آورد.

References

- [1] P. Susarla, A. H. Mirza, M. A. Rahman, and A. Bamis, "Non-contact multimodal indoor human monitoring systems: A survey," *Inf. Fusion.*, vol. 110, p. 102457, Oct. 2024, doi:10.1016/j.inffus.2024.102457.
- [2] D. Vandenberghe and J. Albrecht, "The financial burden of non-communicable diseases in the European Union: A systematic review," *Eur. J. Public Health.*, vol. 30, no. 4, pp. 833–839, Aug. 2020, doi:10.1093/eurpub/ckz073
- [3] M. I. Khan, M. R. Amin, M. S. Islam, and S. A. Rahman, "Tracking vital signs of a patient using channel state information and machine learning for a smart healthcare system," *Neural Comput. Appl.*, vol. 37, no. 28, pp. 23065–23079, Oct. 2025, doi:10.1007/s00521-020-05631-x.
- [4] M. Atif, S. Muralidharan, H. Ko, and B. Yoo, "COVID-Beat: A low-cost breath monitoring approach for people in quarantine during the

۶- نتیجه‌گیری

در این پژوهش، یک چارچوب غیرتهاجمی مبتنی بر سیگنال CSI وای‌فای برای تخمین و طبقه‌بندی ضربان قلب در شرایط داده‌محدود ارائه شد. با توجه به چالش‌های ذاتی جمع‌آوری و برچسب‌گذاری داده‌های فیزیولوژیکی بین‌سوژه‌ای، از راهبرد یادگیری داده‌محدود مبتنی بر فرایادگیری به منظور افزایش قابلیت تعمیم و تطبیق سریع مدل با کاربران جدید بهره گرفته شد. در این راستا، دو ساختار یادگیری شباهت‌محور و رابطه‌محور مورد بررسی قرار گرفت و عملکرد آن‌ها در ترکیب با معماری‌های کانولوشنی مختلف ارزیابی شد.

نتایج تجربی نشان داد که انتخاب هم‌زمان معماری مناسب شبکه و نوع نمایش سیگنال ورودی نقش تعیین‌کننده‌ای در عملکرد سیستم ایفا می‌کند. نتایج نشان داد به‌طور خاص، ترکیب معماری SE-DenseNet با مدل SiameseHR توانست با دستیابی به کمترین خطای تخمین و ضریب همبستگی بالا، بهترین عملکرد را در سناریوی یادگیری داده‌محدود به دست آورد. همچنین، استفاده از سیگنال زمانی CSI در معماری با ورودی زمانی، SE-ResNet10

pandemic," *J. Comput. Des. Eng.*, vol. 9, no. 3, pp. 992–1006, Jun. 2022, doi:10.1093/jcde/qwac037.

- [5] R. Yared and B. Abdulrazak, "Ambient technology to assist elderly people in indoor risks," *Computers*, vol. 5, no. 4, p. 22, Oct. 2016, doi:10.3390/computers5040022.
- [6] S. Yue, H. He, H. Wang, H. Rahul, and D. Katabi, "Extracting multi-person respiration from entangled RF signals," *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, vol. 2, no. 2, Art. 86, Jul. 2018, doi:10.1145/3214289.
- [7] L. Qiao, Y. Zhang, Y. Liu, J. Wang, and Y. Li, "Spectral unmixing successive variational mode decomposition for robust vital signs detection using UWB radar," *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–13, May. 2023, doi:10.1109/TIM.2023.3274171.
- [8] X. Wang, C. Yang, and S. Mao, "On CSI-based vital sign monitoring using commodity WiFi," *ACM Trans. Comput. Healthcare*, vol.



- 1, no. 3, Art. 12, May. 2020, doi:10.1145/3377165.
- [9] J. C. H. Soto, I. Galdino, E. Caballero, V. Ferreira, D. Muchalut-Saade, and C. Albuquerque, "A survey on vital signs monitoring based on Wi-Fi CSI data," *Comput. Commun.*, vol. 195, pp. 99–110, Nov. 2022, doi:10.1016/j.comcom.2022.08.004.
- [10] J. Liu, Y. Wang, Y. Chen, J. Yang, X. Chen, and J. Cheng, "Tracking vital signs during sleep leveraging off-the-shelf WiFi," in *Proc. 16th ACM Int. Symp. Mobile Ad Hoc Netw. Comput.*, Hangzhou, China, Jun. 2015, pp. 267–276, doi:10.1145/2746285.2746303.
- [11] R. Zhang, Y. Li, Z. Chen, H. Wang, and Q. Liu, "Hybrid subcarrier selection method for vital sign monitoring with long-term and short-term data considerations," *IEEE Sens. J.*, vol. 22, no. 23, pp. 23209–23220, Oct. 2022, doi:10.1109/JSEN.2022.3215443.
- [12] B. Fang, N. D. Lane, M. Zhang, A. Boran, and F. Kawsar, "BodyScan: Enabling radio-based sensing on wearable devices for contactless activity and vital sign monitoring," in *Proc. 14th Annu. Int. Conf. Mobile Syst., Appl., Serv.*, Singapore, 2016, pp. 97–110, doi:10.1145/2906388.2906411.
- [13] X. Wang, C. Yang, and S. Mao, "PhaseBeat: Exploiting CSI phase data for vital sign monitoring with commodity WiFi devices," in *Proc. IEEE 37th Int. Conf. Distrib. Comput. Syst. (ICDCS)*, 2017, pp. 1230–1239, doi:10.1109/ICDCS.2017.206.
- [14] K. Tsubota, Y. Nagatsu, and H. Hashimoto, "Biometric information acquisition system using VMD in Wi-Fi channel status information," in *IECON 2021 – 47th Annu. Conf. IEEE Ind. Electron. Soc.*, 2021, pp. 1–6, doi:10.1109/IECON48115.2021.9589628.
- [15] Y. Gu, X. Zhang, Z. Liu, and F. Ren, "WiFi-based real-time breathing and heart rate monitoring during sleep," in *Proc. IEEE Global Commun. Conf. (GLOBECOM)*, 2019, pp. 1–6, doi:10.1109/GLOBECOM38437.2019.9014297.
- [16] X. Zhang, Y. Wang, J. Liu, and D. Fang, "Wital: A COTS WiFi devices based vital signs monitoring system using NLOS sensing model," *IEEE Trans. Hum.-Mach. Syst.*, vol. 53, no. 3, pp. 629–641, Apr. 2023, doi:10.1109/THMS.2023.3264247.
- [17] L. Gui, C. Ma, B. Sheng, Z. Guo, J. Cai, and F. Xiao, "In-home monitoring sleep turnover activities and breath rate via WiFi signals," *IEEE Syst. J.*, vol. 17, no. 2, pp. 2355–2365, Dec. 2023, doi:10.1109/JSYST.2022.3225072.
- [18] J. A. Armenta-Garcia, F. F. Gonzalez-Navarro, J. Caro-Gutierrez, G. Galaviz-Yanez, J. E. Ibarra-Esquer, and W. Flores-Fuentes, "Mining Wi-Fi channel state information for breathing and heart rate classification," *Pervasive Mob. Comput.*, vol. 91, p. 101764, Apr. 2023, doi:10.1016/j.pmcj.2023.101768.
- [19] J. Hu, J. Yang, J. B. Ong, D. Wang, and L. Xie, "ResFi: WiFi-enabled device-free respiration detection based on deep learning," in *Proc. IEEE 17th Int. Conf. Control & Autom. (ICCA)*, 2022, pp. 510–515, doi:10.1109/ICCA54724.2022.9831898.
- [20] H. A. Solgun, A. Ozcan, and O. Pinarer, "Real-time heart rate monitoring via Wi-Fi signal," in *Proc. IEEE Int. Conf. Big Data*, 2023, pp. 4973–4978, doi:10.1109/BigData59044.2023.10386433.
- [21] M. Liu, Z. Lin, P. Xiao, and W. Xiang, "Human biometric signals monitoring based on WiFi channel state information using deep learning," *arXiv preprint, arXiv:2203.03980*, 2022. doi:10.48550/arXiv.2203.03980
- [22] Z. Xie, H. Wang, S. Han, E. Schoenfeld, and F. Ye, "DeepVS: A deep learning approach for RF-based vital signs sensing," in *Proc. 13th ACM Int. Conf. Bioinformatics, Comput. Biol. Health Informatics*, Northbrook, IL, USA, 2022, pp. 1–10, doi:10.1145/3535508.3545554.
- [23] Islam, S. Akter, and T. F. Sanam, "Secure Tracking of Patient's Vital Signs Using CSI-Based Homomorphic Encryption-Enabled Deep Learning Framework," *IEEE J. Biomed. Health Inform.*, vol. 30, no. 2, pp. 1314–1327, Aug. 2026, doi:10.1109/JBHI.2025.3601969.
- [24] Z. Wang, J. Li, W. Wang, Z. Dong, Q. Zhang, and Y. Guo, "Review of few-shot learning application in CSI human sensing," *Artif Intell Rev*, vol. 57, no. 8, p. 195, May 2024, doi:10.1007/s10462-024-10812-4.



- [25] Y. Song, T. Wang, P. Cai, S. K. Mondal, and J. P. Sahoo, "A comprehensive survey of few-shot learning: Evolution, applications, challenges, and opportunities," *ACM Comput. Surv.*, vol. 55, no. 13s, Art. 271, Dec. 2023, doi:10.1145/3582688.
- [26] F.-F. Li, R. Fergus, and P. Perona, "One-shot learning of object categories," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 28, no. 4, pp. 594-611, Apr. 2006, doi:10.1109/TPAMI.2006.79.
- [27] F. Sung, Y. Yang, L. Zhang, T. Xiang, P. H. S. Torr, and T. M. Hospedales, "Learning to Compare: Relation Network for Few-Shot Learning," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, Salt Lake City, UT, USA, Jun. 2018, pp. 1199-1208, doi:10.1109/CVPR.2018.00131.
- [28] Z. Zhao, C. Tingwei, C. Zhijie, L. Xiaoyang, L. Hang, C. Qimei, and Z. Guangxu, "CrossFi: A Cross Domain Wi-Fi Sensing Framework Based on Siamese Network," *IEEE Internet Things J.*, vol. 12, no. 12, pp. 20138-20155, Jun. 2025, doi:10.1109/JIOT.2025.3542850.
- [29] Z. Wang, O. Lei, S. Chen, H. Ding, G. Wang, and F. Wang, "SimID: Wi-Fi-Based Few-Shot Cross-Domain User Recognition with Identity Similarity Learning," *Sensors (Basel, Switzerland)*, vol. 25, Aug. 2025, doi:10.3390/s25165151
- [30] J. Mei, L. Kong, and F. Jia, "SE-DenseNet: A Dynamic Dense Network with Squeeze-and-Excitation Module for Pneumonia Classification in Chest X-ray Images," in *Proc. 9th Int. Conf. Multimedia Image Process.*, Osaka, Japan, 2024, doi:10.1145/3665026.3665047.

Convolutional Neural Network and Few-Shot Learning for Non-Contact Heart Rate Estimation from Channel State Information in Data-Limited Scenarios

Alireza Abolghasemi¹, S.M.T Almodarresi^{2*}

¹Ph.D. Candidate in Electrical Engineering, Department of Electrical Engineering, Yazd University, Yazd, Iran

²Associate Professor, Department of Electrical Engineering, Yazd University, Yazd, Iran

Article Information

Original Research Paper

Received:

2025 December 29

Accepted:

2026 February 26

Keywords:

Heart Rate, Few-Shot Learning, Non-Contact Monitoring, Channel State Information (CSI), Wi-Fi Sensing

Corresponding Author*:

Smta@yazd.ac.ir

Abstract

Non-contact heart rate monitoring using Wi-Fi Channel State Information (CSI) has emerged as a promising approach in biomedical sensing, enabling continuous physiological monitoring without physical contact or wearable devices. However, significant inter-subject variability in CSI patterns and the scarcity of labeled data pose major challenges to developing accurate and generalizable deep learning models. In this paper, a few-shot learning-based framework is proposed for heart rate estimation from CSI signals, leveraging both similarity-based (Siamese) and relation-based learning paradigms. Within this framework, convolutional neural networks including SE-DenseNet, SE-ResNet10, and MobileNetV2 are employed as feature encoders to extract discriminative representations from temporal CSI signals and frequency-domain CSI spectrograms. Using only a limited number of support samples, the proposed model is able to rapidly adapt to the data distribution of unseen subjects while effectively mitigating overfitting. Performance evaluation under the Leave-One-Subject-Out (LOSO) protocol demonstrates that the similarity-based model with an SE-DenseNet feature encoder achieves the lowest mean absolute error of 1.38 bpm. This study highlights the critical role of aligning network architecture, CSI representation (temporal or spectral), and few-shot learning strategy in the design of robust and non-contact heart rate monitoring systems.

 : 10.22034/ABMIR.2026.24171.1214

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2026.24171.1214) /© 2026. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

