

مدل سازی آشوب‌گرای سیگنال فوتوپلتیسموگرام جهت تخمین فشارخون مبتنی بر شبکه‌های عصبی عمیق کانولوشنی

محمدباقر خدابخشی^{۱*}، نعیم اسلامی همدانی^۲، سیده زهره صدرالدینی^۲

*نویسنده مسئول، دریافت: ۱۴۰۰/۰۳/۲۰، بازنگری: ۱۴۰۰/۰۴/۲۱، پذیرش: ۱۴۰۰/۰۵/۰۵

^۱ استادیار، گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

^۲ دانش‌آموخته کارشناسی، مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران

چکیده

تخمین فشارخون به صورت غیرتهاجمی از طریق پردازش سیگنال‌های محیطی شامل سیگنال‌های قلبی و فوتوپلتیسموگرام از مسائل مورد توجه در حوزه پردازش سیگنال‌های پزشکی است. عمده مطالعات بر استخراج ویژگی‌های متنوع از سیگنال‌های محیطی و تخمین فشارخون به وسیله مدل‌های مبتنی بر هوش محاسباتی متمرکز هستند. در این مقاله یک مدل شبکه عصبی عمیق کانولوشنی پیشنهاد شده که با به کارگیری شکل موج سیگنال فوتوپلتیسموگرام و ویژگی‌های آشوب‌گرای آن می‌تواند فشارخون را با دقت بالایی تخمین زند. ویژگی آشوب‌گرای سیگنال در فضای فاز با نام آنالیز کمی بازخداد به همراه نمونه‌های سری زمانی فوتوپلتیسموگرام به عنوان ورودی مدل شبکه عصبی عمیق کانولوشنی در نظر گرفته شده‌اند. نتایج آزمون مدل پیشنهادی بر روی داده‌گان استخراجی از مجموعه داده MIMIC-II بر اساس استانداردهای انجمن فشارخون بریتانیا (BHS) و انجمن توسعه ابزار پزشکی (AAMI) نشان می‌دهد که این ترکیب در ورودی می‌تواند دقت بالایی در تخمین فشارخون فراهم کند. به طور خاص در تخمین فشارخون دیاستول و سیستول، معیار ضریب همبستگی پیرسون (R) برای روش پیشنهادی به ترتیب ۰/۹۳۹۱۶ و ۰/۹۳۳۵۷ به دست آمد. مطابق استاندارد BHS این روش حائز درجه کیفی A در تخمین فشارخون است و دارای میانگین و انحراف معیار خطای تخمین برای فشارخون دیاستول و سیستول به ترتیب برابر ۰/۴۵±۳/۵ و ۰/۴۸±۶/۶۹ مطابق نیازمندی‌های استاندارد AAMI می‌باشد.

کلمات کلیدی: پردازش سیگنال، شبکه‌های عصبی کانولوشنی، یادگیری عمیق، آشوب، آنالیز کمی بازخداد

۱- مقدمه

فشارخون بالا یکی از نشانه‌های پنهان بروز بیماری‌های قلبی و عروقی است، که یکی از عوامل اصلی مرگ و میر در سراسر جهان است [۱]. در بعضی موارد فشارخون بالا می‌تواند باعث آسیب رساندن به اندام‌های داخلی مانند مغز، چشم‌ها و کلیه‌ها شود و عارضه‌هایی همچون سکته مغزی، کوری و نارسایی کلیوی را به همراه داشته باشد [۲]. یکی از راه‌های موثر در کاهش خطر بروز بیماری‌های قلبی کنترل مداوم فشارخون است.

روش‌های اندازه‌گیری فشارخون عمدتاً به دو دسته تقسیم می‌شوند: تهاجمی و غیرتهاجمی. در حالت اول، پزشک فشارخون را با قرار دادن کاتتر در شریان اندازه‌گیری می‌کند. با وجود دقت بالای این روش، به دلیل ماهیت تهاجمی بودن آن کمتر مورد استفاده قرار می‌گیرد. در کنار این روش، با استفاده از روش

اسیلومتری به همراه کاف، فشارخون مطلوب را با رویکردی غیرتهاجمی ثبت می‌کنند. اما این روش، قابلیت اندازه‌گیری فشارخون را بطور مداوم ندارد و همچنین بر اثر وقفه‌ای که در این روش بین دو اندازه‌گیری متوالی ایجاد می‌شود مقادیر به دست آمده برای کاربردهای بلندمدت غیر قابل اطمینان هستند [۳]. در نتیجه روشی که بتواند فشارخون را بطور مداوم و غیرتهاجمی همراه با دقت بالا اندازه‌گیری کند بسیار سودمند خواهد بود.

هدف این مطالعه توسعه یک روش جدید مبتنی بر الگوریتم‌های هوشمند در جهت تخمین فشارخون به صورت غیرتهاجمی و مداوم است. به طور معمول، از چندین منبع بیولوژیکی مانند سیگنال‌های قلبی و فوتوپلتیسموگرافی برای تخمین فشارخون استفاده می‌شود [۴-۷]. اکثر روش‌های پیش فشارخون بر اساس استخراج ویژگی زمان گذر نبض^۱ از دو سیگنال الکتروکاردیوگرام و فوتوپلتیسموگرام طراحی شده‌اند [۸-۱۱]. گرچه زمان گذر نبض ارتباط مستقیمی

۲- مواد و روش ها

در این بخش، ابتدا پایگاه داده مورد استفاده به اختصار معرفی می‌گردد. سپس روش پیش پردازش صورت گرفته برای قطعه بندی سیگنال‌های فوتوپلتیسموگرام بر اساس مرجع [۳] بیان می‌شود. در ادامه، پس از معرفی ویژگی‌های آشوب‌گرای مبتنی بر بازخداد، مدل شبکه عصبی مبتنی بر شبکه‌های کانولوشنی ارائه می‌گردد.


۲-۱- پایگاه داده

مجموعه داده مورد استفاده در این مطالعه از پایگاه داده MIMIC-II با رگرسی برده شده است [۳۲، ۳۱]. MIMIC-II مجموعه داده‌ای است که حاوی سیگنال‌های فیزیولوژیکی با وضوح بالا است که در آن علائم حیاتی بیماران از مانیتورهای چند پارامتری به دست آمده که مربوط به بیش از ۱۰ هزار بیمار در بخش مراقبت‌های ویژه است. در این مطالعه سوابق ۲۰۰ بیمار، حاوی سیگنال‌های قلبی، PPG و فشار خون شریانی (که به طور تهاجمی با قرار دادن کاتتر در شریان رادیال اندازه‌گیری شده)، در نظر گرفته شده است. سیگنال‌های PPG با استفاده از پالس اکسی‌متر از انگشتان گرفته شده و فرکانس نمونه برداری برای هر سیگنال ۱۲۵ هرتز است. میانگین و انحراف معیار سن بیماران $۶۱/۶ \pm ۱۴/۶$ سال بود [۳]. مقادیر مرتبط با فشارخون سیستول و دیاستول به عنوان مقادیر هدف در نظر گرفته شدند.

۲-۲- پیش پردازش-قطعه بندی سیگنال ورودی

در این بخش، ابتدا مرحله پیش پردازش سیگنال توصیف می‌گردد سپس روش قطعه‌بندی سیگنال PPG معرفی می‌شود. ابتدا نوفه‌ها و آرتیفکت‌های سیگنال‌های قلبی و PPG را با استفاده از فیلتر میان‌گذر باترورث با فرکانس‌های قطع $۰/۴۸$ هرتز و ۴۰ هرتز حذف می‌کنیم. با این کار نوفه برق و آرتیفکت ناشی از تنفس و همچنین حرکات غیرطبیعی عضلات از بین می‌رود. سپس با به کارگیری روش ارائه شده در شکل ۱ سیگنال‌های PPG قطعه بندی می‌شوند. همانگونه که پیداست بخش بندی سیگنال PPG بر اساس محل قله‌های سیگنال قلبی صورت پذیرفته است. بنابراین ابتدا لازم است این قله‌ها مکان یابی شوند. در این مطالعه از الگوریتم معرفی شده در [۳۳] برای این کار استفاده شده است.

همانطور که مشاهده می‌شود، نمونه‌های توالی زمانی PPG که بین سه قله پی در پی سیگنال قلبی هستند، به عنوان قطعه‌های مورد نظر جهت اعمال به شبکه عصبی انتخاب شده‌اند. طول هر یک از بخش‌ها که معادل تعداد نورون‌های لایه ورودی شبکه عصبی است؛ ۲۵۰ نمونه لحاظ گردیده است. از آنجا که فواصل بین قله‌های سیگنال قلبی یکسان نیستند، طول سیگنال‌های مربوط به هر قطعه یکسان نخواهد بود. در نتیجه، برای برابر کردن تعداد نمونه‌هایی که به شبکه وارد می‌شوند، طول بخش‌هایی که کمتر از ۲۵۰ نمونه است با قرار دادن صفر در انتهای آن یکسان می‌گردند.



شکل ۱- قطعه بندی سیگنال PPG (پایین) بر اساس قله‌های سیگنال قلبی (بالا).

با مقادیر مطلق فشار خون ندارد، اما می‌توان از آن به کمک ابزارهای هوش مصنوعی برای پیش بینی تغییرات فشار خون طی یک دوره خاص استفاده کرد [۱۲، ۱۳].

علاوه بر این، مطالعات دیگری در مورد تخمین فشارخون از طریق ویژگی‌های استخراج شده از سیگنال فوتوپلتیسموگرام (PPG) انجام شده است [۱۵-۱۳]. در مقابل، در برخی از مطالعات با به کارگیری ابزارهای پوشیدنی، از سیگنال قلبی برای تخمین فشار خون استفاده شده است [۱۶، ۱۷]. با این وجود، نظارت مستمر بر فشارخون با استفاده از مدل‌های چند پارامتری به طور همزمان به هر دو سیگنال قلبی و فوتوپلتیسموگرافی احتیاج دارد [۲۱-۱۷].

فارغ از رویکردهای مختلف برای استخراج ویژگی از سیگنال‌های محیطی، از روش‌های مختلف تخمین برای یافتن نگاهت بین جفت‌های ورودی و خروجی استفاده می‌شود. در این راستا می‌توان از روش‌های رگرسیون هوشمند شامل شبکه‌های عصبی، رگرسیون بردار پشتیبان و سیستم‌های فازی نام برد [۲۱-۲۷]. علاوه بر این، استفاده از چارچوب‌های مبتنی بر شبکه‌های عصبی کانولوشنی و یادگیری عمیق، بدون به کارگیری ویژگی‌های اشاره شده و تنها با اعمال سیگنال‌های PPG می‌تواند تخمینی بسیار قابل اعتماد ارائه دهد. تانویر^۳ و همکارانش با ادغام دو شبکه LSTM^۴ در لایه‌های اولیه مدل به استخراج ویژگی‌های ریخت شناختی در تخمین فشارخون پرداخته‌اند [۲]. حج^۵ و همکارانش با به کارگیری شبکه‌های عصبی بازگشتی با ارتباطات دو طرفه، یک معماری شبکه عمیق جدید برای نظارت بر فشارخون بر اساس سیگنال‌های فوتوپلتیسموگرافی معرفی کرده‌اند [۶]. رویکرد مشابهی در مطالعه دیگری ارائه شده است که در آن با هدف افزایش دقت تخمین فشار خون سیستول و دیاستول، ورودی‌ها به صورت فیدبک‌هایی مابین دو شبکه کانولوشنی و LSTM اعمال می‌شوند [۳]. همچنین، با به کارگیری یک معماری جدید شبکه عمیق با استفاده از لایه‌های حافظه دار در درون یک شبکه شناخته شده ResNet اطلاعات زمانی-مکانی سیگنال قلبی برای پیش فشارخون مورد بررسی قرار گرفته است [۱۶].

با نگاهی به مطالعات قبلی، می‌توان دریافت که اکثر مطالعات با استفاده از رویکردهای محاسبات نرم، ویژگی‌هایی را از سیگنال‌های محیطی استخراج کرده و یک نگاهت ورودی-خروجی مطلوب به وسیله مدل‌های عصبی مصنوعی ایجاد شده است. از آنجا که خواص غیرخطی استخراج شده از سیگنال‌های محیطی عملکرد مطلوبی در تجزیه و تحلیل سیگنال‌های بیولوژیکی دارند، در این مطالعه، یک چارچوب جدید مبتنی بر ویژگی‌های آشوب‌گرا و معماری کانولوشنی برای نظارت مداوم بر فشارخون از طریق سیگنال PPG معرفی شده است. به عبارت دقیق‌تر، ابتدا فواصل معینی از سیگنال PPG بر اساس قله‌های سیگنال قلبی استخراج می‌گردد. در ادامه با استفاده از خصوصیات آشوبی غیرخطی با نام آنالیز کمی بازخداد (RQA)^۶، ویژگی بر اساس تراژکتوری سیگنال‌ها در فضای فاز محاسبه می‌شود [۲۸-۳۰]. سپس مدلی متشکل از یک شبکه عصبی عمیق کانولوشنی برای تخمین فشارخون سیستول و دیاستول بر اساس سیگنال‌های PPG و ویژگی‌های RQA استخراج شده، طراحی شده است. مروری بر پژوهش‌های صورت گرفته در این زمینه نشان می‌دهد، تاکنون هیچ مطالعه‌ای در مورد بررسی ویژگی‌های آشوب‌گرا در کنار شبکه‌های عصبی عمیق برای تخمین فشار خون انجام نشده است. لازم به ذکر است که داده‌های استفاده شده در این مطالعه از پایگاه داده MIMIC-II، که یک مجموعه داده پر استناد است اخذ گردیده است.

در ادامه، ساختار مقاله ارائه شده به این صورت است. در بخش ۲، پس از معرفی پایگاه داده، روش پیشنهادی این مطالعه ارائه شده است که در آن پیش پردازش، استخراج ویژگی‌های غیرخطی و مدل شبکه عصبی معرفی شده است. در بخش ۳، نتایج اعمال مدل پیشنهادی بر روی داده‌ها ارائه شده است. بخش ۴ نتایج را مورد بحث قرار داده و آنها را با سایر روش‌های مشابه مقایسه می‌کند. سرانجام، جمع بندی روش معرفی شده در بخش ۵ بیان شده است.

۳-۲- آنالیز کمی بازرخداد

روش های مختلفی برای تجزیه و تحلیل سری های زمانی در فضای غیرخطی و بر مبنای نظریه آشوب وجود دارد که اغلب آنها بر اساس بازسازی سری های زمانی در فضای فاز (فضای حالت) هستند. یکی از گام های ضروری در بازسازی فضای فاز تعیین بُعد جاسازی (m) است [۲۷]. علاوه بر این، یکی دیگر از الزامات بازسازی فضای فاز تعیین پارامتری به نام تأخیر (τ) است. اگر بعد جاسازی سیگنال بیش از ۳ باشد، ترسیم فضای فاز آن عملاً غیرممکن است. در این شرایط، رسم بازگشتی^۷ (RP) ابزاری مفید است که فضای فاز را بر اساس همسایگی حالت ها و بازگشت مسیر سیستم به حالت های هم جوار، به یک ماتریس قابل رسم در یک صفحه دوبعدی تبدیل می کند.

با فرض اینکه تراژکتوری فضای حالت یک سیستم، شامل T حالت باشد، به طوریکه $r(p) = 1, 2, \dots, T$ که بردار $r(p)$ نشان دهنده p امین حالت در فضای فاز است؛ ماتریس بازگشتی (\mathcal{R}) بر اساس فاصله بین دو حالت p_1 و p_2 از رابطه زیر محاسبه می شود:

$$\mathcal{R}_{p_1, p_2} = \theta(\varepsilon - \|r(p_1) - r(p_2)\|_2) \quad (1)$$

که در آن ε مقدار آستانه برای تعیین همسایگی حالات است و θ تابع پله است. اگر فاصله دو حالت در فضای فاز کمتر از آستانه باشد، عنصر مربوطه در \mathcal{R} ۱ می شود؛ در غیر این صورت، مقدار صفر برای آن عنصر در نظر گرفته می شود. مهمترین مرحله برای بازسازی فضای حالت و استخراج RP تعیین m و τ است. این پارامترها با استفاده از نظریه تیکن و استفاده از روش نزدیکترین همسایه کاذب و اطلاعات متقابل بدست می آیند. نحوه استفاده از این روش ها برای بازسازی فضای فاز در [۳۴-۳۶] شرح داده شده است. با تعیین مقادیر m و τ داشتن سری زمانی N نقطه ای x ، حالت i ام در فضای فاز را می توان به صورت زیر نمایش داد:




$$r(p_i) = [x(i), x(i + \tau), \dots, x(i + (m - 1)\tau)], \quad i = 1, 2, \dots, N - (m - 1)\tau \quad (2)$$

پس از یافتن حالت های سیستم در فضای فاز با انتخاب مقدار مناسب ε ، ماتریس بازگشتی \mathcal{R} بدست می آید. سپس با رسم \mathcal{R} در یک صفحه دو بعدی، رسم بازگشتی سری زمانی مورد نظر ترسیم می شود. شکل ۲ مقایسه رسم های بازگشتی مربوط به قطعاتی از سیگنال PPG در فشار سیستمول بالا (۱۸۵/۲۰) میلی متری جیوه) با یک بخش دیگر است که دارای فشارخون سیستمول پایین است (۹۱،۷۷ میلی متری جیوه). همانطور که مشاهده می شود، چندین ساختار افقی، عمودی و مورب در شکل ظاهر می شود، که نشان دهنده بازگشت حالات مسیر به مجاورت حالات قبلی است. با نگاهی دقیق به این شکل می توان ساختارهای نسبتاً منظمی را مشاهده کرد، که این امر به دلیل ماهیت شبه تناوبی سیگنال PPG است.

همانگونه که مشخص است، رسم های بازگشتی در حالت های مختلف فشار خون از نظر بصری تا حدودی شبیه به هم هستند. بنابراین، لازم است مجموعه ای از ویژگی های کمی استخراج شود تا رفتارهای دینامیکی مختلف آن آشکار شده و برای کاربردهای هوش مصنوعی قابل استفاده باشد. مروان، ۱۳ ویژگی را به عنوان معیارهای کمی با نام آنالیز کمی بازرخداد (RQA) برای این منظور معرفی کرده است [۲۶، ۳۶]. این معیارها آرایش نقاط را که به صورت افقی، عمودی و مورب هستند در جهت تعیین خصوصیات دینامیکی سیستمها در نظر می گیرند [۳۰]. در ادامه این معیارها معرفی می گردند.

نرخ بازگشت (RR): این ویژگی چگالی نقاط بازگشتی را در کل فضای رسم دو بعدی محاسبه می کند که شامل T حالت از طریق معادله زیر است:

$$RR = \frac{1}{T^2} \sum_{i=1}^T \sum_{j=1}^T R_{p_i, p_j} \quad (3)$$



شکل ۲- رسم های بازگشتی مربوط به قطعات سیگنال PPG در دو حالت فشار خون سیستمول بالا (ردیف بالایی) و فشار خون سیستمول پایین (ردیف پایینی)

قطعییت (DET): اگر سیستم رفتاری آشوب گرا داشته باشد، طول خطوط مورب در رسم بازگشتی کاهش می یابد. این به طور مستقیم به پیش بینی پذیری سیستم مربوط می شود. بر این اساس، معادله (۴) شاخص قطعییت را محاسبه می کند، که در آن $p(l)$ تعداد خطوط مورب به طول l است.

$$DET = \frac{\sum_{l=l_{min}} l p(l)}{\sum_{i=1}^T \sum_{j=1}^T \mathcal{R}_{p_i, p_j}} \quad (4)$$

متوسط طول خطوط مورب (L): این معیار نزدیک بودن دو بخش از تراژکتوری را به صورت زیر تعیین می کند:

$$L = \frac{\sum_{l=l_{min}}^N l p(l)}{\sum_{l=l_{min}}^N p(l)} \quad (5)$$

حداکثر طول خطوط مورب (Lmax): این معیار با توجه به معادله زیر طول طولانی ترین خط مورب را تعیین می کند:

$$L_{max} = \max(l_i), i = 1, 2, \dots, N_l \quad (6)$$

که در آن N_l تعداد کل خطوط مورب را نشان می دهد.

آنترپوی خطوط مورب (ENT): احتمال اینکه طول یک خط مورب برابر با l باشد با فرمول $p(l)$ نشان داده می شود. بنابراین، براساس قضیه شانون، آنترپوی این توزیع احتمال به شرح زیر تعریف می شود:

$$ENTR = - \sum_{l=l_{min}}^N p(l) \ln(p(l)) \quad (7)$$

لاپهای بودن (LAM): این معیار شاخصی است که درجه پایداری سیستم را محاسبه می کند. این ویژگی به صورت تعداد نقاط تشکیل دهنده خطوط افقی نسبت به نقاط بازگشتی کل تعریف می شود. رابطه این شاخص به شرح زیر محاسبه می شود:

$$LAM = \frac{\sum_{v=v_{min}}^N v p(v)}{\sum_{v=1}^N v p(v)} \quad (8)$$

$P(v)$ هیستوگرام طول خطوط افقی است.

زمان به دام افتادن (TT): این معیار متوسط زمانی را نشان می دهد که سیستم در حالت خاصی باقی بماند یا تغییرات کمی داشته باشد. بنابراین، زمان به دام افتادن رابطه مستقیمی با طول متوسط خطوط افقی دارد و به صورت زیر بیان می شود:

$$TT = \frac{\sum_{v=v_{min}}^N v p(v)}{\sum_{v=v_{min}}^T p(v)} \quad (9)$$

شبکه‌ها در زمینه‌های مختلف، عملکرد این ساختارها در مدل‌سازی توالی‌های زمانی و سیگنال‌های پزشکی کمتر ارزیابی شده است [۳۷]. به عبارت دیگر، کاربرد اصلی این شبکه‌ها معطوف به ورودی‌های تصویر دو بعدی چند کاناله است. با این حال، مطالعاتی در مورد توالی‌های زمانی ثبت شده از بدن انجام شده است که صورت مسئله اصلی آن رگرسیون و تقریب توابع است [۳۸، ۳۹].

شکل ۳ نمودار بلوکی مدل CNN ارائه شده در این مقاله را نشان می‌دهد. از آنجا که قطعه‌های PPG پیش پردازش شده دارای ۲۵۰ نمونه هستند اندازه ورودی مدل برابر ۲۵۰ در نظر گرفته شده است. همانطور که مشاهده می‌شود، معماری شبکه شامل لایه‌های کانولشن یک بعدی، عملگرهای نرمال سازی دسته‌ای^{۱۱}، توابع فعال‌سازی Relu^{۱۱}، لایه‌های تجمیع میانگین^{۱۲} و لایه‌های تمام متصل است. در ادامه، هر یک از عناصر مورد استفاده در لایه‌های شبکه معرفی می‌شود:

(الف) لایه کانولوشنی: این لایه شامل فیلترهایی است که در طول توالی زمانی سیگنال‌های ورودی حرکت می‌کند. در این مطالعه، طول فیلترها ۲۵ بود و عملیات کانولوشنی بین نقاط بخش‌های زمانی ورودی و فیلترها از طریق رابطه زیر انجام می‌شود:

$$y_k = \sum_{n=0}^{N-1} x_k h_{k-n} \quad (17)$$

که در آن h توالی زمانی برای فیلتر ۲۵ نقطه ای است و N طول سیگنال است.

(ب) لایه تجمیع: این لایه که به آن لایه کاهش ابعاد نیز گفته می‌شود، برای کاهش هزینه محاسباتی شبکه استفاده می‌شود. لایه‌های مختلف کاهش ابعاد با معیار انتخاب حداکثر مقادیر خروجی^{۱۳} یا میانگین آنها وجود دارد. در این مطالعه با توجه به اینکه هدف تقریب مقدار فشار خون در خروجی شبکه عمیق است، از لایه تجمیع میانگین بهره برده شده که جزئیات محاسباتی در لایه‌های میانی شبکه حفظ شود.

(ج) تابع فعال سازی: این توابع خصوصیات غیرخطی را به عملکرد شبکه اضافه می‌کنند. در استفاده از شبکه‌های عصبی عمیق، تابع فعال سازی Relu با رابطه ریاضی $f(x) = \max(0, x)$ به دلیل سادگی عملکرد و مشتق گیری آسان، به طور گسترده ای مورد استفاده قرار گرفته است. به طور مشابه، تابع فعال سازی Leaky-Relu که مقداری از سیگنال‌های منفی را با شیب ملایم عبور می‌دهد تا اثرات نویزهای ورودی را کاهش دهد، به شرح زیر:

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0.01x & \text{o.w.} \end{cases} \quad (18)$$

(د) لایه نرمال سازی: ورودی‌ها معمولاً برای استاندارد سازی داده‌های خام که روند آموزش شبکه را تسهیل می‌کنند، نرمال می‌شوند. نرمال کردن دسته‌ای یک روش نرمال سازی است که بین لایه‌های شبکه‌های عمیق اعمال می‌شود. بدین ترتیب، سرعت یادگیری شبکه می‌تواند افزایش یابد. شایان ذکر است که عملیات نرمال کردن دسته‌ای بر روی دسته‌های کوچکی از داده‌ها (در عوض کل قسمت‌های مجموعه داده) انجام می‌شود.

$$Z^{Normalized} = \frac{Z - \text{mean}(Z)}{STD(Z)} \quad (19)$$

(ه) لایه تمام متصل: همانطور که در شبکه‌های عصبی معمول دیده می‌شود، نورون‌ها در لایه‌های تمام متصل کاملاً به نورون‌های لایه قبلی متصل هستند. در شبکه‌های عمیق نیز، این لایه‌ها از وزن و بایاس تشکیل شده‌اند که وظیفه بیان تصمیم کلی لایه‌ها از خروجی لایه‌های قبلی را بر عهده دارند. خروجی این لایه‌ها به سادگی با یک ضرب ماتریس و به دنبال آن یک وزن بایاس محاسبه می‌شود. در اینجا، با توجه به اینکه هدف تخمین تنها یک عدد پیوسته به عنوان فشار خون در خروجی شبکه است، اندازه خروجی لایه تمام متصل ۱ در نظر گرفته می‌شود.

حداکثر طول خطوط عمودی (Vmax):

اگر N_v تعداد کل خطوط عمودی باشد، معادله ۱۰ طول طولانی ترین خط عمودی را به شرح زیر محاسبه می‌کند:

$$V_{max} = \max(V_i), i = 1, 2, \dots, N_v \quad (10)$$

زمان بازگشت نوع اول (T1): مجموعه ای از نقاط در همسایگی ϵ از نقطه r_i قرار دارند که توسط $R_i = \{rp1, rp2, \dots | Rpi, pj = 1\}$ نشان داده می‌شود. اعضای این مجموعه با نقاط بازگشتی ستون اول رسم بازگشتی مطابقت دارند. زمان بازگشت، در این حالت، در معادله ۱۱ تعریف شده است. میانگین این زمان‌ها، زمان بازگشت نوع اول در نظر گرفته می‌شود.

$$T_k^{(1)} = p_{k+1} - p_k | r_{p_{k+1}}, r_{p_k} \in R_i, k = 1, 2, \dots, T \quad (11)$$

زمان بازگشت نوع دوم (T2): در این شاخصه برای حاسبه زمان بازگشت حالت‌های متوالی نزدیک در نظر گرفته نشده است. معادله ۱۲، این ویژگی را به شرح زیر بیان می‌کند:

$$T_k^{(2)} = p_{k+1} - p_k | r_{p_{k+1}}, r_{p_k} \in R_i, r_{p_{k+1}} \notin R_i, k = 1, 2, \dots, T \quad (12)$$

آنتروپی چگالی دوره بازگشتی:

این شاخص با نرمال سازی آنتروپی توزیع زمان بازگشت، با فرض اینکه طول یک خط مورب l است، با استفاده از معادله زیر محاسبه می‌شود:

$$\bar{p}(l) = \frac{p(l)}{\sum_{l_1=l_{min}}^T p(l_1)} \quad (13)$$

ضریب خوشه بندی (C):

این شاخص، خصوصیتی مربوط به شبکه‌های پیچیده^{۱۴} است که از شباهت بین ماتریس مجاورت در شبکه‌های پیچیده و ماتریس بازگشت در رسم بازگشتی به دست آمده است. این ویژگی معیاری برای بیان درجه تمایل به تشکیل خوشه‌ای از گره‌ها است. اگر گره‌های مجاور یک گره خاص همه با هم مرتبط باشند، مقدار ضریب خوشه بندی آن گره ۱ خواهد بود. بر این اساس، مقدار ضریب خوشه بندی گره i ام به شرح زیر تعریف می‌شود:

$$C = \frac{2L_i}{k_i(k_i-1)} \quad (14)$$

که در آن k_i مرتبه گره و L_i تعداد لبه‌های مرتبط با گره i ام است.

انتقال پذیری (Tr):

رابطه بین ماتریس مجاورت در شبکه‌های پیچیده و ماتریس‌های بازگشتی به شرح زیر تعریف می‌گردد:

$$A_{i,j} = R_{pi,pj} - \delta_{i,j} \quad (15)$$

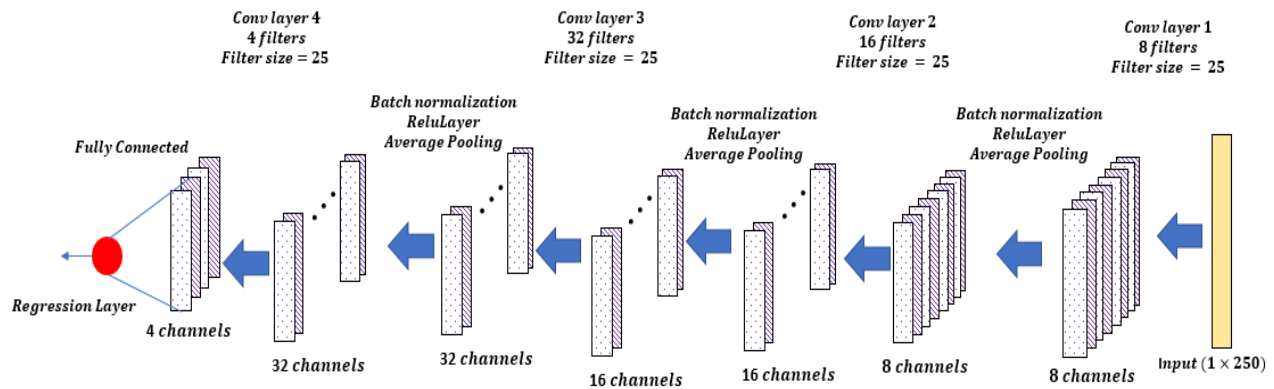
که در آن δ_i ، تابع دلتای دیراک است و $A_{i,j}$ عنصر ماتریس مجاورت است. در یک شبکه پیچیده، شاخص انتقال پذیری به عنوان احتمال اتصال دو گره مجاور به گره سوم تعریف می‌شود. بنابراین، شاخص ذکر شده به شرح زیر تعریف می‌شود:

$$Tr = \frac{\sum_i \sum_j \sum_k A_{i,j} A_{j,k} A_{k,i}}{\sum_j \sum_k A_{j,k} A_{k,i}} \quad (16)$$

به طور کلی، هرچه رفتار سیستم بیشتر آشوبی باشد، شاخص انتقال پذیری کاهش می‌یابد.

۲-۴- شبکه عصبی عمیق کانولوشنی

CNN^{۱۵} ها شبکه‌های عصبی عمیق شناخته شده‌ای هستند که در سال‌های اخیر در کاربردهای مختلفی از جمله پردازش تصاویر پزشکی، تشخیص الگو، تخمین و طبقه بندی بیماری مورد استفاده قرار گرفته‌اند. با وجود رشد سریع این



شکل ۳- بلوک دیاگرام شبکه عصبی کانولوشنی به کار رفته در این مطالعه

می شوند که به ترتیب ۷۰٪، ۱۰٪ و ۲۰٪ داده های هر یک از ۲۰۰ فرد تحت آزمایش را به خود اختصاص می دهند. با توجه به اینکه دینامیک سیگنال ورودی (PPG) و ارتباط آن با فشار خون تهاجمی در لحظات مختلف برای هر فرد در حال تغییر است وجود بخشی از دادگان هر فرد در مجموعه آموزش ضروری است.

برای پیاده سازی مدل شبکه عصبی عمیق، از جعبه ابزار یادگیری عمیق در محیط نرم افزار متلب استفاده شده است. همچنین برای بهینه سازی عملکرد تابع هزینه آنتروپی متقابل استفاده شده که به وسیله روش گرادینان نزول تصادفی^{۱۴} بهینه می گردد. همچنین، مقدار اولیه نرخ یادگیری و اندازه دسته های داده ها به ترتیب ۰/۰۰۱ و ۶۴ انتخاب شدند. ارزیابی صحت عملکرد شبکه توسط سه معیار ضریب همبستگی پیرسون (R)، خطای جذر میانگین مربعات (RMSE) و میانگین خطای مطلق (MAE) و بر اساس معادلات زیر صورت گرفته اند:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (20)$$

$$R = \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (21)$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (21)$$

$$MAE = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N} \quad (22)$$

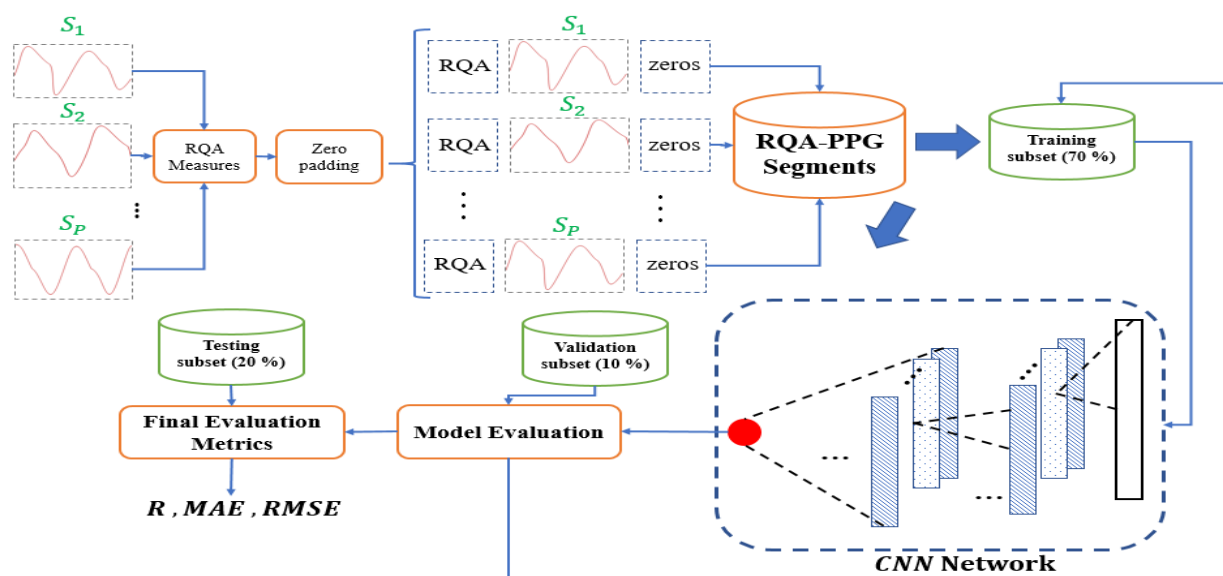
که در آن N تعداد نمونه است، y_i و \hat{y}_i به ترتیب مقادیر اندازه گیری شده و پیش بینی شده مربوط به i امین نمونه ورودی هستند. جداول ۱ و ۲ مقادیر بدست آمده از معیارها را برای تخمین فشار خون سیستول و دیاستول را در حالاتی که ویژگی ها با توالی های مختلفی در ورودی قرار دارند نشان می دهد. در این جدول، نتایج برای زمانی که از هر ۱۳ ویژگی RQA در ورودی استفاده شده است با نام RQA(13)-PPG بیان شده است. در کنار آن برای بهبود نتایج به روش سعی و خطا مقادیر کمتری از ویژگی های ۱۳ گانه را نیز مورد ارزیابی قرار دادیم که در نهایت ۶ ویژگی عملکرد بهتری ارائه نمودند. در جداول ۱ و ۲ نتایج مربوط به این ویژگی ها با عنوان RQA(6)-PPG نام گذاری شده است. این دو حالت با حالتی که فقط بخش های PPG (بدون لحاظ کردن ویژگی های آشوبگر) به ورودی اعمال شد مقایسه شدند. همانطور که مشاهده می شود، بهترین عملکرد در حالت PPG-RQA(6) بدست آمده است.

انتخاب تعداد لایه ها، ابعاد فیلترها و نحوه چیدمان آن ها در کنار یکدیگر می تواند عملکرد شبکه را به شدت تحت تاثیر قرار دهد. بنابراین لازم است از مدل هایی که در مطالعات معتبر به کار رفته، الگوی مناسبی از معماری اولیه به دست آید. در انتخاب معماری شبکه عصبی کانولوشنی به کار رفته در این مطالعه از مقالاتی که پیش از این بر روی همین پایگاه داده در تخمین فشار خون انجام شده، الگوگیری شده است. به طور خاص در مطالعه [۳] ساختاری چند مرحله ای متشکل از لایه های کانولوشنی به همراه لایه های LSTM مورد استفاده قرار گرفته است. در مقاله حاضر ساختار CNN مرجع [۳] به عنوان مدل اولیه در نظر گرفته شد. اما با توجه به اینکه این مدل به تنهایی نتیجه مطلوبی در تخمین فشار خون ایجاد نمی کند ساختار اصلاح شده شکل ۳ معرفی گردیده است. این ساختار با آزمایش و خطا و صحت سنجی تخمین فشار خون بر روی مجموعه دادگان اعتبارسنجی به دست آمده است. شکل ۳ نشان می دهد که شبکه در نظر گرفته شده از چهار مجموعه لایه پی در پی تشکیل شده است، از جمله لایه یک بعدی کانولوشنی، لایه نرمال سازی، لایه تابع فعال سازی Relu و لایه تجمیع میانگین. لایه های یک بعدی کانولوشنی به ترتیب شامل ۸، ۱۶، ۳۲، ۴ فیلتر به طول ۲۵ هستند. هر لایه کانولوشنی توسط یک فرآیند نرمالیزاسیون دسته ای و یک لایه Relu دنبال می شود. سپس، یک لایه تجمیع میانگین به طول ۶ و گام ۴ استفاده می شود. سرانجام، شبکه به یک لایه تک خروجی تمام متصل و همچنین یک لایه رگرسیون مجهز شده است.

در ادامه ویژگی های استخراج شده از هر قطعه PPG را در کنار توالی زمانی آن ها به عنوان ورودی مدل شبکه عصبی معرفی شده قرار داده شده تا عملکرد مدل را بررسی شود. بنابراین، آزمایشات مختلفی برای تعیین عملکرد رویکرد معرفی شده در نظر گرفته شده است که در بخش نتایج به آن ها پرداخته خواهد شد.

۳- نتایج

برای آموزش شبکه و ارزیابی عملکرد آن، داده های به دست آمده از ۲۰۰ نفر را در پایگاه داده MIMIC-II مورد استفاده قرار دادیم. شکل ۴ نمودار بلوکی چارچوب ارائه شده در این مطالعه را به نمایش می گذارد. پس از اتمام مرحله پیش پردازش، تعداد کل ۵۱۸۸۴ قطعه از سیگنال PPG حاصل می شود. تمام ۱۳ ویژگی RQA برای هر قطعه محاسبه شده و مجموعه جدیدی از مولفه ها با نام RQA-PPG ایجاد می شود. در واقع، بخش های RQA-PPG با ویژگی های بدست آمده توسط RQA ها شروع می شوند و به وسیله بخش های PPG ادامه می یابند. کلیه قطعات به ۳ زیر مجموعه آموزش، اعتبار سنجی و آزمون تقسیم



شکل ۴- بلوک دیاگرام روش کلی این مطالعه. ابتدا ویژگی‌های RQA از هریک از بخش‌های استخراج شده سیگنال PPG به دست می‌آید. سپس این ویژگی‌ها در کنار دنباله‌های زمانی PPG قرار می‌گیرد و به عنوان ورودی مدل شبکه عصبی عمیق کانولوشنی مورد استفاده قرار می‌گیرد.

جدول ۲ عملکرد روش پیشنهادی ما را بر اساس معیار استاندارد انجمن فشار خون بریتانیا بیان می‌کند [۴۰]. این انجمن معیارهایی را برای بررسی قابلیت اطمینان دستگاه‌های اندازه‌گیری فشار خون تعریف کرده است. بر اساس آن، با تعریف سطوح مختلف خطا و اندازه‌گیری درصد خطای تجمعی برای همه نمونه‌های آزمایش، درجات اطمینان مختلفی به روش‌ها و دستگاه‌های اندازه‌گیری فشار خون اختصاص می‌یابد. این درجه بندی در جدول ۳ با عناوین A، B و C نشان داده شده است. همانطور که مشاهده می‌شود، اگر میزان خطای تجمعی برای ۶۰، ۸۵ و ۹۵ درصد نمونه‌ها به ترتیب کمتر از ۵، ۱۰ و ۱۵ میلی‌متر جیوه باشد مدل تخمینی در دسته‌ی روش‌های حائز درجه کیفی A قرار می‌گیرد. بر اساس اندازه‌گیری‌های انجام شده، روش معرفی شده در این مقاله حائز درجه کیفی A گردید.

۳-۲- ارزیابی مدل براساس استاندارد انجمن توسعه ابزارهای پزشکی (AAMI)

مطابق این استاندارد تعداد افراد مورد نیاز برای اعتبار سنجی روش باید بیشتر از ۸۵ نفر باشد. همچنین میانگین و انحراف معیار خطای تخمین برای فشار خون دیاستول و سیستول به ترتیب باید کمتر از ۵ و ۸ میلی‌متر جیوه باشد. با این فرضیات و مطابق نتایج ارائه شده در جدول ۴ عملکرد روش پیشنهادی این مقاله بر پایه شبکه‌های عصبی عمیق از منظر این استاندارد نیز مورد تایید است.

۴- بحث

در این مطالعه، یک مدل شبکه عصبی عمیق برای تخمین فشارخون دیاستول و سیستول به صورت غیر تهاجمی توسط سیگنال PPG و با استفاده از ویژگی‌های آشوبگرهای آن معرفی شده است. در استفاده از مدل شبکه عصبی عمیق، از مدل‌های کانولوشنی با قابلیت استخراج ویژگی در لایه‌های میانی استفاده شد. از آنجا که ورودی‌های شبکه سری‌های زمانی یک بعدی بودند، ساختار معرفی شده از فیلترهای یک بعدی در لایه‌های شبکه تشکیل شده بود.


لازم به ذکر است از آنجا که ترکیبی از تمام ویژگی‌های RQA با سری زمانی PPG به طور قابل توجهی عملکرد مدل را بهبود نمی‌بخشد، سعی شد بهترین زیر مجموعه از ویژگی‌های ۱۳ گانه را که منجر به شش ویژگی شد انتخاب گردد. برای انتخاب این شش ویژگی، عملکرد شبکه عصبی عمیق را با اعمال جایگشت‌های مختلف از ۱۳ ویژگی اولیه بر روی دقت تخمین مجموعه داده اعتبارسنجی مورد بررسی قرار دادیم. نهایتاً این بررسی تایید کرد که بهترین عملکرد زمانی به دست می‌آید که شش ویژگی شامل DET، RR، Lmax، ENT، LAM و TT در ورودی اعمال شوند. به عبارت دیگر، بالاترین مقدار ضریب همبستگی پیرسون و کمترین خطای جذر میانگین مربعات خطا و میانگین خطای مطلق برای این حالت اعمال ورودی بدست آمد.

در پیاده‌سازی‌های الگوریتم، معماری شبکه معرفی شده ثابت باقی مانده است. بنابراین، بهبود عملکرد چارچوب در نظر گرفته شده فقط به دلیل وجود یا عدم وجود ویژگی‌های آشوبگر است.


شکل‌های ۵ و ۶ نمودارهای رگرسیون را برای تخمین فشارخون سیستول و دیاستول نشان می‌دهند. در این اشکال، تخمین مقادیر فشارخون سیستول و دیاستول به طور جداگانه توسط مدل شبکه عصبی معرفی شده در مقایسه با مقادیر واقعی برای سه زیر مجموعه‌ی آموزش و اعتبارسنجی و آزمون ارائه شده است. مقادیر ضریب همبستگی پیرسون برای داده‌های آموزش، اعتبارسنجی و آزمون به ترتیب ۰/۹۷۱۵۲، ۰/۹۵۲۲۶ و ۰/۹۹۳۱۶ برای تخمین فشار خون دیاستول و ۰/۹۷۰۶۳، ۰/۹۴۷۸۳ و ۰/۹۳۳۵۷ برای فشار خون دیاستول بود. شکل ظاهری منحنی‌های رگرسیون و اعداد گزارش شده فوق موید همبستگی بالای مقادیر تخمینی و مقادیر واقعی است.

هیستوگرام‌های خطای به دست آمده از مدل آموزش دیده برای همه زیر مجموعه‌های داده در شکل ۷ نشان داده شده است. همانطور که مشخص است، بیشتر مقادیر مرتبط با خطاهای تخمین در محدوده صفر توزیع شده‌اند (به طور دقیق‌تر در محدوده ۳- تا ۴ میلی‌متر جیوه). همچنین، چارچوب پیشنهادی ما از نظر دامنه خطای تخمین، عملکرد بهتری در تقریب دیاستول نسبت به سیستول دارد.

۳-۱- ارزیابی مدل ارائه شده بر اساس استاندارد انجمن فشار خون بریتانیا (BHS)



شکل ۵- رسم رگرسیون برای تخمین فشار خون دیاستول مربوط به دادگان آموزش، اعتبارسنجی و آزمون



شکل ۶- رسم رگرسیون برای تخمین فشار خون سیستول مربوط به دادگان آموزش، اعتبارسنجی و آزمون

جدول ۲- مقایسه نتایج روش ارایه شده در تخمین فشار خون سیستول

R	RMSE (mmHg)	MAE (mmHg)	STD (mmHg)	نوع داده ورودی	
۰/۸۹۸۷۶	۹/۵۸	۷/۴۳	۸/۳۷	PPG	دادهای
۰/۹۰۲۵۵	۸/۵۶	۶/۳۳	۷/۲۴	RQA(13)-PPG	
۰/۹۷۶۸	۴/۵۹	۳/۱۴	۴/۵۷	RQA(6)-PPG	
۰/۸۹۵۱۴	۹/۸۹	۷/۷۴	۸/۳۹	PPG	دادهای
۰/۸۸۱۷۷	۱۰/۴۴	۹/۹۵	۷/۳۷	RQA(13)-PPG	
۰/۹۴۸۷۳	۵/۹۵	۳/۷۴	۵/۹۵	RQA(6)-PPG	
۰/۸۷۹۶۷	۷/۷۴	۸/۰۶	۸/۸۶	PPG	دادهای
۰/۸۶۷۸۵	۹/۸۸	۱۰/۱۹	۸/۲۸	RQA(13)-PPG	
۰/۹۳۳۵۷	۶/۷۱	۴/۲۸	۶/۶۹	RQA(6)-PPG	

جدول ۱- مقایسه نتایج روش ارایه شده در تخمین فشار خون دیاستول

R	RMSE (mmHg)	MAE (mmHg)	STD (mmHg)	نوع داده ورودی	
۰/۹۴۵۶۲	۳/۰۱	۲/۱۱	۳/۰۰	PPG	دادهای
۰/۹۳۳۷۴	۳/۵۵	۲/۹۵	۳/۲۷	RQA(13)-PPG	
۰/۹۷۱۵۲	۲/۲۳	۱/۵۷	۲/۲۱	RQA(6)-PPG	
۰/۹۲۸۷۰	۳/۴۳	۲/۲۹	۳/۴۳	PPG	دادهای
۰/۹۰۴۴۰	۳/۶۷	۳/۰۱	۳/۳۵	RQA(13)-PPG	
۰/۹۵۲۲۶	۲/۸۴	۱/۸۳	۲/۸۲	RQA(6)-PPG	
۰/۹۲۸۸۴	۳/۳۹	۲/۳۴	۳/۳۹	PPG	دادهای
۰/۸۹۹۵	۳/۸۹	۳/۳۲	۳/۲۴	RQA(13)-PPG	
۰/۹۳۹۱۶	۳/۱۸	۲/۱۶	۳/۱۵	RQA(6)-PPG	

نمودارهای بلند-آلتمن مربوط مدل معرفی شده در شکل ۸ ترسیم شده است. در این شکل، محور افقی میانگین مقادیر فشارخون را نشان می‌دهد که میانگین تخمین‌ها و مقادیر واقعی فشارخون هستند. محور عمودی نیز اختلاف مقادیر تخمینی و مقادیر واقعی را نشان می‌دهد. مقادیر بایاس (میانگین خطاها) و حدود قابل قبول خطا به ترتیب با خطوط قرمز و آبی به نمایش گذاشته شده‌اند. این شکل تأیید می‌کند که بیش از ۹۵ درصد نقاط در محدوده قابل قبول خطا قرار گرفته‌اند. این یافته با نتایج گزارش شده در جدول ۳ مطابقت دارد که استاندارد انجمن فشار خون بریتانیا را برآورد می‌کند و نشانگر عملکرد تخمینی مناسب روش معرفی شده است.

جدول ۵ نتایج این مطالعه را با برخی از روش‌های مرور شده در مقدمه در مقایسه می‌کند. تجزیه و تحلیل مقایسه‌ای ما نشان داد که چارچوب اعمال شده در این مقاله بر بسیاری از روش‌های اعمال شده غلبه کرده است. به طور خاص

پیش از این، برای تخمین فشارخون از سیگنال‌های PPG یا ترکیب آنها با سیگنال‌های قلبی استفاده شده است [۳، ۶، ۱۶]. با این حال، در این مطالعه، از ویژگی‌های آشوب‌گرایی آنها یعنی RQA استفاده شده است. نتایج جدول ۱ نشان می‌دهد که استفاده از شکل موج PPG به نوبه خود نتایج قابل قبولی را ارائه داده است. با این حال، ویژگی‌های مبتنی بر بازخورد و ترکیب آنها با سری‌های زمانی ذکر شده نتایج را بهبود بخشیده است. در فرآیند آموزش، استفاده از مجموعه ۶ گانه RQA نتایج تخمین دیاستول و سیستول را از منظر همبستگی پیرسون به ترتیب ۲/۴ و ۸ درصد معیار بهبود داده است. همین بهبودها برای مجموعه داده آزمون ۱/۱ و ۶/۱ درصد بوده است. از دیدگاه RMSE، خطای تخمین به میزان ۶/۶ و ۱۵ درصد برای دیاستول و سیستول کاهش یافت.

جدول ۳- ارزیابی مدل معرفی شده بر اساس استاندارد BHS

درجات اعتبار	کمتر از ۵ mmHg	کمتر از ۱۰ mmHg	کمتر از ۱۵ mmHg
A	۶۰٪	۸۵٪	۹۵٪
B	۵۰٪	۷۵٪	۹۰٪
C	۴۰٪	۶۵٪	۸۵٪
خطای تجمعی تخمین فشار خون دیاستول	۹۱/۸۶٪	۹۸/۶۴٪	۹۹/۶۵٪
خطای تجمعی تخمین فشار خون سیستول	۷۳/۰۳٪	۹۱/۲۲٪	۹۵/۹۹٪

جدول ۴- ارزیابی مدل معرفی شده بر اساس استاندارد AAMI

	تعداد افراد	انحراف معیار خطا	میانگین خطا
تخمین دیاستول	۲۰۰	۳/۱۵	۰/۴۵
تخمین سیستول	۲۰۰	۶/۶۹	۰/۴۸

اگرچه مدل معرفی شده با ادغام ویژگی‌های RQA و سری زمانی PPG توانست عملکرد مطلوبی ارائه دهد، اما موارد زیر را می‌بایست به عنوان محدودیت‌ها و کارهای آینده مطالعه حاضر مورد توجه قرار داد. در وهله اول، مجموعه داده بخشی از پایگاه داده MIMIC-II بود و نتایج را نمی‌توان به صورت نظیر به نظیر با مطالعات انجام شده بر روی نسخه‌های دیگر دادگان مقایسه کرد.


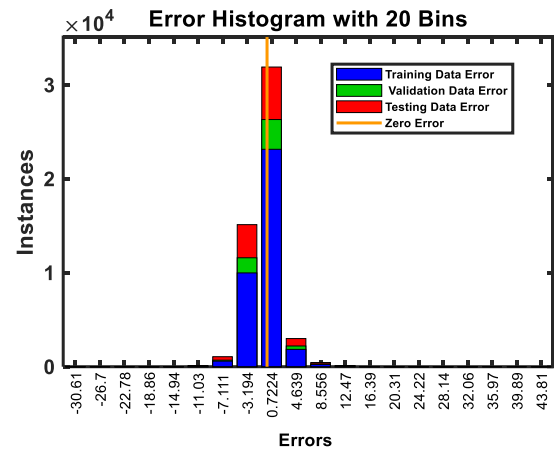
همچنین یافته‌های این مطالعه نشان داد که مجموعه کامل ۱۳ گانه ویژگی‌های آشوب‌گرا نمی‌تواند بر روش‌های معمول غلبه کند. در نتیجه سعی شد با استفاده از آزمون و خطا بهترین زیرمجموعه از آن‌ها مورد استفاده قرار گیرد. بنابراین، با وجود استفاده از شبکه‌های عصبی با معماری ساده، استفاده از ویژگی‌های مختلف دست ساز^{۱۵} مانند ویژگی‌های آماری و فرکانسی یا دیگر ویژگی‌های غیرخطی می‌تواند به بهبود نتایج کمک کنند.

۵- نتیجه گیری

در این مطالعه، یک مدل شبکه عصبی عمیق با استفاده از ویژگی‌های آشوب‌گرای سیگنال PPG در ورودی برای تخمین فشارخون سیستول و دیاستول معرفی شده است. نتایج نشان داد که ترکیبی از شکل موج PPG و خصوصیات غیرخطی آن‌ها دقت بالایی را در تخمین ایجاد کرده است. مدل شبکه کانولوشنی متشکل از ۴ مجموعه لایه کانولوشن یک بعدی، نرمال سازی دسته-ای، لایه تجمیع میانگین و تابع فعال سازی Relu است که می‌تواند خصوصیات ریخت شناختی موج های PPG ورودی را استخراج کند. از آنجا که ویژگی‌های استخراج شده به تنهایی توانایی محدودی در تخمین فشار خون دارند، نتایج این مطالعه نشان داد که ترکیب مذکور خطای تخمین بسیار کمتری را ایجاد می‌کند. همچنین تجزیه و تحلیل مقایسه‌ای ما تایید کرد چارچوب پیشنهادی می‌تواند فشارخون‌های سیستول و دیاستول را به طور همزمان و با خطای تخمین قابل قبولی تخمین بزند. به طور خاص، در مقایسه با مدل‌های داری لایه‌های LSTM، در چارچوب معرفی شده این مقاله، عملکرد برجسته‌ای از منظر معیار همبستگی پیرسون و معیارهای خطا تنها با معماری جلوسوی کانولوشنی حاصل شده است. بنابراین، استفاده از مدل‌های عصبی پیچیده‌تر که دارای لایه‌های حافظه دار هستند می‌تواند گزینه موثری در بهبود نتایج تخمین باشد.

روش ارائه شده در مقایسه با مراجع [۱۱ و ۱۳ و ۱۵ و ۱۶] که با استخراج ویژگی از سیگنال ورودی اقدام به تخمین فشار خون نموده‌اند عملکرد مطلوب‌تری داشته است. به بیان دیگر، به کارگیری شبکه عصبی عمیق برای تخمین فشار خون بر روش‌های مرسوم استخراج ویژگی فایده آورده است. در مقایسه با مطالعاتی که در آن‌ها از معماری‌های متنوع شبکه‌های عصبی عمیق استفاده شده نیز نتایج مطالعه حاضر کاملاً رقابتی است. به طور خاص، در [۱۶] از ترکیبی از شبکه‌های ResNet و LSTM برای تخمین استفاده شده. با این وجود، در مطالعه حاضر بدون به کارگیری ساختارهای پیچیده فوق و با افزودن خصوصیات آشوب‌گرا در ورودی معماری CNN معرفی شده، نتایج بسیار بهتری از منظر معیار R و STD به دست آمده است. این موارد، به نوبه خود، تأیید می‌کند که ویژگی‌های آشوب‌گرای به کار رفته برای تمایز بین شرایط مختلف فشارخون دارای قابلیت اطمینان بالا است و دقت تخمین آنها را افزایش داده است.

با این حال، با اتخاذ مدل چند مرحله‌ای عصبی عمیق مشابه آنچه در [۳] معرفی شده است عملکردی نسبتاً بهتر از روش موجود در رویکرد ما قابل دست‌یابی است. شایان ذکر است، شبکه کانولوشنی اعمال شده در این مقاله دارای یک معماری ساده‌تر با پارامترهای آزاد کمتر از مدل چند مرحله‌ای اشاره شده است [۳]. این بدان معناست که استفاده از ویژگی‌های مبتنی بر نظریه بازخداد در فضای فاز با معماری عمیق ساده‌تر و به صورت تک‌مرحله‌ای نتایج برجسته‌ای ارائه داده است. بنابراین، اگر این ویژگی‌ها در ساختارهای پیچیده‌تر مدل‌های شبکه عصبی عمیق، که آشکار کننده ویژگی‌های توالی‌های زمانی PPG هستند، ظاهر شوند، می‌توانند نتایج دقیق‌تری نسبت به مدل پایه‌ای کانولوشنی ارائه دهند.



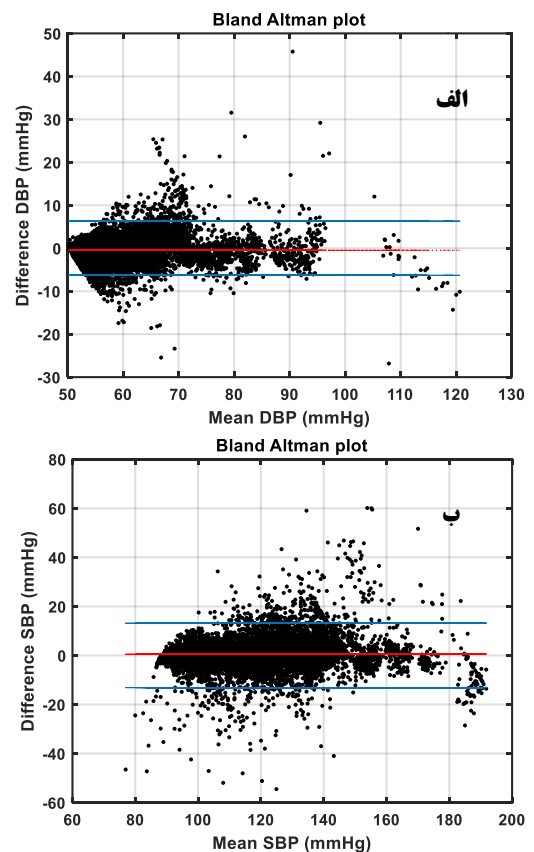
شکل ۷- هیستوگرام خطای تخمین به وسیله مدل معرفی شده برای تخمین فشار خون دیاستول (الف) و سیستول (ب)

جدول ۵- مقایسه نتایج این مطالعه با دیگر مطالعات

تخمین فشار خون سیستول			تخمین فشار خون دیاستول			نوع ورودی	روش
R	RMSE (mmHg)	STD (mmHg)	R	RMSE (mmHg)	STD (mmHg)		
۰/۹۱	-	۵/۲۱	۰/۸۹	-	۴/۰۶	PPG و سیگنال قلبی	PTT-Regression [۱۱]
۰/۹۵	-	۹/۱	۰/۹۳	-	۵/۲۱	MIMIC-II	تخمین دینامیکی [۱۵]
۰/۷۱	-	۱۴/۴۸	۰/۶۷	-	۸/۲۶	MIMIC-III	Random Forest [۱۶]
۰/۵۹	-	۱۰/۰۹	۰/۴۸	-	۶/۱۴	PPG و سیگنال قلبی	ADABOOST [۱۳]
۰/۸۸	-	۹/۹۹	۰/۷۱	-	۶/۲۹	MIMIC-III	RES-LSTM [۱۶]
۰/۸۰	-	۱۳/۱۰	۰/۶۷	-	۸/۰۷	MIMIC-III	LSTM [۱۶]
۰/۹۹	۱/۵۶	-	۰/۹۹	۰/۸۵	-	MIMIC-I	شبکه عصبی- LSTM [۲]
۰/۹۵	-	۵/۵۵	۰/۹۵	-	۲/۸۴	MIMIC-II	عمیق چندمرحله‌ای [۳]
۰/۸۲	-	۱۱/۸۷	۰/۷۱	-	۶/۸۴	MIMIC-III	ResNet [۱۶]
۰/۹۳۳	۶/۷۱	۶/۶۹	۰/۹۳۹	۳/۱۸	۳/۱۵	MIMIC-II	روش این مطالعه

۷- مراجع

- [1] W.-H. Lin, F. Chen, Y. Geng, N. Ji, P. Fang, and G. Li, "Towards accurate estimation of cuffless and continuous blood pressure using multi-order derivative and multivariate photoplethysmogram features," *Biomedical Signal Processing and Control*, vol. 63, p. 102198, 2021.
- [2] M. S. Tanveer and M. K. Hasan, "Cuffless blood pressure estimation from electrocardiogram and photoplethysmogram using waveform based ANN-LSTM network," *Biomedical Signal Processing and Control*, vol. 51, pp. 382-392, 2019.
- [3] J. Esmalpoor, M. H. Moradi, and A. Kadkhodamohammadi, "A multistage deep neural network model for blood pressure estimation using photoplethysmogram signals," *Computers in Biology and Medicine*, vol. 120, p. 103719, 2020.
- [4] M. Simjanoska, M. Gjoreski, M. Gams, and A. Madevska Bogdanova, "Non-invasive blood pressure estimation from ECG using machine learning techniques," *Sensors*, vol. 18, no. 4, p. 1160, 2018.
- [5] A. Attarpour, A. Mahnam, A. Aminitabar, and H. Samani, "Cuff-less continuous measurement of blood pressure using wrist and fingertip photo-plethysmograms: Evaluation and feature analysis," *Biomedical Signal Processing and Control*, vol. 49, pp. 212-220, 2019.
- [6] C. El-Hajj and P. Kyriacou, "Deep learning models for cuffless blood pressure monitoring from PPG signals using attention mechanism," *Biomedical Signal Processing and Control*, vol. 65, p. 102301, 2021.
- [7] H. Gesche, D. Grosskurth, G. Küchler, and A. Patzak, "Continuous blood pressure measurement by using the pulse transit time: comparison to a cuff-based method," *European journal of applied physiology*, vol. 112, no. 1, pp. 309-315, 2012.
- [8] X.-R. Ding et al., "Continuous blood pressure measurement from invasive to unobtrusive: Celebration of 200th birth anniversary of Carl Ludwig," *IEEE journal of biomedical and health informatics*, vol. 20, no. 6, pp. 1455-1465, 2016.
- [9] R. Mukkamala and J.-O. Hahn, "Toward ubiquitous blood pressure monitoring via pulse transit time: Predictions on maximum calibration period and acceptable error limits," *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 6, pp. 1410-1420, 2017.
- [10] T. H. Huynh, R. Jafari, and W.-Y. Chung, "Noninvasive cuffless blood pressure estimation using pulse transit time and impedance plethysmography," *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 4, pp. 967-976, 2018.
- [11] X.-R. Ding, Y.-T. Zhang, J. Liu, W.-X. Dai, and H. K. Tsang, "Continuous cuffless blood pressure estimation using pulse



شکل ۸- نمودار بلند-آلتمن در تخمین الف) فشار خون دیاستول ب) سیستول

۶- تشکر و قدردانی

نویسندگان کمال تشکر را از آقای جمال اسماعیل پور برای اظهار نظرهای کارشناسانه و مهربانانه وی در مورد پیاده سازی مدل هوش مصنوعی اعلام می-دارند.

- [30] N. Marwan, N. Wessel, U. Meyerfeldt, A. Schirdewan, and J. Kurths, "Recurrence-plot-based measures of complexity and their application to heart-rate-variability data," *Physical review E*, vol. 66, no. 2, p. 026702, 2002.
- [31] M. Saeed et al., "Multiparameter Intelligent Monitoring in Intensive Care II (MIMIC-II): a public-access intensive care unit database," *Critical care medicine*, vol. 39, no. 5, p. 952, 2011.
- [32] A. E. Johnson, M. M. Ghassemi, S. Nemati, K. E. Niehaus, D. A. Clifton, and G. D. Clifford, "Machine learning and decision support in critical care," *Proceedings of the IEEE*, vol. 104, no. 2, pp. 444-466, 2016.
- [33] A. Ramakrishnan, A. Prathosh, and T. Ananthapadmanabha, "Threshold-independent QRS detection using the dynamic plosion index," *IEEE Signal Processing Letters*, vol. 21, no. 5, pp. 554-558, 2014.
- [34] N. Marwan, Encounters with neighbours: current developments of concepts based on recurrence plots and their applications. Norbert Marwan, 2003.
- [35] A. M. Fraser and H. L. Swinney, "Independent coordinates for strange attractors from mutual information," *Physical review A*, vol. 33, no. 2, p. 1134, 1986.
- [36] M. B. Khodabakhshi and V. Saba, "A nonlinear dynamical approach to analysis of emotions using EEG signals based on the Poincaré map function and recurrence plots," *Biomedical Engineering/Biomedizinische Technik*, vol. 65, no. 5, pp. 507-520, 2020.
- [37] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals," *Computers in biology and medicine*, vol. 100, pp. 270-278, 2018.
- [38] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network," *Information sciences*, vol. 405, pp. 81-90, 2017.
- [39] U. R. Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan, and M. Adam, "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals," *Information Sciences*, vol. 415, pp. 190-198, 2017.
- [40] R. Lawrence E., B. Williams, G. D. Johnston, G. A. MacGregor, L. Poston, J. F. Potter, N. R. Poulter, and G. Russell, "British Hypertension Society guidelines for hypertension management 1999: summary," *Bmj*, vol. 319, no. 7210, pp. 630-635, 1999.
- transit time and photoplethysmogram intensity ratio," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 5, pp. 964-972, 2015.
- [12] Y. Z. Yoon, J. M. Kang, Y. Kwon, S. Park, S. Noh, Y. Kim, and S. W. Hwang, "Cuff-less blood pressure estimation using pulse waveform analysis and pulse arrival time," *IEEE journal of biomedical and health informatics*, vol. 22, no. 4, pp. 1068-1074, 2017.
- [13] M. Kachuee, M. M. Kiani, H. Mohammadzade, and M. Shabany, "Cuffless blood pressure estimation algorithms for continuous health-care monitoring," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 4, pp. 859-869, 2016.
- [14] M. Forouzanfar, S. Ahmad, I. Batkin, H. R. Dajani, V. Z. Groza, and M. Bolic, "Coefficient-free blood pressure estimation based on pulse transit time-cuff pressure dependence," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 7, pp. 1814-1824, 2013.
- [15] I. Sharifi, S. Goudarzi, and M. B. Khodabakhshi, "A novel dynamical approach in continuous cuffless blood pressure estimation based on ECG and PPG signals," *Artificial intelligence in medicine*, vol. 97, pp. 143-151, 2019.
- [16] F. Miao, B. Wen, Z. Hu, G. Fortino, X. P. Wang, and Y. Li, "Continuous blood pressure measurement from one-channel electrocardiogram signal using deep-learning techniques," *Artificial Intelligence in Medicine*, vol. 108, p. 101919, 2020.
- [17] G. Ward, P. Milliken, B. Patel, and N. McMahon, "Comparison of non-invasive and implanted telemetric measurement of blood pressure and electrocardiogram in conscious beagle dogs," *Journal of pharmacological and toxicological methods*, vol. 66, no. 2, pp. 106-113, 2012.
- [18] G. Thambiraj, U. Gandhi, U. Mangalanathan, V. J. M. Jose, and M. Anand, "Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning," *Biomedical Signal Processing and Control*, vol. 60, p. 101942, 2020.
- [19] F. Riaz, M. A. Azad, J. Arshad, M. Imran, A. Hassan, and S. Rehman, "Pervasive blood pressure monitoring using Photoplethysmogram (PPG) sensor," *Future Generation Computer Systems*, vol. 98, pp. 120-130, 2019.
- [20] U. Senturk, K. Polat, and I. Yucedag, "A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks," *Applied Acoustics*, vol. 170, p. 107534, 2020.
- [21] Z. Xu, J. Liu, X. Chen, Y. Wang, and Z. Zhao, "Continuous blood pressure estimation based on multiple parameters from electrocardiogram and photoplethysmogram by Back-propagation neural network," *Computers in Industry*, vol. 89, pp. 50-59, 2017.
- [22] P. Melin, I. Miramontes, and G. Prado-Arechiga, "A hybrid model based on modular neural networks and fuzzy systems for classification of blood pressure and hypertension risk diagnosis," *Expert Systems with Applications*, vol. 107, pp. 146-164, 2018.
- [23] A. Dervishi, "Fuzzy risk stratification and risk assessment model for clinical monitoring in the ICU," *Computers in biology and medicine*, vol. 87, pp. 169-178, 2017.
- [24] Huang, J. Chi, Y. C. Tsai, P. Y. Wu, Y. H. Lien, C. Y. Chien, C. F. Kuo, J. F. Hung, S. C. Chen, and C. H. Kuo, "Predictive modeling of blood pressure during hemodialysis: a comparison of linear model, random forest, support vector regression, XGBoost, LASSO regression and ensemble method," *Computer Methods and Programs in Biomedicine*, vol. 195, p. 105536, 2020.
- [25] M. W. K. Fong, E. Ng, K. E. Z. Jian, and T. J. Hong, "SVR ensemble-based continuous blood pressure prediction using multi-channel photoplethysmogram," *Computers in biology and medicine*, vol. 113, p. 103392, 2019.
- [26] M. B. Khodabakhshi, M. H. Moradi, Z. M. Sanat, and P. Jafari Moghadam Fard, "Lung sound decomposition using recurrent fuzzy wavelet network," *Journal of Intelligent & Fuzzy Systems*, vol. 33, no. 4, pp. 2497-2508, 2017.
- [27] F. Sohrabi and M. B. Khodabakhshi, "The trajectory intersection: an approach for nonlinear down-sampling," *Chaos, Solitons & Fractals*, vol. 124, pp. 10-17, 2019.
- [28] G. Ouyang, X. Zhu, Z. Ju, and H. Liu, "Dynamical characteristics of surface EMG signals of hand grasps via recurrence plot," *IEEE journal of biomedical and health informatics*, vol. 18, no. 1, pp. 257-265, 2013.
- [29] Y. Chen and H. Yang, "Multiscale recurrence analysis of long-term nonlinear and nonstationary time series," *Chaos, Solitons & Fractals*, vol. 45, no. 7, pp. 978-987, 2012.

محمدباقر خدابخشی مدرک کارشناسی خود را

در رشته مهندسی پزشکی از دانشکده فنی و مهندسی دانشگاه شاهد در سال ۱۳۸۷ اخذ نمود. همچنین وی مدارک تحصیلی کارشناسی ارشد و دکتری تخصصی خود را در سال‌های ۱۳۹۰ و ۱۳۹۶



به ترتیب از دانشگاه علم و صنعت ایران و دانشگاه صنعتی امیرکبیر دریافت نمود. هم اکنون وی به عنوان عضو هیات علمی گروه مهندسی پزشکی بیوالکترونیک و سرپرست کارگاه تجهیزات پزشکی در دانشگاه صنعتی همدان مشغول فعالیت است. زمینه‌های تحقیقاتی مورد علاقه ایشان ابزار دقیق پزشکی، پردازش سیگنال‌های بیولوژیکی، شبکه‌های عصبی عمیق و کاربرد آن‌ها در حوزه پزشکی است. آدرس پست الکترونیک ایشان عبارت است از:

mb.khodabakhshi@hut.ac.ir

نعیم اسلامی همدانی مدرک کارشناسی مهندسی

پزشکی (گرایش بیوالکترونیک) را از دانشگاه صنعتی همدان، در سال ۱۴۰۰ کسب کرده است. وی موفق به اخذ پذیرش در مقطع کارشناسی ارشد رشته مهندسی پزشکی گرایش بیوالکترونیک با استفاده از سهمیه استعدادهای



درخشان در دانشگاه شهید بهشتی تهران، ایران شده است. نامبرده در مقطع کارشناسی موفق به نگارش مقالات همایشی، داخلی و خارجی شده است. زمینه مورد علاقه تحقیقات وی در حوزه کاربرد های نظریه آشوب در پزشکی، پردازش سیگنال های زیستی، پردازش تصاویر پزشکی و یادگیری عمیق است. آدرس پست الکترونیک ایشان عبارت است از:

naeem.eslamyeh@stu.hut.ac.ir

سیده زهره صدرالدینی تحصیلات خود را در مقطع کارشناسی، رشته مهندسی پزشکی از دانشگاه صنعتی همدان به اتمام رساند. همچنین وی موفق به اخذ پذیرش در مقطع کارشناسی ارشد رشته مهندسی پزشکی گرایش بیوالکتریک با استفاده از سهمیه استعدادهای درخشان در دانشگاه شاهد تهران، ایران شده است. نامبرده در مقطع کارشناسی موفق به نگارش مقالات همایشی، داخلی و خارجی شده است. زمینه مورد علاقه تحقیقات وی در حوزه کاربرد های نظریه آشوب در پزشکی، پردازش سیگنال های زیستی، پردازش تصاویر پزشکی و یادگیری عمیق است.



zohreh.sadredini@stu.hut.ac.ir

-
- ¹ PTT (Pulse transient time)
 - ² PPG (Photoplethysmogram)
 - ³ Tanveer
 - ⁴ LSTM (Long short term memory)
 - ⁵ Hajj
 - ⁶ RQA (recurrence quantification analysis)
 - ⁷ RP (recurrence plot)
 - ⁸ Complex networks
 - ⁹ Convolutional Neural Networks
 - ¹⁰ Batch normalization
 - ¹¹ Relu activation function
 - ¹² Average pooling
 - ¹³ Max pooling
 - ¹⁴ SGDM (Stochastic gradient descent with momentum)
 - ¹⁵ Hand crafted features

Chaotic modelling of photoplethysmogram signal for blood pressure estimation based on deep convolutional neural networks

Mohammad Bagher Khodabakhshi¹, Naeem Eslamyeh¹, Zohreh Sadredini¹

¹ Biomedical Engineering Department, Hamedan University of Technology, Hamedan, Iran

Abstract

Estimation of blood pressure (BP) non-invasively through peripheral signals, including electrocardiogram (ECG) and photoplethysmogram (PPG) signals, is one of the most critical issues in the field of medical signal processing. Major studies focus on extracting various handcrafted features from peripheral signals and estimating BP using computational intelligence-based models. In this study, a novel framework based on deep convolutional neural networks (CNN) is introduced in which the PPG sequences and their nonlinear features are adopted to create high accuracy in estimating BP. These nonlinear features are the chaotic properties of signals in phase space called recurrence quantification analysis (RQA) which are utilized alongside the PPG waveform samples as the CNN input. The proposed framework was evaluated on data extracted from the benchmark MIMIC-II dataset. The results showed that this combination could provide high accuracy in estimating systolic blood pressure (SBP) and diastolic blood pressure (DBP). Precisely, in SBP and DBP monitoring, the Pearson's correlation coefficient (R) for the proposed method was obtained to be 0.93916 and 0.93357, respectively. The model was also evaluated according to the standards of the British Hypertension Society (BHS) and the Association for the Advancement of Medical Instrumentation (AAMI). According to BHS standard, this method had a quality grade of A in estimating both systolic and diastolic BPs. Also, the mean and standard deviation of the estimation error for DBP and SBP are 0.45 ± 3.5 mmHg and 0.48 ± 6.69 mmHg, respectively, which are under the requirements of the AAMI standard. Compared with the existing methods, this algorithm could create a high generalizing capability in estimating both SBP and DBP.

Keywords: Signal Processing, convolutional neural networks, deep learning, chaos theory, recurrence quantification analysis.